

PENERAPAN METODE *SUPPORT VECTOR MACHINE* (SVM) UNTUK MENDETEKSI PENYALAHGUNAAN NARKOBA

Application of Support Vector Machine (SVM) Method to Detect Drug Abuse

R. Dasmasela¹, B. P. Tomasouw^{2*}, Z. A. Leleury³

^{1,2,3}Program Studi Matematika, FMIPA Universitas Pattimura

e-mail: ^{2*}bptomasouw@gmail.com

Abstrak

Pada penelitian ini, metode *Support Vector Machine* (SVM) diterapkan untuk mendeteksi jenis narkotika pada pemakai narkoba berdasarkan gejala-gejala yang dialami. Untuk memperoleh tingkat akurasi terbaik, maka data pelatihan dan pengujian dibagi ke dalam tiga skema pembagian data, yaitu 60/40, 70/30, dan 80/20. Setelah dilakukan proses pelatihan dan pengujian menggunakan metode SVM dengan berbagai variasi parameter, maka diperoleh tingkat akurasi terbaik sebesar 95% pada skema pembagian data 80/20 untuk model SVM non linier dengan kernel RBF.

Kata Kunci: *Deteksi, Narkoba, Support Vector Machine.*

Abstract

In this research, the Support Vector Machine (SVM) method was applied to detect types of narcotics in drug users based on the symptoms experienced. To get the best level of accuracy, the training and test data are divided into three data allocation schemes, namely 60/40, 70/30, and 80/20. After the training and testing process was carried out using the SVM method with various parameters, the best accuracy rate was 95% at the allocation scheme 80/20 for the non-linear SVM model with the RBF kernel.

Keywords: *Detect, Drug, Support Vector Machine.*

 <https://doi.org/10.30598/parameter.v1i2pp111-122>



This article is an open access article distributed under the terms and conditions of the [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).

1. PENDAHULUAN

Indonesia merupakan salah satu Negara yang terjerat dalam kasus Narkoba. Di era globalisasi sekarang ini banyak sekali terjadi perdagangan bebas, salah satunya adalah obat-obatan terlarang dan narkotika. Narkoba adalah singkatan dari beberapa kata yaitu, narkotika, psikotropika dan bahan adiktif lain. Narkotika merupakan salah satu obat, bahan atau zat yang jika masuk tubuh berpengaruh pada fungsi tubuh, terutama otak. Pemakaian dan peredaran narkotika dan psikotropika diawasi secara ketat dengan Undang-Undang, yaitu Undang-Undang Nomor 35 tahun 2009 tentang Narkotika. Kepemilikan, pemakaian serta peredaran narkotika dan psikotropika secara tidak sah merupakan pelanggaran hukum. Pada Tahun 2013 Badan Narkotika Nasional (BNN) mencatat jumlah penyalahgunaan narkoba di Indonesia mencapai empat juta. Sebesar 70 persen dari jumlah tersebut adalah pengguna dari golongan pekerja, sementara 22 persen merupakan kelompok pelajar atau mahasiswa, serta delapan persen pengangguran dan lainnya[1]. Pemerintah dan seluruh masyarakat bersama-sama melakukan upaya untuk melakukan pencegahan penyalahgunaan narkoba serta pemberantasan peredarannya. Salah satu upaya tersebut yaitu membangun fasilitas rehabilitasi atau terapi medis bagi para penyalahguna narkoba. Sebelum rehabilitasi, para penyalahguna melakukan serangkaian tes untuk dapat mengetahui jenis narkoba apa yang digunakan. Tes yang dapat dilakukan yaitu tes biologis seperti mendeteksi melalui urin, darah, rambut, keringat dan lain-lain. Akan tetapi karena kendala waktu, maka biaya serta fasilitas yang minim di beberapa daerah membuat pendeteksian seseorang menderita narkoba menjadi terhambat. Jaringan syaraf tiruan, merupakan salah satu bagian dari *Artificial Intelligence* atau kecerdasan buatan yang merupakan salah satu penerapan buatan dari otak manusia yang mencoba untuk mensimulasikan proses pembelajaran pada otak manusia. Sejumlah proses perhitungan selama proses pembelajaran dapat diterapkan dengan menggunakan program komputer yang mampu menyelesaikannya.

Support Vector Machine (SVM) merupakan suatu teknik yang dapat memisahkan dua himpunan data dari dua kelas yang berbeda dengan memaksimalkan batas fungsi pemisah (hyperplane). Salah satu kelebihan dari metode ini adalah dapat melakukan pengklasifikasian dan mengatasi regresi dengan linear maupun non-linear. SVM memiliki tingkat akurasi klasifikasi yang lebih baik dibandingkan dengan metode klasifikasi lainnya[2]. Metode SVM ini sudah banyak diterapkan sebagai metode klasifikasi data antara lain klasifikasi akreditasi sekolah [3], klasifikasi kualitas pengelasan *Shield Metal Arc Welding* [4], klasifikasi penyimpangan tumbuh kembang anak [5], dan klasifikasi pasangan usia subur [6]. Selain itu, metode SVM juga telah digunakan sebagai metode dalam deteksi dini atau diagnosa penyakit, antara lain penyakit Liver [7], penyakit Saluran Pernapasan [8], penyakit Hepatitis [9], penyakit DBD [10], dan gangguan autism [11]. Penelitian-penelitian ini menunjukkan bahwa metode SVM memiliki performa dan hasil yang baik.

1.1 *Support Vector Machine* (SVM) Linier

Misalkan terdapat m data pelatihan $\{(x_1, y_1), (x_2, y_2), \dots, (x_m, y_m)\}$ dimana $x_i \in R^n$ adalah sampel data dan $y_i \in \{1, -1\}$ adalah target atau kelas dari sampel data. Misalkan juga bahwa data untuk kedua kelas terpisah secara linier (*linearly separable*) maka ingin dicari fungsi pemisah (*hyperplane*)

$$f(x) = xw + b = 0 \quad (1)$$

dimana $w \in R^{n \times 1}$ adalah parameter bobot dan $b \in R$ adalah parameter bias, serta berlaku:

$$x_i w + b > 0 \text{ untuk } y_i = 1 \quad (2)$$

$$x_i w + b < 0 \text{ untuk } y_i = -1$$

Misalkan $H : xw + b = 0$ adalah *hyperplane* yang ingin dicari sedangkan $H_1 : xw + b = 1$ dan $H_2 : xw + b = -1$ adalah *hyperplane* dari kelas 1 dan kelas -1. Untuk mendapatkan H yang optimal maka jarak H_1 dan H_2 ke H haruslah sama dengan syarat bahwa tidak ada sampel data antara H_1 dan H_2 serta jarak H_1 ke H_2 adalah jarak yang maksimal. Untuk memaksimalkan jarak H_1 dan H_2 maka digunakan sampel data positif yang terletak pada H_1 dan sampel data negatif yang terletak pada H_2 . Sampel data ini disebut *support vector* karena fungsinya sebagai penentu dalam mendapatkan *hyperplane* yang optimal. Sedangkan sampel data yang lain dapat dibuang atau digerakan menuju H_1 dan H_2 asalkan tidak melewati masing-masing *hyperplane*.


Misalkan $(x_0, y_0) \in R^2$ sebarang titik maka jarak titik ini ke garis $Ax + By + C = 0$ adalah

$$\frac{|Ax + By + C|}{\sqrt{A^2 + B^2}} \quad (3)$$

sehingga jarak sampel data x yang terletak pada H_1 ke H adalah

$$\frac{|xw + b|}{\sqrt{w^T w}} = \frac{1}{\|w\|} \quad (4)$$

Karena jarak H_1 dan H_2 ke H adalah sama maka jarak H_1 ke H_2 adalah $\frac{2}{\|w\|}$.



Gambar 1. Hyperplane Optimal yang Memisahkan 2 Kelas

Masalah memaksimalkan $\frac{2}{\|w\|}$ ekuivalen dengan masalah meminimumkan $\frac{\|w\|^2}{2}$ dengan syarat bahwa tidak ada sampel data di antara H_1 dan H_2 yakni

$$x_i w + b \geq 1 \quad \text{untuk } y_i = 1$$

$$x_i w + b \leq 1 \quad \text{untuk } y_i = -1$$

Jika digabungkan dua kondisi di atas maka diperoleh $y_i(x_i w + b) \geq 1$. Dengan demikian, masalah mencari parameter w dan b yang optimal agar diperoleh *hyperplane* yang optimal merupakan masalah pemrograman kuadratik

$$\min_{w,b} \frac{1}{2} w^T w$$

dengan kendala (5)

$$y_i(x_i w + b) \geq 1, \quad i = 1, \dots, m$$

Biasanya agak sulit menyelesaikan bentuk primal di atas, sehingga bentuk primal tersebut diubah ke bentuk dualnya dengan memperkenalkan pengali Lagrange.

Misalkan $\alpha \in R^{m \times 1}$ adalah pengali Lagrange maka masalah pemrograman kuadratik (5) di atas berubah menjadi

$$L(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^m \alpha_i (y_i (x_i w + b)) + \sum_{i=1}^m \alpha_i \quad (6)$$

Solusi dari masalah ini harus memenuhi syarat Karush-Kuhn-Tucker (KKT) yakni

$$\begin{aligned} \text{i. } \frac{\partial L}{\partial w} = 0 &\Rightarrow w - \sum_{i=1}^m \alpha_i y_i x_i = 0 \\ &\Rightarrow w = \sum_{i=1}^m \alpha_i y_i x_i \end{aligned} \quad (7)$$

$$\begin{aligned} \text{ii. } \frac{\partial L}{\partial b} = 0 &\Rightarrow 0 - \sum_{i=1}^m \alpha_i y_i = 0 \\ &\Rightarrow \sum_{i=1}^m \alpha_i y_i = 0 \end{aligned} \quad (8)$$

$$\text{iii. } a_i (y_i (x_i w + b) - 1) = 0. \quad (9)$$

$$\text{iv. } a_i \geq 0. \quad (10)$$

Dengan demikian bentuk dual yang diperoleh adalah

$$\text{Max } L(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j x_i x_j^T$$

dengan kendala (11)

$$\sum_{i=1}^m \alpha_i y_i = 0 \text{ dan } \alpha_i \geq 0 \text{ dimana } i = 1, 2, \dots, m$$

Parameter bobot dan bias dapat dihitung dengan persamaan

$$w = \sum_{i=1}^{N_n} \alpha_i y_i x_i \text{ dan } b = \frac{1}{N_{SV}} \sum_{i=1}^{N_{SV}} (y_i - x_i w) \quad (12)$$


SV adalah himpunan *support vector* dan $i \in SV$ jika $\alpha_i \neq 0$. N_{SV} adalah jumlah *support vector*. Dengan menggunakan persamaan

$$f(x) = xw + b$$

maka data input $x \in R^n$ yang baru diklasifikasikan menjadi

$$\begin{cases} \text{klas } +1, & \text{jika } f(x) > 0 \\ \text{klas } -1, & \text{jika } f(x) < 0 \end{cases} \quad (13)$$

Selanjutnya jika terjadi kasus pemisahan yang tidak sempurna dalam hal ini terdapat data antara H_1 dan H_2 seperti tampak pada gambar di bawah ini.



Gambar 2. Kasus Pemisahan Data Yang Tidak Sempurna

Untuk mengatasi masalah ini, akan diperkenalkan variabel *slack* μ yang tak negatif ($\mu \geq 0$) dan dimasukkan pada fungsi kendala (5) sehingga menjadi

$$y_i(x_i w + b) \geq 1 - \mu_i, \quad i = 1, \dots, m$$

Sedangkan pada fungsi objektifnya ditambahkan parameter positif C sehingga menjadi

$$\frac{1}{2} w^T w + C \sum_{i=1}^m \mu_i$$

Secara lengkap, masalah pemrograman kuadratik (5) berubah menjadi

$$\min_{w,b} \frac{1}{2} w^T w + C \sum_{i=1}^m \mu_i$$

dengan kendala (14)

$$y_i(x_i w + b) \geq 1 - \mu_i, \quad \mu_i \geq 0, \quad i = 1, \dots, m$$

Dengan menggunakan pengali Lagrange $\alpha \in R^{m \times 1}$ maka bentuk primal (14) dapat diubah menjadi bentuk dual sebagai berikut

$$\text{Max} \quad L(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j x_i x_j^T$$

dengan kendala (15)

$$\sum_{i=1}^m \alpha_i y_i = 0 \quad \text{dan} \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, \dots, m$$

1.2 Support Vector Machine (SVM) Non-Linier

Dalam masalah klasifikasi kebanyakan sampel data tidak terpisah secara linier sehingga jika digunakan SVM linier maka hasil yang diperoleh tidak optimal dan mengakibatkan hasil klasifikasi yang buruk. Yang menjadi salah satu keunggulan SVM terletak pada bagian ini, yakni SVM dapat diperluas untuk menyelesaikan masalah non-linier. SVM linier dapat diubah menjadi SVM non-linier dengan menggunakan metode kernel. Metode ini bekerja dengan cara memetakan data input ke ruang *feature* yang dimensinya lebih tinggi menggunakan fungsi sebuah ϕ . Sebagai misalkan $u = (u_1, u_2)$ adalah data input pada R^2 dan $\phi(u) = (1, \sqrt{2}u_1, \sqrt{2}u_2, u_1^2, u_2^2, \sqrt{u_1 u_2})$ adalah data input pada ruang *feature* yang berdimensi lebih tinggi yakni R^5 . Diharapkan data input hasil pemetaan ke ruang *feature* akan terpisah secara linier sehingga dapat dicari *hyperplane* yang optimal.

Misalkan $x \rightarrow \phi(x)$ maka Persamaan (14)-(15) dapat ditulis menjadi

$$\text{Max} \quad \psi(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j \phi^T(x_i) \phi(x_j)$$

dengan kendala (16)

$$\sum_{i=1}^m \alpha_i y_i = 0 \quad \text{dan} \quad \alpha_i \geq 0 \quad \text{dimana} \quad i = 1, 2, \dots, m$$

Parameter bobot dan bias dapat dihitung dengan persamaa

$$w = \sum_{i=1}^{N_{SV}} \alpha_i y_i \phi(x_i) \quad \text{dan} \quad b = \frac{1}{N_{SV}} \sum_{i=1}^{N_{SV}} (y_i - w^T \phi(x_i)) \quad (17)$$

Sedangkan *hyperplane* optimal pada Persamaan (1) berubah menjadi

$$f(x) = w^T \phi(x) + b = 0 \quad (18)$$

Permasalahan yang muncul adalah jika sampel data input untuk tahap *training* dalam jumlah besar maka perhitungan hasil kali titik $\phi^T(x_i) \phi(x_j)$ P(16) akan membuat waktu

perhitungan semakin lama. Oleh karena itu diperlukan cara untuk menghitung $\phi^T(x_i)\phi(x_j)$ tanpa mengetahui fungsi ϕ . Misalkan K adalah sebuah fungsi dengan sifat

$$K(u, v) = \phi^T(u)\phi(v)$$

dimana $u, v \in R^n$ dan $\phi: R^n \rightarrow R^m$, $n < m$. Fungsi K ini disebut sebagai fungsi kernel. Menurut Shigeo Abe (2010), fungsi kernel yang sering digunakan adalah sebagai berikut:

- kernel linier : $K(u, v) = u^T v$.
- kernel polinomial : $K(u, v) = (1 + u^T v)^d$, $d \geq 1$
- kernel RBF (Radial Basis Function) : $K(u, v) = \exp(-\gamma \|u - v\|^2)$, $\gamma > 0$

Dengan menggunakan konsep fungsi kernel di atas maka Persamaan (16) - (18) berubah menjadi $\text{Max } \psi(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j K(x_i, x_j)$

Dengan kendala $\sum_{i=1}^m \alpha_i y_i = 0$ dan $\alpha_i \geq 0$ dimana $i = 1, 2, \dots, m$ (19)

parameter bias dapat dihitung dengan persamaan

$$b = \frac{1}{N_{SV}} \sum_{i=1}^{N_{SV}} \left(y_i - \sum_{i=1}^{N_{SV}} \alpha_i y_i K(x_i, x_j) \right) \quad (20)$$

sedangkan *hyperplane* optimalnya

$$f(x) = \sum_{i=1}^{N_{SV}} \alpha_i y_i K(x_i, x) + b \quad (21)$$

Data input $x \in R^n$ yang baru tetap diklasifikasikan berdasarkan syarat pada Persamaan (13). Kemudian untuk proses normalisasi data dapat dilakukan dengan rumus berikut ini:

$$y_i = 2 \left(\frac{x_i - \min(x)}{\max(x) - \min(x)} \right) - 1 \quad (22)$$

Keterangan :

- y_i : Hasil normalisasi data ke- i
- x_i : Data ke- i
- $\min(x)$: Nilai terkecil pada data
- $\max(x)$: Nilai terbesar pada data

Berikut ini merupakan Algoritma Multi Kelas *Support Vector Machine* (SVM):

Misalkan terdapat N jumlah kelas dari sampel data yang akan diklasifikasi, multi kelas

SVM bekerja dengan cara membentuk semua kombinasi pasangan dua kelas yakni sebanyak $N(N-1)/2$ dimana $N > 2$. Misalkan *hyperplane* optimal yang diperoleh dari kelas i dan kelas j adalah

$$f_{ij}(x) = \phi(x)w_{ij} + b_{ij} \quad (23)$$

dimana $i = 1, 2, \dots, N - 1$ dan $j = i + 1, i + 2, \dots, N$ serta berlaku $f_{ij}(x) = -f_{ji}(x)$.

Maka algoritmanya sebagai berikut :

1. Dapatkan *hyperplane* optimal yakni Persamaan (23) untuk semua kombinasi pasangan dua kelas.
2. Untuk data input x yang baru, pilih sebarang pasangan dua kelas dan hitung nilai $f_{ij}(x)$. Jika $f_{ij}(x) > 0$ maka tandai kelas i sebagai kelas yang terpilih dan hapus kelas j . Sebaliknya jika $f_{ij}(x) < 0$ maka tandai kelas j sebagai kelas yang terpilih dan hapus kelas i .
3. Kelas yang terpilih dipasangkan dengan satu kelas yang dipilih secara acak dari keseluruhan kelas yang tersisa.
4. Ulangi langkah (2) dan (3) sampai menyisakan hanya satu kelas (kelas pemenang). Data input x diklasifikasikan sebagai anggota dari kelas pemenang[12].

2. METODE PENELITIAN

2.1 Tipe Penelitian

Tipe penelitian yang dipakai adalah studi kasus, yaitu dengan mengaplikasikan metode *Support Vector Machine* (SVM) untuk mendeteksi penyalahgunaan narkoba berdasarkan jenis narkotika yang digunakan.

2.2 Data dan Variabel Penelitian

Dalam penelitian ini, data yang digunakan adalah data 101 orang pasien rawat jalan yang diperoleh dari BNN Provinsi Maluku. Data dari 101 orang tersebut lengkap dengan 23 jenis gejala dan jenis narkoba yang dipakai. Berdasarkan data yang diperoleh maka ditetapkan empat kelas yang akan digunakan sebagai target dalam penentuan jenis narkotika yang digunakan. Adapun empat jenis narkotika yang digunakan adalah (1) Sabu, (2) Ganja, (3) Lem dan (4) Sintesis. Sedangkan gejala-gejala yang akan digunakan sebagai variabel input disajikan pada Tabel 1. berikut ini.

Tabel 1. Kriteria dan inisialisasi gejala Narkoba

Kriteria yang dinilai	Inisialisasi	Kriteria yang dinilai	Inisialisasi
Muda tersinggung	x_1	Mental terganggu	x_{13}
Kecanduan	x_2	Sembelit	x_{14}
Depresi	x_3	Nafsu makan hilang	x_{15}
Agitasi	x_4	Keracunan	x_{16}
Insomnia	x_5	Paranoid	x_{17}
Kerusakan Ginjal	x_6	Susunan syaraf pusat rusak	x_{18}
Gangguan Sex	x_7	Mudah gugup	x_{19}
Paru-paru terganggu	x_8	Pusing	x_{20}

Kriteria yang dinilai	Inisialisasi	Kriteria yang dinilai	Inisialisasi
Mudah lelah	x_9	Detak jantung meningkat	x_{21}
Muntah	x_{10}	Otot melemah	x_{22}
Berkeringat	x_{11}	Susah buang air kecil	x_{23}
Gelisah	x_{12}		

3. HASIL DAN PEMBAHASAN

Data yang telah dibagi akan diproses menggunakan metode *Support Vektor Machine* linier dan *Support Vektor Machine* non-linier dengan bantuan *software* MATLAB sehingga bisa diketahui tingkat akurasi yang diperoleh.

3.1 Hasil dengan Menggunakan Metode SVM Linier

Hasil Pengolahan dan pengujian data menggunakan *Support Vektor Machine* Linier untuk ketiga skema pembagian data seperti yang disajikan pada Tabel 2 berikut.

Tabel 2. Tingkat Akurasi Dengan Metode SVM Linier

No	Skema Pembagian	Tingkat Akurasi
1	60/40	77.5 %
2	70/30	83.3 %
3	80/20	80

3.2 Hasil dengan Menggunakan Metode SVM Non Linier

Untuk metode SVM non-linier, akan digunakan dua buah kernel sebagai pembanding yakni kernel *Polynomial* dan kernel RBF (*Radial Basis Function*). Nilai parameter yang akan dibuat bervariasi pada kernel polinomial adalah nilai d (*degree*) sedangkan pada kernel RBF adalah nilai γ (*sigma*). Hal ini bertujuan untuk mendapatkan tingkat akurasi yang terbaik. Hasil pengolahan dan pengujian data menggunakan SVM non-linier untuk ketiga skema pembagian data dapat dilihat pada Tabel 3, Tabel 4 dan Tabel 5 berikut ini.

Tabel 3. Tingkat Akurasi dengan Skema Pembagian Data 60/40

		Jenis Kernel : Kernel polinomial							
Parameter Kernel		$d = 1$	$d = 2$	$d = 3$	$d = 4$	$d = 5$	$d = 6$	$d = 7$	$d = 8$
Tingkat Akurasi		77.5 %	75 %	75 %	75 %	72.5 %	77.5 %	77.5 %	77.5 %
		Jenis Kernel : Kernel RBF (<i>Radial Basis Function</i>)							
Parameter Kernel		$\gamma = 1.5$	$\gamma = 2$	$\gamma = 2.5$	$\gamma = 3$	$\gamma = 3.5$	$\gamma = 4$	$\gamma = 4.5$	$\gamma = 5$
Tingkat Akurasi		77.5 %	80 %	80 %	80 %	80 %	80 %	80 %	77.5 %

Berdasarkan Tabel 3 terlihat bahwa hasil pengujian dengan kernel *Polynomial* memperoleh hasil terbaik pada nilai parameter $d = 1$, $d = 6$, $d = 7$ dan $d = 8$ dengan tingkat akurasi sebesar 77.5 % , kemudian selanjutnya dengan menggunakan kernel RBF diperoleh tingkat akurasi sebesar 80% untuk $\gamma = 2$, $\gamma = 2.5$, $\gamma = 3$, $\gamma = 3.5$, $\gamma = 4$, dan $\gamma = 4.5$.

Tabel 4. Tingkat Akurasi dengan Skema Pembagian Data 70/30

Jenis Kernel : Kernel polinomial								
Parameter Kernel	$d=1$	$d=2$	$d=3$	$d=4$	$d=5$	$d=6$	$d=7$	$d=8$
Tingkat Akurasi	83.3 %	83.3 %	83.3 %	80 %	83.3%	80%	76.6%	73.3%
Jenis Kernel : Kernel RBF (<i>Radial Basis Function</i>)								
Parameter Kernel	$\gamma = 1.5$	$\gamma = 2$	$\gamma = 2.5$	$\gamma = 3$	$\gamma = 3.5$	$\gamma = 4$	$\gamma = 4.5$	$\gamma = 5$
Tingkat Akurasi	83.3 %	83.3 %	90 %	86.6 %	86.6 %	86.6 %	86.6 %	86.6 %

Berdasarkan Tabel 4 terlihat bahwa hasil pengujian dengan kernel polinomial memperoleh hasil terbaik pada nilai parameter $d = 1$, $d = 2$, $d = 3$ dan $d = 5$ dengan tingkat akurasi sebesar 83.3 %, kemudian selanjutnya dengan menggunakan kernel RBF diperoleh tingkat akurasi sebesar 90 % untuk $\gamma = 2.5$.

Tabel 5. Tingkat Akurasi dengan Skema Pembagian Data 80/20

Jenis Kernel : Kernel polinomial								
Parameter Kernel	$d=1$	$d=2$	$d=3$	$d=4$	$d=5$	$d=6$	$d=7$	$d=8$
Tingkat Akurasi	80 %	85 %	95 %	90 %	90 %	85 %	80 %	75 %
Jenis Kernel : Kernel RBF (<i>Radial Basis Function</i>)								
Parameter Kernel	$\gamma = 1.5$	$\gamma = 2$	$\gamma = 2.5$	$\gamma = 3$	$\gamma = 3.5$	$\gamma = 4$	$\gamma = 4.5$	$\gamma = 5$
Tingkat Akurasi	95 %	95%	95 %	95 %	95 %	95 %	95 %	95 %

Dari Tabel 5 terlihat bahwa hasil pengujian dengan kernel *Polynomial* memperoleh hasil terbaik pada nilai parameter $d = 3$ dengan tingkat akurasi sebesar 95 %, kemudian selanjutnya dengan menggunakan kernel RBF diperoleh tingkat akurasi sebesar 95 % untuk $\gamma = 1.5$, $\gamma = 2$, $\gamma = 2.5$, $\gamma = 3$, $\gamma = 3.5$, $\gamma = 4$, $\gamma = 4.5$ dan $\gamma = 5$.

Berdasarkan hasil yang diperoleh, metode SVM non linier memiliki tingkat akurasi yang lebih baik dibandingkan SVM linier. Hal ini dikarenakan dari ketiga skema pembagian data, SVM linier hanya memiliki tingkat akurasi sebesar 83.3% sedangkan SVM non linier memiliki tingkat akurasi sebesar 95%. Khusus untuk SVM non linier, kernel RBF cenderung memiliki tingkat akurasi yang lebih baik dibandingkan kernel polinomial. Hal ini terlihat dari hasil pengujian ketiga skema pembagian data, kernel RBF memiliki hasil terbaik pada skema pembagian 60/40 dan skema pembagian 70/30 dengan tingkat akurasi tertinggi masing-masing sebesar 80% dan 90%. Sedangkan untuk skema pembagian data 80/20, kernel polinomial dan kernel RBF memiliki tingkat akurasi yang sama yaitu 95%.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dibahas maka dapat disimpulkan bahwa klasifikasi dengan model SVM Linier pada tiga skema pembagian data diperoleh hasil tingkat akurasi terbaik pada skema 70/30 yaitu sebesar 83.3%. Sedangkan klasifikasi dengan model SVM non linier diperoleh tingkat akurasi terbaik yaitu 95% pada skema 80/20 dengan Kernel RBF. Dengan demikian, model SVM yang tepat untuk mendeteksi penyalahgunaan narkoba adalah model SVM non linier dengan Skema Pembagian Data

DAFTAR PUSTAKA

1. Pangrestu, D. P., Widiastuti, N. I. 2014. Pembangunan Sistem Pendeteksi Penyalahgunaan Narkoba Menggunakan Algoritma Jaringan Syaraf Tiruan Metode Backpropagation. *Jurnal Ilmiah Komputer dan Informatika (Komputa)*. Vol. 3. No. 1.
2. Vapnik, V., dan Cortes, C. (1995). Support Vector Networks. *Machine Learning*, vol. 20(3), pp. 273-297.
3. Octaviani, P.A., Wilandari, Y., Ispriyanti, D. 2014. Penerapan Metode Klasifikasi *Support Vector Machine* (SVM) Pada Data Akreditasi Sekolah Dasar Di Kabupaten Magelang. *Jurnal Gaussian*, Vol. 3, No. 4.
4. Ritonga, A. S., Purwaningsih, E. S. 2018. Penerapan Metode Support Vector Machine (SVM) Dalam Klasifikasi Kualitas Pengelasan SMAW (Shield Metal Arc Welding). *Jurnal Ilmiah Edutic*, Vol. 5, No.1.
5. Parapat, I, M., Furqon, M. T, Sutrisno. 2018. Penerapan Metode Support Vector Machine (SVM) Pada Klasifikasi Penyimpangan Tumbuh Kembang Anak. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*. Vol. 2, No. 2.
6. Yuliati, I. F, Wulandary, Sihombing, P. R. 2020. Penerapan Metode *Support Vector Machine* (SVM) dan *Backpropagation Neural Network* (BPNN) dalam Pengklasifikasian Pasangan Usia Subur di Jawa Barat. *Jurnal Statistika dan Aplikasinya (JSA)* Vol. 4 No. 1.
7. Ramana, B. V., Babu, S. P., & Venkateswarlu, N. B. 2011. A Critical Study Of Selected Classification Algorithms For Liver Disease Diagnosis. *International Journal Of Database Management Systems* , Vol. 3 (2), Hal. 101-114.
8. Leleury, Z. A., Tomasouw, B. P. 2015. Diagnosa Penyakit Saluran Pernapasan Dengan Menggunakan Support Vector Machine (SVM). *Barekeng: Jurnal Ilmu Matematika dan Terapan*. Vo. 9, N0. 2.
9. Munawarah, R., Soesanto, O., Faisal, M. R. 2016. Penerapan Metode Support Vector Machine Pada Diagnosa Hepatitis. *Jurnal Ilmiah Klik: Kumpulan Jurnal Ilmu Kompute*. Vol. 3 (1).
10. Hasibuan, C. A., Mukid, M. A., & Prahutama, A. 2017. Klasifikasi Diagnosa Penyakit Demam Berdarah Dengue (DBD) Menggunakan Support Vector Machine (SVM) Berbasis Gui MATLAB. *Jurnal Gaussian*. Vol.6, no. 2, pp. 171-180
11. Sugara, B., Subekti, A. 2019. Penerapan Support Vector Machine (SVM) Pada Small Dataset Untuk Deteksi Dini Gangguan Autisme. *Jurnal Pilar Nusa Mandiri*. Vol. 15, No.
12. Tomasouw. B. P, Irawan. M. I. 2012. Multiclass Twin Bounded Support Vector Machine Untuk Pengenalan Ucapan, *Prosiding Seminar Nasional Penelitian, Pendidikan dan Peneraan MIPA, Fakultas MIPA, Universits Negeri Yogyakarta*.

