

Support Vector Machine untuk Pengenalan Bentuk Manusia Menggunakan Kumpulan Fitur yang Dioptimalkan

Alex Wenda* 

Jurusan Teknik Elektro, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim, Riau, Indonesia

ARTICLE INFO

Article history:

Received February 08, 2022

Revised February 09, 2022

Accepted April 14, 2022

Available online April 25, 2022

Kata Kunci:

Pengenalan Manusia, Support Vector Machine

Keywords:

Human Recognition, Support Vector Machine



This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

Copyright © 2022 by Author. Published by Universitas Pendidikan Ganesha.

ABSTRAK

Banyak terjadinya kendala dalam pendeteksian tubuh. Dengan demikian, beberapa proses pengenalan tubuh menjadi menjadi cukup suli dan metode pengenalan tubuh yang memiliki tingkat akurasi yang baik juga dibagi dalam dalam beberapa penelitian. Penelitian ini bertujuan untuk menganalisis penerapan sebuah pendekatan pembelajaran mesin bernama Support Vector Machine (SVM) untuk pengenalan bentuk manusia dan bukan manusia. Jenis penelitian eksperimen. Profil pusat 100 bentuk manusia dan nonmanusia pada interval 10° diekstraksi dan menghasilkan 36 profil fitur pusat. Profil fitur yang terekstraksi ini kemudian dianalisis dan dikenakan proses seleksi fitur untuk mengoptimalkan jumlah profil fitur yang digunakan. Ada dua metode yang digunakan dalam penelitian ini, yaitu metode statistik analisis varian (ANOVA) dan metode forward feature selection. Fitur terpilih diatur dari kedua metode tersebut dan digunakan sebagai input untuk SVM. Secara keseluruhan, kemampuan klasifikasi SVM ditemukan tidak berpengaruh lintas tiga fungsi inti yaitu linear, polynomial, dan basis radial gaussian. Metode ANOVA terbukti unggul dibandingkan metode forward feature selection. Hasil penelitian menunjukkan bahwa efektivitas SVM sebagai pengklasifikasi terkonfirmasi. Kinerja yang sempurna bisa dicapai ketika SVM diberikan sekumpulan fitur yang teroptimasi sebagai input. Temuan dalam penelitian ini membuktikan bahwa potensi yang besar dari penerapan SVM pada pendeteksian manusia untuk berbagai penerapan.

ABSTRACT

This paper investigated the application of a machine learning approach namely the Support Vector Machine (SVM) for the recognition of human and non-human shapes. Much work has shown that the silhouette contour of a shape contained essential shape information. Therefore, a suitable scheme, which we named as centroidal profile, is developed which represents the Euclidean distances between the centroid of a shape and the shape's boundary pixels. The centroidal profile of 100 human and non-human images at 10° interval were extracted yielding 36 centroidal feature profiles. These extracted feature profiles were further analyzed and subjected to a feature selection process to optimize the number of feature profiles used. Two methods were considered and they are the statistical method of analysis of variance (ANOVA) and the forward feature selection method. The selected feature sets from both methods were used as inputs to the SVM. Overall, the classification ability of the SVM was found to be unaffected across three kernels function namely linear, polynomial and gaussian radial basis. The ANOVA method was proven to be superior compared to the forward feature selection method. All in all, the effectiveness of SVM as classifier was confirmed. Perfect performance can be achieved when the SVM are fed with an optimized feature sets as input. The findings demonstrate considerable potential in applying SVM in human detection for various applications.

1. PENDAHULUAN

Pembelajaran mesin merupakan salah satu cabang dari bidang kecerdasan buatan yang berkembang pesat saat ini (Andrizal & Arif, 2017). Pembelajaran mesin menjadi metode analisis data yang mengotomasi pembuatan model analitik. Ini adalah cabang dari kecerdasan buatan yang berdasarkan ide bahwa sistem dapat belajar dari data, mengidentifikasi pola, dan mengambil keputusan dengan sedikit intervensi manusia (Darwis, 2016; De Lima et al., 2019). Ilmu ini berfokus untuk membuat sistem atau algoritma yang terus belajar dari data dan meningkatkan akurasi dari waktu ke waktu tanpa pemrograman tertentu. Salah satu pembelajarannya yaitu pengenalan bentuk. Pengenalan bentuk adalah sebuah tugas penting di visi komputer dan telah menarik banyak perhatian. Kebanyakan pendekatan untuk pengenalan bentuk menekankan pada ketepatan dan efisiensi pengenalan itu sendiri. Kinerja sistem pengenalan bentuk apapun pada akhirnya bergantung pada metode representasi bentuk yang digunakan (Costa & Cesar, 2009; Maroof et al., 2020; Polap & Wozniak, 2019). Ekstraksi bentuk manusia adalah sebuah prosedur terkomputerisasi untuk menemukan bentuk manusia dalam gambar. Kelas teknik ini lebih dikenal

*Corresponding author.

E-mail addresses: alexwenda@uin-suska.ac.id (Alex Wenda)

secara umum sebagai ekstraksi fitur, proses pengestraksian beberapa bentuk bermakna atau fitur dari sebuah gambar. Sebagaimana diketahui bahwa manusia memiliki bentuk yang fleksibel, tidak begitu terdefinisi dengan baik, dan bentuk yang kompleks. Tugas pemodelan manusia, deteksi, dan pengenalan dalam satu gambar sangat dibutuhkan karena hal-hal tersebut bisa muncul dalam semua warna dan dalam konteks yang bervariasi di depan latar belakang yang berbeda (Hariyono & Jo, 2017; Maroof et al., 2020).

Namun, beberapa permasalahan yang sering muncul dalam sistem pengenalan tubuh manusia. Ini disebabkan oleh banyak terjadinya kendala dalam pendeteksian tubuh. Dengan demikian, beberapa proses pengenalan tubuh menjadi menjadi cukup sulit, metode pengenalan tubuh yang memiliki tingkat akurasi yang baik juga dibagi dalam beberapa penelitian (Kindhi et al., 2018; Laref et al., 2018). Hal tersebut dilakukan agar sistem pengenalan tubuh mampu mengidentifikasi tubuh manusia secara baik menggunakan sistem komputer. Solusi yang dapat diterapkan, yaitu menggunakan sebuah mekanisme yang menggabungkan SVM dengan sebuah metode deteksi untuk mendeteksi manusia tanpa batasan jenis kelamin, pakaian, dan variasi postur. Metode SVM terbukti mampu mengenali bentuk manusia dan kemudian dengan tepat mengklasifikasikan bentuk yang tidak terlihat apakah itu manusia atau non manusia. Support Vector Machines (SVM) telah muncul sebagai sebuah teknik yang kuat untuk tujuan umum pengenalan pola. Teknik tersebut telah diterapkan pada masalah-masalah regresi dan klasifikasi dengan kinerja yang sangat bagus di rentang tugas klasifikasi biner (Altawaier & Tiun, 2016; Assignments, 2001; Chen et al., 2015; Kremer et al., 2014; Qian et al., 2015). Kelebihan utama dari SVM adalah kemampuan yang dimilikinya untuk meminimalkan risiko struktural dan empiris (Breerton & Lloyd, 2010) yang mengarah ke generalisasi yang lebih baik untuk klasifikasi data baru. Terlepas dari keberhasilan SVM dalam pengenalan pola lainnya, hanya ada sedikit penelitian tentang kemampuan klasifikasi SVM dalam mendeteksi manusia dan bukan manusia (Lee & Grimson, 2002) yang menunjukkan bahwa SVM mencapai akurasi 94% dalam klasifikasi gender menggunakan data gait video sequence. (Lee & Grimson, 2002) mendeteksi pola gerakan manusia dan SVM dilatih dengan pola aliran optik padat yang berasal dari manusia tetapi tidak ada hasil pengenalan yang dilaporkan. Dalam penelitian ini, kami melatih SVM menggunakan profil centroidal yang dioptimalkan dari kedua kategori untuk menyelidiki pengaruh relatifnya terhadap pengenalan bentuk manusia.

Beberapa hasil penelitian menyatakan bahwa implementasi *Iterative Closest Point* sebagai metode ekstraksi ciri dan *Support Vector Machine* sebagai metode klasifikasi telah mampu memberikan akurasi yang tinggi pada sistem identifikasi pengenalan wajah 3D (De Lima et al., 2019). Pengklasifikasian data dimensi tinggi dengan pembagian kelas lebih dari dua pada SVM dalam penelitian ini ternyata mampu memberikan hasil akurasi yang baik (Yulianti et al., 2019). SVM adalah implementasi perkiraan metode "minimisasi risiko struktural" yang bertujuan untuk mencapai probabilitas kesalahan generalisasi yang rendah. Support vector machine (SVM) sebagai salah satu metode dari data mining terbukti memiliki tingkat akurasi yang tinggi dalam mengklasifikasikan pola-pola paket data jaringan. Tujuan penelitian ini untuk menganalisis *support vector machine* untuk pengenalan bentuk manusia menggunakan kumpulan fitur yang dioptimalkan.

2. METODE

Jenis penelitian adalah penelitian eksperimen. SVM adalah teknik yang relatif baru untuk tugas klasifikasi dan regresi. Dalam tugas klasifikasi biner seperti pada penelitian ini, tujuannya adalah untuk menemukan hyperplane pemisah yang optimal. Gambar 1(a) menunjukkan masalah dua kelas dengan banyak kemungkinan hyperplane yang memisahkan dua set data yang belum tentu optimal. Pada Gambar 1(b), ditampilkan hyperplane pemisah (OSH) yang optimal yang menghasilkan margin maksimum (garis putus-putus) antara dua set data. Kedua angka diduplikasi dari (Sain & Vapnik, 1996). SVM menemukan K3 ini dengan memaksimalkan margin antar kelas. SVM pertama-tama mentransformasikan data input menjadi ruang dimensi yang lebih tinggi melalui fungsi kernel dan kemudian membangun OSH linier antara dua kelas dalam ruang yang diubah. Vektor data yang paling dekat dengan garis yang dibangun dalam ruang yang diubah disebut vektor pendukung (SV). (Borges, 1998; Haykin & Network, 2004). Secara singkat teori SVM adalah sebagai berikut (Sain & Vapnik, 1996). Pertimbangkan satu set pelatihan $D = \{(x_i, y_i)\}_{i=1}^L$ dengan masing-masing input $x_i \in \mathcal{R}^n$ dan output terkait $y_i \in \{-1, +1\}$. Setiap input x pertama-tama dipetakan ke dalam ruang fitur F oleh $z = \phi(x)$ berdimensi lebih tinggi melalui pemetaan non linier $\phi: \mathcal{R}^n \rightarrow F$. Pertimbangkan kasus ketika data dapat dipisahkan secara linear dalam F , maka terdapat vektor $w \in F$ dan skalar b yang mendefinisikan hyperplane pemisah sedemikian rupa sebagai $w \cdot z + b = 0$ sehingga $y_i(w \cdot z_i + b) \geq 1, \forall i$.

Dengan memaksimalkan batas pemisahan antar kelas ($2 / \|w\|$), SVM membangun OSH yang unik sebagai salah satu yang meminimalkan $w \cdot w/2$ dibawah batasan persamaan (1). Ketika data tidak dapat dipisahkan secara linier, masalah minimalisasi yang dijelaskan di atas dimodifikasi untuk memungkinkan kesalahan klasifikasi dengan memasukkan beberapa variabel non-negatif $\xi_i \geq 0$, sering disebut variabel slack, sehingga $y_i(w \cdot z_i + b) \geq 1 - \xi_i, \forall i$. ξ_i yang merupakan bukan nol menunjukkan titik data dengan kesalahan klasifikasi dan $\sum_{i=1}^L \xi_i$ dapat dianggap sebagai ukuran kesalahan klasifikasi. SVM menentukan K3 dengan memaksimalkan margin dan meminimalkan kesalahan pelatihan sebagai solusi dari masalah optimasi. C adalah parameter konstan, yang disebut parameter regularisasi yang menentukan trade-off antara margin maksimum dan kesalahan klasifikasi minimum. Meminimalkan suku pertama sesuai dengan meminimalkan dimensi Vapnik-Chervonenkis (VC) dari pengklasifikasi dan meminimalkan suku kedua mengontrol risiko empiris (Brereton & Lloyd, 2010; Sain & Vapnik, 1996). Mencari hyperplane optimal dalam Persamaan. (3) adalah masalah pemrograman kuadratik (QP) yang dapat diselesaikan dengan membangun Lagrangian dan mentransformasikannya menjadi dual problem.

$$W(\alpha) = \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \alpha_i \alpha_j y_i y_j z_i z_j \quad (4)$$

menjadi $\sum_{i=1}^L y_i \alpha_i = 0$ dan $0 \leq \alpha_i \leq C, \forall i$

Dimana $\alpha = (\alpha_1, \dots, \alpha_L)$ adalah pengali Lagrangian non-negatif. Titik data x_i bersesuaian dengan $\alpha_i > 0$ terletak di sepanjang margin batas keputusan dan merupakan SV. Istilah $z_i \cdot z_j$ pada persamaan (4) dapat dihitung dengan menggunakan fungsi kernel $K(x_i, x_j)$ tanpa harus memperoleh $\phi(x_i)$ dan $\phi(x_j)$ secara eksplisit sedemikian rupa sehingga $z_i \cdot z_j = \phi(x_i) \cdot \phi(x_j) = K(x_i, x_j)$. Setelah menentukan pengali Lagrange yang optimal, solusi optimal untuk vektor bobot w dapat diperoleh dengan $w = \sum_{i \in SVs} \alpha_i y_i z_i$. Dimana SV adalah vektor pendukung. Untuk setiap vektor uji $x \in \mathfrak{R}^n$, outputnya kemudian diperoleh dari $y = f(x) = \text{sign}(w \cdot z + b)$

$$y = \text{sign} \left(\sum_{i \in SVs} \alpha_i y_i K(x_i, x) + b \right)$$

Untuk menyusun SVMs, pengguna harus memilih fungsi kernel. Sejauh ini, tidak ada studi analitis atau empiris yang secara meyakinkan menetapkan keunggulan satu kernel di atas yang lain; dengan demikian, kinerja SVM dalam tugas tertentu dapat bervariasi dengan pilihan ini. Dalam penelitian ini, kami bereksperimen dengan tiga kernel seperti yang ditunjukkan pada Tabel 1.

Tabel 1. Daftar Kernels yang digunakan untuk Mengembangkan Model SVM

Fungsi Kernel	Rumus Matematis
Linear	$K(x_i, x_j) = x_i \cdot x_j$
Polynomial	$K(x_i, x_j) = (x_i \cdot x_j + 1)^d$, d adalah derajat polynomial
Fungsi Gaussian Radial Basis (RBF)	$K(x_i, x_j) = \exp(-\ x_i - x_j\ ^2 / 2 \sigma^2)$ σ adalah dengan lebar fungsi RBF

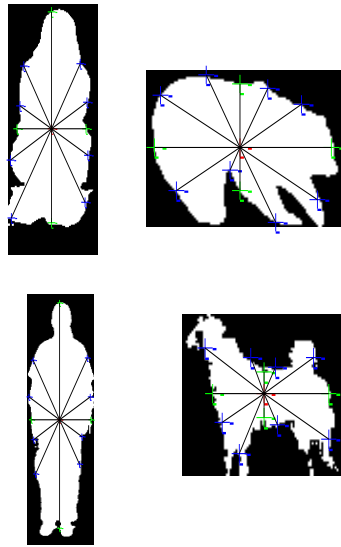
Profil centroidal, dua langkah utama dalam analisis citra adalah segmentasi citra dan pengenalan (da Fontoura Costa & Cesar Jr, 2010). Skema yang sesuai mewakili bentuk manusia menggunakan profil centroidal ditunjukkan pada Gambar 2. Siluet manusia dihasilkan setelah dilakukan penurunan latar belakang. Gambar tersebut kemudian dipotong ke area yang diinginkan untuk menentukan centroid bentuk manusia (x_c, y_c) menggunakan rumus $x_c = \frac{1}{N} \sum_{i=1}^N x_i$ & $y_c = \frac{1}{N} \sum_{i=1}^N y_i$, . N adalah jumlah total piksel batas, dan (x_i, y_i) mewakili piksel ke-i pada batas. Selanjutnya, urutan vektor dalam hal ini dihasilkan pada

interval sudut yang sesuai. Oleh karena itu, profil centroidal adalah urutan paling urut yang diperoleh dengan menghitung jarak Euclidean E , antara centroid dan setiap piksel batas,

$$E = \sqrt{(x_i - x_c)^2 + (y_i - y_c)^2} \quad \text{dan} \quad i = 1, 2, \dots, n$$

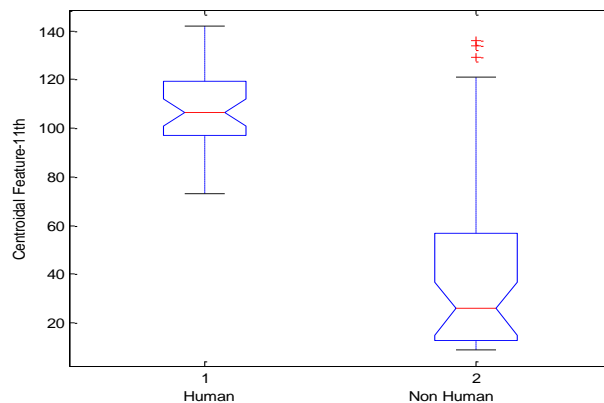
$n = 360 / \text{interval sudut yang dipilih (dalam derajat)}$.

Interval sudut 10° angle dipilih sehingga profil 36 titik dari suatu gambar diperoleh dan berfungsi sebagai vektor fitur yang diekstraksi dan fitur optimasi yang menjalani analisis ANOVA seperti yang di tunjukkan pada [Gambar 1](#).



Gambar 1. Profil Centroidal Tergeneralisasi untuk Pemodelan Bentuk

Pemilihan fitur, profil centroidal dari setiap gambar memiliki total 36 fitur. Beberapa fitur ini kemungkinan tidak signifikan apabila ditujukan untuk pengenalan atau klasifikasi. Oleh karena itu, diperlukan proses pemilihan fitur untuk mendapatkan kumpulan fitur yang optimal. Salah satu cara untuk melakukan seleksi fitur adalah dengan menggunakan pendekatan statistik. Dalam penelitian ini, seleksi fitur dilakukan dengan menguji apakah sekumpulan fitur signifikan untuk klasifikasi atau pengenalan menggunakan analysis of variance (ANOVA). ANOVA adalah teknik standar untuk mengukur signifikansi statistik dari satu set variabel independen dalam memprediksi variabel dependen. ANOVA mengambil satu fitur dan kelas yang terkait dengan sampel data dan mengukur signifikansi variabel kelas dalam memprediksi rata-rata fitur tersebut. Ukuran yang dihasilkan ANOVA adalah nilai p untuk set fitur dan variabel kelas. Misalnya, dalam kasus fitur tertentu, seperti titik 110° , berguna untuk membedakan antara bentuk manusia dan bukan manusia. Gambar 3 menunjukkan plot kotak titik 110° untuk manusia dan bukan manusia. Dalam kasus khusus ini, nilai p secara numerik tidak dapat dibedakan dari nol, dan plot kotak mengkonfirmasi yang oleh karena itu maka kami menyimpulkan bahwa fitur tersebut berguna dalam membedakan antara bentuk manusia dan bukan manusia, seperti yang ditunjukkan [Gambar 2](#).



Gambar 2. Kotak Bidang Centroidal yang Menunjukkan Perbedaan Antara Manusia dan Non Manusia

Pelatihan dan pengujian SVM, dalam skema ini, set data dibagi menjadi lima subset secara leave-one-out cross validation, di mana satu subset digunakan untuk pengujian dan empat lainnya untuk melatih dan membuat permukaan keputusan SVM. Tahapan ini diulang untuk himpunan bagian lain sehingga semua himpunan bagian digunakan sebagai sampel pengujian. Tiga ukuran mencakup akurasi, sensitivitas dan spesifisitas digunakan untuk menilai kinerja classifier SVM (Chan et al., 2002; Pang et al., 2003).

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} \times 100\%$$

$$Sen = \frac{TP}{TP + FN} \times 100\%$$

$$Spec = \frac{TN}{TN + FP} \times 100\%$$

Dimana:


- TP adalah jumlah positif benar;
- TN adalah jumlah negatif benar;
- FP adalah identifikasi manusia palsu;
- FN adalah identifikasi non-manusia palsu.

SVM mengidentifikasi bentuk manusia dan bukan manusia yang masing-masing diberi label sebagai manusia dan bukan manusia. Acc mewakili akurasi, yang menunjukkan akurasi deteksi keseluruhan di mana Sen merupakan kependekan dari sensitivitas, didefinisikan sebagai kemampuan pengklasifikasi SVM untuk mengenali manusia secara akurat. Spec, yang mewakili kekhususan/perbedaan, menunjukkan kemampuan pengklasifikasi untuk tidak menghasilkan deteksi palsu (bukan manusia).

3. HASIL DAN PEMBAHASAN

Hasil

Berdasarkan uji ANOVA pada tingkat signifikan = 0,05, kami memperoleh kumpulan fitur yang dioptimalkan yang terdiri dari 19 fitur. Nilai-p untuk sembilan belas fitur profil centroidal ini secara numerik tidak dapat dibedakan dengan nol. Oleh karena itu, fitur-fitur ini dapat dikatakan cocok untuk diterapkan sebagai input ke pengklasifikasi untuk membedakan dua kategori bentuk dalam penelitian ini. Fitur-fitur masing-masing ini dikategorikan ke dalam empat wilayah individu. Dengan demikian, fitur-fitur tersebut adalah profil 80°, 90°, 100° 110° yang terletak di wilayah 1, diikuti oleh empat fitur lainnya dari wilayah 2 yang terletak pada interval sudut 180°, 190°, 200° dan 210°. Wilayah 3 dalam hal ini memiliki 7 fitur dimana fitur-fitur tersebut terletak pada interval sudut 250°, 260°, 270°, 280°, 290°, 300°, 310°. Yang terakhir, empat fitur diposisikan pada interval sudut 350°, 360°, 10° dan 20° di Wilayah 4 seperti yang digambarkan pada Gambar3.



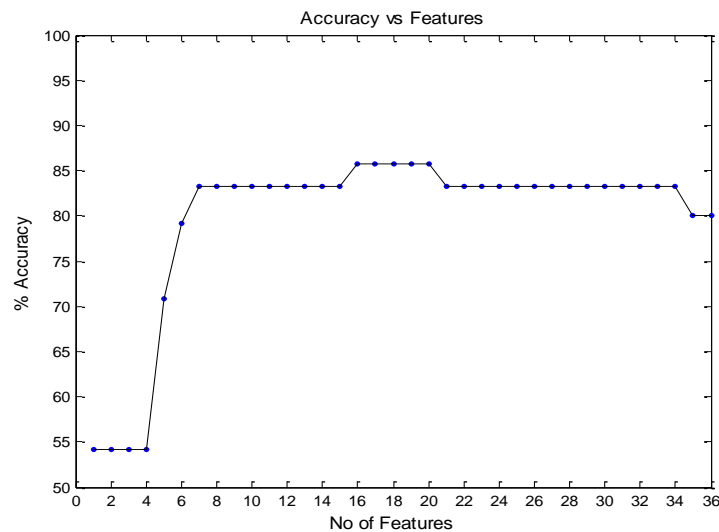
Gambar 3. Profil Gaya Berjalan Centroidal yang Tergeneralisasi oleh Analisa ANOVA

Pada mulanya, pengklasifikasi SVM dilatih dengan setiap set fitur wilayah untuk kemudian diuji. Keempat set fitur region selanjutnya digabungkan dan digunakan sebagai input. Seperti disebutkan di atas, tiga kernel yang berbeda dipertimbangkan penggunaannya di penelitian ini, yaitu RBF linier, polinomial dan Gaussian. Hasil klasifikasi ditabulasikan dalam hal akurasi, sensitivitas dan spesifisitas sebagaimana disajikan dalam Tabel 2.

Tabel 2. Ukuran Kinerja Eksperimen 5 Fold

Pengukuran Kinerja	Fungsi Kernel	Fitur Centroidal				Semua Wilayah
		R1	R2	R3	R4	
Ketepatan (<i>Acc</i>)	Linear	95.8	62.5	95.8	58.3	100
	Polynomial	95.8	58.7	91.6	62.5	100
	RBF	87.5	62.5	98.2	62.5	100
Sensitivitas (<i>Sen</i>)	Linear	88.8	47.0	88.8	44.4	100
	Polynomial	88.8	53.1	80	57.8	100
	RBF	72.7	66.7	92.5	57.8	100
Kekhususan (<i>Spec</i>)	Linear	100	66.760	100	62.3	100
	Polynomial	100	47.0	100	68.2	100
	RBF	90		100	68.2	100

Berdasarkan data, set fitur region individual digunakan sebagai input ke SVM, akurasi terbaik yang diperoleh adalah 98,2% untuk set fitur region 3 yang dilatih dengan kernel RBF. Kumpulan fitur terbaik berikutnya dimiliki oleh region 1 dengan 95,8% untuk kernel linier dan polinomial. Namun, kinerja terbaik dicapai ketika semua set fitur region digunakan sebagai input. Ketiga kernel mengkonfirmasi kinerja terbaik ketika fitur dari keempat wilayah diterapkan. Hasil seperti ini adalah hasil yang diharapkan karena fitur gabungan sebelumnya ditentukan sebagai kumpulan yang dioptimalkan yang oleh karenanya fitur-fitur tersebut dipilih dari 36 fitur asli. Hal ini menegaskan validitas penggunaan ANOVA dalam melakukan proses seleksi fitur. Dari ukuran kinerja sensitivitas, ditemukan bahwa set fitur region 4 menunjukkan sensitivitas paling rendah dengan persentase 44,4% untuk kernel linier sedangkan yang paling sensitif adalah set fitur Region 3 dengan persentase 92,5% untuk kernel RBF. Pada ketiga kernel, spesifisitas maksimum diperoleh untuk set fitur Wilayah 3. Proses pemilihan fitur alternatif dilakukan dengan menggunakan metode *forward feature selection* di mana fitur secara berurutan ditambahkan satu per satu dari yang paling meningkatkan akurasi klasifikasi. Gambar 5 menggambarkan plot akurasi sebagai fungsi fitur. Akurasi kinerja pengklasifikasi SVM meningkat karena lebih banyak profil centroidal yang digunakan. Akurasi klasifikasi terbaik yang diperoleh adalah 85,8%, yaitu ketika setidaknya enam belas profil centroidal pertama digunakan. Namun, akurasinya turun menjadi 80% ketika lebih dari 20 profil digunakan dan memburuk ketika lebih banyak profil ditambahkan, seperti yang ditunjukkan dalam Gambar 4.



Gambar 4. Ketepatan Klasifikasi pada Jumlah Fitur yang dipilih oleh Metode Forward Selection

Pembahasan

SVM pada akhirnya dapat membedakan antara manusia dan bukan manusia asalkan set fitur yang optimal digunakan. Dalam penelitian ini, metode ANOVA digunakan untuk mengoptimalkan profil centroidal di mana 36 profil centroidal awal dikurangi menjadi 19. Sebanyak 19 profil yang dipilih selanjutnya diregionalisasi menjadi empat wilayah berbeda dalam upaya untuk lebih mengurangi dan mengoptimalkan set fitur. Pemilihan fitur alternatif dan prosedur optimasi juga diterapkan untuk tujuan perbandingan. Hasil terbaik yang diperoleh dari teknik ini hanya menghasilkan akurasi 85,8%. Performa sempurna dicapai untuk ketiga kernel ketika semua 19 fitur ANOVA yang dipilih digunakan sebagai input ke SVM. Upaya untuk lebih mengurangi fitur input menurut wilayah tidak dapat menandingi kinerja ketika semua set fitur wilayah digunakan. Namun, upaya regionalisasi mengungkapkan beberapa fakta penting yang dapat ditindaklanjuti secara lebih lanjut dalam upaya mengoptimalkan fitur input di masa depan. Dari pengamatan kami, secara umum kami menemukan bahwa set fitur R1 dan R3 terdiri dari fitur yang dominan karena keduanya menghasilkan akurasi pengenalan yang tinggi dan spesifisitas yang tinggi. Yang paling tidak dominan adalah set fitur R4 dimana set fitur ini adalah yang paling tidak sensitif. Metode SVM terbukti mampu mengenali bentuk manusia dan kemudian dengan tepat mengklasifikasikan bentuk yang tidak terlihat apakah itu manusia atau non manusia. Support Vector Machines (SVM) telah muncul sebagai sebuah teknik yang kuat untuk tujuan umum pengenalan pola. Teknik tersebut telah diterapkan pada masalah-masalah regresi dan klasifikasi dengan kinerja yang sangat bagus di rentang tugas klasifikasi biner (Altawaier & Tiun, 2016; Assignments, 2001; Chen et al., 2015; Kremer et al., 2014; Qian et al., 2015). Beberapa hasil penelitian menyatakan implementasi *Iterative Closest Point* sebagai metode ekstraksi ciri dan *support vector machine* sebagai metode klasifikasi telah mampu memberikan akurasi yang tinggi pada sistem identifikasi pengenalan wajah 3D (De Lima et al., 2019). Pengklasifikasian data dimensi tinggi dengan pembagian kelas lebih dari dua pada SVM dalam penelitian ini ternyata mampu memberikan hasil akurasi yang baik (Yulianti et al., 2019).

4. SIMPULAN

SVM pada akhirnya dapat membedakan antara manusia dan bukan manusia asalkan set fitur optimal digunakan. Penelitian telah berhasil mengembangkan pengklasifikasi SVM yang dapat mengenali dan mengklasifikasikan atau mengidentifikasi manusia dan bukan manusia berdasarkan bentuknya dengan sempurna. Kualitas diskriminatif tersebut dapat diterapkan untuk sistem deteksi pejalan kaki, pengawasan, dan deteksi aktivitas.

5. DAFTAR PUSTAKA

Altawaier, M. M., & Tiun, S. (2016). Comparison of Machine Learning Approaches on Arabic Twitter Sentiment Analysis. *International Journal on Advanced Science, Engineering and Information Technology*, 6(6), 1067–1073. <https://doi.org/10.18517/ijaseit.6.6.1456>.

- Andrizal, A., & Arif, A. (2017). Pengembangan Media Pembelajaran Interaktif pada Sistem E-Learning Universitas Negeri Padang. *INVOTEK: Jurnal Inovasi Vokasional Dan Teknologi*, 17(2), 1–10. <https://doi.org/10.24036/invotek.v17i2.75>.
- Assignments, R. (2001). Support Vector Machines (SVM) Support Vector Machines (SVM). *Gesture*, 23(6), 349–361.
- Brereton, R. G., & Lloyd, G. R. (2010). Support Vector Machines for Classification and Regression. In *Analyst* (Vol. 135, Issue 2, pp. 230–267). <https://doi.org/10.1039/b918972f>.
- Burges, C. J. C. (1998). A tTtorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2), 121–167. <https://doi.org/10.1023/A:1009715923555>.
- Chan, K., Lee, T. W., Sample, P. A., Goldbaum, M. H., Weinreb, R. N., & Sejnowski, T. J. (2002). Comparison of Machine Learning and Traditional Classifiers in Glaucoma diagnosis. *IEEE Transactions on Biomedical Engineering*, 49(9), 963–974. <https://doi.org/10.1109/TBME.2002.802012>.
- Chen, D., Wang, L., & Li, L. (2015). Position Computation Models for High-Speed Train Based on Support Vector Machine Approach. *Applied Soft Computing Journal*, 30, 758–766. <https://doi.org/10.1016/j.asoc.2015.01.017>.
- Costa, L. da F., & Cesar, R. M. (2009). Shape Classification and Analysis: Theory and Practice, Second Edition. In *Shape Classification and Analysis: Theory and Practice, Second Edition*. Crc Press.
- da Fontoura Costa, L., & Cesar Jr, R. M. (2010). *Shape Analysis and Classification: Theory and Practice*. CRC press.
- Darwis, M. (2016). Aplikasi Watpasdroid untuk Perbaikan Sambungan Poros Mesin Listrik pada Praktikum Uji Pembebanan Motor. *Integrated Lab Journal*, 4(1), 37–44. <https://doi.org/10.14421/ilj.2016.%25x>.
- De Lima, N. V, Novamizanti, L., & Susatio, E. (2019). Sistem Pengenalan Wajah 3D Menggunakan ICP dan SVM. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 6(6), 601–610. <https://doi.org/10.25126/jtiik.2019661609>.
- Hariyono, J., & Jo, K. H. (2017). Detection of Pedestrian Crossing road: A study on Pedestrian Pose Recognition. *Neurocomputing*, 234, 144–153. <https://doi.org/10.1016/j.neucom.2016.12.050>.
- Haykin, S., & Network, N. (2004). A Comprehensive Foundation. *Neural Networks*, 2(2004), 41.
- Kindhi, B. Al, Sardjono, T. A., & Purnomo, M. H. (2018). Optimasi Support Vector Machine untuk Memprediksi Adanya Mutasi pada DNA Hepatitis C Virus. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 7(3). <https://doi.org/10.22146/jnteti.v7i3.441>.
- Kremer, J., Steenstrup Pedersen, K., & Igel, C. (2014). Active Learning with Support Vector Machines. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 4(4), 313–326. <https://doi.org/10.1002/widm.1132>.
- Laref, R., Losson, E., Sava, A., & Siadat, M. (2018). Support Vector Machine Regression for Calibration Transfer between Electronic Noses Dedicated to Air Pollution Monitoring. *SENSORS*, 18(11), 3716. <https://doi.org/10.3390/s18113716>.
- Lee, L., & Grimson, W. E. L. (2002). Gait Analysis for Recognition and Classification. *Proceedings - 5th IEEE International Conference on Automatic Face Gesture Recognition, FGR 2002, Mld*, 155–162. <https://doi.org/10.1109/AFGR.2002.1004148>.
- Maroof, M. A., Mahboubi, A., Noorzad, A., & Safi, Y. (2020). A New Approach to Particle Shape Classification of Granular Materials. *Transportation Geotechnics*, 22, 100296. <https://doi.org/10.1016/j.trgeo.2019.100296>.
- Pang, C. C. C., Upton, A. R. M., Shine, G., & Kamath, M. V. (2003). A Comparison of Algorithms for Detection of Spikes in The Electroencephalogram. *IEEE Transactions on Biomedical Engineering*, 50(4), 521–526. <https://doi.org/10.1109/TBME.2003.809479>.
- Polap, D., & Wozniak, M. (2019). Bacteria Shape Classification by The Use of Region Covariance and Convolutional Neural Network. *Proceedings of the International Joint Conference on Neural Networks, 2019-July*, 1–7. <https://doi.org/10.1109/IJCNN.2019.8851958>.
- Qian, Y., Zhou, W., Yan, J., Li, W., & Han, L. (2015). Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. *Remote Sensing*, 7(1), 153–168. <https://doi.org/10.3390/rs70100153>.
- Sain, S. R., & Vapnik, V. N. (1996). The Nature of Statistical Learning Theory. *Technometrics*, 38(4), 409. <https://doi.org/10.2307/1271324>.
- Yulianti, R., Wijaya, I. G. P. S., & Bimantoro, F. (2019). Pengenalan Pola Tulisan Tangan Suku Kata Aksara Sasak Menggunakan Metode Moment Invariant dan Support Vector Machine. *Intelligent System and Computer Vision*, 3(2), 91–98. <https://doi.org/10.29303/jcosine.v3i2.181>.