

# JST\_SIN2

*by* Jst\_sin2 Jst\_sin2

---

**Submission date:** 07-Feb-2022 10:36PM (UTC+0700)

**Submission ID:** 1756900299

**File name:** DONE\_TRANSLATE\_PAK\_ALEX\_0402\_JST.docx (201.9K)

**Word count:** 2957

**Character count:** 18091

# Support Vector Machine Untuk Pengenalan Bentuk Manusia Menggunakan Kumpulan Fitur Yang Dioptimalkan

Alex Wenda

<sup>3</sup>  
*Departemen Teknik Elektro, Fakultas Sains dan Teknologi,  
Universitas Islam Negeri Sultan Syarif Kasim Riau, Indonesia.*

alexwenda@uin-suska.ac.id

## Abstrak

Artikel ini meneliti penerapan sebuah pendekatan pembelajaran mesin bernama Support Vector Machine (SVM) untuk pengenalan bentuk manusia dan bukan manusia. Banyak penelitian telah menunjukkan bahwa kontur siluet sebuah bentuk mengandung informasi bentuk yang esensial. Oleh karena itu, sebuah skema yang cocok, yang kami namai sebagai profil pusat, dikembangkan yang merepresentasikan jarak euclidean antara pusat bentuk dan piksel batas bentuknya. Profil pusat 100 bentuk manusia dan non manusia pada interval 10° diekstraksi dan menghasilkan 36 profil fitur pusat. Profil fitur yang terekstraksi ini kemudian dianalisa dan dikenakan ke 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. Setelah dipertimbangkan semuanya, efektifitas SVM sebagai pengklasifikasi terkonfirmasi. Kinerja yang sempurna bisa dicapai ketika SVM diberikan sekumpulan fitur yang teroptimasi sebagai input. Temuan dalam penelitian ini membuktikan potensi yang besar dari penerapan SVM pada pendeteksian manusia untuk berbagai penerapan.

**Kata kunci:** *Pengenalan Manusia, Support Vector Machine, Klasifikasi, ANOVA*

## Abstract

<sup>1</sup>  
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.

**Keywords:** *Human Recognition, Support Vector Machine, Classification, ANOVA*

## PENDAHULUAN

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 tergantung pada metode representasi bentuk yang digunakan [1] [2] [3]. Ekstraksi bentuk manusia adalah sebuah prosedur terkomputerisasi untuk menemukan bentuk manusia dalam gambar. Kelas teknik ini lebih dikenal secara umum sebagai ekstraksi fitur, proses pengekstraksian beberapa bentuk bermakna atau fitur dari sebuah gambar. Sebagaimana yang kita ketahui, manusia memiliki bentuk yang fleksibel, tidak begitu terdefinisi dengan baik, dan bentuk yang kompleks. Tugas daripada 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 [4].

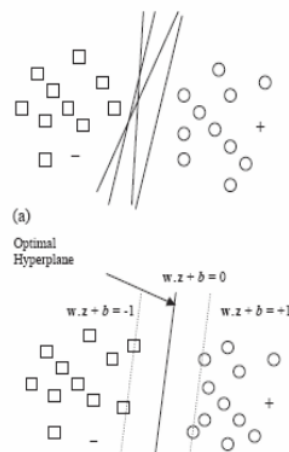
Makalah ini menguraikan sebuah mekanisme yang menggabungkan SVM dengan sebuah metode deteksi untuk mendeteksi manusia tanpa batasan jenis kelamin, pakaian, dan variasi postur. Metode yang kami ajukan terbukti mampu mengenali bentuk manusia dan kemudian dengan tepat mengklasifikasikan bentuk yang tidak terlihat apakah itu manusia atau non manusia. Baru-baru ini, 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 [5], [6] & [15].

Kelebihan utama dari SVM adalah kemampuan yang dimilikinya untuk meminimalkan risiko struktural dan empiris [7] 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 dan Grimson [8] menunjukkan bahwa SVM mencapai akurasi 94% dalam klasifikasi gender menggunakan data gait video sequence. Hedvig [14] 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.

### SUPPORT VECTOR MACHINE

SVM yang diperkenalkan oleh Vapnik [9] 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 [9]. 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). SVM adalah implementasi perkiraan metode "minimisasi risiko struktural" yang bertujuan untuk mencapai probabilitas kesalahan generalisasi yang rendah [10] & [16]. Secara singkat teori SVM adalah sebagai berikut [9]. [Gambar 1]



Pertimbangkan satu set pelatihan  $D = \{(x_i, y_i)\}_{i=1}^L$  dengan masing-masing input  $x_i \in \mathbb{R}^n$  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  $\phi: \mathbb{R}^n \rightarrow F$ . 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

$$y_i(w \cdot z_i + b) \geq 1, \forall i \quad (1)$$

Dengan memaksimalkan batas pemisahan antar kelas ( $2 / \|w\|$ ), SVM membangun OSH yang unik sebagai salah satu yang meminimalkan  $w$ .  $w/2$  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

$$y_i(w \cdot z_i + b) \geq 1 - \xi_i, \forall i \quad (2)$$

$\xi_i$  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 berikut.

minimalkan  $\frac{1}{2} w \cdot w + C \sum_{i=1}^L \xi_i$   
 menjadi  $y_i(w \cdot z_i + b) \geq 1 - \xi_i, \forall i$  (3)  
 dan  $\xi_i \geq 0, \forall i$

di mana  $C$  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 [7] & [9].

Mencari hyperplane optimal dalam Persamaan. (3) adalah masalah pemrograman kuadratik (QP) yang dapat diselesaikan dengan membangun Lagrangian dan mentransformasikannya menjadi dual problem sebagai berikut:

maksimalkan  $W(\alpha) = \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \alpha_i \alpha_j y_i y_j z_i \cdot z_j$  (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  $K(\cdot, \cdot)$  tanpa harus memperoleh  $\phi(x_i)$  dan  $\phi(x_j)$

secara eksplisit sedemikian rupa sehingga  $z_i \cdot z_j = \phi(x_i) \cdot \phi(x_j) = K(x_i, x_j)$ .

dengan lebar fungsi RBF

Setelah menentukan pengali Lagrange yang optimal, solusi optimal untuk vektor bobot  $w$  dapat diperoleh dengan:

$$w = \sum_{i \in SVs} \alpha_i y_i z_i \quad (5)$$

Dimana SV adalah vektor pendukung. Untuk setiap vektor uji  $x \in \mathcal{R}^n$ , outputnya kemudian diperoleh dari

$$y = f(x) = \text{sign}(w \cdot z + b)$$

$$y = \text{sign} \left( \sum_{i \in SVs} \alpha_i y_i K(x_i, x) + b \right) \quad (6)$$

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 [3], 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)	$K(x_i, x_j) = \exp(-\ x_i - x_j\ ^2 / 2 \sigma^2)$ $\sigma$ adalah

### III. EKSTRAKSI FITUR

#### A. Profil Centroidal

Dua langkah utama dalam analisis citra adalah segmentasi citra dan pengenalan [11]. 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 di bawah ini:


$$x_c = \frac{1}{N} \sum_{i=1}^N x_i \quad \& \quad y_c = \frac{1}{N} \sum_{i=1}^N y_i, \quad (7)$$

di mana  $N$  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, dimana:

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

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

Interval sudut  $10^\circ$  angle dipilih berdasarkan .... [12]. Dengan demikian, profil 36 titik dari suatu gambar diperoleh dan berfungsi sebagai vektor fitur yang diekstraksi dan fitur optimasi yang menjalani analisis ANOVA seperti yang disebutkan di bagian selanjutnya. [Gambar 2]




Gambar 2. Profil centroidal Tergeneralisasi Untuk Pemodelan Bentuk

### B. Pemilihan Fitur

Profil centroidal dari setiap gambar memiliki total 36 fitur. Beberapa fitur ini kemungkinan tidak signifikan apabila ditujuka 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  $110^\circ$ , berguna untuk membedakan antara bentuk manusia dan bukan manusia. Gambar 3 menunjukkan plot kotak titik  $110^\circ$  untuk manusia dan bukan manusia.

Dalam kasus khusus ini, nilai p secara numerik tidak dapat dibedakan dari nol, dan plot kotak mengkonfirmasinya yang oleh karena itu maka kami menyimpulkan bahwa fitur tersebut berguna dalam membedakan antara bentuk manusia dan bukan manusia. [Gambar 3]



Gambar 3. Kotak bidang terpilih dari satu fitur centroidal teruji yang menunjukkan perbedaan signifikan antara manusia dan non manusia.

### C. 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 [6] [13].

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

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

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

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).

#### IV. HASIL PENGENALAN DAN PEMBAHASAN

Berdasarkan uji ANOVA pada tingkat signifikan = 0,05, kami memperoleh kumpulan fitur yang dioptimalkan yang terdiri dari 19 fitur. Kami mengantisipasi bahwa 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 Gambar 4. [Gambar 4]




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.

Ketika 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.

TABEL 2 UKURAN KINERJA EKSPERIMEN 5 LIPAT

Pengukuran Kinerja	Fungsi Kernel	R1	R2	R3	R4	Semua Wilayah
		Ketepatan ( <i>Acc</i> )	Linear	95.	62.	95.
	Poly	8	5	8	3	100
	RBF	95.	58.	91.	62.	100
		8	7	6	5	
		87.	62.	98.	62.	
		5	5	2	5	
Sensitivitas ( <i>Sen</i> )	Linear	88.	47.	88.	44.	100
	Poly	8	0	8	45	100
	RBF	88.	53.	80	7.8	100
		8	1	92.	57.	
		72.	66.	5	8	
		7	7			
Kekhususan ( <i>Spec</i> )	Linear	10	66.	10	62.	100
	Poly	0	76	0	3	100
	RBF	10	0	10	68.	100
		0	47.	0	2	
		90	0	10	68.	
				0	2	

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 [6]. 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. [Gambar 5]





## V. KESIMPULAN

Hasil dari penelitian ini telah menunjukkan bahwa SVM pada akhirnya dapat membedakan antara manusia dan bukan manusia asalkan set fitur yang dioptimalkan digunakan. Dalam karya 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.

Kesimpulan yang diperoleh dari penelitian ini adalah bahwa 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.

## REFERENSI

- [1] RH Glendinning, RA Herbert 2003. "Shape Classification Using Smooth Principal Components", in *Journal of Elsevier Science. Pattern Recognition Letters* 24, 2021-2030, 2003.
- [2] Abbasi S. "Affine-similar shape retrieval: Application to Multiview 3D Object Recognition", in *Journal of Image Processing, IEEE Transaction* 10, 131-135, 2001.
- [3] Milios E. "Shape retrieval based on dynamic programming", in *Journal of Image Processing, IEEE Transaction* 9, 141-147, 2001.
- [4] Cristobal C, Johann E, Thomas K, Christos T Werner von S 2000. "Walking Pedestrian Recognition", in *IEEE Transaction* 1, No 3 Sept 2000, 155-163.
- [5] Chapelle o. HaffnerP. Vapnik VN." Support vector machines for histogram-based classification" in *IEEE Transactions on Neural Networks* 10, 1055-1064, 1999.
- [6] Chan K, Lee TW, Sample PA, Goldbaum MH, Weinreb RN, Sejnowski TJ. "Comparison of machine learning and traditional classifiers in glaucoma diagnosis", in *IEEE Transactions on Biomedical Engineering* 49, 963-974, 2002.

- [7] Gunn S, "Support Vector machines for classification and regression", *ISIS Technical Report*, University of Southampton, 1998.
- [8] Lee L, Grimson WEL, " Gait Analysis for recognition and classification", in *Proc of 5<sup>th</sup> International Conf on Automated Face and Gesture Recognition*, IEEE Computer Society, Silver Spring, MD, 2002.
- Vapnik VN, "The nature of Statistical Learning Theory", Springer, New York, 1995.
- [10] Haykin S, "Neural Network: A Comprehensive Foundation". Prentice Hall, Englewood Cliffs, NJ. 1999.
- [11] LF Costa, RM Cesar. "Shape Analysis and Classification – Theory and Practice". CRC Press. 2002.
- [12] Nooritawati Md Tahir and Aini Hussain. "Human Shape Analysis Using Artificial Neural Network", in *Proceeding of ICOM 2005*, Kuala Lumpur, May 2005.
- [13] Pang CCC, Upton ARM, Shine G, Kamath MV, " A Comparison of algorithms for detection of spikes in the electroencephalogram", in *IEEE Transaction on Biomedical Engineering* 50, 521-526, 2003.
- [14] Hedvig S, "Detecting Human Motion with Support Vector Machines", in *Proc of ICPR '04*, 4651-4654, 2004.
- [15] Hua S, Sun Z, " Support Vector Machine approach for protein subcellular localization prediction", *Bioinformatics* 17, 721-728, 2001.
- [16] Burges CJC, " A Tutorial on Support Vector Machines for Pattern Recognition", *Data Mining and Knowledge Discovery* 2, 121-167, 1998.

## ORIGINALITY REPORT

8%

SIMILARITY INDEX

8%

INTERNET SOURCES

4%

PUBLICATIONS

%

STUDENT PAPERS

## PRIMARY SOURCES

1

[www.asprg.net](http://www.asprg.net)

Internet Source

4%

2

[people.eng.unimelb.edu.au](http://people.eng.unimelb.edu.au)

Internet Source

1%

3

[pt.scribd.com](http://pt.scribd.com)

Internet Source

1%

4

[water-soil.tabrizu.ac.ir](http://water-soil.tabrizu.ac.ir)

Internet Source

1%

5

Siddhartha Datta Gupta. "Grading of cellular rejection after orthotopic liver transplantation", *Hepatology*, 01/1995

Publication

1%

6

[es.scribd.com](http://es.scribd.com)

Internet Source

1%

Exclude quotes  Off

Exclude bibliography  On

Exclude matches  < 1%