

## PENDETEKSIAN JENIS DAN KELAS AROMA DENGAN MENGGUNAKAN METODE *ONE-VS-ONE* DAN METODE *ONE-VS-REST*

Zuherman Rustam<sup>1,3</sup>, Benyamin Kusumoputro<sup>2,3</sup> dan Belawati Widjaja<sup>1,2</sup>

<sup>1</sup>Departemen Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Indonesia, Depok 16424, Indonesia

<sup>2</sup>Fakultas Ilmu Komputer, Universitas Indonesia, Depok 16424, Indonesia

<sup>3</sup>Laboratorium Komputasi Intelegensia, Universitas Indonesia, Depok 16424, Indonesia

E-mail: kusumo@cs.ui.ac.id; rustam@makara.cso.ui.ac.id

### Abstrak

Komputasi intelegensia yang digunakan dalam masalah klasifikasi pola dapat digolongkan menjadi dua bagian, yaitu yang berbasis pada Neural Network dan yang berbasis pada Pembelajaran Statistika (*Statistical Learning*). Pembelajaran yang berbasis statistika, pertama kali ditemukan oleh Vapnik pada dekade tujuh-puluhan. Untuk masalah klasifikasi pola Vapnik mengembangkan metode *hyperplane optimal separation*, atau dikenal juga dengan nama metode *Support Vector Machines (SVM)*. Pada awalnya *SVM* dirancang hanya untuk menyelesaikan masalah klasifikasi biner, yaitu dari data-data yang ada, diklasifikasikan menjadi dua kelas. Untuk mengklasifikasikan data yang terdiri dari lebih dari dua kelas, metode *SVM* tidak dapat langsung digunakan. Ada beberapa metode yang dapat digunakan untuk menyelesaikan masalah klasifikasi multikelas *SVM* yaitu: metode *One-vs-One* dan metode *One-vs-Rest*. Kedua metode ini merupakan perluasan dari klasifikasi biner *SVM*. Kedua metode tersebut akan dibahas di artikel ini dan akan dilihat kinerjanya dalam mengklasifikasikan aroma. Data aroma yang digunakan dalam percobaan ini terdiri dari 3 jenis aroma, masing-masing aroma terdiri atas 6 kelas. Pembagian kelas ini berdasarkan pada konsentrasi alkohol yang dicampurkan pada masing-masing aroma. Misalkan untuk aroma A, terdapat 6 jenis aroma A dengan kandungan alkohol : 0%, 15%, 25%, 30%, 45% dan 75%. Kinerja dari kedua metode diukur berdasarkan kemampuan untuk mengenal dan mengklasifikasikan aroma, dengan tepat dan sesuai dengan jenis atau kelas, dari data yang diberikan.

### Abstract

**Aroma classification using one-vs-one and one-vs-rest methods.** Computational Intelligence used in pattern classification problem can be divided into two different parts, one based on Neural Network and the other based on Statistical Learning. The Statistical Learning discovered by Vapnik on 70-est decade. For the pattern classification, Vapnik developed hyperplane optimal separation, which is known as Support Vector Machines Method (SVM). In the beginning, SVM was designed only to solve binary classification problem, where data existing are classified into two classes. To classify data whose consist of more than two classes, the SVM method can not directly be used. There are several methods can be used to solve SVM multiclass classification problem, they are One-vs-One Method and One-vs-Rest Method. Both of this methods are the extension of SVM binary classification, they will be discussed in this article so that we can see their performance in aroma classification process. Data of aroma used in this experiment is consisted of three classes of aroma, each of them has six classes. The division of this class is based on alcohol concentration mixed into each of those aromas. For example, for aroma A, there are six kinds of aroma A with different alcohol concentration: 0%, 15%, 25%, 30%, 45% and 75%. The performance of these methods is measured based on their ability to recognize and classify aroma, precisely and match with the right class or variety of data existed.

*Keywords: classification, kernel, svm, odor*

## 1. Pendahuluan

Komputasi intelegensia dalam masalah klasifikasi pola dapat digolongkan menjadi dua bagian yaitu yang berbasis pada *Neural Network* dan yang berbasis pada Pembelajaran Statistika (*Statistical Learning*). Pembelajaran yang berbasis statistika, pertama kali ditemukan oleh Vapnik pada dekade tujuh-puluhan [1]. Untuk masalah klasifikasi pola, Vapnik mengembangkan metode *hyperplane optimal separation*, yang berbasis pada konsep *Structural Risk Minimization*. Metode *hyperplane optimal separation* ini dikenal juga dengan nama *Support Vector Machines (SVM)*. Pada awalnya *SVM* dirancang hanya untuk menyelesaikan masalah klasifikasi biner, yaitu dari data-data yang ada, diklasifikasikan menjadi dua kelas. Untuk mengklasifikasikan data yang terdiri dari lebih dari dua kelas, metode *SVM* tidak dapat langsung digunakan. Ada beberapa metode yang dapat digunakan untuk menyelesaikan masalah klasifikasi multikelas dengan menggunakan *SVM*, antara lain: metode *One-vs-One* dan metode *One-vs-Rest*. Kedua metode ini merupakan perluasan dari klasifikasi biner *SVM*. Kedua metode tersebut akan dibahas di artikel ini dan akan dilihat kinerjanya dalam mengklasifikasikan aroma. Data aroma yang digunakan dalam percobaan ini terdiri dari 3 jenis aroma, masing-masing aroma terdiri atas 6 kelas. Pembagian kelas ini berdasarkan pada banyaknya konsentrasi alkohol yang dicampurkan pada masing-masing aroma. Misalkan untuk aroma A, terdapat 6 jenis aroma A dengan konsentrasi alkohol: 0%, 15%, 25%, 30%, 45% dan 75%. Kinerja dari kedua metode diukur berdasarkan kemampuan untuk mengenal dan mengklasifikasikan aroma, dengan tepat dan sesuai dengan jenis atau kelas, dari data yang diberikan.

Metode-metode untuk menyelesaikan masalah klasifikasi aroma, yang telah dilakukan di Laboratorium Komputasi Intelegensia Universitas Indonesia, antara lain: Modifikasi *Kernel PCA (Principal Component Analysis)* oleh Kusumoputro *et.al.*[2], *Fuzzy-Neuro LVQ* oleh Kusumoputro *et.al.*[3], metode probabilistik *neural network (PNN)* oleh Kusumoputro *et.al.*[4], dan Jatmiko *et.al.* [5], jaringan neural buatan oleh Jatmiko *et.al.* [6]. Data-data aroma yang digunakan pada metode-metode tersebut, akan dicoba diklasifikasikan dengan menggunakan metode *One-vs-One* dan metode *One-vs-Rest*.

Sistematika penulisan artikel ini sebagai berikut, pada bagian kedua akan dibahas tentang metode *SVM* untuk mengklasifikasikan data menjadi dua kelas. Khusus untuk mengklasifikasikan data menjadi dua kelas, metode ini untuk selanjutnya dinamakan klasifikasi biner. Pada bagian kedua juga akan dibahas tentang Metode *SVM* Multikelas untuk mengklasifikasikan data menjadi beberapa kelas. Metode *SVM* Multikelas dapat dibagi menjadi dua metode yaitu metode *One-vs-One* dan metode *One-vs-Rest*. Pada bagian ketiga, kedua metode *SVM* ini digunakan untuk mengklasifikasikan data aroma yang tersedia di Laboratorium Komputasi Intelenjensia, Universitas Indonesia. Pada bagian ketiga akan dijelaskan tentang tahapan-tahapan dan hasil-hasil percobaan.

## 2. Metode Penelitian

Secara umum masalah klasifikasi biner dapat dinyatakan sebagai berikut. Misalkan diberikan himpunan data sample  $S$ , dimana  $S = \{x_1, x_2, \dots, x_n\}$  dan  $C = \{c_1, c_2, \dots, c_k\}$ . Akan dicari suatu fungsi keputusan  $f$  sedemikian sehingga

$f(x_i) = c_j$ . Dengan menggunakan fungsi tersebut, data sampel dapat dipisahkan menjadi dua kelas yaitu kelas  $c_1$  dan kelas  $c_2$ . Bidang yang memisahkan kedua kelas tersebut merupakan suatu *hyperplane* dengan persamaan  $w \cdot x + b = 0$ , dimana  $w$  merupakan vektor normal (vektor bobot) dari *hyperplane* dan  $b$  konstanta yang menunjukkan jarak *hyperplane* ke titik pusat. Suatu data sampel  $x_i$  akan ditempatkan di kelas  $c_1$ , jika nilai  $w \cdot x_i + b > 0$ . Dan akan ditempatkan di kelas  $c_2$ , jika nilai  $w \cdot x_i + b < 0$ . Kedua pernyataan itu dapat dituliskan dalam bentuk fungsi keputusan:

$$(1)$$

Himpunan data  $S$  dikatakan *linearly separable*, jika ada suatu *hyperplane* sedemikian sehingga data sampel dapat diklasifikasikan kedalam kelas  $c_1$  atau kelas  $c_2$ . Untuk mencari *hyperplane* pemisah tersebut, sama artinya dengan mencari pasangan  $(w, b)$  yang memenuhi persamaan  $w \cdot x_i + b > 0$ . Misalkan  $x_1, x_2, \dots, x_n$  dan  $c_1, c_2, \dots, c_k$  menunjukkan vektor-vektor terluar dari masing-masing kelas, yang paling dekat dengan *hyperplane*. Bidang yang melalui masing-masing vektor-vektor tersebut dinotasikan dengan  $H_1$  dan  $H_2$ . Jarak dari  $x_i$  ke  $H_1$  dan jarak dari  $x_i$  ke

masing-masing dinotasikan dengan  $a_i$  dan  $b_i$ . Sedangkan jarak antara  $a_i$  dengan  $b_i$ , dinamakan margin dan dinotasikan dengan  $\alpha_i$ .

Untuk setiap data sampel akan memenuhi satu dari dua pernyataan berikut ini:

$$(2)$$

Persamaan 2 dapat ditulis dalam bentuk:

$$(3)$$

Pada klasifikasi biner linier, yang akan dicari adalah pasangan  $(w, b)$ , yang dapat membentuk suatu *hyperplane* optimal. Suatu *hyperplane* dikatakan optimal jika jarak dari  $a_i$  ke  $w \cdot x + b$  sama dengan jarak dari  $b_i$  ke  $w \cdot x + b$ . Karena,

$$(4)$$

maka masalah mencari  $(w, b)$ , sama artinya dengan masalah meminimumkan  $\max_i |w \cdot x_i + b - y_i|$ .

Berdasarkan pembahasan di atas, maka model matematis dari masalah klasifikasi biner dapat dinyatakan dalam bentuk:

$$(5)$$

Dengan menggunakan pengali *Lagrange*, model matematis di atas dapat dinyatakan sebagai :

$$(6)$$

Solusi dari persamaan 6 adalah

$$(7)$$

Dengan mensubstitusikan persamaan 7 ke persamaan 6, akan didapatkan model *primal lagrange* untuk klasifikasi biner:

$$(8)$$

Sedangkan model *Dual Lagrange* dari masalah klasifikasi biner adalah:

(9)

Solusi dari masalah dual ini adalah:

(10)

Dengan diperolehnya nilai  $\alpha$  dan  $\beta$  berarti telah ditemukan suatu *hyperplane* optimal, yang dapat memisahkan himpunan data sampel menjadi dua kelas. Dengan adanya *hyperplane* optimal ini, maka untuk menempatkan suatu data sampel ke suatu kelas, digunakan fungsi keputusan:

(11)

Persamaan-persamaan di atas dapat digunakan hanya untuk data *separable*, yaitu data dapat diklasifikasikan dengan tepat ke dalam kelas  $C_1$  atau kelas  $C_2$ , dengan menggunakan suatu *hyperplane*. Untuk data *nonseparable*, dimana *hyperplane* tidak dapat memisahkan data dengan tepat, terjadi *misclassification* untuk beberapa data sampel. Untuk mengatasi hal ini, formulasi yang telah dibahas di atas, perlu diubah. Misalkan  $d_i$  menunjukkan jarak dari data sampel ke *hyperplane*, persamaan 2 dirubah menjadi:

(12)

Karena faktor *misclassification* harus diikut sertakan dalam perhitungan, maka masalah klasifikasi biner untuk data *nonseparable*, menjadi masalah meminimumkan  $\sum d_i$  dan meminimumkan total kesalahan,  $\sum d_i$ , akibat *misclassification*.

(13)

dimana  $\lambda$  adalah parameter yang digunakan untuk mengendalikan hubungan antara *slack variable* dengan  $d_i$ . Berdasarkan persamaan 12 dan 13, maka model *Lagrange* untuk klasifikasi biner *nonseparable* menjadi

(14)

Sedangkan model *Dual Lagrange* dari masalah klasifikasi biner *nonseparable* adalah:

(15)

Solusi dari model matematis persamaan 15 ini adalah

dan

Dengan membandingkan antara kasus *separable* dan *nonseparable*, perbedaan antara keduanya hanya terletak pada adanya penambahan kendala pada masalah *nonseparable*.

Pada pembahasan di atas, *hyperplane* yang digunakan merupakan suatu bidang datar (linier). Untuk data-data yang hanya dapat dipisahkan dengan menggunakan permukaan *non-linear*, persamaan-persamaan di atas tidak dapat langsung digunakan. Langkah pertama untuk mengklasifikasikan input data *non-linear* tersebut adalah dengan mentransformasikan input data ke suatu ruang yang dinamakan ruang *feature*.

Misalkan suatu pemetaan *non-linear* dari ruang input ke ruang *feature*, atau , dimana dimensi dari lebih besar dari dimensi dari input . Dengan menggunakan fungsi , semua data sampel ditransformasikan ke ruang *feature*, dengan perkataan lain, . Setelah semua data sampel ditransformasikan, maka proses klasifikasi tidak lagi dilakukan di ruang input, melainkan dilakukan di ruang *feature*. Di ruang *feature*, proses klasifikasi dilakukan terhadap semua vektor , dengan menggunakan cara-cara yang telah dibahas di atas. Di ruang *feature* semua vektor dapat diklasifikasikan menjadi dua kelas, dimana kedua kelas ini dipisahkan oleh suatu *hyperplane*. Kesulitan yang akan muncul dalam klasifikasi di ruang *feature* adalah, menyelesaikan model matematis klasifikasi yang mengandung suku-suku dalam bentuk . Kesulitan ini timbul karena tidak diketahuinya fungsi dan cara memilih fungsi yang tepat. Kesulitan berikutnya adalah jika fungsi diketahui maka dimensi dari vektor lebih besar dari dimensi dari vektor . Dari sudut pandang *memory* yang digunakan, hal ini berarti perhitungan di ruang *feature* memerlukan *memory* yang lebih besar.

Untuk mengatasi kesulitan tersebut maka didefinisikan fungsi yang dinamakan juga fungsi *Kernel*. Pada model matematis klasifikasi di ruang *feature*, semua suku-suku dalam bentuk diganti dengan bentuk . Dengan menggunakan fungsi *Kernel* ini, maka masalah perhitungan di ruang *feature* dapat dihindari. Hal ini berarti, pencarian *hyperplane* optimal di ruang *feature* tidak akan meningkatkan biaya komputasi secara signifikan.

Dengan menggunakan fungsi *Kernel* maka masalah klasifikasi dapat dinyatakan sebagai berikut:

(16)

Persamaan 11 di ruang *feature* dapat ditulis dalam bentuk,

$$(17)$$

Untuk menempatkan data sampel ke suatu kelas, digunakan fungsi keputusan:

$$(18)$$

Pada percobaan klasifikasi aroma, fungsi *Kernel* yang digunakan adalah:

*Kernel* RBF :

*Kernel* Polinomial berderajat  $d$ :

*Kernel* Linier :

Sampai disini telah lengkap dibahas penggunaan metode *SVM* untuk mengklasifikasikan data menjadi dua kelas. Untuk menyelesaikan masalah klasifikasi multikelas, digunakan metode *One-vs-One* dan metode *One-vs-Rest*. Prinsip kerja dari kedua metode akan dibahas di bawah ini.

Misalkan data sampel terdiri atas buah kelas, . Pada metode *One-vs-One*, untuk setiap pasang kelas yang berbeda , dilakukan klasifikasi biner. Pada setiap proses klasifikasi digunakan fungsi keputusan:

$$(19) \text{ dimana } , \text{ dan } .$$

Karena banyaknya kelas ada buah, maka banyaknya proses klasifikasi biner yang harus dilakukan adalah sebanyak kali. Setelah seluruh proses selesai dikerjakan, maka suatu data sampel akan ditempatkan di kelas , jika ada sedemikian sehingga memaksimumkan :

$$(20)$$

dimana

Pada metode *One-vs-Rest* dilakukan dengan cara sebagai berikut. Untuk himpunan data sampel yang terdiri atas buah kelas, , dilakukan klasifikasi biner antara kelas dengan (kelas sisanya). Proses klasifikasi biner ini dilakukan sebanyak kali, sesuai dengan banyaknya kelas yang ada. Pada setiap proses didefinisikan fungsi:

(21)

dimana , dan .

Suatu data sampel akan ditempatkan di kelas , jika ada sedemikian sehingga memaksimumkan:

(22)

### 3. Hasil Eksperimen

Untuk mengetahui kinerja kedua metode di atas, dilakukan pengujian dengan data aroma yang dimiliki oleh Laboratorium Komputasi Intelegensia Universitas Indonesia. Data aroma yang digunakan terdiri atas 3 jenis aroma A, B dan C. Setiap jenis aroma dicampurkan dengan alkohol berkonsentrasi : 0%, 15%, 25%, 30%, 45% dan 75%. Sehingga total aroma yang akan diklasifikasikan sebanyak 18 kelas. Untuk masing-masing kelas tersedia 200 data. Banyaknya data training yang digunakan sebanyak 10%, 15%, 20%, 25%, 30%, 35%, 40% dan 50% dari data yang tersedia. Data yang tersisa digunakan sebagai data *testing*. Pengujian dilakukan dalam 3 tahap: tahap pertama, dilakukan pengujian pada semua data aroma ABC, tahap kedua dilakukan pengujian pada masing-masing data aroma A, B dan C dan tahap ketiga dilakukan pengujian pada setiap pasang aroma yang berbeda yaitu AB, AC dan BC. Pada setiap tahap pengujian, kinerja dari metode *One-vs-One* dan metode *One-vs-Rest* diukur berdasarkan kemampuan untuk mengklasifikasikan data aroma pada jenis aroma dan kelas yang tepat. Fungsi *Kernel* yang digunakan dalam percobaan adalah *Kernel* Linier, *Kernel* RBF dengan parameter *sigma* 2 dan *Kernel* Polinomial berderajat 4. Sebagai metode pembandingan digunakan metode *k-Nearest Neighborhood* (KNN). Hasil pengujian selengkapnya pada masing-masing tahap dapat dilihat pada Tabel 1, Tabel 2 dan Tabel 3.

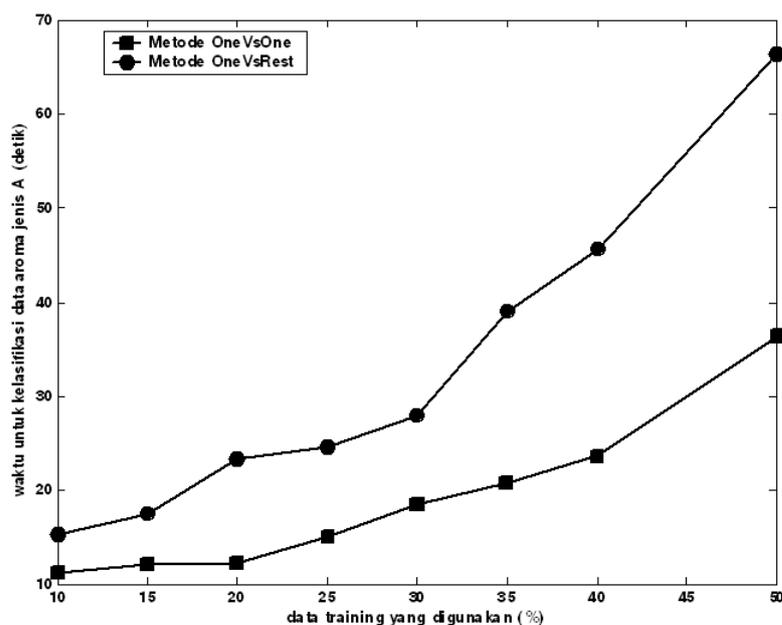
Tabel 1. Persentase keberhasilan klasifikasi data aroma pada pengujian tahap pertama untuk semua data aroma

DataAroma	Metode	Kernel	Persentase Keberhasilan Klasifikasi Data Aroma								Rata-rata
			Dengan Menggunakan Data <i>Training</i> Perkelas Sebanyak:								
			10%	15%	20%	25%	30%	35%	40%	50%	
ABC (18 kelas)	<i>One-vs-One</i>	Linear	91,67	93,70	97,22	99,33	99,81	99,52	100,00	99,89	97,64
		Polinomial	92,78	93,70	97,22	99,56	99,63	99,52	100,00	100,00	97,80
		RBF	90,56	92,96	97,50	99,33	99,81	99,52	100,00	99,89	97,45
	<i>One-vs-Rest</i>	Linear	61,67	77,04	76,11	82,44	75,19	79,37	81,81	81,67	76,91
		Polinomial	79,44	90,00	88,89	92,67	95,56	97,78	96,67	98,56	92,44
		RBF	77,78	87,41	88,89	91,11	93,15	96,83	96,53	98,22	91,24
	KNN		73,89	77,41	81,67	89,78	88,33	88,73	87,36	91,22	84,80

Keterangan Tabel 1: Nilai 99,33 % pada kolom data training 25%, baris pertama, menunjukkan persentase keberhasilan metode *One-vs-One*, dengan menggunakan *Kernel* Polinomial berderajat 4, untuk mengklasifikasikan data aroma ABC pada kelas yang sesuai.

Tabel 2. Persentase keberhasilan klasifikasi data aroma pada pengujian tahap kedua untuk satu jenis aroma

DataAroma	Metode	Kernel	Persentase Keberhasilan Klasifikasi Data Aroma								Rata-rata	
			Dengan Menggunakan Data <i>Training</i> Perkelas Sebanyak :									
			10%	15%	20%	25%	30%	35%	40%	50%		
A (6 kelas)	<i>One-vs-One</i>	Linear	95,00	100,00	100,00	96,67	100,00	96,67	100,00	100,00	98,54	
		Polinomial	96,67	100,00	100,00	98,10	100,00	96,67	99,58	100,00	98,99	
		RBF	95,00	100,00	100,00	96,67	100,00	96,67	100,00	100,00	98,54	
	<i>One-vs-Rest</i>	Linear	90,00	83,33	99,17	96,67	90,56	100,00	97,08	100,00	94,60	
		Polinomial	90,00	83,33	96,67	97,33	93,89	97,62	98,75	100,00	94,70	
		RBF	90,00	83,33	96,67	98,00	93,33	98,10	98,33	100,00	94,72	
	KNN		68,33	82,22	83,33	84,67	85,00	80,48	92,92	90,00	83,37	
	B (6 kelas)	<i>One-vs-One</i>	Linear	96,67	100,00	100,00	100,00	100,00	100,00	100,00	100,00	99,58
			Polinomial	96,67	98,89	100,00	100,00	100,00	100,00	100,00	100,00	99,44
RBF			96,67	100,00	100,00	100,00	100,00	100,00	100,00	100,00	99,58	
<i>One-vs-Rest</i>		Linear	81,67	93,33	95,00	95,33	96,67	96,67	95,00	97,67	93,92	
		Polinomial	91,67	94,44	95,83	100,00	100,00	100,00	100,00	100,00	97,74	
		RBF	83,33	95,56	94,17	98,00	98,33	98,10	100,00	100,00	95,94	
KNN			85,00	85,56	91,67	92,67	96,67	94,76	98,33	98,00	92,83	
C (6 kelas)		<i>One-vs-One</i>	Linear	100,00	100,00	100,00	100,00	100,00	99,52	100,00	100,00	99,94
			Polinomial	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
	RBF		100,00	100,00	100,00	100,00	100,00	99,52	100,00	100,00	99,94	
	<i>One-vs-Rest</i>	Linear	96,67	100,00	100,00	98,67	100,00	100,00	100,00	100,00	99,42	
		Polinomial	96,67	100,00	98,33	96,67	100,00	100,00	100,00	100,00	98,96	
		RBF	96,67	100,00	100,00	98,67	100,00	100,00	100,00	100,00	99,42	
	KNN		78,33	83,33	87,50	86,00	90,56	83,33	92,92	92,33	86,79	

Gambar 1. Perbandingan waktu klasifikasi antara metode *One-vs-One* dengan metode *One-vs-Rest*, untuk mengklasifikasikan data aroma jenis A.



Tabel 3. Persentase keberhasilan klasifikasi data aroma pada pengujian tahap ketiga untuk setiap pasang aroma

Data Aroma	Metode	Kernel	Persentase Keberhasilan Klasifikasi Aroma								Rata-rata	
			Dengan Menggunakan Data Training Sebanyak :									
			10%	15%	20%	25%	30%	35%	40%	50%		
AB ( 12 kelas )	One-vs-One	Liner	89,17	93,33	100,00	99,00	99,17	99,52	100,00	99,33	97,44	
		Polinomial	90,00	93,89	100,00	99,00	99,44	99,52	100,00	99,33	97,65	
		RBF	90,00	93,33	100,00	99,00	99,17	99,52	100,00	99,33	97,54	
	One-vs-Rest	Liner	80,83	76,67	91,67	86,67	91,67	91,19	88,13	93,17	87,50	
		Polinomial	88,33	87,22	94,58	96,00	96,11	98,33	98,13	97,83	94,57	
		RBF	85,00	83,33	93,75	96,00	95,83	97,86	98,75	97,50	93,50	
	KNN			80,00	78,89	84,17	86,67	91,39	91,43	93,13	94,83	87,56
	AC ( 12 kelas )	One-vs-One	Liner	89,17	93,89	99,58	99,00	99,72	99,52	100,00	100,00	97,61
			Polinomial	88,33	93,33	100,00	98,67	100,00	99,52	100,00	100,00	97,48
RBF			90,00	95,00	99,58	99,00	99,72	99,52	100,00	100,00	97,85	
One-vs-Rest		Liner	78,33	84,44	89,58	74,67	85,83	81,43	92,50	93,00	84,97	
		Polinomial	85,00	86,67	95,00	96,00	98,06	96,90	98,96	98,33	94,36	
		RBF	85,83	85,56	96,25	95,67	96,11	96,67	98,33	98,00	94,05	
KNN			76,67	73,89	80,83	83,67	87,22	84,76	90,42	93,00	83,81	
BC ( 12 kelas )		One-vs-One	Liner	99,17	97,22	98,75	99,67	100,00	100,00	100,00	100,00	99,35
			Polinomial	99,17	97,78	99,17	99,67	100,00	100,00	100,00	100,00	99,47
	RBF		96,67	97,22	98,75	99,67	100,00	99,76	100,00	100,00	99,01	
	One-vs-Rest	Liner	83,33	88,33	90,83	89,33	78,33	85,71	77,92	92,83	85,83	
		Polinomial	93,33	93,33	94,17	96,00	96,39	98,33	98,96	99,00	96,19	
		RBF	93,33	93,33	92,50	96,33	96,67	97,86	98,96	99,00	96,00	
	KNN			82,50	75,56	86,25	88,33	90,00	90,95	93,96	96,17	87,96

Percobaan berikutnya adalah menghitung waktu yang dibutuhkan oleh metode *One-vs-One* dan metode *One-vs-Rest* untuk mengklasifikasikan data aroma. Dalam percobaan ini hanya digunakan data aroma jenis A, yang terdiri atas enam kelas, dan menggunakan fungsi *Kernel RBF* dengan parameter  $\sigma = 4$ . Hasilnya dapat dilihat pada Gambar 1.

#### 4. Kesimpulan

Kedua metode yang berbasis *SVM* ini: metode *One-vs-One* dan metode *One-vs-Rest* memiliki kinerja yang lebih unggul dibandingkan dengan KNN. Dari hasil percobaan, dengan menggunakan data *training* lebih dari 15 buah perkelas, metode *One-vs-One* telah mampu 100% untuk mengklasifikasikan data aroma berdasarkan kelas yang tepat. Semakin banyak data *training* yang digunakan, metode *One-vs-One* akan lebih cepat mengklasifikasikan data dibandingkan dengan metode *One-vs-Rest*. Jika ditinjau berdasarkan waktu yang digunakan untuk melakukan klasifikasi, metode *One-vs-One* lebih cepat dibandingkan dengan metode *One-vs-Rest*. Untuk data *training* lebih dari 20 buah untuk setiap kelas, metode *One-vs-Rest* membutuhkan waktu perhitungan yang cukup lama. Dari sudut pandang *Kernel* yang digunakan, penggunaan fungsi *Kernel Polinomial* akan memberikan hasil yang lebih jika dibandingkan dengan menggunakan *Kernel RBF* maupun *Kernel Linear*.

#### Daftar Acuan

- [1] V.N. Vapnik, *The Nature of Statistical Learning*, Springer-Verlag, Berlin, 1999.
- [2] B. Kusumoputro, Z. Rustam, B. Widjaja, *Modifikasi Kernel PCA pada Klasifikasi Aroma Multikelas*, Lab. Komputasi Intelegensia, Universitas Indonesia, Jakarta, 2003.
- [3] B. Kusumoputro, Harry, W. Jatmiko, *ISA Transactions* 41 (2002) 395.
- [4] B. Kusumoputro, Herry, *SNKK III*, Jakarta, 2002.
- [5] W. Jatmiko, B. Kusumoputro, *Jurnal Ilmu Komputasi dan Teknologi Informasi* 1 (2001) 15.
- [6] W. Jatmiko, B. Kusumoputro, 2001, *Jurnal Ilmu Komputasi dan Teknologi Informasi* 1 (2001) 21.

