

# Penerapan Metode Distance Transform Pada Linear Discriminant Analysis Untuk Kemunculan Kulit Pada Deteksi Kulit

Muryan Awaludin

*Pascasarjana Teknik Informatika, STMIK Eresha  
Email: muryan\_awaludin@yahoo.co.id*

Romi Satria Wahono

*Fakultas Ilmu Komputer, Universitas Dian Nuswantoro  
Email: romi@brainmatics.com*

**Abstract:** Deteksi kulit memainkan peranan penting dalam berbagai aplikasi pengolahan citra, mulai dari deteksi wajah, pelacakan wajah, penyaringan konten pornografi, berdasarkan sistem pencarian citra dan berbagai domain interaksi manusia dan komputer. Pendekatan informasi warna dapat mendeteksi warna kulit dengan baik menggunakan *skin probability map* (SPM) dengan aturan bayes. Namun SPM memiliki permasalahan dalam mendeteksi tekstur kulit. *Linear discriminant analysis* (LDA) merupakan algoritma ekstraksi fitur, dalam deteksi kulit digunakan untuk mengekstrak fitur tekstur kulit yang dapat menangani masalah SPM. Namun LDA memiliki permasalahan apabila digunakan untuk mengekstrak fitur tekstur kulit pada kernel yang berbeda. *Distance transform* (DT) merupakan algoritma untuk menghitung jarak citra biner pada setiap piksel gambar dan fitur poin terdekatnya, DT merupakan algoritma yang dapat mengatasi masalah pada LDA. Kombinasi algoritma SPM, LDA dan DT diusulkan untuk memperbaiki performa dari kemunculan kulit pada deteksi kulit. Dataset pada metode yang diusulkan menggunakan IBTD dataset. Hasil dari metode yang diusulkan bahwa metode yang diusulkan menunjukkan peningkatan akurasi deteksi kesalahan yang signifikan pada SPM dan LDA.

**Keywords:** deteksi kulit, skin probability map, linear discriminant analysis, distance transform

## 1 PENDAHULUAN

Deteksi kulit memainkan peranan penting dalam berbagai aplikasi pengolahan citra mulai dari deteksi wajah, pelacakan wajah, penyaringan pornografi, berdasarkan sistem pencarian citra dan berbagai domain interaksi manusia dan komputer (Kakumanu, Makrogiannis, & Bourbakis, 2007) (Lee, Kuo, Chung, & Chen, 2007) (Jie, Xufeng, Yitan, & Zhonglong, 2008). Deteksi kulit pada umumnya mentransformasikan piksel kulit ke ruang warna yang tepat, kemudian mengelompokkan piksel kulit tersebut apakah termasuk kulit atau *non-kulit* (Tan, Chan, Yogarajah, & Condell, 2012).

Deteksi kulit manusia pada ruang warna adalah kunci utama dalam tahap proses aplikasi pengolahan citra (Guerrero-Curieses et al., 2009). Sebagian besar penelitian pada deteksi kulit menggunakan model berdasarkan warna kulit diusulkan untuk beragam warna kulit (Amjad, Griffiths, & Patwary, 2012). Beberapa ruang warna seperti RGB, normalisasi RGB, HSV, YcbCr merupakan ruang warna untuk menggambarkan warna kulit (Cheng, Feng, Weng, & Lee, 2012).

Secara umum, deteksi warna kulit mengandalkan pemodelan statistik kulit berdasarkan aturan dari pendekatan deteksi kulit (Kawulok, Kawulok, & Smolka, 2011), melalui

sebuah survey yang membandingkan berbagai pendekatan deteksi kulit berdasarkan warna yang disajikan (Kakumanu et al., 2007).

SPM adalah metode deteksi kulit yang banyak digunakan, tetapi SPM mempunyai kelemahan sulit mendeteksi warna terutama gambar yang menyerupai tekstur kulit manusia (Jiang, Yao, & Jiang, 2007). Algoritma *linear discriminant analysis* telah sukses digunakan banyak aplikasi seperti pengenalan karakter tulisan tangan, pengenalan wajah, pengambilan gambar dan sebagainya, namun untuk masalah *multi-class* terbukti tidak optimal (Yao, Lu, Li, Xu, & Han, 2014). LDA baik digunakan untuk menentukan sebuah kelas vector yang diperkirakan pada ruang fitur, namun LDA mempunyai masalah jika digunakan untuk mengukur sampel yang lebih besar (Lu, Zou, & Wang, 2012).

Algoritma distance transform (DT) merupakan algoritma yang bagus untuk berbagai aplikasi seperti pengolahan citra, computer vision, pengenalan pola, analisis bentuk dan geometri komputasi (Arcelli, di Baja, & Serino, 2011), Distance transform (DT) dari citra biner akan menghitung jarak diantara setiap piksel citra dan fitur titik terdekatnya (J. Wang & Yagi, 2013).

Pada penelitian ini, kami mengembangkan skema penggabungan dari analisa spasial dengan keunggulan pemodelan kulit adaptif DT pada pencahayaan dan probabilitas kulit untuk mengatasi batas daerah kulit dan *non-kulit* yang kabur dengan ukuran kernel yang berbeda. Dan untuk mencapai ketepatan batas wilayah dari kulit dan *non-kulit* serta tepatnya informasi warna piksel menggunakan algoritma *linear discriminant analysis* (LDA) dan *skin probability map* (SPM). Dari integrasi metode diatas diharapkan dapat digunakan pada deteksi kulit dan mengurangi *false positive* yang menghasilkan tingkat akurasi yang tinggi untuk meminimalkan jarak antara kulit dan *non-kulit* dari ukuran kernel yang berbeda.

Pada penelitian ini akan disusun sebagai berikut. Pada bagian 2 akan dijelaskan tentang penelitian terkait. Bagian 3 metode yang diusulkan. Membandingkan hasil eksperimen metode yang diusulkan dengan metode lain dibahas pada bagian 4. Terakhir, penelitian yang kami lakukan ini diringkas dalam bagian terakhir.

## 2 PENELITIAN TERKAIT

SPM digunakan untuk menyaring warna dengan rendahnya penerimaan nilai ambang batas piksel warna yang diterapkan dalam ruang warna RGB. Kemudian, fitur tekstur diekstrak menggunakan *Gabor wavelets* dari sebuah citra warna masukan dikonversi ke *grayscale* (Jiang et al., 2007).

Respon yang diperoleh tergantung pada nilai ambang batas piksel warna, yang menghasilkan nilai piksel biner.

Tujuan menerapkan *Gabor wavelets* adalah untuk mengurangi *false positive rate* (FPR) berdasarkan penyaringan daerah kulit dan *non-kulit* yaitu dengan nilai piksel yang besar pada fitur tekstur (Yahya, Tan, & Hu, 2013). Tekstur yang tidak mirip kulit, tidak diklasifikasikan sebagai kulit pada penyaringan piksel warna kulit. Akhirnya, daerah kulit yang tumbuh menggunakan segmentasi *watershed* dengan penanda wilayah didefinisikan dengan baik untuk memanfaatkan informasi warna kulit.

Hasil yang ditunjukkan bahwa metode tersebut dapat mengurangi *false positive rate* (dari 20,1% menjadi 4,2%) dan meningkatkan *true positive rate* (dari 92,7% menjadi 94,8%) yang dilakukan dengan penyaringan warna untuk dataset yang berisi 600 gambar (Bouzerdoum, 2003). Namun, dari keterangan diatas tidak memberikan nilai ambang batas piksel warna yang berbeda untuk diterapkan pada setiap gambar.

Algoritma *Artificial Neural Network* (ANN) pada deteksi kulit digunakan untuk mengestimasi kepadatan *non-parametrik* kelas kulit dan *non-kulit* (Taqa & Jalab, 2010). Umumnya, analisa tekstur terhadap citra masukan membantu mengurangi jumlah kesalahan klasifikasi piksel pada deteksi piksel warna kulit. Namun, daerah kekasaran kulit dan *non-kulit* dapat bervariasi antara gambar, sehingga penerapan dari algoritma segmentasi berdasarkan tekstur sulit untuk generalisasi dataset yang nyata.

Analisa SPM untuk segmentasi kulit dikendalikan oleh difusi (Ruiz-del-Solar & Verschae, 2004). Kelemahan dari metode ini adalah performa dalam kasus batas daerah kulit dan *non-kulit* yang kabur, karena proses difusi tidak berhenti jika transisi antara piksel kulit dan *non-kulit* halus.

LDA pada deteksi kulit dimanfaatkan untuk informasi tekstur kulit pada setiap citra masukan yang terdeteksi diekstrak pada fitur tekstur kulit yang paling diskriminatif (Kawulok et al., 2011). Setelah itu, seluruh gambar diproyeksikan keruang *discriminative textural features* (DTF). Pada percobaan penelitian tersebut menegaskan bahwa pentingnya menggunakan informasi tekstur dan menunjukkan bahwa metode tersebut secara signifikan meningkatkan hasil pewarnaan yang diperoleh, meskipun domain DFT bagus untuk propagasi warna, namun ketepatannya terbatas pada batas daerah kulit dan *non-kulit* karena ukuran yang berbeda.

Pada penelitian yang dilakukan (Michal Kawulok, Jolanta Kawuloky, Jakub Nalepa, 2013) memperkenalkan pengembangan skema penggabungan dari analisa spasial dengan keunggulan pemodelan kulit adaptif menggunakan *distance transform* (DT) dan memecahkan masalah LDA yaitu terbatas pada batas wilayah karena ukuran kernel besar.

Dari penelitian yang berkaitan diatas masalah akurasi pada warna dan fitur tekstur sangat penting untuk meningkatkan sistem deteksi kulit dimana disebabkan oleh pengaruh pencahayaan, *background*, dan *real life* dataset. Oleh karena itu pada penelitian ini, kami menggabungkan dari beberapa algoritma diatas, sistem kemunculan kulit akan diusulkan dimana didalamnya terdapat kombinasi tiga algoritma yaitu SPM yang digunakan untuk informasi warna piksel kulit. LDA digunakan untuk informasi fitur tekstur kulit dan DT yang digunakan untuk mengatasi masalah batas wilayah kulit dengan ukuran kernel yang lebih besar pada deteksi kulit.

### 3 METODE YANG DIUSULKAN

Kami mengusulkan sebuah metode yang disebut SPMLDA+DT, singkatnya untuk informasi piksel warna kulit

dan informasi fitur tekstur kulit dengan SPM dan LDA kemudian untuk digunakan untuk kernel yang berbeda pada deteksi kulit menggunakan DT, untuk mencapai kinerja yang lebih baik pada deteksi kulit. Gambar 1 merupakan aktifitas diagram metode yang disusun SPMLDA+DT.

SPM diperoleh menggunakan pemodelan kulit bayes. Menurut (Clair L. Alston, 2013) inti dari *bayes rule* (aturan bayes) adalah bagaimana caranya untuk mendapatkan nilai probabilitas hipotesis  $C_s$  benar jika diberikan evidence  $v$ , untuk mengetahui  $P(C_s|v)$ . Bahwa nilai probabilitas yang diberikan piksel termasuk kelas kulit dihitung dengan menggunakan aturan bayes:

$$P(C_s|v) = \frac{P(v|C_s)P(C_s)}{P(v|C_s)P(C_s) + P(v|C_{ns})P(C_{ns})}$$

Dimana  $v$  adalah piksel warna, probabilitas apriori  $P(C_s)$  adalah probabilitas kulit dan  $P(C_{ns})$  adalah probabilitas *non-kulit* dapat diperkirakan berdasarkan jumlah piksel di kedua kelas, tetapi sangat sering diasumsikan bahwa warna kulit dan *non-kulit* adalah sama  $P(C_s) = P(C_{ns}) = 0.5$  (Kawulok, Kawulok, & Nalepa, 2013).

Tujuan menggunakan SPM yaitu untuk mendapatkan informasi warna piksel kulit menggunakan ruang warna YCbCr. Ruang YCbCr dipilih karena alasan berikut (Powar, 2011):

1. Gambar bitmap menggunakan ruang warna RGB sebagai warna gambar. Namun penelitian medis membuktikan bahwa mata manusia memiliki sensitivitas yang berbeda untuk warna dan kecerahan. Sehingga menggunakan transformasi RGB ke YCbCr.
2. Komponen pencahayaan (Y) dari YCbCr merupakan warna independen, sehingga dapat diadopsi untuk memecahkan masalah variasi pencahayaan dan mudah untuk digunakan.
3. Menurut (Hsu, Member, & Abdel-mottaleb, 2002) pengelompokan warna kulit lebih bagus menggunakan ruang warna YCbCr daripada ruang warna lain.
4. YCbCr memiliki adanya tumpang tindih paling sedikit antara kulit dan data *non-kulit* di bawah berbagai kondisi pencahayaan. YCbCr secara luas digunakan dalam standar kompresi video (misalnya, MPEG dan JPEG).
5. YCbCr adalah salah satu dari dua ruang warna utama yang digunakan untuk mewakili komponen video digital.
6. Perbedaan antara YCbCr dan RGB adalah bahwa YCbCr merupakan warna kecerahan dan dua sinyal warna yang berbeda, sedangkan RGB merupakan warna seperti merah, hijau dan biru.

LDA merupakan teknik yang efektif dan banyak digunakan untuk pengurangan dimensi dan ekstraksi fitur tekstur (Kim, Stenger, Kittler, & Cipolla, 2010), selain itu juga untuk menemukan sedikitnya subruang baru yang memberikan pemisahan terbaik antara kelas yang berbeda dalam input data (Fekry, Elsadek, Ali, & Ziedan, 2011).

Untuk menemukan subruang didefinisikan oleh arah yang paling diskriminatif dalam pelatihan himpunan vektor M-dimensi diklasifikasikan ke dalam kelas K. Analisis ini dilakukan, pertama dengan menghitung dua matriks kovarians: intra-class scatter matrix:

$$S_w = \sum_{i=1}^K \sum_{u_k \in K_i} (u_k - \mu_i)(u_k - \mu_i)^T$$

Dan *inter-class scatter matrix*:

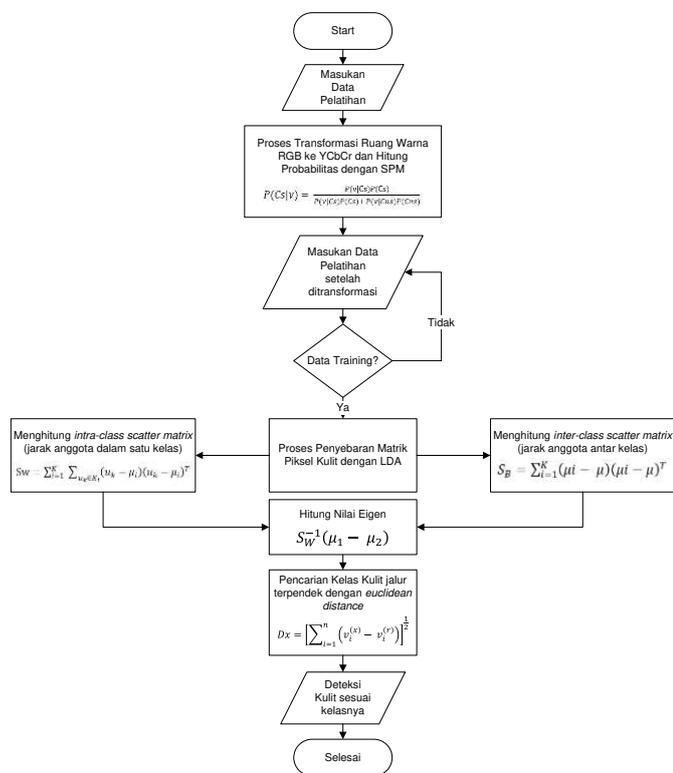
$$S_B = \sum_{i=1}^K (\mu_i - \mu)(\mu_i - \mu)^T$$

Dimana  $K$  adalah jumlah kelas,  $\mu$  adalah vektor rata-rata data pelatihan dan  $\mu_i$  adalah vektor rata-rata kelas  $i$  (disebut  $K_i$ ),  $i$  adalah kelas,  $u_k$  adalah gambar ke- $k$  dan  $T$  adalah vektor dimensi.

Tujuan menggunakan DT untuk penghitung jarak citra biner antara setiap piksel gambar dan fitur poin terdekatnya (J. Wang & Yagi, 2013). Peta kemungkinan kemunculan kulit diperoleh berdasarkan *euclidean distance* ( $D$ ) (Lagerstrom & Buckley, 2012) atau jarak kesamaan vector kulit dan *non-kulit* dihitung dalam ruang kemunculan kulit pada setiap piksel  $x$  dari referensi piksel  $r$ , euclidean distance dapat didefinisikan sebagai:

$$Dx = \left[ \sum_{i=1}^n (v_i^{(x)} - v_i^{(r)})^2 \right]^{\frac{1}{2}}$$

Dimana  $v_i^{(x)}$  adalah dimensi  $i$  dari vektor jarak transform kemunculan kulit diperoleh untuk pixel  $x$ ,  $i$  adalah dimensi,  $n$  adalah jumlah dimensi,  $x$  adalah bobot vektor kelas pertama,  $r$  adalah bobot vektor kelas kedua. Referensi piksel ditentukan sebagai piksel dari nilai probabilitas maksimal dalam SPM mengalami pengurangan dengan menggunakan besarnya kernel. Semakin kecil skor  $D(x,r)$  maka semakin mirip kedua vector fitur yang dicocokkan. Sebaliknya semakin besar skor  $D(x,r)$ , maka akan semakin berbeda pada kedua vector fitur.



Gambar 1. Diagram Aktifitas dari Metode SPMLDA+DT

4 HASIL EKSPERIMEN

Percobaan dilakukan dengan menggunakan platform komputer berbasis Intel Core i3 2,3 GHz CPU, 4 GB RAM, dan Microsoft Windows 7 Professional 64-bit dengan sistem

operasi SP1. Software yang digunakan untuk pengembangan pada penelitian kami adalah MATLAB R2009a.

Data set yang digunakan adalah dataset IBTD. Dataset ini dapat diperoleh melalui situs <http://lbmedia.ece.ucsb.edu/resources/dataset/ibt.zip>. Seperti pada Gambar 2, data yang berupa gambar ini memiliki ekstensi \*.JPEG.



Gambar 2. Contoh Dataset IBTD yang Digunakan dalam Penelitian

Salah satu metode untuk menentukan nilai atribut menggunakan informasi matrik, yaitu dengan menggunakan standar deviasi untuk menentukan keputusan yang obyektif (Y.-M. Wang & Luo, 2010). Standar deviasi dan rata-rata deviasi banyak diusulkan untuk menentukan bobot vektor yang optimal secara objektif dengan asumsi bobot atribut sudah diketahui (Xu & Da, 2010). Oleh karena itu, pada penelitian ini untuk mengukur tingkat kesalahan deteksi kulit salah satunya menggunakan standar deviasi untuk mengetahui keragaman suatu kelompok data kulit dan *non-kulit*.

Hasil eksperimen dilakukan dengan berbagai macam kondisi pencahayaan, latar belakang, perbedaan etnis dan perbedaan kernel dengan menggunakan dataset IBTD. Dalam pengujian SPM menggunakan semua dataset untuk mendapatkan nilai minimal (proyeksi kelas pertama) dan maksimal (proyeksi kelas kedua) agar mendapatkan nilai standar deviasi seperti pada Tabel 1.

Tabel 1. Hasil Eksperimen Model SPM

Training Data	Nilai Kemunculan Kulit dengan SPM					Std. Deviasi Kelas Kedua
	Proyeksi Kelas Pertama		Std. Deviasi Kelas Pertama	Proyeksi Kelas Kedua		
	Kelas Kulit	Kelas non-Kulit		Kelas Kulit	Kelas non-Kulit	
111	113.432	74.396	<b>27.603</b>	187.793	145.405	<b>29.972</b>
222	112.923	77.640	<b>24.949</b>	184.333	146.635	<b>26.657</b>
333	107.357	77.372	<b>21.203</b>	185.694	151.450	<b>24.214</b>
444	108.011	78.500	<b>20.868</b>	185.885	150.896	<b>24.741</b>
555	107.649	78.198	<b>20.825</b>	186.085	150.905	<b>24.876</b>

Hasil eksperimen pada Tabel 1 yang terdapat 555 data dari dataset IBTD, merupakan nilai rata-rata antara proyeksi kelas pertama dan kelas kedua mempunyai jarak antar rerata yaitu standar deviasi lebih besar kelas kedua dari kelas pertama.

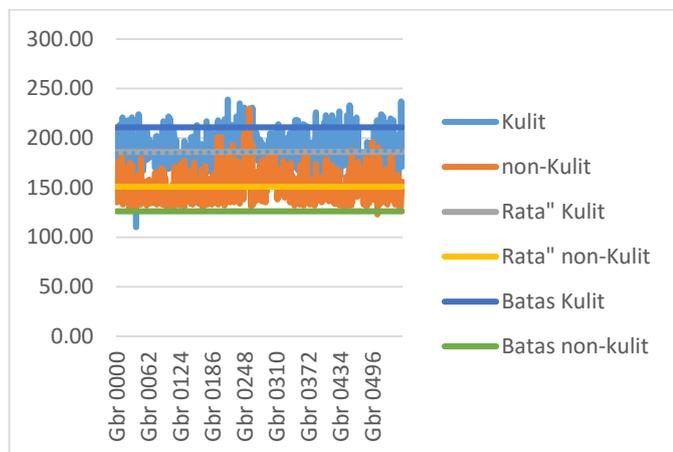
Pada Tabel 2 merupakan hasil deteksi *error* menggunakan metode SPM.

Tabel 2. Hasil Deteksi Error untuk Deteksi Kulit dengan SPM

Jumlah Dataset	DR	FNR	FPR
555	92,97%	7,03%	39%

Dari perhitungan seluruh dataset yang digunakan, nilai 92,97% merupakan bagian dari piksel kulit yang benar diklasifikasikan sebagai kulit dihitung dengan (*Recall*)  $\eta_{tp} = TP/(FN+TP)$ . Nilai 7,03% merupakan bagian pengelompokan piksel kulit sebagai background dihitung dengan  $\delta_{fn} = FN/(FN+TP)$  dan nilai 39% merupakan bagian pengelompokan piksel background sebagai kulit dihitung dengan  $\delta_{fp} = FP/(FP+TN)$ .

Pada Gambar 3 menunjukkan grafik standar deviasi penyebaran warna kulit dan *non*-kulit pada deteksi kulit dengan SPM.



Gambar 3. Standar Deviasi Penyebaran Warna Kulit dan *non*-Kulit dengan SPM

Hasil eksperimen terdapat 555 data dari database IBTD, merupakan nilai jarak piksel kulit dan non-kulit dari proyeksi kelas pertama dan kelas kedua hasil komparasi antara SPM dan DT. Nilai standar deviasi untuk menentukan bobot vektor yang optimal secara objektif dengan asumsi bobot atribut sudah diketahui (Xu & Da, 2010), seperti yang ditunjukkan pada Tabel 3.

Tabel 3. Hasil Eksperimen Model SPM+DT

Nilai Piksel Kemunculan Kulit dan <i>non</i> -Kulit dengan SPM+DT			
Training Data	Proyeksi Kemunculan Kulit		Std. Deviasi
	Kelas Kulit	Kelas <i>non</i> -Kulit	
111	46.10	70.96	17.58
222	43.25	69.26	18.39
333	43.04	74.02	21.91
444	42.98	72.61	20.95
555	40.74	72.88	22.73

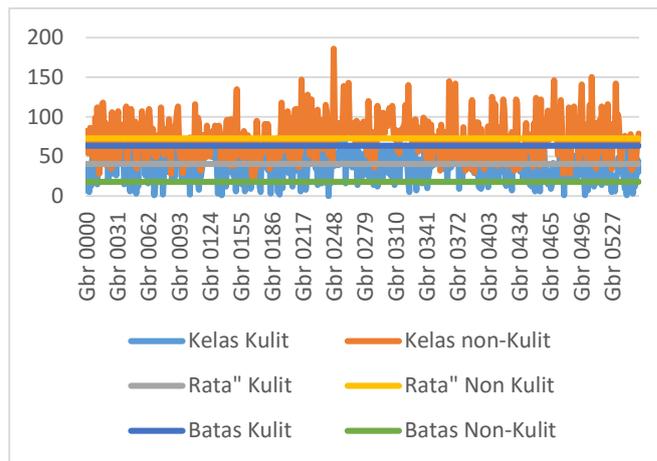
Hasil eksperimen pada Tabel 3 yang terdapat 555 data dari dataset IBTD, merupakan nilai jarak piksel kulit dan non-kulit dari proyeksi kelas pertama dan kelas kedua hasil komparasi antara SPM dan DT. Hasil deteksi error komparasi antara SPM+ DT seperti ditunjukkan pada Tabel 4.

Tabel 4. Tabel Hasil Deteksi Error Model SPM+DT

Jumlah Dataset	DR	FNR	FPR
555	94%	6,13%	34%

Dari perhitungan seluruh dataset yang digunakan, nilai 94% merupakan bagian dari piksel kulit yang benar diklasifikasikan sebagai kulit dihitung dengan (*Recall*)  $\eta_{tp} = TP/(FN+TP)$ . Nilai 6,13% merupakan bagian pengelompokan piksel kulit sebagai background dihitung dengan  $\delta_{fn} = FN/(FN+TP)$  dan nilai 34% merupakan bagian pengelompokan piksel background sebagai kulit dihitung dengan  $\delta_{fp} = FP/(FP+TN)$ .

Gambar 4 menunjukkan grafik standar deviasi penyebaran warna kulit dan *non*-kulit pada deteksi kulit dengan SPM+ DT.



Gambar 4. Standar Deviasi Penyebaran Warna Kulit dan *non*-Kulit dengan SPM+DT

Hasil eksperimen SPM+LDA pertama dilakukan dengan SPM untuk mencari nilai probabilitas dari kulit dan *non*-kulit menggunakan ruang warna Cb dan Cr (Powar, 2011) (Aibinu, Shafie, & Salami, 2012) (Sanchez-Cuevas, Aguilar-Ponce, & Tecpanecatl-Xihuitl, 2013) (Zaidan et al., 2014).

Kemudian dengan menggunakan metode LDA untuk matriks kovarian antar kelas (between-class covariance matrix) (Yao et al., 2014), sekaligus meminimumkan matriks kovarian dalam kelas (within-class covariance matrix), agar anggota di dalam kelas lebih terkumpul penyebarannya dan pada akhirnya dapat meningkatkan keberhasilan pengenalan.

Dalam pengujian SPM+LDA menggunakan semua dataset untuk mendapatkan nilai minimal (proyeksi kelas pertama) dan maksimal (proyeksi kelas kedua) agar mendapatkan nilai standar deviasi seperti pada Tabel 5.

Tabel 5. Hasil Eksperimen dengan SPM+LDA

Nilai Kemunculan Kulit dengan SPM+LDA						
Training Data	Proyeksi Kelas Pertama		Std. Deviasi	Proyeksi Kelas Kedua		Std. Deviasi
	Kelas Kulit	Kelas <i>non</i> -Kulit		Kelas Kulit	Kelas <i>non</i> -Kulit	
111	262.571	313.511	<b>36.020</b>	194.246	231.931	<b>26.647</b>
222	258.846	308.613	<b>35.190</b>	197.664	236.732	<b>27.626</b>
333	256.425	305.571	<b>34.752</b>	202.242	241.658	<b>27.871</b>
444	257.064	306.260	<b>34.787</b>	202.460	241.648	<b>27.710</b>
555	257.020	305.981	<b>34.621</b>	202.263	241.972	<b>28.078</b>

Hasil eksperimen pada Tabel yang terdapat 555 data dari dataset IBTD, merupakan nilai rata-rata antara proyeksi kelas

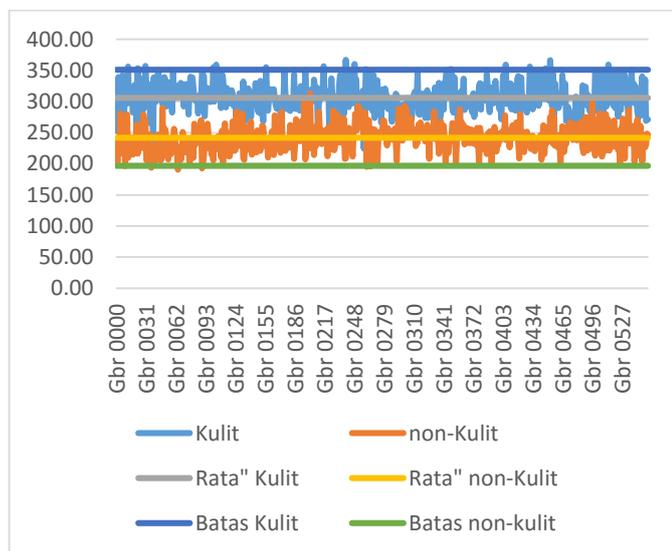
pertama dan kelas kedua mempunyai jarak antar rerata yaitu standar deviasi lebih besar kelas pertama dari kelas kedua. Pada Tabel 6. merupakan hasil deteksi error komparasi antara SPM dan LDA.

Tabel 6. Hasil Deteksi Error Model SPM+LDA

Jumlah Dataset	DR	FNR	FPR
555	96,76%	3,24%	18%

Dari perhitungan seluruh dataset yang digunakan, nilai 96,76% merupakan bagian dari piksel kulit yang benar diklasifikasikan sebagai kulit dihitung dengan (*Recall*)  $\eta_{tp} = TP/(FN+TP)$ . Nilai 3,24% merupakan bagian pengelompokan piksel kulit sebagai background dihitung dengan  $\delta_{fn} = FN/(FN+TP)$  dan nilai 18% merupakan bagian pengelompokan piksel background sebagai kulit dihitung dengan  $\delta_{fp} = FP/(FP+TN)$ .

Gambar 5. menunjukkan grafik standar deviasi penyebaran warna kulit dan non-kulit pada deteksi kulit dengan SPM dan LDA.



Gambar 5. Standar Deviasi Penyebaran Warna Kulit dan non-Kulit Model SPM+LDA

Hasil eksperimen terdapat 555 data dari database IBTD, merupakan nilai jarak piksel kulit dan non-kulit dari proyeksi kelas pertama dan kelas kedua hasil komparasi antara SPM dan LDA, yang diproyeksikan kemunculan nilai piksel kulit dan non-kulit kedalam DT. Seperti yang ditunjukkan pada Tabel 7.

Tabel 7. Hasil Eksperimen Model SPMLDA+DT

Nilai Piksel Kemunculan Kulit dan non-Kulit Model SPMLDA+DT			
Training Data	Proyeksi Kemunculan Kulit		Std. Deviasi
	Kelas Kulit	Kelas non-Kulit	
111	50.97	37.64	9.43
222	49.96	38.49	8.11
333	49.51	39	7.23
444	49.51	39.28	7.24
555	49.39	39.28	7.15

Dari hasil eksperimen dengan 555 data dari dataset IBTD, pada hasil yang ditunjukkan Tabel 7. Merupakan proyeksi kemunculan kulit model SPMLDA+DT. Pada Tabel 8. merupakan hasil deteksi error model SPMLDA+DT.

Tabel 8. Tabel Hasil Deteksi Error Model SPMLDA+DT

Jumlah Dataset	DT	FNR	FPR
555	97,12%	2,88%	16%

Dari perhitungan seluruh dataset yang digunakan, nilai 97,12% merupakan bagian dari piksel kulit yang benar diklasifikasikan sebagai kulit dihitung dengan (*Recall*)  $\eta_{tp} = TP/(FN+TP)$ . Nilai 2,88% merupakan bagian pengelompokan piksel kulit sebagai background dihitung dengan  $\delta_{fn} = FN/(FN+TP)$  dan nilai 16% merupakan bagian pengelompokan piksel background sebagai kulit dihitung dengan  $\delta_{fp} = FP/(FP+TN)$ .

Gambar 6. menunjukkan grafik standar deviasi penyebaran warna kulit dan non-kulit pada deteksi kulit model SPMLDA+DT.



Gambar 6. Standar Deviasi Penyebaran Warna Kulit Model SPMLDA+DT

Pada Tabel 9. menunjukkan perbandingan *false positive rate* (FPR) yaitu bagian pengelompokan piksel background sebagai kulit dan *false negative rate* (FNR) yaitu bagian pengelompokan piksel kulit sebagai background (Jones & Rehg, 2002) dengan menggunakan dataset IBTD.

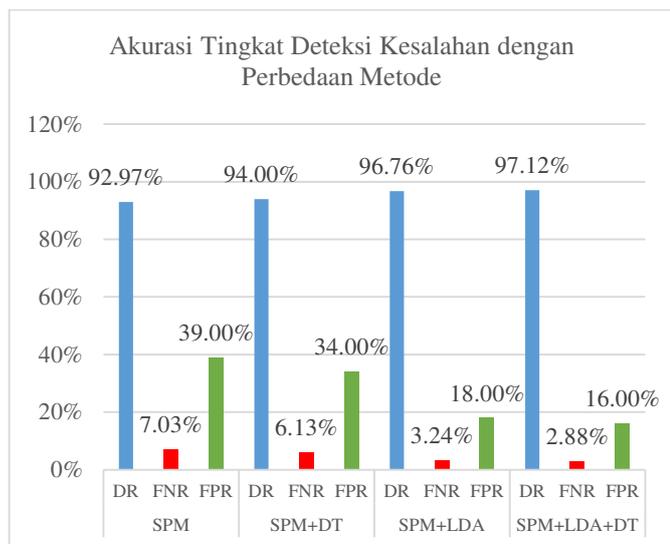
Tabel 9. Perbandingan FNR dan FPR Menggunakan Dataset IBTD

Metode	DR	FNR	FPR
SPM (Jiang et al., 2007)	92,97%	7,03%	39%
SPM+DT (Michal Kawulok, Jolanta Kawuloky, Jakub Nalepa, 2013)	94%	6,13%	34%
Metode yang diusulkan	97,12%	2,88%	16%

Hasil eksperimen dengan menerapkan metode *LDA pada SPM* didapatkan nilai FNR adalah 3,24% dan hasil ini menunjukkan bahwa metode *SPM+LDA* lebih baik daripada hanya menggunakan *SPM* yang memiliki nilai FNR sebesar 7,03% dan *SPM+DT* yang menghasilkan nilai FNR sebesar 6,13%.

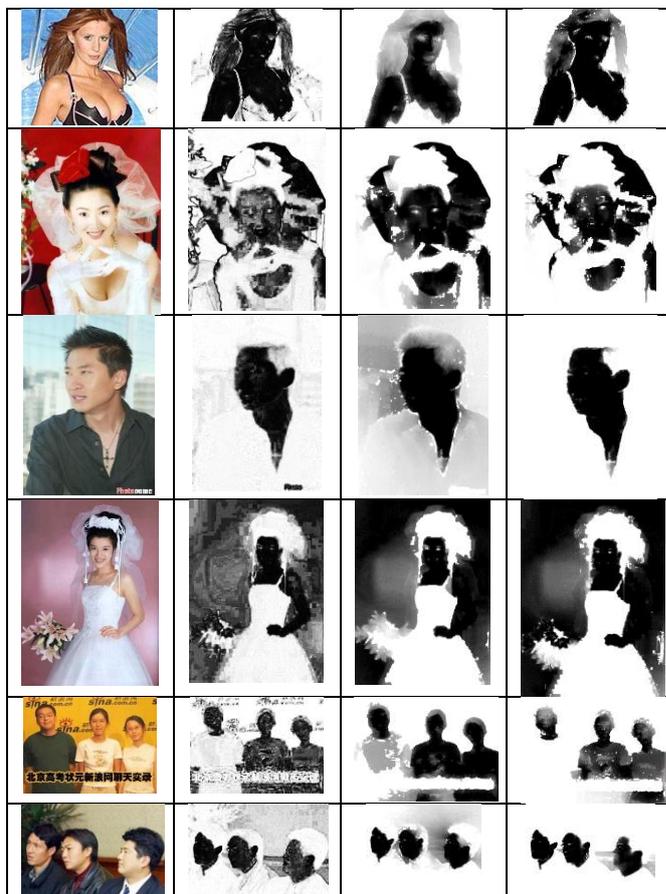
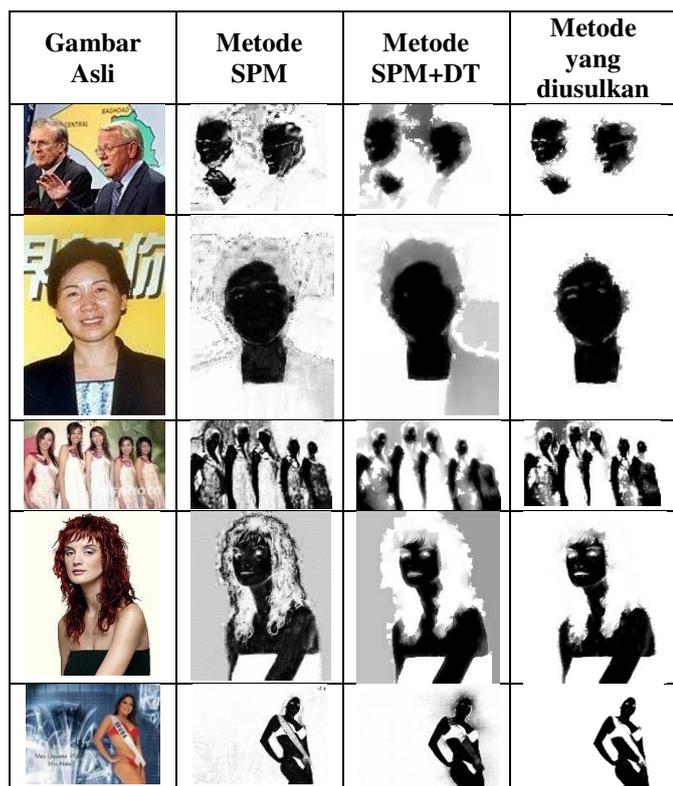
Hasil metode *SPMLDA+DT* yang diusulkan didapatkan nilai FNR sebesar 2,88% dan hasil ini menunjukkan bahwa metode yang diusulkan lebih baik daripada menggunakan metode *SPM* (FNR=7,03%), *SPM+DT* (FNR=6,13%), maupun *SPM+LDA* (FNR=3,24%).

Hasil FNR dan FPR yang ditunjukkan pada tabel 9. menunjukkan bahwa metode yang diusulkan lebih baik dari metode yang lain seperti yang ditunjukkan pada Gambar 7.



Gambar 7. Diagram Persentase dari Perbedaan Metode

Hasil pengujian aplikasi deteksi kulit dengan perbedaan metode ditunjukkan pada Gambar 8, dengan model terbaik *SPM LDA+DT*.



Gambar 8. Aplikasi Deteksi Kulit dengan Perbedaan Metode

5 KESIMPULAN

Teknik kombinasi algoritma skin probability map, linear discriminant analysis dan distance transform disulkan untuk memperbaiki kinerja dari deteksi kulit. Skin probability map digunakan untuk mencari informasi warna kulit, linear disriminant anlalysis digunakan untuk informasi fitur tekstur kulit, sedangkan distance transfrom untuk mencari jarak terpendek antara kulit dan non-kulit sekaligus mengatasi jika digunakan pada kernel yang berbeda. Dataset yang digunakan disulkan menggunakan IBTD dataset. Hasil eksperimen menunjukkan bahwa metode yang diusulkan menghasilkan tingkat *error* deteksi yang kecil yaitu sebesar 2,88%. Oleh karena itu, kami berkesimpulan bahwa metode yang diusulkan memberikan perbaikan kinerja pada skin probability map dan linear discriminant analysis.

REFERENSI

Aibinu, a. M., Shafie, A. a., & Salami, M. J. E. (2012). Performance Analysis of ANN based YCbCr Skin Detection Algorithm. *Procedia Engineering*, 41(Iris), 1183–1189.

Amjad, a., Griffiths, A., & Patwary, M. N. (2012). Multiple face detection algorithm using colour skin modelling. *IET Image Processing*, 6(8), 1093–1101.

Arcelli, C., di Baja, G. S., & Serino, L. (2011). Distance-driven skeletonization in voxel images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(4), 709–20.

Bouzerdoum, S. lam P. D. C. A. (2003). Adaptive Skin Segmentation In Color Images. *Proceedings of IEEE ICASSP*, 353–356.

Cheng, Y., Feng, Z., Weng, F., & Lee, C. (2012). Enhancing Model-based Skin Color Detection : from Low-level rgb Features to High-level Discriminative Binary-class Features School of Ece. *ICASSP IEEE*, 1401–1404.

- Clair L. Alston, K. L. M. and A. N. P. (2013). *Case studies in bayesian statistics*. (A. L. Alston, Clair; L. Mengersen, Kerrie; N. Pettitt, Ed.). Wiley.
- Fekry, S., Elsadek, A., Ali, H. F., & Ziedan, I. E. (2011). High Precision Face Detection and Recognition based on Fusion of Discernment Techniques. *ICGST International Journal on Graphics Vision and Image Processing (gvip)*, 11(2), 31–39.
- Guerrero-Curieses, a, Rojo-Álvarez, J. L., Conde-Pardo, P., Landesa-Vázquez, I., Ramos-López, J., & Alba-Castro, J. L. (2009). On the Performance of Kernel Methods for Skin Color Segmentation. *EURASIP Journal on Advances in Signal Processing*, 2009(1), 856039.
- Hsu, R., Member, S., & Abdel-mottaleb, M. (2002). Face Detection in Color Images. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(5), 1–23.
- Jiang, Z., Yao, M., & Jiang, W. (2007). Skin Detection Using Color, Texture and Space Information. *Fourth International Conference on Fuzzy Systems and Knowledge Discovery*, 366–370.
- Jie, Y., Xufeng, L., Yitan, Z., & Zhonglong, Z. (2008). A face detection and recognition system in color image series. *Mathematics and Computers in Simulation*, 77(5-6), 531–539.
- Kakumanu, P., Makrogiannis, S., & Bourbakis, N. (2007). A survey of skin-color modeling and detection methods. *Pattern Recognition*, 40(3), 1106–1122.
- Kawulok, M., Kawulok, J., & Nalepa, J. (2013). Spatial-based skin detection using discriminative skin-presence features. *Pattern Recognition Letters*.
- Kawulok, M., Kawulok, J., & Smolka, B. (2011). Image colorization using discriminative textural features. *IAPR Conference on Machine Vision And Applications*, 198–201.
- Kim, T.-K., Stenger, B., Kittler, J., & Cipolla, R. (2010). Incremental Linear Discriminant Analysis Using Sufficient Spanning Sets and Its Applications. *International Journal of Computer Vision*, 91(2), 216–232.
- Lagerstrom, R., & Buckley, M. (2012). An attribute weighted distance transform. *Pattern Recognition Letters*, 33(16), 2141–2147.
- Lee, J.-S., Kuo, Y.-M., Chung, P.-C., & Chen, E.-L. (2007). Naked image detection based on adaptive and extensible skin color model. *Pattern Recognition*, 40(8), 2261–2270.
- Lu, G.-F., Zou, J., & Wang, Y. (2012). Incremental complete LDA for face recognition. *Pattern Recognition*, 45(7), 2510–2521.
- Michal Kawulok, Jolanta Kawuloky, Jakub Nalepa, M. P. (2013). Skin Detection Using Spatial Analysis With Adaptive Seed. *ICIP IEEE*, 978-1-4799, 3720–3724.
- Powar, V. (2011). Skin Detection in YCbCr Color Space. *International Journal of Computer Applications in Technology*, 1–4.
- Ruiz-del-Solar, J., & Verschae, R. (2004). Skin detection using neighborhood information. *Automatic Face and Gesture ...*
- Sanchez-Cuevas, M. C., Aguilar-Ponce, R. M., & Tecpanecatli-Xihuitl, J. L. (2013). A Comparison of Color Models for Color Face Segmentation. *Procedia Technology*, 7(444), 134–141.
- Tan, W. R., Chan, C. S., Yogarajah, P., & Condell, J. (2012). Human Skin Detection. *IEEE Transaction on Industrial Informatics*, 8(1), 138–147.
- Taq, A. Y., & Jalab, H. A. (2010). Increasing the reliability of skin detectors. *Academic Journals*, 5(17), 2480–2490.
- Wang, J., & Yagi, Y. (2013). Shape priors extraction and application for geodesic distance transforms in images and videos. *Pattern Recognition Letters*, 34(12), 1386–1393. doi:10.1016/j.patrec.2013.04.008
- Wang, Y.-M., & Luo, Y. (2010). Integration of correlations with standard deviations for determining attribute weights in multiple attribute decision making. *Mathematical and Computer Modelling*, 51(1-2), 1–12.
- Xu, Y.-J., & Da, Q.-L. (2010). Standard and mean deviation methods for linguistic group decision making and their applications. *Expert Systems with Applications*, 37(8), 5905–5912.
- Yahya, A. A., Tan, J., & Hu, M. (2013). A Novel Model of Image Segmentation Based on Watershed Algorithm. *Advances in Multimedia*, 2013.
- Yao, C., Lu, Z., Li, J., Xu, Y., & Han, J. (2014). A subset method for improving Linear Discriminant Analysis. *Neurocomputing*, 138, 310–315.
- Zaidan, a. a., Ahmad, N. N., Abdul Karim, H., Larbani, M., Zaidan, B. B., & Sali, A. (2014). Image skin segmentation based on multi-agent learning Bayesian and neural network. *Engineering Applications of Artificial Intelligence*, 32, 136–150.

## BIOGRAFI PENULIS



meliputi pengolahan citra dan computer vision.

**Muryan Awaludin.** Memperoleh gelar S.Kom dari Sekolah Tinggi Ilmu Komputer Cipta Karya Informatika (STIKOM CKI) Jakarta dan M.Kom dari program pasca sarjana program studi Teknik Informatika STMIK Eresha (d/a STTBI Benarif). Saat ini bekerja sebagai dosen di STIKOM CKI Jakarta. Minat penelitiannya saat ini meliputi pengolahan citra dan computer vision.



bergerak di bidang pengembangan software. Minat penelitian pada bidang software engineering dan machine learning. Profesional member dari asosiasi ilmiah ACM, PMI dan IEEE Computer Society.

**Romi Satria Wahono.** Memperoleh Gelar B.Eng dan M.Eng pada bidang ilmu komputer di Saitama University, Japan, dan Ph.D pada bidang software engineering di Universiti Teknikal Malaysia Melaka. Menjadi pengajar dan peneliti di Fakultas Ilmu Komputer, Universitas Dian Nuswantoro. Merupakan pendiri dan CEO PT Brainmatics, sebuah perusahaan yang bergerak di bidang pengembangan software. Minat penelitian pada bidang software engineering dan machine learning. Profesional member dari asosiasi ilmiah ACM, PMI dan IEEE Computer Society.