

Automatic Nipple Detection Pada Citra Pornografi Menggunakan Algoritma Viola And Jones Berbasis Adaboost Untuk Feature Selection

Muhammad Fikri Hidayattullah¹, Yustia Hapsari²

¹Program Studi DIII Manajemen Informatika Politeknik Muhammadiyah Pekalongan
Jl. Pahlawan No.10 Kajen 51161
Email: muhammadfikri.uad@gmail.com

²Program Studi S1 Teknik Informatika STMIK YMI Tegal
Jl. Pendidikan No.1 Pesurungan Lor Tegal52147
Email: yustia.hapsari@gmail.com

ABSTRAK

Perkembangan teknologi internet sangat pesat sekali. Akan tetapi didalamnya terdapat banyak hal yang berbahaya, seperti konten pornografi. Banyak para peneliti melakukan kajian penelitian dalam deteksi citra pornografi dengan tujuan untuk melakukan filterisasi konten porno tersebut. Akan tetapi, sebagian dari penelitian itu hanya mengandalkan luasan persentase kulit saja untuk menentukan citra pornografi atau bukan. Dan mereka meninggalkan hal yang paling fundamental yang menjadi ciri sebuah citra pornografi yaitu organ intim. Pada penelitian ini melakukan deteksi puting payudara wanita pada citra pornografi dengan menggunakan algoritma Viola and Jones yang terkenal handal dalam pendeteksian objek. Rata-rata akurasi sebesar 83,75%, precision rate sebesar 88,20% dan recall rate sebesar 90,21%.

Kata kunci: citra pornografi, deteksi puting payudara, fitur Haar-like, Viola and Jones

1 PENDAHULUAN

Perkembangan teknologi internet berkembang dengan sangat pesat dan sangat mudah sekali untuk mengaksesnya. Akan tetapi, didalamnya terdapat banyak konten yang merusak seperti kekerasan dan pornografi. Dampak persebaran pornografi di internet memiliki efek merugikan yang sangat besar. Setiap detik sebanyak 3075,64 USD dibelanjakan untuk pornografi, setiap detik 28258 pengguna internet melihat situs pornografi, setiap detik sebanyak 372 pengguna internet mengetikkan kata kunci yang berkaitan dengan pornografi pada mesin pencari dan setiap 39 menit video porno baru dibuat di Amerika Serikat. Bahkan 12% dari seluruh website yang ada di internet adalah web porno [1]. Pada tahun 2002 National Research Council Report menyatakan bahwa 74 % halaman web yang ada di dunia maya berupa tampilan citra pornografi dan seringkali berupa banner iklan yang menggoda pengunjung.

Untuk memberikan perlindungan bagi pengguna internet khususnya anak-anak, pendeteksian dan pemblokiran citra pornografi sangat diperlukan [2]. Banyak para peneliti [3][4][5][6][7][8][9] yang telah melakukan deteksi citra pornografi. Banyak dari mereka yang melakukan penelitian hanya sebatas berdasarkan luasan persentase kulit saja [4][5][7][9] tanpa memperhatikan organ intim/seksual yang menjadi ciri utama sebuah citra pornografi [2][10]. Sehingga deteksi yang dihasilkan tidak efektif.

Secara garis besar metode deteksi citra pornografi terbagi kedalam dua kategori [11]: deteksi berbasis kulit dan deteksi berbasis fitur. Metode deteksi berbasis kulit berfokus pada deteksi kulit. Yu-Chun Lin *et al.* [12] melakukan deteksi citra pornografi menggunakan algoritma Support Vector Machine (SVM) untuk pengenalan polanya dan distribusi warna kulit. Namun, metode ini memiliki kekurangan yaitu banyak pada citra bukan porno yang mengandung banyak warna kulit dideteksi sebagai citra pornografi. Begitu juga sebaliknya, citrapornografi yang mengandung sedikit warna kulit dideteksi sebagai bukan citrapornografi. Johnson I Agbinya *et al.* [9] melakukan deteksi otomatis citra pornografi online dengan melakukan segmentasi area kulit manusia dengan ruang warna HSV, jika area kulit pada sebuah citra lebih dari 20% akan disimpulkan bahwa citra tersebut merupakan citrapornografi. Metode inipun memiliki kelemahan, yaitu pada citra yang bukan porno dengan luasan warna seperti warna kulit akan dideteksi sebagai citra pornografi. Sedangkan deteksi berbasis fitur berfokus pada penggunaan pengekstrakan fitur secara langsung pada sebuah citra [2]. Semua metode yang memanfaatkan deteksi kulit (color histogram, distribusi kromatik, informasi warna dan tekstur) mengalami permasalahan yang mendasar yaitu metode-metode tersebut tidak melakukan deteksi pada organ intim

Salah satu organ intim yang terdapat pada sebuah citra pornografi dan menjadi ciri sebuah citra pornografi adalah puting payudara. Sehingga, dengan melakukan deteksi puting payudara diharapkan dapat memberikan deteksi citra pornografi lebih optimal dibandingkan hanya dengan deteksi warna kulit. Deteksi puting payudara dapat dilakukan dengan memanfaatkan pengenalan objek secara langsung berdasarkan *training set* sampel positif dan sampel negatif dengan algoritma Viola and Jones.

2 TINJAUAN PUSTAKA

2.1 Pornografi

Henry George Liddell dan Robert Scott didalam *A Greek-English Lexicon* memberikan definisi pornografi. "Porno" (π ορνο) berasal dari bahasa Yunani yang melambangkan pelacur serta budak perempuan, karena prostitusi pada masa Yunani kuno

biasa membeli budak untuk dijadikan pelacur. “Graphy” ($\gamma\rho\alpha\phi\omicron\zeta$) melambangkan menulis. Secara Etimologi pornografi adalah menggambarkan wanita sebagai budak seks, dan secara seksual serta psikiis kembali memperbudak perempuan dalam produksi dan proses konsumsi[13]. Namun demikian, beberapa wacana ilmu sosial mencoba untuk mendefinisikan pornografi sebagai Media seksual eksplisit yang memiliki tujuan utama untuk membangkitkan seksual penonton [14]. Dalam kamus Oxford Dictionaries pornografi memiliki definisi “*printed or visual material containing the explicit description or display of sexual organs or activity, intended to stimulate sexual excitement*”(bahan cetak atau visual yang berisi deskripsi eksplisit atau memamerkan organ atau aktivitas seksual, dimaksudkan untuk merangsang gairah seksual). Pornografi juga secara khusus merupakan konten yang berisi *nudity* (ketelanjangan) dan berbagai variasi adegan seks atau persetubuhan [15].

2.2 Algoritma Viola and Jones

Algoritma Viola and Jones pertama kali diusulkan oleh Paul Viola dan Michael Jones pada tahun 2011 [16] untuk deteksi wajah manusia. Dalam penelitiannya, Viola dan Jones menggunakan 4916 citra positif dan 10.000 citra yang tidak berisi wajah untuk proses pelatihan (*training*). Setiap citra input kemudian dihitung nilai fiturnya menggunakan *integral image*. Hasil perhitungan *training* menggunakan suatu algoritma *boosting* yang merupakan variasi dari algoritma AdaBoost. Hasil *training* inilah yang digunakan untuk membentuk *cascaded classifier*, yang digunakan untuk mengklasifikasikan wajah.

Kemudian algoritma ini dikembangkan lagi oleh Rainer Lienhart dan Jochen Maydt[17]. Algoritma ini memberikan tiga kontribusi utama yaitu citra integral atau *summed area tables*[17], algoritma pembelajaran berbasis AdaBoost dan *cascade classifier*. Kontribusi pertama dari algoritma ini adalah sebuah representasi citra baru yang disebut citra integral yang memungkinkan untuk evaluasi fitur dengan sangat cepat. Sebagian penelitian ini dilandasi dari penelitian Papageorgiou *et al.* [18]. Viola and Jones menggunakan seperangkat fitur yang mirip dengan fungsi Haar Basis. Untuk dapat menghitung fitur-fitur tersebut dengan cepat pada berbagai skala, Viola Jones memperkenalkan suatu representasi citra integral. Citra integral dapat dihitung menggunakan sedikit operasi per piksel. Setelah citra integral dihitung, maka fitur Haar-like juga dapat dihitung pada berbagai skala dan lokasi dalam waktu yang konstan.

Kontribusi kedua dari algoritma ini adalah metode untuk membangun *classifier* dengan memilih sejumlah kecil fitur penting menggunakan AdaBoost. Dalam setiap *subwindow* citra jumlah total fitur Haar-like sangat besar, jauh lebih besar dari jumlah piksel pada citra tersebut. Untuk memastikan agar klasifikasi cepat, proses pembelajaran harus menghilangkan sebagian besar fitur yang tersedia, dan fokus pada satu set kecil fitur penting. Penyeleksian fitur diperoleh dengan modifikasi sederhana prosedur AdaBoost: *weak learner* dibatasi sehingga setiap *classifier* lemah yang dikembalikan dapat bergantung hanya pada fitur tunggal. Akibatnya setiap tahap dari proses *boosting*, yang memilih *classifier* lemah baru, dapat dilihat sebagai proses seleksi fitur. AdaBoost memberikan algoritma *learning* yang efektif dan memiliki batas kuat pada kinerja generalisasi.

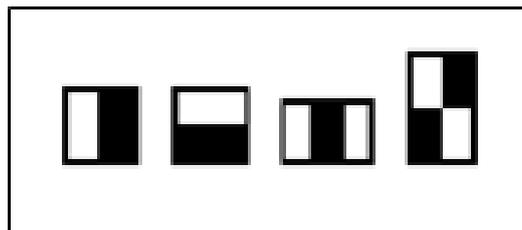
Kontribusi ketiga dari algoritma ini adalah metode untuk menggabungkan *classifier-classifier* yang lebih kompleks secara berturut-turut dalam struktur *cascade* yang secara dramatis meningkatkan kecepatan detektor dengan memfokuskan perhatian pada daerah-daerah yang menjanjikan pada citra. Proses yang lebih kompleks hanya diperuntukkan bagi daerah-daerah yang menjanjikan pada citra tersebut. Ukuran kunci pendekatan seperti itu adalah *false negative rate* pada proses atensi.

Beberapa *sub windows* yang tidak ditolak oleh *initial classifiers* diproses oleh sederetan *classifiers* yang lainnya, yang masing-masing lebih kompleks dari *classifier* yang terakhir. Jika ada *classifier* yang menolak sub window, maka tidak dilakukan proses selanjutnya. Struktur proses deteksi *cascade* merupakan degenerasi pohon keputusan.

2.2.1 Haar-Like Feature dan Integral Image

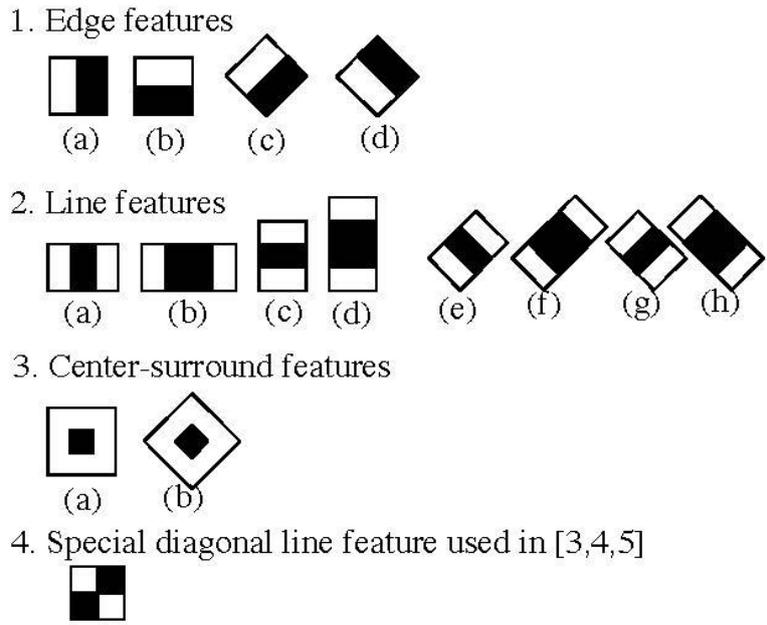
Algoritma Viola and Jones menggunakan fitur yang dinamakan fitur Haar-like yang mirip dengan fungsi Haar-basis [18]. Fitur Haar-like merupakan sebuah persegi panjang dua dimensi yang terdiri dari area gelap dan terang. Sistem pendeteksian objek Viola Jones mengklasifikasikan citra berdasarkan nilai dari fitur-fitur sederhana. Ada beberapa alasan untuk menggunakan fitur dibanding penggunaan piksel. Salah satu alasan utamanya adalah bahwa fitur dapat meng-*encode* pengetahuan domain *ad-hoc* yang sulit dipelajari menggunakan data latihan dengan jumlah yang terbatas. Alasan lainnya adalah bahwa sistem berbasis fitur beroperasi lebih cepat daripada sistem berbasis piksel.

Ada tiga macam fitur [19] yaitu *two-rectangle feature*, *three-rectangle feature* dan *four-rectangle feature*.



Gambar 1. Haar-like Feature

Fitur Haar-like dikembangkan lagi oleh R Lienhart *et al.* [17] dengan membuat turunannya (*Extended Haar-like Features*).

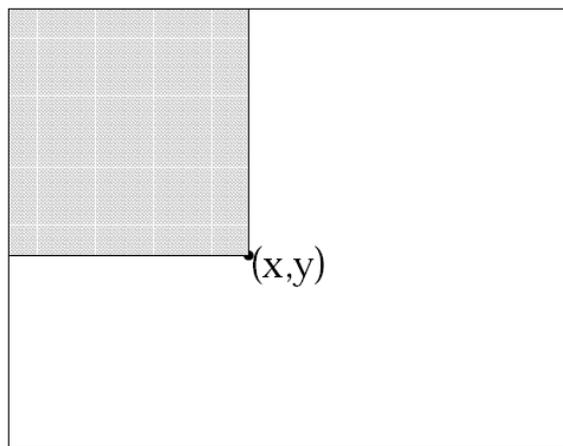


Gambar 2. Extended Haar-like Feature

Nilai dari fitur Haar-like dapat ditentukan dengan mencari selisih nilai antarajumlahnilai-nilaiipikselgray leveldalamdaerahkotakhitamdandaerahkotakputih. Proses perhitungan ini dilakukan dengan mengurangi nilai rata-rata piksel daerah gelap dengan nilai rata-rata piksel daerah terang. Jika nilai yang dihasilkan diatas nilai *threshold* (ambang batas), maka subwindow yang dideteksi dengan fitur tersebut dianggap sebagai positif objek dan berhenti tidak ke *stage* selanjutnya. Penentuan nilai *threshold* dilakukan saat *training* menggunakan algoritma AdaBoost[20]. Rumus perhitungannya:

$$f(x) = \text{Sum}_{\text{black rectangle}} (\text{pixel gray level}) - \text{Sum}_{\text{white rectangle}} (\text{pixel gray level}) \quad (1)$$

Untuk menghitung nilai penjumlahan piksel daerah gelap dan daerah terang menggunakan representasi citra integral. Dengan citra integral perhitungan fitur sangat cepat.



Gambar 3. Nilai citra integral pada titik (x,y) adalah jumlah seluruh piksel yang berada di atas dan di kiri titik tersebut

Citra integral pada lokasi x,y berisi jumlah piksel sebelah atas dan sebelah kiri x,y, termasuk:

$$ii(x,y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (2)$$

Di mana $ii(x,y)$ adalah citra integral dan $i(x,y)$ adalah gambar asli.

$$s(x,y) = s(x, y - 1) + i(x, y) \quad (3)$$

$$ii(x,y) = ii(x - 1, y) + s(x, y) \quad (4)$$

Atau dapat dituliskan secara sederhana:

$$ii(x, y) = i(x, y) + ii(x - 1, y) + ii(x, y - 1) - ii(x - 1, y - 1) \tag{5}$$

Dimana $s(x, y)$ adalah jumlah kumulatif baris, $s(x, -1) = 0$, dan $ii(-1, y) = 0$ citra integral yang dapat dihitung sekali jalan (*single pass*) dari citra input.

Dengan menggunakan citra integral, jumlah dari setiap persegi dapat dihitung dengan menggunakan empat referensi array. Perbedaan antara jumlah dua persegi dapat dihitung dengan delapan referensi. Fitur dua persegi dapat dihitung dengan enam referensi array, delapan untuk fitur tiga persegi, dan sembilan untuk fitur empat persegi.

2.3 Algoritma AdaBoost

Algoritma Adaboost merupakan singkatan dari *Adaptive Boosting*, pertama kali diperkenalkan oleh Freund dan Schapire pada tahun 1997 [21]. Algoritma Adaboost merupakan salah satu algoritma *machine learning* yang digunakan untuk *feature selection* dan melatih *classifiers*. Pada bentuk aslinya algoritma Adaboost digunakan untuk melakukan *boosting* kinerja klasifikasi dari sebuah algoritma pembelajaran yang sederhana, seperti digunakan untuk *boosting* kinerja *simple perceptron*. Hal tersebut dilakukan dengan mengkombinasikan sekumpulan fungsi klasifikasi lemah untuk membentuk sebuah *classifier* yang lebih kuat yang kemudian diistilahkan dengan *weak learner*. Misalkan sebuah algoritma pembelajaran perceptron menelusuri sekumpulan perceptron yang mungkin dan mengembalikan perceptron dengan kesalahan klasifikasi terendah. Pembelajar disebut lemah karena fungsi klasifikasi yang terbaik sekalipun tidak dapat mengklasifikasikan data latih dengan baik. Agar pembelajar lemah dapat ditingkatkan, maka harus dipanggil untuk memecahkan sederetan masalah pembelajaran. Setelah tahap pertama pembelajaran, beberapa sampel diberi nilai bobot ulang dengan tujuan untuk menekankan sampel-sampel tersebut yang salah diklasifikasikan oleh *classifier* lemah sebelumnya. Terakhir adalah *classifier* kuat mendapatkan bentuk sebuah perceptron, sebuah kombinasi berbobot dari *classifiers* lemah yang diikuti dengan sebuah nilai ambang (*threshold*).

Tabel 1. Algoritma boosting untuk learningquery secara online[16]

- Diberikan sampel citra $(x_1, y_1), \dots, (x_n, y_n)$ dimana $y_i=0,1$ untuk sampel negatif dan positif berturut-turut.
- Inisialisasikan bobot $w_{1,i} = \frac{1}{2m}, \frac{1}{2l}$ untuk $y_i = 0,1$ berturut-turut, dimana m dan l adalah jumlah positif dan negatif berturut-turut.
- Untuk $t = 1, \dots, T$:
 1. Normalisasikan bobot,

$$w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}$$
 Sehingga w_t adalah distribusi probabilitas.
 2. Pilih classifier lemah terbaik dengan urutan ke bobot kesalahan

$$\epsilon_t = \min_{f,p,\theta} \sum w_i |h(x_i, f, p, \theta) - y_i|.$$
 3. Definisikan $h_t(x)=h(x,f_t,p_t,\theta_t)$ dimana f_t, p_t , dan θ_t adalah bentuk minimize dari ϵ_t .
 4. Update bobot:

$$w_{t+1,i} = w_{t,i} \beta_t^{1-e_i}$$
 dimana $e_i = 0$ jika sampel x_i diklasifikasikan dengan benar, $e_i = 1$ sebaliknya, dan $\beta_t = \frac{\epsilon_t}{1-\epsilon_t}$.
- 1. Terakhir classifier kuat adalah:

$$C(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ \text{sebaliknya} & \end{cases}$$

dimana $\alpha_t = \log \frac{1}{\beta_t}$

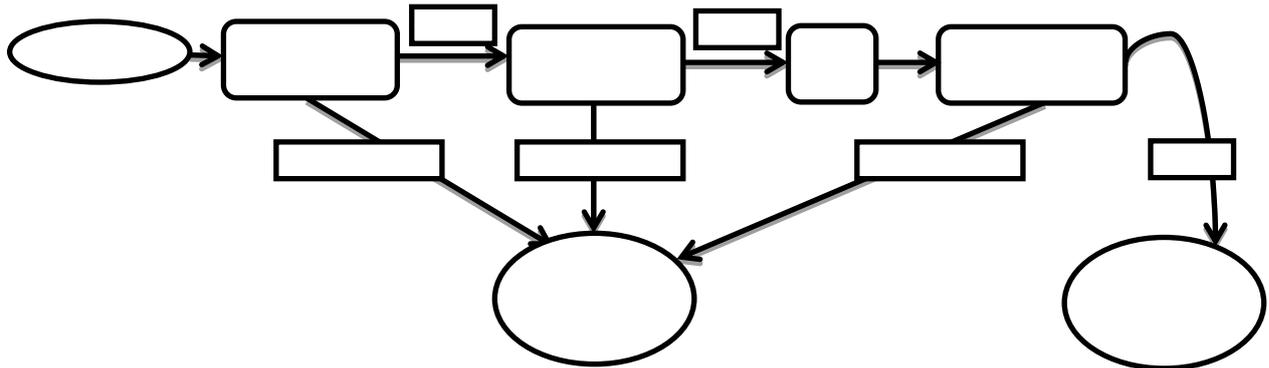
2.4 Cascade Classifier

Cascade classifier digunakan untuk mencapai peningkatan deteksi secara radikal dengan mengurangi waktu komputasi. *Boosted classifier* dapat dibangun dengan menolak beberapa *subwindow* yang negatif ketika mendeteksi hampir semua sampel

positif (nilai *thresholdboostedclassifier* dapat disesuaikan, sehingga tingkat negatif palsu (*false negative rate*) mendekati nol). *Classifiersederhana* digunakan untuk menolak sebagian besar *subwindows* sebelum *classifiers* yang lebih kompleks dipanggil untuk mencapai tingkat positif palsu (*false positive rate*) yang rendah.

Bentuk keseluruhan proses deteksi berupa degenerasi pohon keputusan dari setiap *stage*, yang disebut *cascade*. Hasil positif dari *classifier* pertama memicu evaluasi *classifier* kedua yang juga telah disesuaikan untuk mencapai tingkat deteksi yang sangat tinggi. Hasil positif dari *classifier* kedua memicu *classifier* ketiga, dan seterusnya. Hasil negatif pada titik manapun mengarah ke penolakan langsung dari *subwindow*.

Tahapan dalam *cascade* dibangun oleh *training classifier* menggunakan AdaBoost dan kemudian menyesuaikan ambang batas untuk meminimalkan negatif palsu. Nilai *threshold* AdaBoost dirancang untuk menghasilkan tingkat kesalahan rendah pada *datatraining*. Secara umum nilai *threshold* yang lebih rendah memberikan hasil tingkat deteksi lebih tinggi dan tingkat positif palsu yang lebih tinggi.



Gambar 4. Struktur *cascade classifiers*

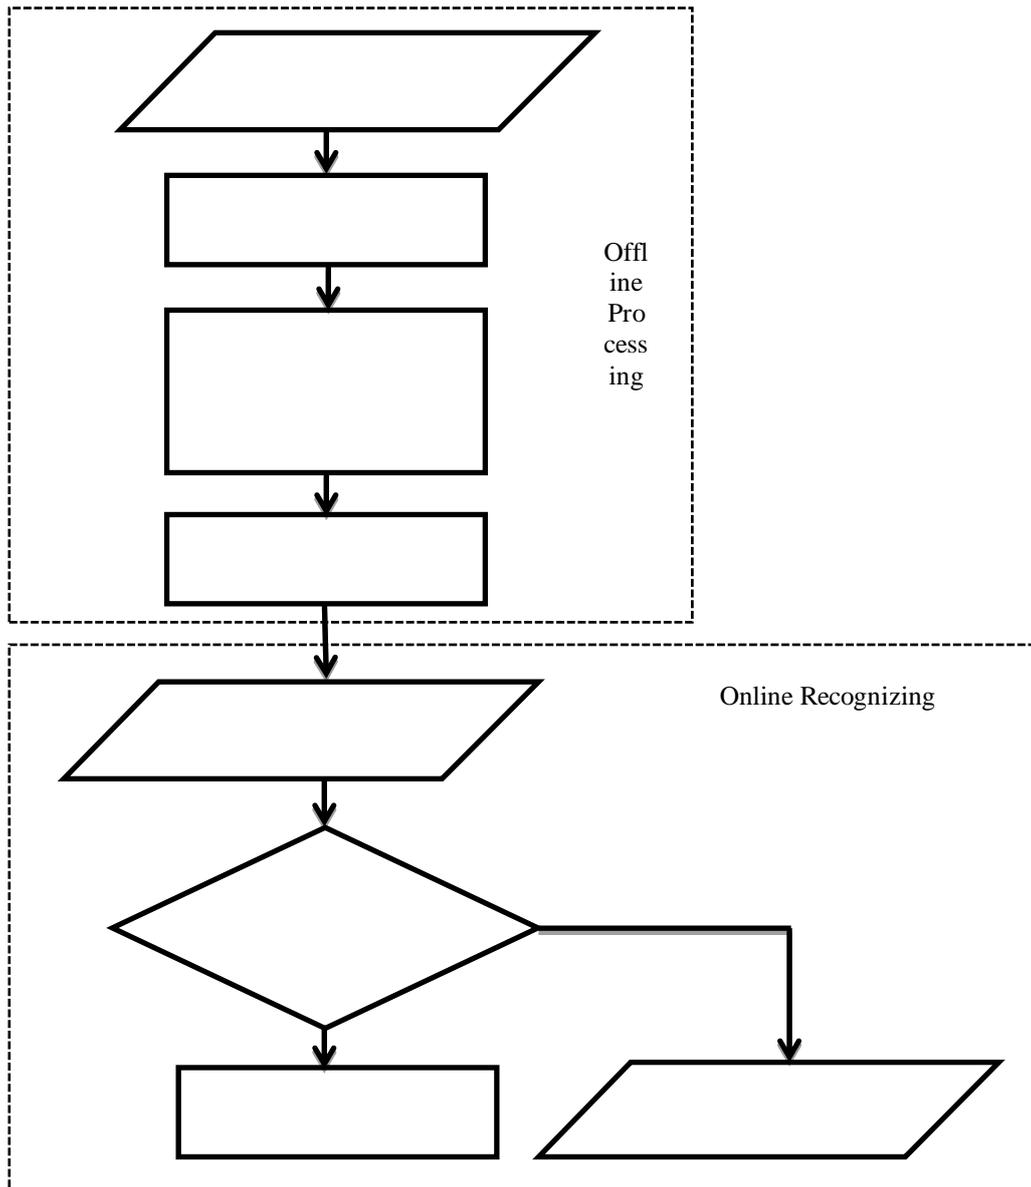
3 METODE VIOLA JONES UNTUK DETEKSI PUTING PAYUDARA

Penelitian bermula dari banyaknya metode untuk mendeteksi citra pornografi namun hanya sebatas pada perkiraan luasan persentase kulit pada objek yang akan dideteksi. Jika nilai persentase lebih besar dari nilai *threshold* yang ditentukan, maka akan dianggap sebagai citra pornografi. Pada kenyataannya terjadi beberapa kekeliruan antara lain citra yang memiliki luasan area kulit lebih dominan dibanding *background*-nya akan dianggap sebagai citra porno, begitu juga area citra yang memiliki luasan warna yang memiliki kesamaan dengan warna kulit akan dianggap sebagai citra pornografi juga dan sebaliknya citra yang mengandung unsur pornografi akan tetapi dengan area kulit yang lebih sedikit maka dianggap bukan citra pornografi, dan ini merupakan suatu kesalahan fatal. Salah satu kekeliruan yang mendasar pada metode tersebut adalah tidak melakukan deteksi pada organ intim citra pornografi. Padahal sebuah citra dianggap porno adalah apabila menampilkan organ intim dengan tujuan untuk membangkitkan gairah [14]. Berdasarkan studi literatur diketahui bahwa bahwa hal tersebut dapat dicarikan solusi dengan deteksi organ intim menggunakan algoritma Viola and Jones. Algoritma ini sangat cepat dan *robust* dalam mendeteksi objek.

Pada penelitian ini jumlah citra positif (citra yang mengandung objek puting) yang digunakan sebesar 897 citra, sedangkan citra negatif (citra yang tidak mengandung objek puting) sebesar 1836 gambar. Citra positif dibagi dua, 731 untuk pelatihan dan 166 untuk pengujian. Citra negatif juga dibagi dua 1756 untuk pelatihan dan 80 untuk pengujian. Sehingga, gambar yang digunakan untuk pengujian tidak sama dengan yang digunakan untuk pelatihan. Puting payudara yang digunakan sebagai *data training* maupun *data testing* memiliki bentuk, ukuran, warna, tekstur, posisi dan pencahayaan yang berbeda-beda. Dikarenakan bentuk payudara wanita sangat variatif.

Langkah pertama adalah melakukan *training* terhadap sampel positif dan negatif dengan ukuran *subwindow* 20x20 untuk menghasilkan *cascade classifiers* atau *cascade detector*. Pada proses *training* ini menggunakan algoritma AdaBoost untuk menyeleksi fitur-fitur dan melatih *classifiers*. *Classifier* kuat dihasilkan dari penggabungan sekumpulan *classifiers* lemah. Jumlah *stages* yang digunakan pada adalah 27 *stages*. Setelah proses *training* ini selesai akan dihasilkan sebuah detektor *cascade classifiers* dalam bentuk XML file yang dapat digunakan untuk mendeteksi puting payudara.

Pada Gambar 5 menampilkan langkah *offline processing* untuk menghasilkan *cascade classifiers* dan proses deteksi *online recognizing*.



Gambar 5. Skema model deteksi puting payudara menggunakan Viola and Jones

4 HASIL PENELITIAN

Penelitian ini diimplementasikan kedalam program *prototype* C++ dengan kompiler Code Blocks 12.11 dan *framework computer vision* OpenCV 2.1. Pada penelitian ini hanya melakukan deteksi pada citra payudara yang bersifat *frontal*. Sehingga, semua citra payudara yang tidak menghadap lurus ke depan (*frontal*) tidak menjadi objek deteksi dan tidak dihitung sebagai *false negative*.

Hasil deteksi objek puting payudara dengan *bounding box* berwarna hijau ditunjukkan oleh Gambar 6.



Gambar 6. Hasil deteksi puting payudara pada citra pornografi

Meskipun Viola and Jones sangat handal dalam mendeteksi objek, namun banyak area yang memiliki kesamaan bentuk dan warna dengan puting payudara dianggap sebagai puting, seperti area mata dan pusar.



Gambar 7. False positive

Nilai rata-rata akurasi yang diperoleh dari pengujian seluruh citra testing sebesar 83,75%, *precision rate* sebesar 88,20% dan *recall rate* sebesar 90,21%.

5 KESIMPULAN

Metode Viola and Jones untuk deteksi pornografi dengan memanfaatkan organ intim yang salah satunya adalah puting payudara terbukti akurat untuk mengenali objek *nudity*. Akan tetapi, masih banyak area bukan puting yang dianggap sebagai puting karena memiliki kesamaan warna dan bentuk seperti mata dan pusar. Kedepannya metode ini perlu dihibrid dengan algoritma lain dan juga dapat digabung dengan deteksi kulit agar menghasilkan deteksi yang lebih akurat.

DAFTAR PUSTAKA

- [1] Jerry Ropelato, "Internet Pornography Statistics - TopTenREVIEWS," 2006. [Online]. Available: <http://internet-filter-review.toptenreviews.com/internet-pornography-statistics.html>.
- [2] Y. Wang, J. Li, H. Wang, and Z. Hou, "Automatic Nipple Detection Using Shape and Statistical Skin Color Information," *Proceeding MMM'10 Proceedings of the 16th international conference on Advances in Multimedia Modeling Pages 644-649 Springer-Verlag Berlin, Heidelberg ©2010*, pp. 644–649, 2010.

- [3] X. Wang, C. Hu, and S. Yao, "A Breast Detecting Algorithm for Adult Image Recognition," *Information Management, Innovation Management and Industrial Engineering, 2009 International Conference on*, vol. 4, no. 26–27 Dec. 2009, pp. 341–344, 2009.
- [4] H. Zhu and S. Zhou, "An algorithm of pornographic image detection," *Image and Graphics, 2007. ICIG 2007. Fourth International Conference on*, no. 22–24 Aug. 2007, pp. 801–804, 2007.
- [5] R. Ap-apid, "An Algorithm for Nudity Detection," *Proceedings of the 5th Philippine Computing Science Congress*, no. March 4–5, 2005, pp. 201–205, 2005.
- [6] X. Wang, "An Adult Image Recognizing Algorithm Based on Naked Body Detection," *Computing, Communication, Control, and Management, 2009. CCCM 2009. ISECS International Colloquium on*, vol. 4, no. 8–9 Aug. 2009, pp. 197–200, 2009.
- [7] R. Ap-apid, "Image-Based Pornography Detection," *Proceedings of IPCV*, pp. 627–631, 2008.
- [8] H. Zuo, W. Hu, and O. Wu, "Patch-Based Skin Color Detection and Its Application to Pornography Image Filtering," *Proceedings of the 19th international conference on World wide web*, pp. 1227–1228, 2010.
- [9] J. I. Agbinya, B. Lok, Y. S. Wong, and S. D. Silva, "Automatic Online Porn Detection and Tracking," *Faculty of Engineering, University of Technology, Sydney, 1 Broadway, Sydney 2007, 2007*.
- [10] P. Fuangkhan, "Neural Network-Based Nipple Detection for Obscene Pictures," *WSEAS Transaction on Computer*, vol. 4, no. 9, pp. 1138–1145, 2005.
- [11] W. Hu, O. Wu, Z. Chen, Z. Fu, S. Maybank, and S. Member, "Recognition of Pornographic Web Pages by Classifying Texts and Images," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 29, no. 6, pp. 1019–1034, 2007.
- [12] Y. Lin, H. Tseng, and C. Fuh, "Pornography Detection Using Support Vector Machine," *16th IPPR Conference on Computer Vision, Graphics and Image Processing (CVGIP 2003)*, vol. 19, no. Cvgip, pp. 123–130, 2003.
- [13] T. Shibata, "' Pornography ', Sexual Objectification and Sexual Violence in Japan and in the World," *Centre for East and South-East Asian Studies, Lund University*, no. 27, 2008.
- [14] N. Malamuth, "Pornography," *N. J. Smelser & P. B. Baltes (Ed.) International Encyclopedia of Social and Behavioral Sciences, Elsevier: Amsterdam, New York.*, vol. 17, pp. 11816–11821, 2001.
- [15] M. C. Rea, "What Is Pornography?†," *Blackwell Publisher Inc.*, no. October 1996, pp. 118–145, 2001.
- [16] P. Viola, "Rapid Object Detection using a Boosted Cascade of Simple Features," *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on*, vol. 1, no. 2001, p. I-511 – I-518 vol.1, 2001.
- [17] R. Lienhart and J. Maydt, "An extended set of Haar-like features for rapid object detection," *Proceedings. International Conference on Image Processing*, vol. 1, p. I-900–I-903, 2002.
- [18] C. P. Papageorgiou, M. Oren, and T. Poggio, "A general framework for object detection," in *Sixth International Conference on Computer Vision (IEEE Cat. No.98CH36271)*, 1998, pp. 555–562.
- [19] P. Viola and M. J. Jones, "Robust Real-Time Face Detection," *International Journal of Computer Vision*, vol. 57, no. 2, pp. 137–154, May 2004.
- [20] Z. Zhu, T. Morimoto, H. Adachi, O. Kiriya, T. Koide, and H. J. Mattausch, "Multi-view Face Detection and Recognition using Haar-like Features," pp. 2–4, 2002.
- [21] Y. Freund, R. E. Schapire, and M. Hill, "Experiments with a New Boosting Algorithm," *Machine Learning: Proceedings of the Thirteenth International Conference*, pp. 148–156, 1996.