

Penerapan *Histogram of Oriented Gradients*, *Principal Component Analysis*, dan AdaBoost untuk Sistem Pengenalan Wajah

Adhika Gunadarma^{#1}, Ken Ratri Retno Wardani^{#2}

[#]Departemen Informatika, Institut Teknologi Harapan Bangsa
Jalan. Dipatiukur No. 80-8, Bandung, Indonesia 40132

¹adhikagunadarma@gmail.com

²ken_ratri@ithb.ac.id

This the human face image has a lot of information that can be used in the field of computer vision to create a human face recognition system. The method used in this study is the Histogram of Oriented Gradients (HOG) method used for feature extraction. The Principal Component Analysis (PCA) method is applied from the features of the HOG method to reduce the dimensionality of feature data from high to low without losing much of the information. Finally, the Adaptive Boosting method (AdaBoost) is used to process the resulting feature classification. Before performing facial recognition process, the initial treatment is done to detect and cut the face of the next part of the image pieces will be the same size so that the face taken has a uniform size. Based on the test results of cell, block and bins values, the best total eigenvalue and total iteration for this process were 8,16,4, -, 15 for the classifier using the HOG plus AdaBoost method with the resulting accuracy to recognize the face of 86% and 8.16,16,20,10 for classifier using HOG method, PCA with AdaBoost with accuracy level for face recognition of 96%.

Keywords— *face recognition, face detection, HAAR, histogram of oriented gradients, principal component analysis, adaptive boosting*

Abstrak— Citra wajah manusia memiliki banyak informasi yang dapat digunakan pada bidang *computer vision* untuk membuat sistem pengenalan wajah manusia. Metode yang digunakan pada penelitian kali ini adalah metode *Histogram of Oriented Gradients* (HOG) yang digunakan untuk ekstraksi fitur. Metode *Principal Component Analysis* (PCA) diterapkan dari hasil fitur metode HOG untuk mereduksi dimensionalitas data fitur dari tinggi ke rendah tanpa menghilangkan banyak informasi. Terakhir, metode *Adaptive Boosting* (AdaBoost) dipakai untuk proses klasifikasi fitur yang dihasilkan. Sebelum melakukan proses pengenalan wajah, dilakukan pengolahan awal untuk mendeteksi dan memotong bagian wajah yang selanjutnya bagian potongan citra akan di samakan ukurannya agar wajah yang terambil mempunyai ukuran seragam. Berdasarkan hasil pengujian nilai sel, block dan bins, jumlah eigen dan jumlah iterasi terbaik untuk keseluruhan pada proses ini adalah 8,16,4,-,15 untuk *classifier* menggunakan metode HOG dan AdaBoost dengan tingkat akurasi yang dihasilkan untuk mengenali wajah sebesar 86% dan 8,16,16,20,10 untuk *classifier* menggunakan metode HOG, PCA dengan AdaBoost dengan tingkat akurasi untuk pengenalan wajah sebesar 96%.

Kata Kunci— *sistem pengenalan wajah, deteksi wajah, HAAR, histogram of oriented gradients, principal component analysis, adaptive boosting*

I. PENDAHULUAN

Citra wajah manusia memiliki banyak informasi yang dapat digunakan pada bidang komputer *vision* untuk membuat sistem pengenalan wajah manusia. Sistem pengenalan wajah manusia merupakan salah satu bidang visi komputer yang populer dikembangkan sampai saat ini, karena relatif lebih mudah untuk diimplementasikan dan tidak membutuhkan biaya yang mahal dibanding dengan sistem pengenalan lainnya. Sistem pengenalan wajah manusia cukup banyak dipakai di berbagai kebutuhan contohnya seperti sistem absensi, sistem pelacakan dan sistem keamanan. Untuk bisa mengatasi kebutuhan semacam itu dibutuhkan sebuah sistem yang dapat mengenali wajah manusia. Sistem pengenalan wajah merupakan proses untuk mengenali wajah manusia dari foto/citra yang tertangkap dari kamera.

Dalam pengenalan wajah manusia, ada banyak metode ekstraksi fitur yang dapat dipakai, seperti metode *Scale-Invariant Features Transform*, *Speeded-Up Robust Features*, *Principal Component Analysis*, *Histogram of Oriented Gradients*. Metode *Histogram of Oriented Gradients* ditambah dengan metode *Principal Component Analysis* [1] menghasilkan akurasi paling rendah 67% untuk beberapa skala citra. Akurasi dari beberapa metode yang disebutkan masih tergolong kecil.

Metode *Neural Neighbour*, *Support Vector Machine*, *Artificial Neural Network* dan *Boosting* merupakan metode yang cukup umum dalam melakukan pengambilan keputusan pada pengenalan wajah manusia. Metode ekstraksi fitur menggunakan *Histogram of Oriented Gradients* dan *Principal Component Analysis* yang dikombinasikan dengan *Neural Neighbour* berbasis *Euclidean Distance* sebagai *classifier* [1] memiliki kekurangan karena jika klasifikasi hanya berdasarkan jarak kedekatan saja tidak cukup untuk menghasilkan sebuah keputusan. Untuk metode *Histogram of Oriented Gradients* yang dikombinasikan dengan *Support Vector Machine* [2] hanya memiliki akurasi rata-rata sebesar

78 dari berbagai *dataset* yang berbeda. Perbandingan metode *Support Vector Machine* dan AdaBoost yang dikombinasikan dengan metode *Principal Component Analysis* menghasilkan akurasi berturut-turut sebesar >75% dan >68%. Namun memakai metode *Support Vector Machine* memiliki kekurangan dimana waktu yang dibutuhkan untuk pengujian relative lebih lama dibandingkan dengan metode *Adaptive Boosting* [3].

Pada penelitian ini akan digunakan HOG sebagai metode untuk ekstraksi fitur dikombinasikan dengan PCA untuk ekstraksi sekaligus reduksi dimensi fitur serta menggunakan AdaBoost sebagai metode untuk klasifikasi dan pengambilan keputusan dengan *dataset* Caltech Faces 1999 dan AT&T ORL Faces *dataset*. Adapun kelas yang dipakai untuk penelitian kali ini merupakan kelas wajah manusia. Kelebihan metode HOG yaitu informasi fitur yang digunakan tidak sensitif terhadap perubahan pencahayaan, kecerahan dan kontras dimana akan cocok dengan public *dataset* seperti Caltech Faces 1999 yang memiliki citra dari beragam kondisi pencahayaan, perbedaan kecerahan serta kontras. Kelebihan dari metode PCA yaitu mereduksi dimensi fitur yang digunakan sehingga akan mempercepat waktu komputasi secara keseluruhan. Kelebihan dari metode AdaBoost yaitu relatif lebih mudah untuk diimplementasikan dan waktu pengujian yang relatif cepat sehingga cocok dipakai dalam implementasi kondisi *real time*.

II. KONTEN UTAMA (METODOLOGI/DASAR TEORI)

A. Landasan Teori

1) Page Histogram of Oriented Gradients (HOG)

Histogram of Oriented Gradients (HOG) merupakan salah satu teknik pengambilan fitur yang bertujuan untuk mengambil informasi penting dari sebuah citra. Cara kerja metode ini, yaitu dengan mengevaluasi histogram lokal yang sudah ternormalisasi secara baik dari distribusi gradien citra dalam grid yang padat [4]. Teknik mengekstrak fitur untuk metode ini yaitu dari distribusi lokal dari intensitas gradien tiap *pixel* yang terdapat pada sebuah objek citra. Dalam metode *Histogram of Oriented Gradients* pada pengenalan wajah manusia, ukuran sel berupa kumpulan atau gabungan *pixel* dan blok berupa kumpulan atau gabungan sel beserta jumlah *orientation bin* yang merupakan tempat untuk menampung hasil arah dan besar gradien akan mempengaruhi hasil keluaran fitur vektor yang dihasilkan dan juga akurasi yang didapat [5].

Pertama untuk setiap *pixel* dari citra akan dihitung gradiennya dari sumbu x dan y dengan menggunakan persamaan 1.

$$\begin{aligned} G_x(x, y) &= I(x+1, y) - I(x-1, y) \\ G_y(x, y) &= I(x, y+1) - I(x, y-1) \end{aligned} \quad (1)$$

Rumus diatas menjelaskan bahwa gradient didapat dengan mengurangi nilai piksel didepannya dengan nilai piksel di belakangnya sesuai dengan sumbunya. Setelah didapat nilai

gradien dari sumbu x dan y untuk setiap pixelnya, proses selanjutnya adalah menghitung besar nilai dan arah gradiennya dengan menggunakan persamaan 3.

$$M(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (2)$$

$$\theta(x, y) = \tan^{-1} \frac{G_y(x, y)}{G_x(x, y)} \quad (3)$$

Nilai *magnitude* gradien dan arah sudut gradien dipakai sebagai komponen dalam proses selanjutnya. G_x dan G_y merupakan gradient dari sumbu x dan y masing-masing. Kemudian, dari setiap pixel citra akan dibagi ke dalam beberapa sel, dimana setiap selnya akan dihitung persebaran *Histogram of Oriented Gradient*-nya melalui proses *vote*. Proses *vote* dalam *Histogram of Oriented Gradients* pertama akan menentukan nilai-nilai dari bin dengan membagi total jumlah sudut gradien ke dalam jumlah *orientation bin*. Kemudian untuk setiap arah sudut gradien dari setiap piksel dalam sel akan dimasukkan ke dalam rentang *orientation bin* yang sudah ditentukan pada pertama kali, kemudian membagi besar nilai gradiennya dengan *orientation bin* yang terkait.

Setelah HOG sudah dibuat untuk setiap sel, proses selanjutnya adalah melakukan normalisasi terhadap hasil *vote* pada setiap *bin* dalam sel. Normalisasi akan dilakukan dalam 1 blok, dengan ukuran blok merupakan $m \times n$ sel. Metode untuk normalisasi terdapat sebanyak 4, yaitu L2-Norm, L2-Hys, L1-sqrt, dan L1-norm [5]. Persamaan normalisasinya dapat dilihat sebagai berikut:

Adapun proses normalisasi blok akan dilakukan dalam *sliding window* yang akan bergerak melakukan proses dengan pergeseran sebesar 1 x ukuran sel secara vertikal dan horizontal. Proses ini kemudian akan bersifat *overlapping* untuk beberapa sel yang dinormalisasi sehingga menimbulkan informasi yang redundan, namun akurasi yang dihasilkan akan semakin meningkat [5]. Terakhir, hasil dari normalisasi tiap blok akan digabungkan menjadi 1 fitur vektor besar [6].

2) Principal Component Analysis (PCA)

Principal Component Analysis (PCA) merupakan salah satu metode standar yang digunakan untuk pengenalan objek dengan cara mereduksi dimensi untuk dipakai dalam ekstraksi fitur [7]. Pada penelitian kali ini, proses hasil dari metode HOG akan dimasukkan kedalam metode PCA untuk direduksi dimensi data dari M -dimensi ke dalam K -dimensi ruang fitur dimana $K < M$ [8]. Dalam pengenalan wajah manusia metode PCA dikenal sebagai *eigenface*. *Eigenface* merupakan vektor eigen yang memiliki konfigurasi menyerupai wajah. Metode PCA mereduksi dimensi dengan menggunakan K vektor eigen dari matriks kovarian sesuai dengan nilai eigen terbesar.

Pada metode PCA data yang digunakan untuk pelatihan sebanyak N data berukuran $A \times B$ direpresentasikan menjadi data berukuran $(A \times B) \times 1$ di mana semua datanya berukuran sama. Selanjutnya mencari nilai rata-rata dari data latihan menggunakan persamaan 4.

$$\mu = \frac{\sum_{i=1}^N A_i}{N} \quad (4)$$

A merupakan matriks kolom hasil dari metode HOG dari setiap data citra, sedangkan N merupakan jumlah total data citra yang dipakai. Setelah mencari nilai rata-rata dari data latih maka selanjutnya melakukan normalisasi pada data hasil proses metode HOG menggunakan persamaan 5.

$$\varphi_i = A_i - \mu \quad (5)$$

μ merupakan nilai rata-rata dari data latih. Setelah proses normalisasi, langkah selanjutnya yaitu menggabungkan setiap matriks data hasil normalisasi φ ke dalam matriks S . Kemudian menghitung matriks kovarian dari citra wajah dengan persamaan 6.

$$C = SS^T, S = [\varphi_1, \varphi_2, \varphi_3, \dots, \varphi_N] \quad (6)$$

Matriks kovarian yang terbentuk akan memiliki $AB2 \times AB2$ dimensi sehingga mempunyai $AB2$ vektor *eigen* dan nilai *eigen*. Untuk mencari nilai *eigen* dan vektor *eigen* sebanyak $AB2$ akan memerlukan komputasi yang sangat besar dan tidak efisien karena hanya M vektor *eigen* yang akan digunakan. Untuk mengatasi masalah tersebut maka vektor *eigen* dicari dari matriks kovarians L .

$$L = S^T S, S = [\varphi_1, \varphi_2, \varphi_3, \dots, \varphi_N] \quad (7)$$

Hasil matriks kovarian akan memiliki $M \times M$ dimensi. Selanjutnya mencari nilai *eigen* dengan persamaan 8.

$$|L - \lambda| = 0 \quad (8)$$

λ adalah nilai *eigen* yang dicari. Setelah mendapatkan nilai *eigen*, langkah selanjutnya adalah mencari vektor *eigen* dari matriks kovarian L dengan persamaan 9.

$$(L - \lambda)v = 0 \quad (9)$$

v adalah vektor *eigen* yang dicari. M vektor *eigen* yang terbentuk digunakan untuk mencari M vektor *eigen* dari matriks kovarian C dengan persamaan 10.

$$u_i = S * v_i \quad (10)$$

Dari vektor *eigen* yang sudah terbentuk, hanya K vektor *eigen* yang diambil berdasarkan nilai *eigen* terbesar. Setelah mengambil K vektor *eigen*, selanjutnya data latih diproyeksikan ke ruang *eigenface*. Bobot fitur dari data latih dapat diperoleh menggunakan persamaan 11.

$$w_i = u^T * \varphi_i \quad (11)$$

Hasil dari metode PCA kemudian dapat diperoleh menggunakan persamaan 12.

$$w_i = [w_1, w_2, w_3, \dots, w_N] \quad (12)$$

3) Adaptive Boosting (AdaBoost)

Adaptive Boosting (AdaBoost) merupakan metode klasifikasi yang didasari oleh *machine learning* yang bekerja dengan prinsip *boosting*. Rumus AdaBoost pertama kali ditelusuri oleh Freund and Schapire [9] yang relatif efisien, simpel dan mempunyai algoritme yang mudah untuk meningkatkan performa klasifikasi. Prinsip *boosting* sendiri didapat dengan melatih beberapa *classifier* lemah sehingga menghasilkan suatu *classifier* kuat yang dapat mengambil keputusan. Ide dari *boosting* sendiri yaitu mengecilkkan bobot untuk data sampel yang diasumsikan benar, dan menaikkan bobot untuk data sampel yang diasumsikan salah. AdaBoost sendiri menerapkan ide *boosting* yaitu mengambil bobot dari sampel yang diasumsikan salah, dimana akan dipakai untuk pelatihan klasifikasi lemah di iterasi berikutnya [10].

Pada metode AdaBoost data yang digunakan untuk pelatihan sebanyak N data yang sudah diberi label (x_i, y_i) di mana x_i merupakan hasil bobot fitur vektor dari proses PCA dan y_i merupakan label yang ditandai dengan $(-1, +1)$. Pertama dari N data pelatihan, setiap data sampelnya akan diberi bobot yang dapat dilihat pada persamaan 13.

$$D_i = \frac{1}{N} \quad (13)$$

N merupakan total jumlah data citra yang dipakai. Setelahnya, pada setiap iterasi, cari *classifier* lemahnya dengan cara mencari nilai *mean threshold* dari setiap dimensi nilai fiturnya yang dapat dilihat pada persamaan 14.

$$\theta_i = \frac{\sum_{i=1}^N x_{i,j}}{N} \quad (14)$$

$x_{i,j}$ merupakan nilai fitur dari dimensi kolom j dan baris i . Setelah dicari nilai ambang dari setiap dimensi, cari *classifier* lemah dari setiap bobot fitur yang ada pada hasil proses PCA dengan menggunakan persamaan 15.

$$h(x_{i,j}) = \begin{cases} +1 & \text{jika } x_{i,j} > \theta_j \\ -1 & \text{lainnya} \end{cases} \quad (15)$$

Dengan mendapatkan *classifier* lemah dari setiap bobot fitur yang ada, hitung nilai kesalahan dari masing-masing dimensi fitur dengan menggunakan persamaan 16.

$$\mathcal{E}_j^i = \sum_{i=1}^N D_i I(y_i \neq h(x_{i,j})) \quad (16)$$

$I(x)$ menandakan apabila label y tidak sama dengan hasil klasifikasi dari *classifier* lemah, maka hasilnya bernilai 1. Setelah itu, mencari nilai α dari nilai kesalahan yang terkecil yang sudah dipilih, menggunakan persamaan 17.

$$\alpha_i = \frac{1}{2} \ln \frac{(1 - \epsilon^t)}{\epsilon^t} \quad (17)$$

Kemudian, dari hasil nilai α yang didapat, dicari bobot distribusi baru akan dihitung dengan menggunakan persamaan 18.

$$D = \begin{cases} D_i' \exp^{-\alpha} & \text{jika } y_i = h(x_{i,j}) \\ D_i' \exp^{\alpha} & \text{jika } y_i \neq h(x_{i,j}) \end{cases} \quad (18)$$

Terakhir, lakukan normalisasi dengan tujuan agar bobot distribusi D pada iterasi berikutnya bernilai 1 bila dijumlahkan untuk keseluruhan data pada setiap bobot distribusi. Persamaan yang digunakan, yaitu persamaan 19.

$$D_i^{(t+1)} = \frac{D_i^{(t)}}{\sum_{i=1}^N D_i^{(t)}} \quad (19)$$

Berikut ini merupakan persamaan yang digunakan untuk mencari model latih yang dibutuhkan, untuk proses pengambilan keputusan final menggunakan persamaan 20.

$$H(x) = \text{sign} \left[\sum_{t=1}^T \alpha_t h_t(x) \right] \quad (20)$$

Hasil perhitungan untuk *classifier* final akan menghasilkan nilai (+1) yang menandakan bahwa kelas tersebut memang cocok dengan data pelatihan dan (-1) untuk sebaliknya.

B. Perancangan sistem

Sistem pengenalan wajah manusia dimulai dari pengambilan data untuk *training*, *preprocessing*, hingga sistem dapat mendeteksi gerakan. Berikut merupakan *flowchart training* dan *testing* dari sistem pengenalan wajah manusia (Gambar 1).

Pada penelitian ini data sampel yang akan digunakan pertama dari *dataset* Caltech dimana terdapat lebih dari 450 citra wajah manusia dengan total sebanyak 27 orang yang berbeda. Citra yang diambil dari *dataset* Caltech merupakan citra berwarna dengan 3 channel warna. Ukuran untuk setiap citra wajah manusia berukuran 896 x 592 piksel. Adapun jumlah kelas yang akan digunakan untuk proses pelatihan/pembelajaran pada penelitian kali ini berjumlah 19 kelas wajah manusia yang diambil dengan jumlah citra dari masing - masing kelas sebanyak 20. *Dataset* kedua yang digunakan yaitu merupakan *dataset* ORL dengan ukuran 256 x 384 dengan channel warna 8 derajat keabuan. Kelas yang digunakan pada *dataset* ORL sebanyak 20, dengan masing -

masing kelasnya memiliki 10 total citra untuk pelatihan dan pengujian. Citra masukan berupa citra warna dengan channel RGB. Jumlah citra masukan yang dipakai untuk data pelatihan sebanyak 80% dan untuk data pengujian sebanyak 20% dari data citra total.

III. HASIL DAN PEMBAHASAN

A. Pengujian

Pada tahap ini, akan dijelaskan hasil pengujian yang dilakukan. Hasil akhir dari pengujian ini dilihat dari kelas yang ditentukan pada citra dan kelas yang diklasifikasi oleh system.

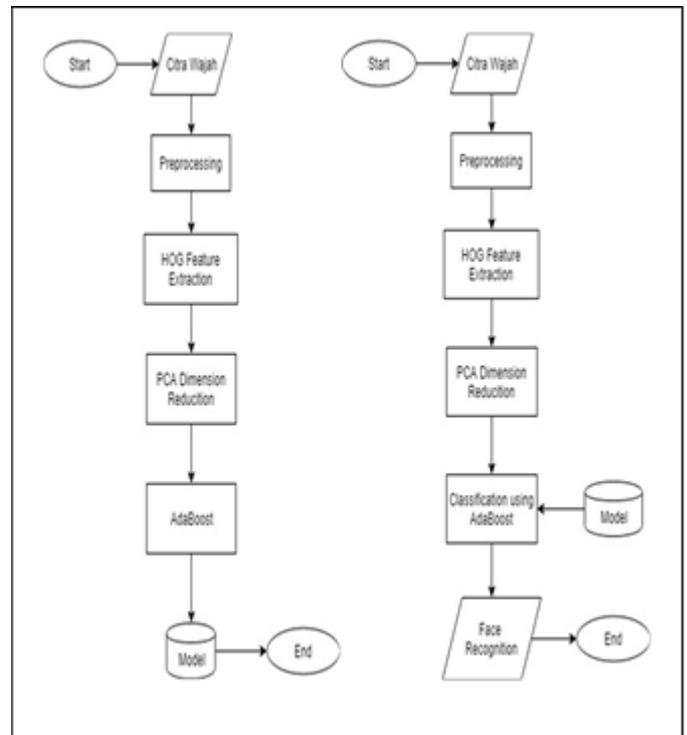
1) Pengujian Kombinasi Parameter beserta Classifier

Dalam pengujian ini seluruh parameter dari metode yang digunakan akan diuji seluruhnya. Pengujian Parameter akan menggunakan *dataset* Caltech. Pertama metode yang akan diuji adalah HOG. Parameter yang diuji dari metode ini yaitu ukuran sel, blok dan jumlah *bins*. Hasil dari pengujian terhadap metode HOG dapat dilihat pada Gambar 2.

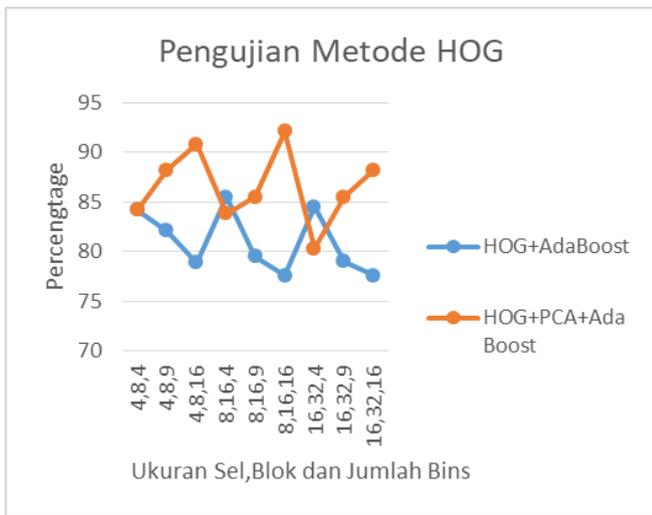
Metode kedua yang diuji yaitu PCA. Parameter yang diuji disini yaitu jumlah *eigen vector*. Hasil dari pengujian terhadap metode PCA dapat dilihat pada Gambar 3.

Metode ketiga yang diuji yaitu AdaBoost. Parameter yang diuji disini yaitu jumlah iterasi. Hasil dari pengujian terhadap metode AdaBoost dapat dilihat pada Gambar 4.

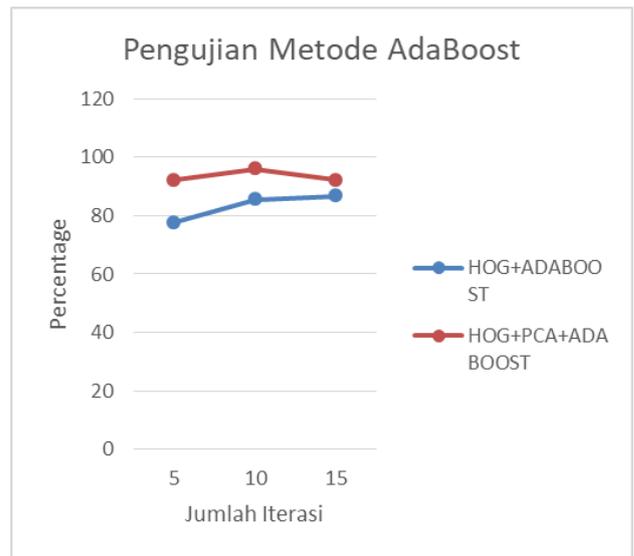
Kemudian setelah didapat parameter terbaik. Pengujian parameter terbaik akan dilakukan dengan membandingkan *dataset* dari Caltech dan ORL. Hasil dari pengujian *dataset* dapat dilihat pada Gambar 5.



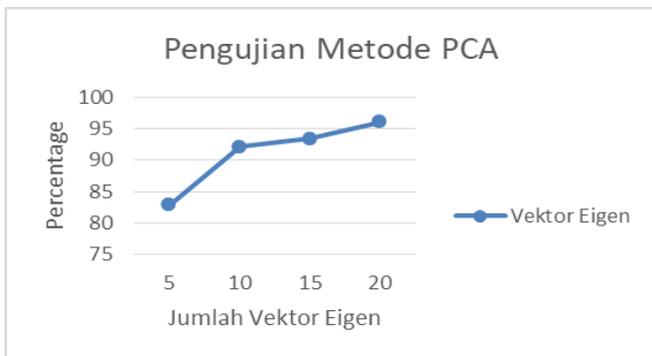
Gambar 1 Grafik proses *training* dan *testing*



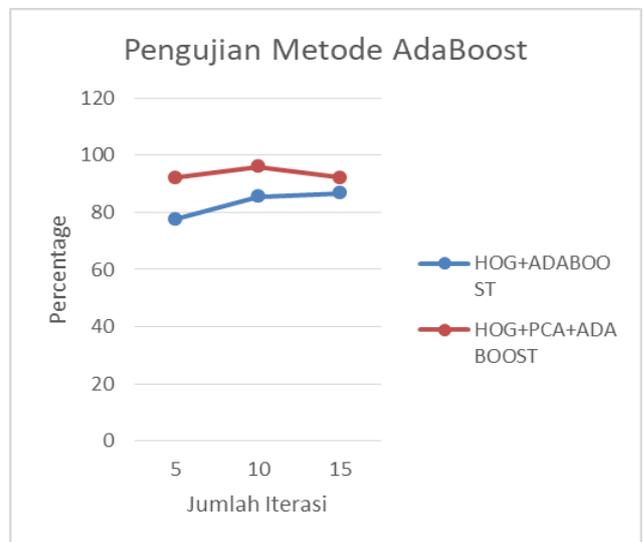
Gambar 2 Grafik hasil kombinasi parameter metode HOG



Gambar 4 Grafik hasil kombinasi parameter metode AdaBoost



Gambar 3 Grafik hasil kombinasi parameter metode PCA



Gambar 4 Grafik hasil kombinasi parameter metode AdaBoost

2) Pengujian Kontras Cahaya

Dalam pengujian ini kontras citra akan dinaikkan dan diturunkan kemudian akan dibandingkan dengan citra biasa yang tidak diubah kontrasnya. Parameter yang digunakan dari masing-masing *classifier* akan diambil dari hasil terbaik pengujian sebelumnya. Berikut hasil pengujian (Gambar 6).

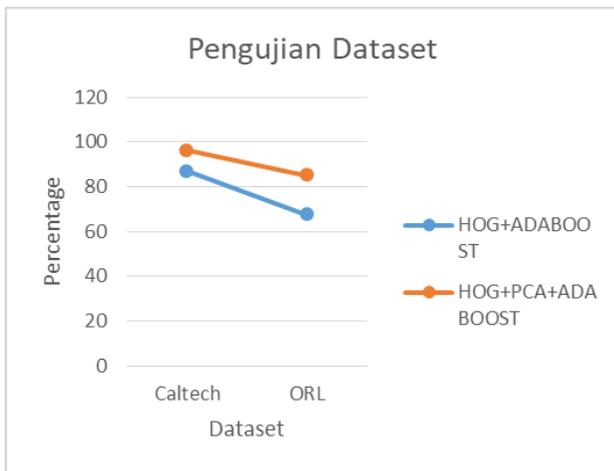
B. Evaluasi

Berdasarkan hasil dari pengujian diatas, dengan semakin meningkatnya jumlah *bins*, akurasi yang dihasilkan semakin menurun sedangkan dengan meningkatnya ukuran sel dan blok, akurasi yang dihasilkan juga cenderung menurun. Kemudian untuk jumlah *eigen vector* didapat bahwa semakin banyak jumlahnya, maka akurasinya pun meningkat. Terakhir untuk jumlah iterasi, semakin meningkatnya jumlah iterasi akurasi yang dihasilkan semakin meningkat, namun semakin banyak jumlah iterasi juga dapat menimbulkan *overfitting* yang menyebabkan akurasinya malah menurun seperti yang dapat dilihat pada 15 iterasi *classifier* HOG + PCA + AdaBoost. Terdapat faktor-faktor lain yang dapat menyebab-

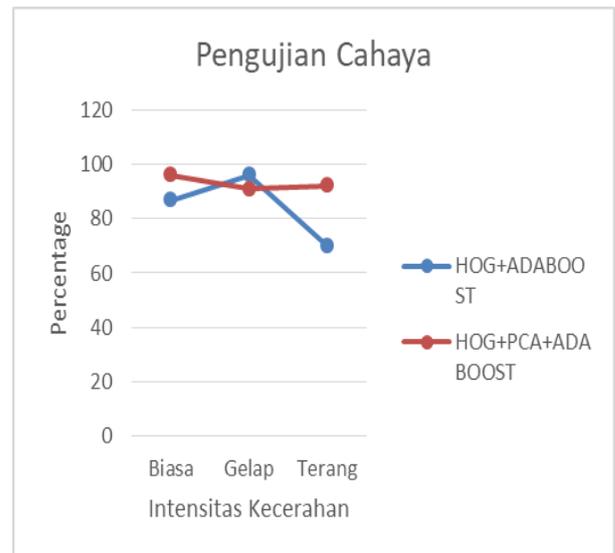
kan kesalahan terhadap pengenalan seperti kualitas dari citra, ekspresi wajah manusia dan kemiripan bentuk dari komponen wajah manusia di mana hal tersebut akan mempengaruhi fitur yang dihasilkan dari metode HOG.

IV. KESIMPULAN

Dengan menggunakan *classifier* HOG + AdaBoost, hasil yang didapat untuk sistem pengenalan wajah sebesar 86%. Akurasi ini didapat dengan menggunakan ukuran sel sebesar 8, ukuran blok sebesar 16 dan jumlah *bin* sebanyak 4 pada metode HOG dan jumlah iterasi sebanyak 15 ternyata sudah cukup untuk bisa mengenali wajah manusia.



Gambar 5 Grafik hasil perbandingan *dataset*



Gambar 6 Grafik hasil pengujian kontras cahaya

Dengan menggunakan *classifier* HOG + PCA + AdaBoost, hasil yang didapat untuk sistem pengenalan wajah sebesar 96%. Akurasi ini didapat dengan menggunakan ukuran sel sebesar 8, ukuran blok sebesar 16 dan jumlah bin sebanyak 16 pada metode HOG beserta nilai komponen vektor *eigen* yang ditentukan sebesar 20 dari metode PCA. Dengan jumlah iterasi sebanyak 10 untuk metode AdaBoost ternyata sudah cukup untuk bisa mengenali wajah manusia. Adapun model yang dihasilkan pada iterasi sebanyak 10 ternyata sudah optimal karena ketika iterasi dinaikkan, maka akan terjadi *overfitting* dalam klasifikasi sehingga menyebabkan akurasi menurun.

Dalam pengujian cahaya menggunakan kedua *classifier*, didapat bahwa akurasi yang dihasilkan antara citra pada kondisi normal, terang dan gelap ternyata berbeda, sehingga dapat disimpulkan bahwa fitur yang diambil dari metode ekstraksi fitur belum mampu membedakan wajah manusia dalam kondisi pencerahan yang bervariasi, namun pola yang dihasilkan sudah mampu untuk bisa membedakan wajah manusia dengan objek lain.

DAFTAR REFERENSI

[1] F. G. Zbeda, et al. "PCA-HOG Descriptors for Face Recognition in very Small Images," *International Journal of Advanced Research in Computer Science and Software Engineering*, Volume 6, Issue 9, 2016.
 [2] H. S. Dadi and G. K. Mohan Pillutla. Improved Face Recognition Rate Using HOG Features and SVM Classifier. *IOSR Journal of Electronics and Communication Engineering (IOSR-JECE)*, Volume 11, Issue 4, Ver. I, 2016.
 [3] M. Yao and C. Zhu. "SVM and Adaboost-based Classifiers with Fast PCA for Face Recognition". *IEEE International Conference on Consumer Electronics-China (ICCE-China)*, 2016.

[4] N. Dalal and B. Triggs. "Histograms of Oriented Gradients for Human Detection". *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005.
 [5] S. Chang, et al. "Histogram of the Oriented Gradient for Face Recognition," *Tsinghua Science and Technology*, Vol. 16 No. 2, 2011.
 [6] "Histogram of Oriented Gradients". [Online]. Available: <https://www.learnopencv.com/histogram-of-oriented-gradients/>
 [7] R. Kaur and Er. Himanshi. "Face Recognition Using Principal Component Analysis". *IEEE International Advance Computing Conference (IACC)*, 2015.
 [8] I. T. Jolliffe. *Principal Component Analysis*, 2nd Edition, USA: Springer, 2002.
 [9] Y. Freund and R. Schapire. "A decision-theoretic generalization of online learning and an application to boosting". *Computational Learning Theory: Eurocolt '95*, 1:23-37, 1995.
 [10] P. Harrington. "Machine Learning in Action". *Manning Publications Company*, 7:129-148, 2012.

Adhika Gunadarma, menyelesaikan pendidikan Sarjana Strata 1 (S1) di Program Studi Informatika, Institut Teknologi Harapan Bangsa, Bandung, pada tahun 2018.

Ken Ratri Retno Wardani, menerima gelar Sarjana Teknik Informatika dari Sekolah Tinggi Sains Dan Teknologi Indonesia pada tahun 1993. Menyelesaikan studi Magister di Institut Teknologi Bandung jurusan Teknologi Informasi tahun 2004. Saat ini aktif sebagai pengajar di Departemen Teknik Informatika, Institut Teknologi Harapan Bangsa di Bandung. Minat penelitian pada pengolahan citra dan Interaksi manusia Komputer.