

Pengenalan Mobil pada Citra Digital Menggunakan HOG-SVM

Derry Alamsyah
STMIK GI MDP Palembang
derry@mdp.ac.id

Abstract

The image data on a highway has been available on several online sites. It can be used to pull some information such as traffic congestion, vehicle volume per day, etc. To obtain this information required basic information such as the introduction of the vehicle, in this case the car. The introduction of the car is done by utilizing the features that form the image Histogram of Oriented Gradient (HOG). The introduction of a car based on this feature is done by using a model of linear equations formed from the algorithm Support Vector Machine (SVM), which is a binary classification. The accuracy of the results obtained in this study was 82, 5%.

Keywords: Car Recognition, HOG, SVM

Abstrak

Data citra pada jalan raya telah sedia pada beberapa online sites. Hal ini dapat dimanfaatkan untuk menarik beberapa informasi seperti kemacetan, volume kendaraan perhari, dll. Untuk mendapatkan informasi ini dibutuhkan informasi mendasar seperti pengenalan kendaran, dalam hal ini mobil. Pengenalan mobil dilakukan dengan memanfaatkan fitur bentuk pada citra yaitu Histogram of Oriented Gradient (HOG). Pengenalan mobil berdasarkan fitur ini dilakukan dengan menggunakan suatu model persamaan linier yang dibentuk dari algoritma Support Vector Machine (SVM) yang merupakan suatu klasifikasi biner. Hasil Akurasi yang didapat pada penelitian ini adalah 82, 5%.

Kata kunci: Car Recognition, HOG, SVM

1. PENDAHULUAN

Beberapa data citra digital dapat diperoleh dari *online cites*, salah satunya merupakan citra digital pada jalan raya, atau pun pada wilayah parkir kendaraan. Data tersebut dapat dimanfaatkan untuk memperoleh informasi mengenai keadaan yang terjadi seperti kemacetan, volume kendaraan per hari. Untuk mendapat informasi tersebut diperlukan informasi yang lebih mendasar seperti deteksi kendaraan atau lebih mendasar berupa pengenalan kendaraan.

Kendaraan yang dapat dikenali terdiri dari berbagai jenis yaitu Mobil, Bus, Motor, dll. Beberapa penelitian terkait mengenai deteksi/pengenalan Mobil telah dilakukan, yaitu segmentasi mobil melalui fitur ciri bentuk seperti SURF dan *hough circle* [1]. Selanjutnya penggunaan fitur kontur [2], namun umumnya fitur ini rentan pada permasalahan iluminasi. Fitur berikutnya yang memberikan hasil akurasi yang tinggi yaitu 95% dihasilkan melalui fitur *Haar-like* dengan klasifikasi menggunakan ANN [3]. Meskipun hasil akurasi yang dihasilkan tinggi, namun proses pelatihan dengan menggunakan fitur ini memerlukan komputasi yang besar sesuai dengan jumlah data latih. Hal ini merupakan sifat alami dari penggunaan fitur *Haar-like*, ditambah penggunaan ANN maka proses pencarian ciri yang terbaik membutuhkan waktu yang lama. Pada umumnya penggunaan fitur *Haar-Like* memakan waktu beberapa hari,

namun hal ini dapat dikurangi dengan menggabungkan penggunaan memori RAM dan VGA. Penggunaan kedua memori tersebut membutuhkan biaya yang tidak murah terutama pada VGA.

Fitur bentuk lain untuk mengenali sebuah objek dilakukan dengan memanfaatkan informasi gradien pada citra [4] yaitu *Histogram of Oriented Gradient* (HOG). Fitur telah digunakan untuk mendeteksi pejalan kaki [5] dan tulisan tangan [6]. Penggunaan fitur ini didampingi oleh klasifikasi biner *Support Vector Machine* (SVM). Hasil akurasi yang dihasilkan untuk mendeteksi objek dengan menggunakan HOG-SVM memiliki akurasi yang tinggi. Proses pelatihan menggunakan fitur ini memiliki waktu yang cepat. Pada penelitian ini pengenalan objek yang dilakukan berupa pengenalan mobil. Fitur yang digunakan adalah HOG dengan algoritma klasifikasi biner yaitu SVM.

2. Histogram of Oriented Gradient (HOG)

HOG-Algorithm (I: Image)

Gradient Image:

Gradient

$$\begin{aligned} I_x(r, c) &= I(r, c + 1) - I(r, c - 1) \\ I_y(r, c) &= I(r - 1, c) - I(r + 1, c) \end{aligned}$$

Magnitude

$$\mu = \sqrt{I_x + I_y}$$

Orientation

$$\theta = \frac{180}{\pi} (\tan^{-1}(I_y, I_x) \bmod \pi)$$

Cell Orientation Histogram:

Untuk $binB$ dan $cellC$:

Vote bin pada setiap $cell$

$$v_j = \mu \frac{c_{j+1} - \theta}{w}$$

untuk $binj = \left\lfloor \frac{\theta}{w} - \frac{1}{2} \right\rfloor \bmod B$

dengan batas $bin[w_i, w(i + 1))$

dimana

$w = \frac{180}{B}$ dan

$$c_i = w \left(i + \frac{1}{2} \right)$$

sebagai pusat masing-masing bin .

Kemudian vote bin ,

$$v_{j+1} = \mu \frac{\theta - c_j}{w}$$

untuk $bin(j + i) \bmod B$

Block Normalization:

Normalisasi setiap *block* yang terdiri dari $c \times c_{cell}$.

$$b = \frac{b}{\sqrt{|b|^2 + \varepsilon}}$$

Hog Feature:

Normalisasi setiap fitur HOG dari setiap blok.

$$h = \frac{h}{\sqrt{|h|^2 + \varepsilon}}$$

Return $h[4]$.

3. Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan metode klasifikasi biner yang memanfaatkan suatu persamaan *hyperplane* (garis untuk bidang dua dimensi) yang ditunjukkan oleh Gambar 1[7][8][9]. Persamaan umum SVM:

$$f_{svm}(\mathbf{x}) = w \cdot \mathbf{x} + b$$


dimana

$$w = \sum_{i \in N} \alpha_i y_i \phi(\mathbf{x}_i)$$

dengan

$$K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i) \phi(\mathbf{x}_j)$$

merupakan fungsi kernel dan b nilai bias.



Gambar 1. SVM Hyperplane

SVM-Train Algorithm(X, Y)

Feature vector (X):

$\mathbf{x}^d \in X$ dimana $d \in N$

Label (Y):

$$Y = \{1, -1\}$$

Gaussian Kernel:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(\frac{-|\mathbf{x}_i - \mathbf{x}_j|^2}{2\sigma^2}\right)$$

Optimize:

$$Ld = \max_{\alpha_i \in \mathbb{R}} \sum_{i \in N} \alpha_i - \frac{1}{2} \sum_{i \in N} \sum_{j \in N} \alpha_i \alpha_j y_i y_j K(x_i, x_j)$$

dengan

$$0 \leq \alpha_i \leq C \text{ dan } \sum_{i \in N} \alpha_i y_i = 0$$

SVM-Model:

$$f_{svm}(x) = \sum_{i \in N} \alpha_i y_i K(x_i, x) + b$$

Return f_{svm}

SVM-Classifer Algorithm(x, f_{svm})

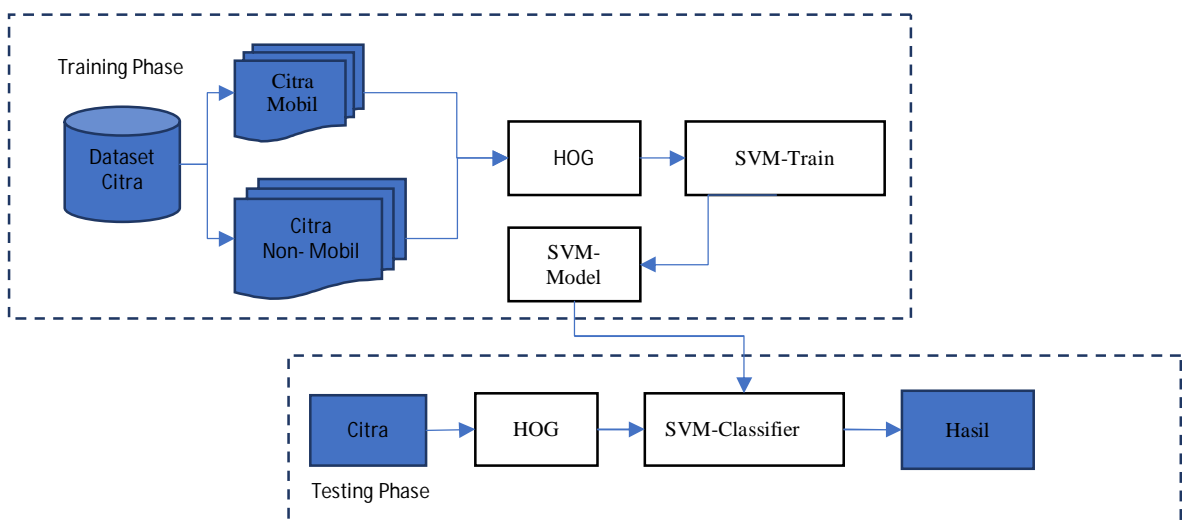
$$class = \begin{cases} 1, & f_{svm}(x) \geq 0 \\ -1, & \text{selainnya} \end{cases}$$

Return class

Optimasi dilakukan dengan *Sequential Minimal Optimization* (SMO).

4. Pengenalan Mobil

Pengenalan mobil dibagi kedalam dua tahap yang ditunjukkan oleh Gambar 2, yaitu tahap melatih sistem (*training phase*) dan tahap pengenalan objek (*testing phase*) baik sebagai mobil atau bukan. Dataset yang digunakan diperoleh dari UIUC *Image Database for Car Detection*.



Gambar 2. Pengenalan Mobil





Gambar 3. Dataset Mobil



Gambar 4. Dataset Non-Mobil


Jumlah dataset adalah 1000 citra dengan ukuran 40×100 piksel. Dataset dibagi menjadi dua bagian yaitu dataset mobil (citra +) (Gambar 3) dan data set non-mobil (citra-) (Gambar 4).

5. HASIL DAN PEMBAHASAN

Pengujian sistem yang telah dibuat dilakukan dalam 3 cara yaitu: Pengujian pertama dilakukan berdasarkan perbandingan dataset citra (+) dan citra (-) dengan ratio 1:1. Hasil pada pengujian pertama memiliki tingkat akurasi yang baik yaitu diatas 70%. Peningkatan akurasi didapat dengan menambahkan jumlah data latih (*Train Data*) pada sistem. Hasil pengujian pertama ditunjukkan oleh Tabel 1.

Pengujian tahap pertama ini dibagi kedalam dua pengujian yaitu pengujian dengan menggunakan data latih dan pengujian menggunakan data uji (*Test Data*). Pengujian untuk data latih menghasilkan akurasi yang tepat yaitu 100%, namun belum menghasilkan akurasi yang optimal untuk pengujian data uji. Hal ini dikarenakan sistem belum cukup banyak mendapatkan informasi mengenai ciri mobil yang sebenarnya. Oleh karena itu dengan penambahan data latih pada sistem, menghasilkan hasil akurasi yang optimal yaitu 82.5% pada 300 data latih untuk masing-masing citra (+) dan citra (-).

Akan tetapi, penambahan data latih sejumlah 400 citra (+) dan citra (-) menurunkan tingkat akurasi, hal ini dikarenakan terjadi *overfitting* pada proses pelatihan sistem.



Gambar 5. Deteksi Mobil

Tabel 1. Pengujian Pertama

n-Train Data (image)	n-Test Data (image)	Acc. Train Data (percent)	Acc. Test Data (percent)
100+, 100-	100	100	74.5
200+, 200-	100	100	78.5

300+, 300-	100	100	82.5
400+, 400-	100	100	76.5

Pengujian kedua dilakukan berdasarkan perbandingan dataset citra (+) dan citra (-) dengan ratio 1:0.5. Pengujian ini menghasilkan tingkat akurasi yang sama baik pada data latih maupun data uji. Hasil pengujian kedua ditunjukkan oleh Tabel 2.

Tabel 2. Pengujian Kedua

n-Train Data (image)	n-Test Data (image)	Acc. Train Data (percent)	Acc. Test Data (percent)
100+, 50-	100	100	50
200+, 100-	100	100	50
300+, 150-	100	100	50
400+, 200-	100	100	50

Pengujian ketiga dilakukan berdasarkan perbandingan dataset citra (+) dan citra (-) dengan ratio 1:0.75. Hasil pengujian ini ditunjukkan oleh Tabel 3, dimana tingkat akurasi pada data latih dan data uji sama.

Tabel 3. Pengujian Ketiga

n-Train Data (image)	n-Test Data (image)	Acc. Train Data (percent)	Acc. Test Data (percent)
100+, 75-	100	100	50
200+, 150-	100	100	50
300+, 225-	100	100	50
400+, 300-	100	100	50

Hasil akurasi yang sama pada pengujian kedua dan ketiga menunjukkan bahwa sistem tidak menemukan model yang tepat dari data latih yang diberikan. Penerapan sederhana untuk permasalahan deteksi mobil dengan menggunakan sistem ini ditunjukkan oleh gambar 5.

6. KESIMPULAN

Akurasi pengenalan mobil yang terbaik didapatkan pada pelatihan sistem dengan menggunakan ratio 1:1 untuk citra (+) dan citra (-) yaitu sebesar 82.5%. Dimana, jumlah data latih berjumlah 300 untuk masing-masing jenis citra dataset. Sedangkan untuk semua proses pelatihan sistem dengan menggunakan ratio yang tidak sebanding (1:0.5 dan 1:0.75) memiliki nilai akurasi yang tidak baik, dengan semua nilai berjumlah 50%.

DAFTAR PUSTAKA

- [1] A. Naba, B. M. Pratama, A. Nadhir, and H. Harsono, “*Haar-Like Feature Based Real-Time Neuro Car Detection System*,” pp. 67–70, 2016.
- [2] C. J. C. Junli and J. L. J. Licheng, “*Classification Mechanism of Support Vector Machines*,” *WCC 2000 - ICSP 2000. 2000 5th Int. Conf. Signal Process. Proceedings. 16th World Comput. Congr. 2000*, Vol. 3, pp. 0–3, 2000.
- [3] N. Dalal and W. Triggs, “*Histograms of Oriented Gradients for Human Detection*,” *2005 IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. CVPR05*, Vol. 1, No. 3, pp. 886–893, 2004.
- [4] N. Sapankevych and R. Sankar, “*Time Series Prediction Using Support Vector Machines: A Survey*,” *IEEE Comput. Intell. Mag.*, Vol. 4, No. 2, pp. 24–38, 2009.
- [5] L. Li, S. Yoon, J. Liu, and J. Yi, “*Multi-Scale Car Detection and Localization Using Contour Fragments*,” *2014 IEEE Int. Conf. Image Process. ICIP 2014*, pp. 1609–1613, 2014.
- [6] P. Nskh, N. V. M, and R. R. Naik, “*Principle Component Analysis Based Intrusion Detection System Using Support Vector Machine*,” pp. 1344–1350, 2016.
- [7] R. Singh, T. D. Biradar, M. Godse, M. E. S. Extc, A. P. Extc, and H. O. D. Biomedical, “*Improving Histograms of Oriented Gradients for Pedestrian Detection*,” Vol. 2, No. 3, pp. 195–199, 2013.
- [8] R. Ebrahimzadeh, “*Efficient Handwritten Digit Recognition Based on Histogram of Oriented Gradients and SVM*,” Vol. 104, No. 9, pp. 10–13, 2014.
- [9] V. Vinoharan, A. Ramanan, and S. R. Kodituwakku, “*A Wheel-Based Side-View Car Detection Using Snake Algorithm*,” *ICIAFS 2012 - Proc. 2012 IEEE 6th Int. Conf. Inf. Autom. Sustain.*, pp. 185–189, 2012.