

# Penerapan Reduksi Region Palsu Berbasis *Mathematical Morphology* pada Algoritma *Adaboost* Untuk Deteksi Plat Nomor Kendaraan Indonesia

Muhammad Faisal Amin

Software Development Department, CV Adcoms Anugrah  
Email: faisal.indonesia@gmail.com

Romi Satria Wahono

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

**Abstract:** Tahap deteksi plat nomor merupakan langkah yang paling penting dan sulit dalam sistem identifikasi plat nomor. Kondisi plat nomor yang memiliki warna *background* yang mirip dengan warna mobil, dan memiliki variasi yang besar dalam bentuk dan ukuran, menyebabkan deteksi plat nomor menjadi rendah. Kondisi tersebut terjadi pada plat nomor kendaraan pribadi Indonesia. Agar deteksi plat nomor Indonesia menjadi akurat, maka diusulkan untuk menerapkan algoritma *adaboost*. Dibandingkan dengan metode lain, algoritma *adaboost* adalah metode terbaik untuk mengatasi masalah yang terjadi pada plat nomor Indonesia. Algoritma *adaboost* akurat dalam mendeteksi plat nomor tanpa terikat oleh warna, bentuk, dan ukuran. Akan tetapi, akurasi dari algoritma ini rendah ketika terdapat banyak region palsu pada gambar. Oleh karena itu, diusulkan untuk menambahkan proses reduksi region palsu berupa operasi *mathematical morphology* di bagian *online recognizing* algoritma *adaboost*. Hasil eksperimen menunjukkan bahwa integrasi algoritma *adaboost* dan *mathematical morphology* lebih akurat dalam mendeteksi plat nomor Indonesia. Nilai *precision rate* dan *recall rate* masing-masing dari algoritma *adaboost* standard adalah 84,44% dan 84,62%. Setelah algoritma *adaboost* dan *mathematical morphology* diintegrasikan, nilai *precision rate* dan *recall rate* masing-masing naik menjadi 94,47% dan 92,31%.

**Keywords:** sistem deteksi plat nomor, algoritma *adaboost*, *mathematical morphology*

## 1 PENDAHULUAN

Sistem identifikasi plat nomor kendaraan menjadi trend dalam penelitian sistem transportasi cerdas. Sistem identifikasi plat nomor kendaraan terdiri dari tiga tahap, yaitu deteksi plat nomor, segmentasi karakter, dan pengenalan karakter. Diantara ketiga tahap tersebut, tahap deteksi plat nomor merupakan tahap yang paling penting dan paling sulit (Anishiya & Joans, 2011) (Sun, Li, Xu, & Wang, 2009) (Chang, Chen, Chung, & Chen, 2004). Hal ini disebabkan karena tahap ini dapat mempengaruhi keakuratan sistem secara keseluruhan. Jika tahap ini gagal, maka dipastikan tahap berikutnya pasti juga akan mengalami kegagalan.

Kondisi plat nomor yang mempunyai warna *background* yang mirip dengan warna body mobil (Cui & Xie, 2009), dan variasi yang besar dalam bentuk dan ukuran (Liu, Cui, Shu, & Xin, 2011) menyebabkan deteksi terhadap plat nomor menjadi lebih sulit. Kondisi tersebut terjadi pada plat nomor pribadi kendaraan Indonesia. *Background* plat nomor

pribadi kendaraan Indonesia berwarna hitam. Padahal warna hitam adalah salah satu warna mobil paling populer di dunia (Dupont, 2010). Ini artinya, kebanyakan warna *background* plat nomor di Indonesia mirip dengan warna mobil. Masalah lain yang terjadi pada plat nomor pribadi Indonesia, yaitu variasi yang besar baik dalam bentuk dan ukuran. Hal ini terjadi karena terjadi perubahan desain plat nomor kendaraan sejak bulan April 2011. Selain itu, para pemakai kendaraan banyak yang menggunakan plat nomor tidak standard. Gambar 1 menunjukkan contoh variasi dari plat nomor Indonesia.

Metode saat ini yang saat digunakan untuk deteksi plat nomor, yaitu metode berbasis *image processing* dan metode berbasis *machine learning*. Contoh metode deteksi plat nomor berbasis *image processing*, antara lain *color image processing* (Cui & Xie, 2009), deteksi tepi (Suri, Walia, & Verma, 2010), *mathematical morphology* (Anishiya & Joans, 2011), dan sebagainya. Metode berbasis *image processing* cenderung lebih mudah diimplementasikan. Akan tetapi, metode ini tidak kuat terhadap perubahan lingkungan (Zhao, et al., 2010). Berbeda dengan metode berbasis *machine learning* yang lebih kuat terhadap perubahan lingkungan (Zhao, et al., 2010). Contoh metode deteksi plat nomor berbasis *machine learning*, antara lain *neural network* (Sirithinaphong & Chamnongthai, 1998), algoritma *adaboost* (Cui, et al., 2009), dan sebagainya. Dalam mendeteksi objek, algoritma *adaboost* mempunyai keunggulan baik di akurasi dan kecepatan (Viola & Jones, 2004). Algoritma ini memiliki akurasi yang tinggi, seperti *neural network* (NN) tapi lebih cepat dari NN (Viola & Jones, 2004). Algoritma *adaboost* akurat dalam mendeteksi plat nomor dan tidak terikat dengan ukuran, warna, dan posisi plat nomor (Zhang, Shen, Xiao, & Li, 2010). Algoritma ini sesuai untuk plat nomor Indonesia yang memiliki warna mirip dengan warna mobil, dan memiliki variasi yang besar dalam bentuk dan ukuran. Akan tetapi, akurasi deteksi metode ini rendah ketika terdapat banyak region palsu pada gambar input (Wu & Ai, 2008).



Gambar 1. Plat Nomor Kendaraan Indonesia

Untuk mengatasi kekurangan pada algoritma *adaboost* tersebut, diusulkan proses reduksi region palsu pada bagian *online recognizing* algoritma *adaboost*. Proses reduksi region palsu ini sebenarnya diadopsi dari tahap *rough detection* metode deteksi plat nomor berbasis *image processing*. Metode

yang akan digunakan untuk reduksi region palsu adalah operasi *mathematical morphology*. Alasan memilih operasi *mathematical morphology* karena metode ini mampu melakukan analisis pada gambar yang sensitif terhadap bentuk tertentu (Abolghasemi & Ahmadyfard, 2007) dan kontras kecerahan (Sulehria, Zhang, & Irfan, 2007). Sedangkan varian algoritma *adaboost* yang akan digunakan adalah *gentle adaboost*. Alasan memilih algoritma *gentle adaboost* adalah karena algoritma ini memiliki kinerja terbaik dalam deteksi plat nomor dibandingkan varian algoritma *adaboost* yang lain (Cui, et al., 2009). Diharapkan integrasi algoritma *adaboost* dan *mathematical morphology* dapat lebih akurat dalam mendeteksi plat nomor kendaraan Indonesia.

Paper ini disusun sebagai berikut. Pada bagian 2, penelitian terkait dijelaskan. Pada bagian 3 model yang diusulkan dijelaskan. Hasil eksperimen dijelaskan pada bagian 4. Ringkasan pekerjaan pada paper dijelaskan pada bagian terakhir.

## 2 PENELITIAN TERKAIT

Penelitian yang dilakukan oleh Dlagnekov (Dlagnekov, 2004) menggunakan ekstraksi fitur berbasis algoritma *adaboost* untuk mendeteksi plat nomor. Penelitian ini merupakan penelitian pertama yang mengusulkan algoritma *adaboost* untuk deteksi plat nomor. Fitur yang mereka gunakan adalah varian lain dari *haar feature*, yaitu *x-derivative*, *y-derivative*, *variance*, dan *x-derivative*. Metode yang mereka usulkan memperoleh nilai *recall rate* sebesar 95,5% dan *false positive rate* sebesar 5,7%.

Penelitian yang dilakukan oleh Cui, et al (Cui, et al., 2009) melakukan komparasi terhadap tiga algoritma *adaboost*, yaitu *dicrete adaboost*, *real adaboost*, dan *gentle adaboost* untuk deteksi plat nomor. Mereka mengomparasi tingkat deteksi dan tingkat *false positive* ketiga algoritma *adaboost* tersebut dengan beberapa setting pengaturan yang berbeda, seperti subwindow size dan jumlah layer *cascade*. Hasil penelitian mereka menyebutkan bahwa *gentle adaboost* memiliki kinerja yang paling baik berdasarkan *ROC curve*.

Penelitian yang dilakukan oleh Zhang, Shen, Xiao, dan Li (Zhang, Shen, Xiao, & Li, 2010) menggunakan *global feature* dan *local feature* berbasis *adaboost* untuk mendeteksi plat nomor. Kedua *feature* ini dikombinasikan dalam *cascade detector*. Metode yang mereka usulkan memperoleh nilai *recall rate* sebesar 93,5%.


Algoritma *adaboost* akurat dalam mendeteksi plat nomor dan tidak terikat dengan ukuran, warna, dan posisi plat nomor (Zhang, Shen, Xiao, & Li, 2010). Namun, akurasi algoritma ini ini rendah ketika terdapat banyak region palsu pada gambar input (Wu & Ai, 2008). Oleh karena itu, pada penelitian diusulkan proses reduksi region palsu pada bagian *online recognizing* algoritma *adaboost* menggunakan operasi *mathematical morphology*.

## 3 MODEL YANG DIUSULKAN


Kami mengusulkan mengintegrasikan operasi *mathematical morphology* pada bagian *online recognizing* algoritma *adaboost*. Operasi *mathematical morphology* yang digunakan adalah *top-hat transform* dan *dilation*. Operasi *mathematical morphology* ini akan mereduksi region palsu pada gambar input. Setelah itu, *Cascade detector* tinggal memindai kandidat region plat nomor tersebut untuk menentukan region kandidat plat nomor yang valid. Pada

Gambar 2 dan Gambar 3 ditampilkan masing-masing skema algoritma *adaboost* standard dan model yang diusulkan.

Model standard dari algoritma *adaboost* terdiri dari dua bagian, yaitu bagian *offline training* dan bagian *online recognizing*. Bagian *offline training* adalah bagian proses pelatihan data yang tidak bekerja secara *realtime*. Bagian ini meliputi penginputan sampel gambar positif dan sampel gambar negatif, preprocessing, pelatihan data oleh algoritma *adaboost* sampai membangun detektor. Setelah detektor terbentuk kita bisa melakukan pendeteksian secara *realtime/online recognizing* terhadap data pengujian. Sebelum melakukan pendeteksian dengan algoritma *adaboost*, terlebih dahulu data pengujian sudah harus mengalami preprocessing. Kemudian algoritma *adaboost* hasil pelatihan data berupa detektor akan melakukan pendeteksian objek dan menampilkan hasilnya.



Gambar 2. Skema Algoritma Adaboost Standard



Gambar 3. Skema Model yang Diusulkan

Pada penelitian ini diusulkan untuk melakukan reduksi region palsu dengan operasi-operasi *mathematical morphology* pada bagian *online recognizing*. Hasil output dari operasi *mathematical morphology* adalah region kandidat-kandidat plat nomor. Hal ini menjadikan kerja algoritma *adaboost* menjadi lebih ringan karena tidak perlu memindai gambar secara keseluruhan. Diharapkan dengan reduksi region palsu dengan operasi *mathematical morphology* ini akurasi deteksi

algoritma *adaboost* meningkat dan menurunkan tingkat kesalahan deteksi.

Sebelum proses ekstraksi *feature* terlebih dahulu dilakukan *preprocessing*. Hal ini dilakukan untuk mengurangi kompleksitas proses selanjutnya. Terlebih dahulu gambar RGB dikonversi ke *grayscale* dengan persamaan:

$$\text{Gray} = 0.0229R + 0.587G + 0.114B \quad (1)$$

Setelah itu semua gambar untuk pelatihan data mengalami proses normalisasi variance. Ingat bahwa:

$$\sigma^2 = m^2 - \frac{1}{N} \sum x^2 \quad (2)$$

Di mana  $\sigma$  adalah standard deviasi,  $m$  adalah mean, dan  $x$  adalah nilai pixel pada gambar.

*Feature* yang diekstrak oleh algoritma *adaboost* adalah *haar feature*. Nilai *haar feature* adalah perbedaan antara jumlah piksel dalam daerah hitam dan daerah putih sehingga dapat mencerminkan perubahan skala pada gambar *grayscale*. *Haar feature* diekstrak menggunakan *integral image*. Kemudian algoritma *adaboost* akan melakukan seleksi terhadap *feature* dan melakukan pembobotan untuk membentuk *classifier* lemah. Gabungan dari *classifier* lemah membentuk *classifier* kuat. Pada Gambar 4 ditunjukkan skema detail algoritma *adaboost*.

*Haar feature* dihitung melalui *integral image*. Nilai pada *integral image* pada setiap titik  $(x,y)$  dapat dinyatakan sebagai jumlah titik piksel atas kiri saat ini dan dihitung melalui persamaan berikut:

$$ii(x,y) = \sum_{x' \leq x, y' \leq y} i(x',y') \quad (3)$$


Dimana  $ii(x,y)$  adalah *integral image* yang telah dihitung dan  $i(x',y')$  adalah gambar *grayscale* original.

Varian Algoritma *adaboost* yang akan digunakan adalah *gentle adaboost*. Adapun langkah demi langkah algoritma *gentle adaboost* adalah sebagai berikut:

1. Dimulai dengan inisialisasi bobot  $W_i = 1/N, I = 1, 2, \dots, N, F(x) = 0$
2. Ulangi untuk  $m = 1, 2, \dots, M$ :
  - A. Ulangi untuk  $m = 1, 2, \dots, M$ : Neg = menset nilai sample negatif
  - B. Sesuaikan dengan fungsi regresi  $f_m(x)$  dengan pembobotan least-squares dari  $y_i$  ke  $x_i$  dengan bobot  $w_i$
  - C. Update  $F(x) \leftarrow F(x) + f_m(x)$
  - D. Update  $w_i(x) \leftarrow w_i \exp(-y_i f_m(x_i))$  dan normalisasi ulang
3. Output classifier  
 $\text{sign}[F(x)] = \text{sign}[\sum_{m=1}^M f_m]$

Proses berikutnya adalah membentuk *cascade detector*. Tahapan dalam *cascade* ini dibangun oleh pelatihan *classifier* menggunakan *adaboost* dan kemudian menyesuaikan nilai ambang batas untuk meminimalkan negatif palsu. Pada Gambar 5 ditunjukkan *cascade detector*. Algoritma pelatihan untuk membangun *cascade detector* adalah sebagai berikut:

1. Pengguna memilih nilai untuk  $f_i$ , yaitu tingkat maksimum *false positive* dapat diterima per tahap dan  $d_i$ , yaitu tingkat deteksi minimum yang dapat diterima per tahap.
2. Pengguna memilih target keseluruhan dari tingkat *false positive*  $F_{\text{target}}$
3. Pos = menset nilai sample positif
4. Neg = menset nilai sample negatif
5.  $F_0 = 1.0, D_0 = 1.0, i = 0$
6.  $i = 0$
7. While  $F_i > F_{\text{target}}$ 
  - A.  $i \leftarrow i + 1$
  - B.  $n_i = 0; F_i = F_{i-1}$
  - C. While  $F_i > f \times F_{i-1}$ 
    - a.  $n_i \leftarrow n_i + 1$
    - b. Gunakan Pos dan Neg untuk melatih *classifier* dengan fitur  $n_i$  menggunakan *adaboost*
    - c. Lakukan evaluasi terhadap *classifier cascade* saat ini untuk menentukan  $F_i, D_i$
    - d. Menurunkan *threshold* untuk *classifier* ke  $i$  sampai *classifier* saat ini memiliki tingkat deteksi setidaknya  $d \times D_{i-1}$
  - D.  $N \leftarrow \phi$
  - E. If  $F_{i+1} > F_{\text{target}}$  maka lakukan evaluasi pada *cascade detector* saat ini menjadi bukan plat nomor dan menempatkan setiap pendeteksian palsu ke dalam Neg



Gambar 4. Skema Algoritma Adaboost

Operasi *mathematical morphology* bekerja pada gambar biner dan dapat diperluas ke gambar *grayscale*. Terlebih dahulu gambar RGB dikonversi ke *grayscale*. Setelah gambar dikonversi menjadi gambar *grayscale*, kontras dari gambar *foreground* akan ditingkatkan. *Top-hat transform* merupakan hasil subtraksi gambar input dengan gambar yang telah mengalami operasi *opening*. Operasi ini menekan *background* gelap dan menyoroti *foreground* sehingga kontras gambar *foreground* meningkat. *Top-hat transform* dapat dituliskan dengan persamaan berikut ini:

$$\text{TopHat}(\text{src}) = \text{src} - \text{open}(\text{src}) \quad (4)$$

Gambar *grayscale* yang kontrasnya sudah ditingkatkan akan diubah ke gambar biner. Gambar biner tersebut perlu ditekankan. Hal ini dilakukan untuk mengantisipasi hasil biner yang kurang baik dan menggabungkan region berdekatan pada gambar. Di sini operasi *dilation* akan diterapkan dan hasil outputnya adalah berupa kandidat plat nomor. *Dilation* dapat dituliskan dengan persamaan berikut ini:

$$D(A, B) = A \oplus B \quad (5)$$

Dimana A adalah gambar input dan B adalah *structuring element*.

#### 4 HASIL EKSPERIMEN

13 layer *cascade detector* akan dilatih dengan algoritma *adaboost* berdasarkan gambar sampel positif dan gambar sampel negatif. Jumlah sampel gambar positif adalah 2720 gambar dan jumlah sampel gambar negatif adalah 2864.. Adapun setting parameter lain yang dilakukan pada algoritma *adaboost*, yaitu *boosting = gentle adaboost*, *min hit rate = 0.995000*, *max false alarm = 0.500000*, *mode = ALL*, *subwindow size = 40x15, 43x16, 47x15, dan 50x19*. Pada eksperimen ini akan dicoba empat nilai *subwindow size* yang berbeda untuk menemukan akurasi deteksi yang terbaik. Nilai *subwindow size* yang digunakan, yaitu 40x15, 43x16, 47x15, dan 50x19.

Setelah tahap training selesai, maka akan terbentuk *classifier* berupa 4 *cascade detector* dengan *subwindow size* 40x15, 43x16, 47x15, dan 50x19. Masing-masing *cascade detector* itu akan diuji untuk mendeteksi plat nomor pada data pengujian dengan tiga nilai *scale factor* berbeda. Adapun nilai *scale factor* yang digunakan, yaitu 1,1, 1,2, dan 1,3. Dengan demikian, sembilan model *cascade detector* akan diuji untuk mencari akurasi deteksi yang terbaik. Metode pengujian yang akan digunakan, yaitu *precision rate* dan *recall rate*. Berikut ini persamaan untuk menghitung *precision rate* dan *recall rate*.

$$\text{Precision rate} = \frac{TP}{TP + FP} \quad (7)$$

$$\text{Recall rate} = \frac{TP}{TP + FN} \quad (8)$$

Di mana TP adalah *true positive*, FP adalah *false positive*, dan FN adalah *false negative*.

Setelah ditemukan model pengaturan *subwindow size* dan *scale factor* terbaik, maka model tersebut akan diimplementasikan dan akan ditambahkan operasi *mathematical morphology* pada bagian *online recognizing*. Operasi *mathematical morphology* akan mereduksi region palsu dan menghasilkan kandidat region plat nomor. Operasi *mathematical morphology* yang digunakan adalah *top-hat transform* dan *dilation*. Adapun untuk nilai *structuring element* (SE) dan *anchor point* untuk operasi *top-hat transform* adalah masing-masing 13,3 dan 5,2. Sedangkan nilai SE dan *anchor point* untuk operasi *dilation* adalah masing-masing 10,3 dan 5,2. *Cascade detector* tinggal memindai kandidat region plat nomor yang valid. Pengujian berikutnya adalah mengomparasi *classifier* hasil training algoritma *adaboost* standard dengan *classifier* hasil training dari integrasi algoritma *adaboost* dan *mathematical morphology*. Metode pengujian yang digunakan juga sama, yaitu *precision rate* dan *recall rate*. Pada Gambar 5 ditunjukkan hasil deteksi dari algoritma *adaboost* terhadap plat nomor Indonesia dengan berbagai variasi plat nomor. Pada Gambar 6 ditunjukkan langkah-langkah hasil deteksi model yang diusulkan, yaitu integrasi algoritma *adaboost* dan *mathematical morphology*.


Beberapa hasil deteksi yang kurang akurat dari algoritma *adaboost* tetapi akurat dengan model yang diusulkan ditunjukkan pada Gambar 7 dan Gambar 8. Gambar 7 di sebelah kiri menunjukkan deteksi yang kurang akurat dari algoritma *adaboost* (*false positive*) dan gambar sebelah kanan menunjukkan hasil deteksi yang akurat dari model yang

diusulkan. Gambar 8 di sebelah kiri menunjukkan deteksi yang kurang akurat dari algoritma *adaboost* (*false negative*) dan gambar sebelah kanan menunjukkan hasil deteksi yang akurat dari model yang diusulkan.

Pada Tabel 1, Tabel 2, Tabel 3, dan Tabel 4 ditunjukkan nilai *precision rate* dan *recall rate* masing-masing *subwindow* berukuran 40x15, 43x16, 47x15, dan 50x19 dengan *tiga scale factor* berbeda.

Beberapa model algoritma *adaboost* dari eksperimen yang telah dilakukan kebanyakan menghasilkan nilai *precision rate* yang rendah, bahkan ada yang nilainya di bawah 20%. Hal ini berarti bahwa terlalu banyak region bukan plat nomor / *false positive* yang terdeteksi sebagai plat nomor oleh *classifier*. Hanya model *subwindow* berukuran 43x16 yang memiliki nilai *precision rate* yang tinggi. Nilai *precision rate* yang diperoleh 84,44%, 89,97%, dan 94,19% dengan masing-masing *scale factor* 1,1, 1,2, dan 1,3.


Untuk nilai *recall rate* secara umum semua model telah mencapai nilai di atas 60%. Empat model yang memperoleh nilai *recall rate* di atas 80%, yaitu *subwindow* berukuran 40x15 *scale factor* 1,1, *subwindow* berukuran 43x16 *scale factor* 1,1, *subwindow* berukuran 47x15 *scale factor* 1,1, dan *subwindow* berukuran 50x19 *scale factor* 1,1 dengan masing-masing nilai 82,74%, 84,62%, 83,99%, dan 89,18%. Hal menarik yang ditemukan, yaitu semua *subwindow* dengan *scale factor* 1,1 memiliki nilai *recall rate* tertinggi dibandingkan dengan *scale factor* 1,2 dan 1,3.



Gambar 5. Hasil Deteksi Algoritma Adaboost



Gambar 6. Langkah-Langkah Deteksi Model yang Diusulkan



Gambar 7. False Positive Tidak Terjadi



Gambar 8. False Negative tidak Terjadi

Tiga model algoritma *adaboost* yang hanya memperoleh nilai yang tinggi pada salah satu parameter, memperoleh nilai *precision rate* yang tinggi tapi rendah pada *recall rate*, dan sebaliknya. Contohnya nilai *precision rate* pada model *subwindow* berukuran 43x16 *scale factor* 1,3 yang memperoleh nilai *precision rate* tertinggi, yaitu 94,19%, tapi memperoleh nilai *recall rate* yang rendah, yaitu 64,03%. Begitu juga dengan model *subwindow* berukuran 43x16 *scale factor* 1,2 memperoleh nilai *precision rate* yang tinggi, yaitu 89,97%, tapi memperoleh nilai yang rendah pada *recall rate*, yaitu 63,41%. Hal ini berarti bahwa terjadi kesalahan yang tinggi berupa banyaknya region yang kenyataannya plat nomor tidak terdeteksi sebagai plat nomor / *false negative* oleh *classifier*. Begitu juga dengan model *subwindow* berukuran 50x19 memperoleh nilai *recall rate* tertinggi, yaitu 89,18% tapi *drop* pada nilai *precision rate* yang hanya bernilai 19,35%. Hal ini berarti bahwa terjadi kesalahan yang sangat tinggi berupa sangat banyak region bukan plat nomor yang terdeteksi sebagai plat nomor. Terdapat satu model yang memperoleh nilai *precision rate* dan *recall rate* yang sama-sama tinggi, yaitu *subwindow* berukuran 43x16 *scale factor* 1,1. Nilai *precision rate* model ini sebesar 90,48% dan nilai *recall rate* sebesar 88,67%.

Tabel 1. Precision dan Recall Subwindow 40x15

| Scale factor | Hits (TP) | Missed (FN) | False (FP) | Precision | Recall |
|--------------|-----------|-------------|------------|-----------|--------|
| 1.1          | 398       | 83          | 3115       | 11,20%    | 82,74% |
| 1.2          | 329       | 152         | 857        | 27,74%    | 68,40% |
| 1.3          | 308       | 173         | 1802       | 15,59%    | 64,03% |

Tabel 2. Precision dan Recall Subwindow 43x16

| Scale factor | Hits (TP) | Missed (FN) | False (FP) | Precision | Recall |
|--------------|-----------|-------------|------------|-----------|--------|
| 1.1          | 407       | 74          | 75         | 84,44%    | 84,62% |
| 1.2          | 305       | 176         | 34         | 89,97%    | 63,41% |
| 1.3          | 308       | 173         | 19         | 94,19%    | 64,03% |

Tabel 3. Precision dan Recall Subwindow 47x15

| Scale factor | Hits (TP) | Missed (FN) | False (FP) | Precision | Recall |
|--------------|-----------|-------------|------------|-----------|--------|
| 1.1          | 404       | 77          | 1461       | 21,66%    | 83,99% |
| 1.2          | 340       | 141         | 859        | 28,36%    | 70,69% |
| 1.3          | 298       | 183         | 657        | 31,20%    | 61,95% |

Tabel 4. Precision dan Recall Subwindow 50x19

| Scale factor | Hits (TP) | Missed (FN) | False (FP) | Precision | Recall |
|--------------|-----------|-------------|------------|-----------|--------|
| 1.1          | 429       | 12          | 1788       | 19,35%    | 89,18% |
| 1.2          | 380       | 101         | 1013       | 27,28%    | 79%    |
| 1.3          | 345       | 136         | 879        | 28,19%    | 71,73% |

Pada penelitian ingin dikembangkan *classifier* yang bernilai tinggi berdasarkan dua parameter pengukuran, yaitu *precision rate* dan *recall rate*. Jika kedua parameter ini nilainya sama-sama tinggi berarti *classifier* yang dibangun memiliki tingkat akurasi deteksi yang tinggi dan memiliki tingkat kesalahan deteksi yang rendah. Dengan alasan itulah model *subwindow* berukuran 43x16 *scale factor* 1,1 ditetapkan pada algoritma *adaboost*. Setelah itu algoritma *adaboost*

dengan model pengaturan terbaik tadi akan ditambahkan operasi *mathematical morphology* di bagian *online recognizing*. Pengujian berikutnya adalah mengomparasi akurasi dari algoritma *adaboost* standard dengan metode integrasi algoritma *adaboost* dan *mathematical morphology*. Parameter pengukuran yang digunakan juga sama. Pada Tabel 5 ditunjukkan komparasi antara algoritma *adaboost* dengan model yang diusulkan berdasarkan *precision rate* dan *recall rate*.

Dari hasil komparasi antara algoritma *adaboost* standard dan model yang diusulkan berdasarkan dari parameter *precision rate* dan *recall rate* menunjukkan bahwa model yang diusulkan, yaitu integrasi algoritma *adaboost* dan *mathematical morphology* memiliki kinerja deteksi yang lebih akurat. Nilai *precision rate* dan *recall rate* dari metode yang diusulkan masing-masing adalah 94,47% dan 92,31%. Sedangkan algoritma *adaboost* standard memiliki nilai *precision rate* dan *recall rate* yang lebih rendah, yaitu masing-masing 84,44% dan 84,62%. Nilai *precision rate* dan *recall rate* dari integrasi algoritma *adaboost* dan *mathematical morphology* masing-masing lebih tinggi 10,03% dan 7,69% dari nilai *precision rate* dan *recall rate* dari algoritma *adaboost* standard.

Tabel 5. Komparasi Algoritma Adaboost dengan Model yang Diusulkan

| Metode                    | Hits (TP) | Missed (FN) | False (FP) | Precision | Recall |
|---------------------------|-----------|-------------|------------|-----------|--------|
| Algoritma <i>adaboost</i> | 407       | 74          | 75         | 84,44%    | 84,62% |
| Model yang diusulkan      | 444       | 37          | 26         | 94,47%    | 92,31% |

## 5 KESIMPULAN

Dari hasil eksperimen yang telah dilakukan pada dplat nomor Indonesia, dapat ditarik kesimpulan bahwa penerapan algoritma *adaboost* dan *mathematical morphology* lebih akurat dalam mendeteksi plat nomor Indonesia yang kebanyakan memiliki warna *background* yang mirip dengan warna mobil serta memiliki variasi yang besar dalam bentuk dan ukuran. Selain itu, dengan mengintegrasikan algoritma *adaboost* dengan operasi *mathematical morphology* pada bagian *online recognizing*, ternyata dapat mengatasi kekurangan dari algoritma *adaboost* yang akurasi rendahnya ketika mendeteksi objek pada gambar input yang banyak memiliki region palsu. Nilai *precision rate* dan *recall rate* dari integrasi algoritma *adaboost* dan *mathematical morphology* masing-masing 94,47% dan 92,31%. Kedua nilai ini lebih tinggi 10,03% dan 7,69% dari nilai *precision rate* dan *recall rate* algoritma *adaboost* standard.

Metode integrasi algoritma *adaboost* dan *mathematical morphology* memang terbukti akurat untuk deteksi plat nomor yang memiliki warna *background* yang mirip dengan warna mobil, memiliki variasi yang besar dalam bentuk dan ukuran, dan terdapat banyak region palsu pada gambar input. Namun, di penelitian yang akan datang, ada beberapa pekerjaan yang perlu dilakukan. Beberapa gambar input yang region plat nomornya memiliki cahaya yang sangat terang, tidak terdeteksi sebagai plat nomor oleh *classifier*. Perlu sekali mencari metode yang tepat untuk memecahkan permasalahan tersebut.

## REFERENSI

- Abolghasemi, V., & Ahmadyfard, A. (2007). Local Enhancement of Car Image for License Plate Detection. *15th European Signal Processing Conference*, (pp. 2179-2183). Poznan.
- Anishiya, P., & Joans, S. M. (2011). Number Plate Recognition for Indian Cars Using Morphological Dilation and Erosion with the Aid Of Ocrs. *International Conference on Information and Network Technology*, (pp. 115-119). Singapore.
- Chang, S.-L., Chen, L.-S., Chung, Y.-C., & Chen, S.-W. (2004). Automatic license plate recognition. *IEEE Transactions on Intelligent Transportation System*, 5(1), 42-53.
- Cui, D., Gu, D., Member, IEEE, Cai, H., & Sun, J. (2009). License Plate Detection Algorithm Based on Gentle AdaBoost Algorithm with a Cascade Structure. *International Conference on Robotics and Biomimetics*, (pp. 1962-1966). Guilin.
- Cui, Z., & Xie, M. (2009). A Method for Blue Background White Characters Car License Plate Location. *Computer Science and Information Technology*, (pp. 393-395).
- Dlagnekov, L. (2004). *License Plate Detection Using Adaboost*. San Diego.
- Dupont. (2010, December). Retrieved from Dupont Web site: [http://www2.dupont.com/Media\\_Center/en\\_US/daily\\_news/december/article20101208.html](http://www2.dupont.com/Media_Center/en_US/daily_news/december/article20101208.html)
- Liu, Y., Cui, L., Shu, J., & Xin, G. (2011). License Plate Location Method Based on Binary Image Jump and Mathematical Morphology. *International Journal of Digital Content Technology and its Applications*, 259-265.
- Sirithinaphong, T., & Chamnongthai, K. (1998). Extraction of Car License Plate Using Motor Vehicle Regulation and Character Pattern Recognition. *Proceedings of the 1998 IEEE Asia-Pacific Conference on Circuits and Systems*, (pp. 559-562). Chiangmai.
- Sulehria, H. K., Zhang, Y., & Irfan, D. (2007). Mathematical Morphology Methodology for Extraction of Vehicle Number Plates. *International Journal of Computers*, 1(3), 69-73.
- Sun, G., Li, G., Xu, L., & Wang, J. (2009, December). The Location and Recognition of Chinese Vehicle License Plates under Complex Backgrounds. *Journal of Multimedia*, 4, 442-449.
- Suri, P., Walia, E., & Verma, E. A. (2010, Dec). Vehicle Number Plate Detection using Sobel Edge Detection Technique. *International Journal of Computer Science and Technology*, 1(2), 179-182.
- Viola, P., & Jones, M. J. (2004). Robust Real-Time Face Detection. *International Journal of Computer Vision*, 137-154.
- Wu, Y.-W., & Ai, X.-Y. (2008). An Improvement of Face Detection Using AdaBoost with Color Information. *ISECS International Colloquium on Computing, Communication, Control, and Management*, (pp. 317-321).
- Zhang, X., Shen, P., Xiao, Y., & Li, B. (2010). License Plate-Location using Adaboost Algorithm. *Information and Automation*, (pp. 2456-2461). Harbin.
- Zhao, Y., Gu, J., Liu, C., Han, S., Gao, Y., & Hu, Q. (2010). License Plate Location Based on Haar-like Cascade Classifiers and Edges. *Second WRI Global Congress on Intelligent Systems*, (pp. 102-105).

## BIOGRAPHY OF AUTHORS



**Muhammad Faisal Amin.** Received S.Kom degrees in information system from STMIK Banjarbaru, Indonesia and M.Kom degrees in informatic engineering from Dian Nuswantoro University, Indonesia. He is a lecturer at the Under Graduate School of information technology, Lambung Mangkurat University, Indonesia. He is also a founder and chief executive officer of Adcoms, Inc., a software development company in Indonesia. His current research interests include computer vision and machine learning.



**Romi Satria Wahono.** Received B.Eng and M.Eng degrees in Computer Science respectively from Saitama University, Japan, and Ph.D in Software Engineering from Universiti Teknikal Malaysia Melaka. He is a lecturer at the Graduate School of Computer Science, Dian Nuswantoro University, Indonesia. He is also a founder and chief executive officer of Brainmatics, Inc., a software development company in Indonesia. His current research interests include software engineering and machine learning. Professional member of the ACM, PMI and IEEE Computer Society.