

Aerial Image Segmentation with Clustering Using Fireworks Algorithm

Muhammad Hariz Arasy¹, Suyanto², Kurniawan Nur Ramadhani³

School of Computing, Telkom University

Jl. Telekomunikasi Terusan Buah Batu, Bandung, West Java 40257, Indonesia

¹ harizmhd@student.telkomuniversity.ac.id, ² suyanto@telkomuniversity.ac.id, ³ kurniawannr@telkomuniversity.ac.id

Abstract

As an improved method of the standard Fireworks Algorithm, which is one of the swarm intelligence methods, the Adaptive Fireworks Algorithm (AFWA) can be exploited to optimize any cluster-based segmentation method. In this paper, AFWA is applied to perform aerial image segmentation and its performance is then compared to K-means. Since aerial imagery has different data characteristics when compared to other types of images, the segmentation quality is assessed systematically using special benchmarks. Two evaluation metrics are used here. First, Probabilistic Rand Index (PRI). Second, Variation of Information (VI). The experimental results show that AFWA produces better segmentation qualities than K-means.

Keywords: Image segmentation, aerial image, clustering, adaptive fireworks algorithm.

Abstrak

Sebagai perbaikan dari *Algoritma Fireworks* standar, yang merupakan salah satu metode *swarm intelligence*, Adaptive Fireworks Algorithm (AFWA) dapat dimanfaatkan untuk mengoptimasi metode segmentasi berbasis kluster. Pada makalah ini, AFWA diterapkan untuk melakukan segmentasi gambar udara dan selanjutnya kinerjanya dibandingkan dengan K-means. Berhubung pencitraan udara memiliki karakteristik data yang berbeda dibanding jenis gambar lain, maka kualitas segmentasi dinilai secara sistematis menggunakan alat ukur khusus. Di sini digunakan dua metrik evaluasi. Pertama, *Probabilistic Rand Index* (PRI). Kedua, *Variation of Information* (VI). Hasil percobaan menunjukkan bahwa AFWA menghasilkan kualitas segmentasi yang lebih baik daripada K-means.

Kata Kunci: Segmentasi citra, citra udara, *clustering*, *adaptive fireworks algorithm*.

I. PENDAHULUAN

CITRA udara dan citra satelit merupakan jenis citra digital yang digunakan pada *remote sensing*. Perbedaan mendasar yang dimiliki citra udara jika dibandingkan dengan citra satelit adalah proses pemotretannya yang dilakukan dibawah ketinggian awan sehingga menghasilkan citra yang lebih detail dan kompleks. Sebuah citra udara dapat menyediakan data yang digunakan dalam pengambilan keputusan pada pengendalian bencana alam, pengembangan wilayah kota, dan pemantauan lingkungan. Untuk mendapatkan data ini, informasi pada citra udara harus terlebih dahulu diekstrak menjadi format yang dapat dibaca oleh sistem penganalisis citra. Proses ekstraksi ini dikenal dengan proses segmentasi citra. Pada proses segmentasi, citra dipartisi ke dalam *region* (bagian-bagian) yang berbeda. Setiap *region* harus se-homogen mungkin dan sekaligus harus berbeda antar satu sama lain.

Secara garis besar, metode-metode segmentasi citra dapat dikategorikan ke dalam metode berbasis *edge detection*, *thresholding*, *clustering*, dan *region merging* [2]. Tidak semua metode ini bekerja dengan baik pada citra udara. Metode berbasis *edge detection* dan metode berbasis *thresholding* lebih efektif jika digunakan pada citra sederhana yang memiliki objek dengan latar belakang yang kontras [12]. Sementara itu, metode berbasis *region merging* digunakan secara luas oleh komunitas *remote sensing*. Hanya saja,

kelemahan metode berbasis *region merging* adalah dibutuhkannya bantuan *user* dalam menentukan titik awal *region*. Akibatnya, kualitas hasil segmentasi menjadi sangat bergantung pada pemahaman *user* terkait citra yang disegmentasi. Di sisi lain, metode berbasis *clustering* memberikan hasil yang secara keseluruhan cukup baik pada berbagai macam jenis citra [12], baik itu citra natural, citra sintetik, maupun citra udara. Metode yang umum digunakan secara luas adalah *K-means Clustering* [4]. Metode ini bekerja sangat cepat. Tetapi, kualitas segmentasi sangat bergantung pada jumlah *cluster* yang ditentukan oleh *user*. Dalam menentukan jumlah *cluster*, diperlukan pemahaman yang mendalam terhadap data yang hendak dikelompokkan. Tapi untungnya, pada bidang segmentasi citra telah diusulkan metode untuk menentukan jumlah *cluster* secara otomatis [9].

A. Latar Belakang

Fireworks Algorithm (FWA) merupakan salah satu algoritma *metaheuristic* yang menggunakan konsep *Swarm Intelligence* (SI). Sebuah sistem SI memanfaatkan sejumlah *simple agents* berkecerdasan sederhana yang kemudian saling berinteraksi dengan satu sama lain untuk menyelesaikan suatu tugas yang kompleks. Algoritma SI biasa digunakan sebagai alternatif dari algoritma *non-heuristic* dalam menyelesaikan permasalahan *clustering* dan *optimization*. Sejak diperkenalkan tahun 2010 [10], FWA telah dikembangkan secara signifikan menjadi dua variasi, yaitu: *Enhanced FWA* [14] dan *Adaptive FWA* [3]. Berdasarkan hasil dari [10], FWA terbukti memiliki kecepatan konvergensi dan akurasi solusi global yang lebih unggul dibandingkan algoritma SI lainnya.

B. Masalah dan Batasan

Algoritma EFWA dan AFWA belum pernah digunakan untuk melakukan segmentasi citra. FWA di sisi lain, sudah pernah digunakan untuk segmentasi dengan metode berbasis *thresholding* [11] dan metode berbasis *clustering* [6]. Pada kedua penelitian, segmentasi dilakukan pada sejumlah citra *grayscale* yang sebagian besar merupakan citra natural dan citra sintetik. Dengan kata lain, FWA belum pernah digunakan untuk proses segmentasi yang berfokus pada citra udara. Selain itu, kedua penelitian membuktikan bahwa FWA dapat memberikan kualitas yang sebanding dengan algoritma *state-of-art* dari SI. Kualitas FWA telah dinilai berdasarkan kemampuannya dalam mengoptimasi fungsi objektif pada [11] dan dalam mengoptimasi kepadatan dan keterpisahan antar *cluster* pada [6]. Hanya saja, bagaimana hasil segmentasi FWA dapat memenuhi kebutuhan dari proses analisis citra, belum dibahas pada kedua penelitian.

C. Solusi yang Diusulkan

Pada penelitian ini, AFWA diimplementasikan untuk melakukan segmentasi pada citra udara. AFWA dipilih ketimbang FWA dan EFWA karena memiliki performansi yang lebih baik serta merupakan perbaikan dari kedua algoritma tersebut. Kualitas hasil segmentasinya kemudian dinilai secara sistematis dengan menggunakan benchmark yang khusus untuk mengevaluasi segmentasi citra udara. Agar dapat melakukan segmentasi citra, AFWA dapat diimplementasikan sebagai alternatif dari algoritma K-means dalam mengoptimasi proses *clustering* pada metode segmentasi berbasis *clustering*. Teknik *clustering* dipilih selain karena sudah pernah diaplikasikan pada FWA dasar, juga karena lebih sesuai untuk citra udara dibandingkan dengan metode berbasis *thresholding*.

Tujuan dari penelitian ini adalah untuk mengevaluasi AFWA dalam melakukan segmentasi citra udara. Kinerja AFWA dibandingkan dengan kinerja K-means berdasarkan kualitas hasil *clustering* dan kualitas hasil segmentasi. K-means digunakan sebagai pembanding karena merupakan versi *non-heuristic* dari metode segmentasi yang digunakan AFWA pada penelitian ini. Dengan membandingkan kedua metode, seberapa besar kemajuan yang diberikan oleh AFWA dapat diukur dengan jelas.

D. Organisasi Penulisan

Pada bagian 2 akan diulas secara ringkas mengenai *clustering*, konsep dasar dan perkembangan FWA hingga AFWA, dan *benchmark* yang digunakan pada penelitian ini. Pada bagian 3 akan dijelaskan mengenai metode segmentasi yang diusulkan. Kemudian pada bagian 4 akan dipaparkan hasil eksperimen dan evaluasi. Terakhir, pada bagian 5 disampaikan kesimpulan.

II. TINJAUAN PUSTAKA

A. Clustering

Konsep dasar dari *clustering* adalah menemukan kesamaan antar data dan mengelompokkannya ke dalam satu kelompok. Proses pengelompokan ini dilakukan dengan cara memaksimalkan kesamaan data di dalam kelompok dan meminimalkan kesamaan data antar kelompok [2]. Tingkat kesamaan ini dapat diukur menggunakan pengukuran jarak Euclidean, Cosine, Jaccard, dll.

Algoritma *clustering* yang umum digunakan adalah K-means [4]. Algoritma ini membagi sebanyak n data ke dalam k kelompok melalui serangkaian proses yang iteratif. Algoritma ini memiliki dua fase pada setiap iterasi-nya, yakni fase *assignment* dan fase *update*. Sebelum kedua fase ini dimulai, k *centroid* ditempatkan pada ruang data terlebih dahulu. Pada fase *assignment* setiap data dikelompokkan dengan *centroid* yang memiliki *mean* terdekat. Kemudian pada fase *update*, algoritma menghitung *means* dari tiap kelompok untuk menentukan *centroid* baru. Kedua fase ini terus diiterasi hingga fungsi kriteria mencapai nilai minimum [7].

B. Adaptive Fireworks Algorithm

FWA merupakan salah satu algoritma yang menggunakan konsep SI. Ciri khas dari algoritma SI adalah terdapatnya *simple agents* berkecerdasan sederhana yang saling berinteraksi dengan satu sama lain untuk mencapai suatu tujuan. Dalam proses pencarian solusi, *simple agents* pada sistem FWA menggunakan teknik eksplorasi dan eksploitasi yang terinspirasi oleh peristiwa ledakan kembang api [10]. Percikan api yang dihasilkan oleh ledakan kembang api dapat dipandang sebagai sebuah proses pencarian di sekitar titik tertentu. Posisi di mana kembang api akan meledak, dianggap sebagai suatu individu yang dinamakan *fireworks* atau *seed*. Di sekitaran individu tersebut akan bermunculan beberapa individu baru yang dinamakan *sparks* (percikan). *Sparks* terbaik pada setiap ledakan, akan menjadi *fireworks* pada ledakan berikutnya. Ledakan akan terus dihasilkan hingga suatu individu mengenai atau cukup dekat dengan titik solusi yang dicari.

Pada FWA, amplitudo setiap *fireworks* (yang merupakan satu faktor penting) dihitung berdasarkan perbedaan *fitness* antara *fireworks* tersebut dengan individu terbaik (yang *fireworks* atau *sparks*). Perhitungan ini menyebabkan ukuran amplitudo dari *fireworks* terbaik akan selalu bernilai 0 dan tidak terlalu memberikan kontribusi yang signifikan terhadap proses pencarian secara keseluruhan.

Untuk mengatasi permasalahan tersebut, pada EFWA [14] dilakukan pengecekan amplitudo setiap *fireworks*. Dengan menggunakan fungsi penurunan non-linear sebagai ambang batas minimal, amplitudo *fireworks* terbaik dijamin tidak akan bernilai 0 dan juga akan terus berkurang seiring meningkatnya iterasi. Penurunan amplitudo ini dilakukan guna mensimulasikan ruang pencarian yang semakin sempit seiring dengan semakin dekatnya solusi. Akan tetapi, fungsi penurunan ini sering kali tidak cocok dengan fungsi objektif. Pada fungsi objektif tertentu, amplitudo dapat berkurang terlalu cepat sehingga menyebabkan algoritma mencapai konvergensi sebelum waktunya. Sebaliknya, jika amplitudo berkurang terlalu lambat, ruang pencarian menjadi terlalu luas untuk dapat menemukan solusi yang persis.

AFWA [3] diusulkan oleh Li et al. untuk memperbaiki EFWA. Pada AFWA, digunakan sebuah metode adaptif yang menghitung amplitudo *fireworks* terbaik dengan menggunakan informasi yang didapat dari iterasi sebelumnya. Awalnya, pada iterasi pertama, amplitudo terbaik diatur sesuai jarak maksimum dari ruang pencarian. Kemudian pada akhir setiap iterasi, dipilih satu individu (*fireworks* atau *sparks*) dengan *fitness* yang lebih buruk sekaligus memiliki jarak paling dekat dengan *fireworks* terbaik. Jarak ini kemudian dijadikan sebagai amplitudo dari *fireworks* terbaik pada iterasi berikutnya. Metode ini akan menghasilkan amplitudo adaptif yang memiliki peran penting dalam mengendalikan skala pencarian agar sesuai dengan fase pencarian yang sedang dijalani. Sehingga diharapkan algoritma dapat beralih dari fase pencarian global ke fase pencarian lokal dengan laju yang tepat.

C. ASD Benchmark

Aerial image Segmentation Data set (ASD) [13] berisi 80 citra udara beresolusi tinggi berukuran 512×512 piksel. *Data set* terdiri dari berbagai macam obyek, di antaranya sekolah, perumahan, kota, gudang dan pembangkit listrik. ASD juga menyediakan *ground-truth* yang terdiri dari hasil segmentasi

yang dibuat oleh 4 orang subyek manusia. *Ground-truth* dapat digunakan sebagai *benchmark* untuk mengukur kualitas dari hasil segmentasi mesin. Pengukuran dilakukan dengan membandingkan hasil segmentasi mesin terhadap *ground-truth* dengan menggunakan metrik evaluasi. Nilai yang didapatkan dari hasil perhitungan metrik evaluasi, dapat merepresentasikan tingkat kemiripan antara hasil segmentasi mesin dan *ground-truth*. Dua metrik evaluasi yang digunakan oleh *ASD Benchmark* yang juga digunakan pada penelitian ini adalah PRI dan VI.

1) *Probabilistic Rand Index*: PRI awalnya diperkenalkan sebagai metode untuk mengevaluasi hasil *clustering* [8]. Cara kerja metrik ini adalah dengan membandingkan kecocokan antara sepasang data di dalam *cluster*. Indeks Rand dari hasil segmentasi S dan *ground-truth* G dihitung dari jumlah pasangan piksel yang memiliki label yang sama di S dan G serta pasangan dengan label yang berbeda di kedua segmentasi, akan dibagi dengan jumlah total pasangan piksel yang ada. Jika diketahui terdapat beberapa *ground-truth* pada himpunan G_k , maka PRI didefinisikan sebagai

$$PRI(S, G_k) = \frac{1}{T} \sum_{i < j} [c_{ij} p_{ij} + (1 - c_{ij})(1 - p_{ij})], \quad (1)$$

di mana c_{ij} adalah kejadian ketika piksel i dan j memiliki label yang sama, p_{ij} menyatakan probabilitasnya, dan T adalah jumlah total pasangan piksel yang ada [8]. Semakin besar nilai PRI, maka dapat dinyatakan bahwa kecocokan antara kedua segmentasi semakin tinggi.

2) *Variation of Information*: Metrik VI diperkenalkan sebagai metode untuk melakukan perbandingan *clustering* [5]. Metrik ini mengukur jarak antara dua segmentasi dalam hal rata-rata entropi kondisional dari kedua segmentasi. VI dari hasil segmentasi S dan *ground-truth* G didefinisikan sebagai

$$VI(S, G) = H(S) + H(G) - 2I(S, G), \quad (2)$$

di mana H dan I masing-masing menyatakan entropi dan kesamaan informasi antara hasil segmentasi S dan *ground-truth* G [5]. Jika beberapa *ground-truth* digunakan, maka diambil rata-rata dari seluruh hasil evaluasi *ground-truth* [1]. Semakin kecil nilai VI, maka dapat dinyatakan bahwa kesamaan informasi antara kedua segmentasi semakin tinggi.

III. SEGMENTASI CITRA MENGGUNAKAN AFWA

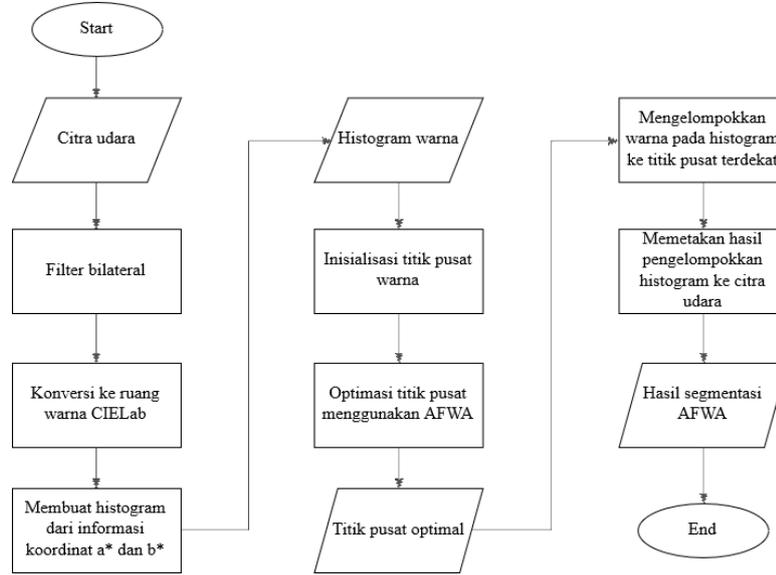
Pada metode *K-means Clustering*, segmentasi citra dilakukan dengan cara mengelompokkan piksel-piksel ke dalam *cluster* yang memiliki kesamaan fitur, seperti tingkat kecerahan, warna, pola tekstur, dan lokasi spasial. Piksel dikelompokkan dengan *centroid* (titik pusat) yang memiliki tingkat kemiripan fitur atau jarak terdekat. Disini, AFWA dapat digunakan untuk mengoptimasi peletakkan *centroid* dengan menggunakan fungsi objektif yang mengukur tingkat kemiripan *centroid* terhadap anggota *cluster*-nya.

Kebanyakan citra udara yang ada pada *data set* ASD memiliki *region* dengan tingkat kecerahan yang berbeda-beda. Contohnya sebuah bangunan dapat memiliki sekaligus bagian terang dan gelap pada bagian atapnya. Hal ini menyebabkan kesalahan segmentasi jika pengelompokkan yang dilakukan adalah berdasarkan tingkat kecerahan. Untuk itu, *clustering* pada K-means dan AFWA dilakukan berdasarkan warna.

Pada Gambar 1, dijabarkan langkah-langkah yang perlu dilalui dalam melakukan segmentasi suatu citra udara menggunakan AFWA. Secara garis besar, langkah-langkah tersebut dapat dikelompokkan menjadi tiga tahapan utama, yakni tahapan *preprocessing*, *clustering*, dan *output*.

A. Preprocessing

Masalah yang ditemukan pada citra ASD adalah *noise* (kebisingan gambar). Citra yang dipenuhi bagian-bagian kecil yang tidak berarti dapat menyebabkan kesalahan segmentasi. Untuk itu digunakan *filter* bilateral pada citra udara. *Filter* ini dipilih karena dapat mengurangi *noise* sambil tetap mempertahankan garis tepi pada citra.



Gambar 1: Alur segmentasi citra udara menggunakan AFWA

Setelah penerapan *filter*, agar dapat dilakukan pengelompokkan warna, citra udara terlebih dahulu diubah kedalam ruang warna CIELab. Koordinat L* pada CIELab menyatakan nilai *lightness* (tingkat kecerahan) pada suatu piksel, sedangkan koordinat a* dan b* menyatakan nilai warna. Agar *lightness* tidak mempengaruhi hasil segmentasi, koordinat L* tidak perlu dipersiapkan untuk proses *clustering*. Selanjutnya, dibuatkan histogram yang menyatakan distribusi nilai koordinat a* dan b*. *Clustering* warna dilakukan dengan mengelompokkan data pada histogram. Hal ini dilakukan untuk efisiensi waktu, mengingat banyaknya piksel pada citra yang memiliki warna yang sama.

B. AFWA Clustering

Dalam melakukan proses *clustering*, warna-warna pada citra dikelompokkan berdasarkan jarak warna tersebut terhadap *centroid* warna. Suatu individu pada sistem optimasi AFWA dapat merepresentasikan vektor koordinat a* dan b* dari N_c *centroid*. Vektor tersebut terbangun sebagai berikut:

$$x_i = (m_{i1a^*}, \dots, m_{ij a^*}, \dots, m_{iN_c a^*}, m_{i1b^*}, \dots, m_{ij b^*}, \dots, m_{iN_c b^*}) \quad (3)$$

di mana x_i menyatakan individu ke- i dari sistem optimasi AFWA, $m_{ij a^*}$ merupakan koordinat a* dari *centroid* ke- j milik individu ke- i , dan $m_{ij b^*}$ merupakan koordinat b* dari *centroid* ke- j milik individu ke- i . *Centroid* yang didapatkan dari suatu individu, digunakan untuk mengelompokkan histogram citra. Setiap warna pada histogram dikelompokkan dengan *centroid* terdekat berdasarkan jarak *squared euclidean*:

$$d(z_p, m_j) = (z_{pa^*} - m_{ja^*})^2 + (z_{pb^*} - m_{jb^*})^2 \quad (4)$$

di mana z_{pa^*} menyatakan data histogram ke- p pada koordinat a* dan m_{ja^*} menyatakan koordinat a* dari *centroid* ke- j . Hasilnya berupa *cluster* warna yang kualitasnya dapat diukur menggunakan *Quantization Error (QE)* sebagai berikut:

$$QE = \frac{\sum_{j=1}^{N_c} [\sum_{\forall Z_p \in C_{ij}} d(z_p, m_j) / |C_{ij}|]}{N_c} \quad (5)$$

di mana $|C_{ij}|$ menyatakan jumlah data yang dikelompokkan pada cluster ke- j dari individu ke- i . Selanjutnya nilai fitness didapat dari fungsi objektif:

$$fitness = 1/QE \quad (6)$$

di mana nilai *fitness* terbaik adalah nilai terbesar. Mengingat tujuan AFWA adalah menemukan vektor koordinat *centroid* yang menghasilkan *cluster* dengan *fitness* terbaik, maka AFWA diatur agar dapat memaksimalkan fungsi objektif. Rangkuman dari proses pengevaluasian *centroid* dari suatu individu x_i mulai dari ekstraksi *centroid* hingga didapatkan nilai *QE* dan *fitness*-nya dapat dilihat pada Algoritma 1.

Algorithm 1 Perhitungan *fitness* suatu individu

```
1: ekstraksi centroid dari vektor  $x_i$ 
2: for setiap data pada histogram do
3:   for setiap centroid pada individu  $x_i$  do
4:     hitung jarak centroid  $m_j$  terhadap data  $z_p$  menggunakan rumus (4)
5:   end for
6:   kelompokkan data  $z_p$  dengan centroid terdekat
7: end for
8: hitung quantization error menggunakan rumus (5)
9: hitung fitness menggunakan rumus (6)
10: return fitness
```

Algorithm 2 Optimasi AFWA

```
1: inialisasi sebanyak  $m$  fireworks di dalam  $UB$  dan  $LB$ 
2: untuk setiap fireworks, hitung fitness sesuai dengan Algoritma 1
3:  $A^* \leftarrow UB - LB$ 
4: repeat
5:   untuk setiap fireworks, hitung  $N_i$  berdasarkan jarak fitness-nya terhadap fitness terbaik
6:   untuk setiap fireworks, hitung  $A_i$  (kecuali  $A^*$ ) berdasarkan jarak fitness-nya terhadap fitness terbaik
7:   untuk setiap fireworks, bangkitkan sebanyak  $N_i$  sparks di dalam amplitudo  $A_i$ 
8:   bangkitkan sebanyak  $NG$  Gaussian sparks
9:   jarak antara fireworks terbaik dengan individu terdekat yang memiliki fitness lebih buruk ditetapkan sebagai  $A^*$  untuk iterasi selanjutnya
10:  untuk setiap individu (fireworks, sparks, dan gaussian sparks), evaluasi fitness sesuai dengan Algoritma 1
11:  tetapkan individu terbaik sebagai fireworks iterasi selanjutnya
12:  secara acak tetapkan  $m - 1$  dari individu sisanya sebagai fireworks iterasi selanjutnya
13: until kriteria penghentian terpenuhi
14: return individu terbaik beserta fitness-nya
```

Proses optimasi AFWA mulai dari proses inialisasi *centroid* hingga didapatkan *centroid* dengan *fitness* terbaik dijelaskan oleh Algoritma 2. Dengan m menyatakan jumlah dari *fireworks*, UB dan LB menyatakan batas atas dan batas bawah, A_i merupakan amplitudo dari *fireworks* ke- i , N_i menyatakan jumlah *sparks* dari *fireworks* ke- i , dan A^* merupakan amplitudo dari *fireworks* terbaik. Pada proses inialisasi *fireworks*, batas atas dan batas bawah menyesuaikan nilai tertinggi dan terendah pada histogram warna.

C. Output

Dari individu dengan *fitness* terbaik, maka didapat *centroid* yang digunakan untuk mengelompokkan histogram warna untuk terakhir kalinya. Hasil *clustering* dari histogram warna ini digunakan untuk memetakan label pada citra udara. Setelah setiap warna pada citra udara diberi label sesuai dengan indeks *cluster*-nya. Akhirnya, citra udara yang telah berlabel di-*output*-kan sebagai hasil segmentasi.

Tabel I: Perhitungan *Quantization Error* terhadap hasil *clustering* K-means dan AFWA

	QE	
	ODS	OIS
K-means	8.588	8.667
AFWA	6.878	6.754

Tabel II: Metrik evaluasi terhadap hasil segmentasi K-means dan AFWA

	PRI		VI	
	ODS	OIS	ODS	OIS
Human	0.826	0.838	1.049	1.002
K-means	0.469	0.474	3.134	3.119
AFWA	0.487	0.492	2.953	2.951

IV. HASIL DAN DISKUSI

Metode segmentasi K-means *clustering* digunakan sebagai pembanding dasar terhadap metode segmentasi AFWA *clustering*. Kedua algoritma dijalankan pada *data set* ASD hingga didapatkan hasil segmentasi berupa citra berlabel. Dua aspek yang dinilai dari kedua metode adalah kualitas hasil *clustering* dan kualitas hasil segmentasi. Dalam membandingkan kualitas hasil segmentasi, digunakan *benchmark framework* yang disediakan oleh *data set*. *Benchmark* ini bekerja dengan cara mengukur perbandingan antara segmentasi yang dihasilkan mesin dan segmentasi hasil buatan manusia dengan menggunakan metrik evaluasi. Pada penelitian ini, hasil segmentasi AFWA dan hasil segmentasi K-means diukur tingkat kemiripannya terhadap *ground-truth* dengan menggunakan perhitungan metrik PRI dan VI. Selanjutnya, untuk menilai kualitas hasil *clustering*, tingkat kerapatan *cluster* yang dihasilkan masing-masing algoritma diukur dengan membandingkan rata-rata *Quantization Error*.

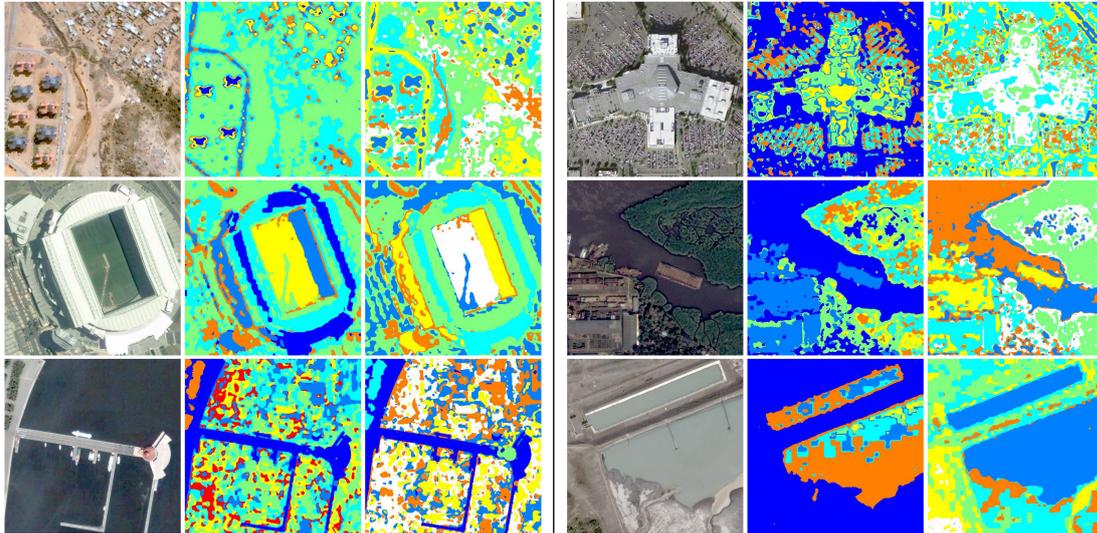
Berhubung kedua metode segmentasi berbasis *clustering*, maka hasil segmentasi yang dikeluarkan bergantung pada jumlah *centroid/cluster* yang dipilih. Berdasarkan cara pemilihan skala (jumlah *centroid*), terdapat dua kemungkinan percobaan. Pertama, *optimal data set scale* (ODS), yang digunakan ketika jumlah *centroid* yang dipilih merupakan jumlah *centroid* yang dianggap sebagai skala yang paling optimal untuk keseluruhan citra di *data set*. Kedua, *optimal image scale* (OIS) [1], yang digunakan ketika jumlah *centroid* yang dipilih merupakan jumlah *centroid* yang dianggap paling optimal untuk citra tersebut.

Pada Tabel I ditampilkan hasil perhitungan *Quantization Error* dari hasil *clustering* AFWA dan K-means dalam pemilihan skala ODS dan OIS. Selanjutnya, Tabel II menunjukkan hasil evaluasi metrik PRI dan VI dari hasil segmentasi AFWA dan K-means menggunakan pemilihan skala ODS dan OIS. Nilai yang ditampilkan pada kedua tabel merupakan nilai rata-rata dari seluruh *data set*. Selain itu, pada Tabel II juga dicantumkan nilai PRI dan VI dari hasil segmentasi manusia. Nilai ini didapatkan dari perbandingan hasil segmentasi salah satu subyek manusia dengan hasil segmentasi subyek lainnya dengan menggunakan metrik evaluasi PRI dan VI. Hasilnya, nilai yang didapatkan merupakan nilai yang dapat merepresentasikan kualitas dari hasil segmentasi manusia.

Pada Tabel I dapat diamati bahwa hasil *clustering* AFWA memiliki nilai *Quantization Error* yang lebih rendah dibandingkan K-means. Dengan kata lain, *cluster* yang dihasilkan AFWA lebih padat dibanding K-means. Hasil ini menunjukkan AFWA mampu menghasilkan *cluster* lebih baik dibanding K-means.

Citra udara yang biasanya dipenuhi oleh objek kecil yang tidak berarti, dapat menyebabkan kekeliruan dalam proses *clustering* dan menghasilkan *region* yang *oversegmented* (tersegmentasi secara berlebihan). Hal ini merupakan tantangan terbesar yang dihadapi oleh metode segmentasi berbasis *clustering*. Hasil segmentasi AFWA dan K-means terhadap enam citra udara dari *data set* dapat dilihat pada Gambar 2 di mana setiap *region* diwarnai secara acak. Secara kasat mata dapat diperhatikan bahwa secara keseluruhan hasil AFWA memiliki jumlah *region* yang lebih sedikit dibandingkan hasil K-means. Hal ini membuktikan bahwa AFWA mampu mengurangi masalah *oversegmentation*. Akan tetapi, *Oversegmentation* masih ditemukan pada citra yang memiliki banyak objek kecil tidak berarti (seperti citra pada kanan atas) dan bagian citra dengan tekstur yang tidak teratur (seperti pada citra kiri bawah).

Pada Tabel II dapat diamati bahwa hasil segmentasi AFWA secara konsisten lebih unggul dibandingkan K-means pada setiap metrik evaluasi. Berdasarkan metrik PRI, AFWA unggul dengan selisih 0.018 pada ODS dan OIS. Kemudian berdasarkan metrik VI, AFWA unggul dengan selisih 0.181 pada ODS dan



Gambar 2: Hasil segmentasi dari 6 citra udara pada *Aerial image Segmentation Data set*. Dari kiri ke kanan: citra udara, hasil segmentasi AFWA *clustering*, hasil segmentasi K-means *clustering*.

0.168 pada OIS. Akan tetapi, jika dibandingkan dengan kualitas segmentasi manusia, AFWA masih jauh tertinggal. Berdasarkan metrik PRI, AFWA masih tertinggal dengan selisih 0.339 pada ODS dan 0.351 pada OIS. Berdasarkan metrik VI, AFWA masih tertinggal dengan selisih 1.904 pada ODS dan 1.949 pada OIS. Memang sudah bisa diprediksi bahwa kemampuan segmentasi mesin masih jauh tertinggal dari kemampuan segmentasi manusia. Akan tetapi, dengan membandingkan kedua hasil segmentasi, kita dapat mengukur seberapa besar kontribusi AFWA dalam mencapai kemampuan segmentasi yang mendekati kemampuan manusia.

V. KESIMPULAN

Pada penelitian ini telah dipaparkan teknik *clustering* menggunakan AFWA dan mengaplikasikannya untuk segmentasi citra udara. Berdasarkan metrik evaluasi PRI dan VI, metode AFWA secara keseluruhan menghasilkan kualitas segmentasi yang lebih baik dibanding K-means dan lebih mendekati hasil segmentasi manusia, walaupun belum cukup signifikan. Hasil segmentasi ini masih dapat ditingkatkan dengan cara memperhitungkan informasi lain pada proses *clustering*, seperti koordinat ruang dan pola tekstur pada citra. Selain itu, FWA dan versi modifikasinya juga sangat berpotensi untuk dikembangkan pada metode segmentasi berbasis *edge detection*, *thresholding*, dan *region merging*.

ACKNOWLEDGMENT

Kami mengucapkan terima kasih sebesar-besarnya kepada seluruh teman dan rekan kerja di Universitas Telkom, khususnya di Fakultas Informatika, atas segala dukungannya dalam penyelesaian riset dan penulisan makalah ini.

PUSTAKA

- [1] P. Arbelaez, M. Maire, C. Fowlkes, and J. Malik. Contour detection and hierarchical image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(5):898–916, May 2011.

- [2] S. Chebbout and H. F. Merouani. Comparative study of clustering based colour image segmentation techniques. In *2012 Eighth International Conference on Signal Image Technology and Internet Based Systems*, pages 839–844, Nov 2012.
- [3] J. Li, S. Zheng, and Y. Tan. Adaptive fireworks algorithm. In *2014 IEEE Congress on Evolutionary Computation (CEC)*, pages 3214–3221, July 2014.
- [4] J. Macqueen. Some methods for classification and analysis of multivariate observations. In *In 5-th Berkeley Symposium on Mathematical Statistics and Probability*, pages 281–297, 1967.
- [5] Marina Meilă. Comparing clusterings: An axiomatic view. In *Proceedings of the 22Nd International Conference on Machine Learning, ICML '05*, pages 577–584, New York, NY, USA, 2005. ACM.
- [6] Priya Ranjan Misra and Tapas Si. Image segmentation using clustering with fireworks algorithm. In *2017 11th International Conference on Intelligent Systems and Control (ISCO)*, pages 97–102. IEEE, 2017.
- [7] S. Na, L. Xumin, and G. Yong. Research on k-means clustering algorithm: An improved k-means clustering algorithm. In *2010 Third International Symposium on Intelligent Information Technology and Security Informatics*, pages 63–67, April 2010.
- [8] William M. Rand. Objective criteria for the evaluation of clustering methods. *Journal of the American Statistical Association*, 66(336):846–850, 1971.
- [9] Siddheswar Ray and Rose H Turi. Determination of number of clusters in k-means clustering and application in colour image segmentation. In *Proceedings of the 4th international conference on advances in pattern recognition and digital techniques*, pages 137–143. Calcutta, India, 1999.
- [10] Ying Tan and Yuanchun Zhu. *Fireworks Algorithm for Optimization*, pages 355–364. Springer Berlin Heidelberg, Berlin, Heidelberg, 2010.
- [11] Milan Tuba, Nebojsa Bacanin, and Adis Alihodzic. Multilevel image thresholding by fireworks algorithm. In *2015 25th International Conference Radioelektronika (RADIOELEKTRONIKA)*, pages 326–330. IEEE, 2015.
- [12] S. S. Varshney, N. Rajpal, and R. Purwar. Comparative study of image segmentation techniques and object matching using segmentation. In *2009 Proceeding of International Conference on Methods and Models in Computer Science (ICM2CS)*, pages 1–6, Dec 2009.
- [13] J. Yuan, S. S. Gleason, and A. M. Cheriyyadat. Systematic benchmarking of aerial image segmentation. *IEEE Geoscience and Remote Sensing Letters*, 10(6):1527–1531, Nov 2013.
- [14] S. Zheng, A. Janecek, and Y. Tan. Enhanced fireworks algorithm. In *2013 IEEE Congress on Evolutionary Computation*, pages 2069–2077, June 2013.

