

Segmentasi Citra Udara dengan Clustering Menggunakan Fireworks Algorithm

Muhammad Hariz Arasy¹, Dr. Suyanto, S.T., M.Sc.², Kurniawan Nur Ramadhani, S.T., M.T.³

^{1,2,3} Fakultas Informatika, Universitas Telkom, Bandung

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

³kurniawanr@telkomuniversity.ac.id

Abstrak

Citra udara memiliki karakteristik data yang berbeda ketika dibandingkan dengan citra jenis lain. Citra udara biasanya memiliki objek kecil tak berarti yang dapat menyebabkan kesalahan pada metode segmentasi unsupervised. K-means clustering, sebagai salah satu metode segmentasi citra unsupervised yang digunakan secara luas, sangat rentan terhadap optimum lokal. Pada penelitian ini, Adaptive Fireworks Algorithm (AFWA) diusulkan sebagai alternatif dari algoritma K-means dalam mengoptimasi proses clustering pada metode segmentasi berbasis clustering. AFWA kemudian diaplikasikan untuk permasalahan segmentasi citra udara dan hasilnya dibandingkan dengan K-means. Berdasarkan perbandingan metrik evaluasi Probabilistic Rand Index (PRI) dan Variation of Information (VI), AFWA secara keseluruhan menghasilkan kualitas segmentasi yang lebih baik. Selain itu, AFWA juga menghasilkan clustering yang lebih baik berdasarkan hasil perhitungan Quantization Error.

Kata Kunci: Segmentasi citra, citra udara, clustering, K-means, adaptive fireworks algorithm.

Abstract

Aerial images have different data characteristics when compared to other types of images. An aerial image usually contains small insignificant objects that can cause errors in the unsupervised segmentation method. K-means clustering, one of the widely used unsupervised image segmentation methods, is highly vulnerable to local optima. In this study, Adaptive Fireworks Algorithm (AFWA) is proposed as an alternative to the K-means algorithm in optimizing the clustering process in the cluster-based segmentation method. AFWA is then applied to perform aerial image segmentation and the results are compared with K-means. Based on the comparison using Probabilistic Rand Index (PRI) and Variation of Information (VI) evaluation metrics, in general AFWA produces better segmentation quality. In addition, AFWA also produces better clustering based on the results of Quantization Error calculations.

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

1. Pendahuluan

Segmentasi citra merupakan tahapan penting dalam rangka menganalisa dan memahami konten dari sebuah citra udara. Dalam proses segmentasi, citra dipartisi ke dalam region (bagian-bagian) yang berbeda di mana setiap region harus se-homogen mungkin dan sekaligus harus berbeda satu sama lain. Hasil segmentasi citra udara ini kemudian dapat diproses lebih lanjut dan digunakan dalam bidang permasalahan lain, seperti memprediksi banjir maupun menyelidiki tingkat kepadatan penduduk wilayah perkotaan.

Lat

terdapat banyak metode yang dapat digunakan untuk melakukan segmentasi citra. Secara garis besar, metode-metode tersebut dapat dikategorikan ke dalam metode berbasis clustering, thresholding, edge-detection, dan region merging [2]. Metode berbasis clustering memberikan hasil yang secara umum lebih baik dan konsisten pada segmentasi citra umum dibandingkan dengan metode basis lainnya [10]. K-means Clustering merupakan salah satu metode segmentasi berbasis clustering yang terkenal akan kesederhanaan algoritma dan kecepatan komputasinya. Akan tetapi, proses clustering pada K-means rentan terhadap optimum lokal. Akibatnya, citra dengan kompleksitas tinggi dapat tersegmentasi secara tidak tepat.

Konsep meta-heuristic seperti halnya Swarm Intelligence (SI) dapat dijadikan sebagai alternatif dalam mengatasi optimum lokal. Fireworks Algorithm (FWA) merupakan salah satu algoritma Swarm Intelligence (SI) yang baru saja dikembangkan. Sejak diperkenalkan pada tahun 2010 [9], FWA telah mendapatkan perbaikan yang signifikan dengan dikembangkannya Enhanced Fireworks Algorithm (EFWA) [12] dan Adaptive Fireworks Algorithm

(AFWA) [3]. Berdasarkan hasil dari [9], FWA terbukti memiliki kecepatan konvergensi dan akurasi solusi global yang lebih unggul dibandingkan algoritma SI lain.

Topik dan Batasannya

Citra udara memiliki karakteristik data yang berbeda ketika dibandingkan dengan citra jenis lain seperti citra alami dan citra remote sensing [11]. Salah satu tantangan dalam bidang segmentasi citra udara adalah kebisingan objek. 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 K-means Clustering maupun metode berbasis clustering lainnya.

Pada penelitian ini, AFWA diusulkan sebagai solusi untuk menghadapi tantangan tersebut. AFWA dipilih keimbang FWA dan EFWA karena memiliki performansi yang lebih baik serta merupakan perbaikan dari kedua algoritma tersebut [3]. Agar dapat melakukan segmentasi citra, AFWA dapat digunakan sebagai alternatif dari algoritma K-means dalam mengoptimasi proses clustering pada metode K-means Clustering. Dengan menggunakan teknik segmentasi yang sama dengan K-means Clustering, kedua algoritma dapat dibandingkan kemampuannya dalam mengoptimasi cluster.

Secara konsep, AFWA dapat digunakan untuk mengoptimasi fungsi objektif manapun. FWA sebelumnya sudah pernah digunakan untuk melakukan segmentasi citra alami pada 8 dengan menggunakan metode berbasis thresholding. Akan tetapi pada penelitian ini, pengaplikasian AFWA lebih difokuskan untuk melakukan segmentasi citra dengan basis clustering.

Tujuan

Tujuan dari penelitian ini adalah untuk mengevaluasi AFWA dalam melakukan segmentasi citra udara. Kemampuan AFWA dalam melakukan clustering dan menghasilkan segmentasi yang berkualitas akan diukur pada penelitian ini. Dalam mengukur kinerja AFWA, algoritma K-means digunakan sebagai pembandingan dasar. Kedua algoritma dijalankan pada data set yang sama, yaitu Aerial image Segmentation Data set (ASD) [11] hingga didapatkan hasil segmentasi berupa citra berlabel. Agar kualitas dari hasil segmentasi dapat diukur secara objektif, 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 rih mevaluasi.

Organisasi Tulisan

Pada bagian 2 akan diulas secara ringkas mengenai algoritma K-means, konsep dasar FWA dan perkembangannya hingga AFWA, serta ASD sebagai benchmark dari penelitian ini. Pada bagian 3 akan dijelaskan mengenai metode segmentasi yang diusulkan. Kemudian pada bagian 4 akan dipaparkan hasil eksperimen dan evaluasi. Terakhir, hasil analisa dan kesimpulan akan dibahas pada bagian 5.

2. Studi Terkait

2.1 K-means Clustering

Konsep dasar dari clustering adalah menemukan kesamaan antar data dan mengelompokkannya ke dalam satu kelompok. Proses pengelompokkan 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.

Salah satu algoritma clustering yang paling populer dan sederhana adalah algoritma K-means [4]. Dalam melakukan proses clustering, algoritma K-means 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 titik pusat ditempatkan pada ruang data terlebih dahulu. Pada fase assignment setiap data dikelompokkan dengan titik pusat yang memiliki mean terdekat. Kemudian pada fase update, algoritma menghitung means dari tiap kelompok untuk menentukan titik pusat baru. Kedua fase ini terus diiterasi hingga fungsi kriteria mencapai nilai minimum [6].

2.2 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 [9]. 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.

Ukuran amplitudo setiap fireworks merupakan faktor yang sangat penting dalam menentukan kinerja algoritma. Pada FWA, amplitudo setiap fireworks dihitung berdasarkan perbedaan fitness antara fireworks tersebut dengan individu terbaik (dapat berupa fireworks ataupun 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 [12] 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 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, amplitudo berkurang terlalu lambat, ruang pencarian menjadi terlalu luas untuk dapat menemukan solusi yang optimal.

A FWA [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.

ASD Benchmark

2.3

erial image Segmentation Data set (ASD) [11] berisi 80 citra udara beresolusi tinggi berukuran 512 x 512 piksel. Data set terdiri dari berbagai macam obyek, di antaranya sekolah, perumahan, kota, gudang dan pemukiman listrik. ASD juga menyediakan ground-truth yang terdiri dari hasil segmentasi yang dibuat oleh 4 orang ahli 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 Probabilistic Rand Index (PRI) dan Variation of Information (VI).

Inf

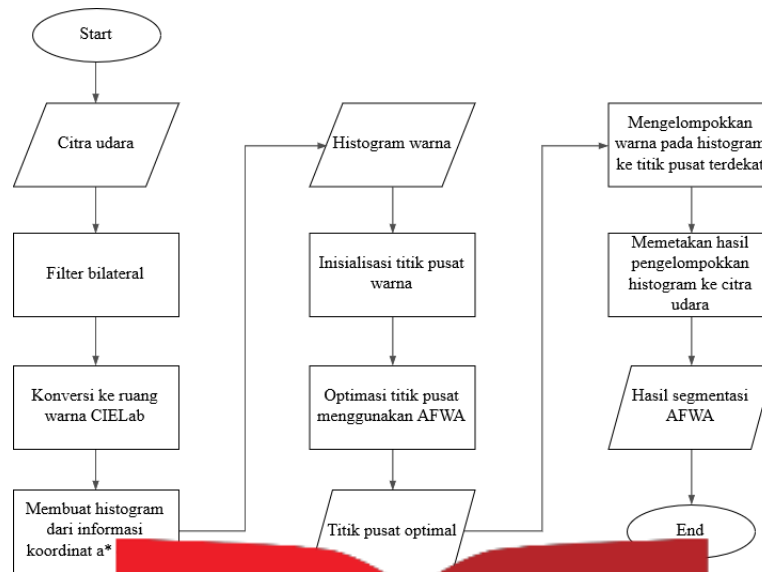
3.1 Probabilistic Rand Index

2.

Indeks Rand [7] awalnya diperkenalkan sebagai metode untuk mengevaluasi hasil clustering. 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 dibagi dengan jumlah total pasangan piksel yang ada. Jika diketahui terdapat beberapa ground-truth pada himpunan G_k , maka Probabilistic Rand Index didefinisikan sebagai berikut

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

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. Semakin besar nilai PRI, maka dapat dinyatakan bahwa kecocokan antara kedua segmentasi semakin tinggi.



Gambar 1. Alur segmentasi citra udara menggunakan AFWA

2.3.2 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 berikut

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

di mana H dan I masing-masing menyatakan entropi dan kesamaan informasi antara hasil segmentasi S dan ground-truth G . 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.

Segmentasi Citra menggunakan AFWA

3. 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. Cluster dikelompokkan dengan centroid (titik pusat) yang memiliki tingkat kemiripan fitur atau jarak terdekat. AFWA dapat digunakan untuk mengoptimasi peletakan centroid dengan menggunakan fungsi objektif. Diskursus mengukur tingkat kemiripan centroid terhadap anggota cluster-nya. Pada kasus data set ASD, data set ini memiliki banyak citra udara yang di dalamnya terdapat 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 didasarkan pada bagian-bagian tersebut. Oleh karena itu pada penelitian ini, K-means dan AFWA melakukan clustering 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 tahap preproses, clustering, dan output.

Preproses

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.

Setelah penerapan filter, agar dapat dilakukan pengelompokkan warna, citra udara terlebih dahulu diubah ke dalam 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.

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:

$$x_i = (m_{i1a^*}, \dots, m_{ija^*}, \dots, m_{iNca^*}, m_{i1b^*}, \dots, m_{ijb^*}, \dots, m_{iNcb^*}) \quad (3)$$

di mana x_i menyatakan individu ke- i dari sistem optimasi AFWA, m_{ija^*} merupakan koordinat a^* dari centroid ke- j milik individu ke- i , dan m_{ijb^*} 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 z_{pb^*} menyatakan koordinat a^* dari centroid ke- j . Hasilnya berupa cluster warna yang kualitasnya dapat diukur menggunakan Quantization Error (QE) sebagai berikut:

$$QE = \frac{\sum_{j=1}^{N_c} [\sum_{z_p \in C_j} d(z_p, m_j)] C_j}{N_c} \quad (5)$$

di mana C_j menyatakan jumlah data yang dikelompokkan pada cluster ke- j dari individu ke- i . Selanjutnya nilai fitness didapat dari fungsi objektif:

$$\text{fitness} = 1/QE \quad (6)$$

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

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.

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.

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
-

	QE	
	ODS	OIS
K-means	8.588	8.667
AFWA	6.878	6.754

Tabel 1. Perhitungan QE terhadap hasil clustering K-means dan AFWA

4. Evaluasi

Metode segmentasi K-means clustering digunakan sebagai pembandingan dasar terhadap metode segmentasi AFWA clustering. Kedua algoritma dijalankan pada data set ASD hingga didapatkan hasil segmentasi berupa citra berlabel. Dalam membandingkan kualitas hasil segmentasi, keluaran setiap algoritma diukur tingkat kemiripannya terhadap ground-truth dengan menggunakan perhitungan metrik PRI dan VI. Kemudian, untuk membandingkan kualitas hasil clustering masing-masing algoritma, tingkat kerapatan cluster diukur dengan menggunakan QE.

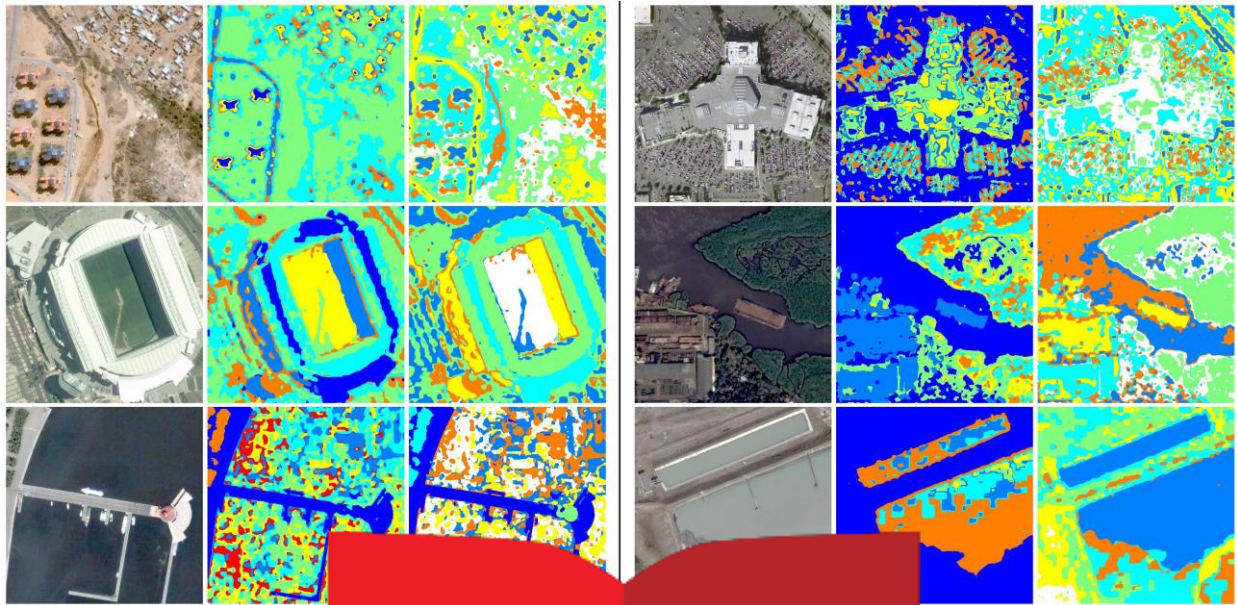
Karena kedua metode segmentasi merupakan metode berbasis clustering, maka hasil segmentasi yang dikeluarkan bergantung pada jumlah centroid yang dipilih. Berdasarkan cara pemilihan skala/jumlah centroid, terdapat dua kemungkinan evaluasi, yaitu optimal data set scale (ODS) dan optimal image scale (OIS) [1]. ODS adalah ketika skala tertentu dipilih sebagai skala yang dianggap optimal untuk seluruh citra pada data set. Sedangkan OIS adalah ketika skala yang dianggap optimal dipilhkan satu-per-satu untuk setiap citra pada data set.

4.1 Hasil Pengujian

Pada Tabel 1 ditampilkan hasil perhitungan QE dari hasil clustering AFWA dan K-means dalam pemilihan skala ODS dan OIS. Selanjutnya, Tabel 2 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 2 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.

	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

Tabel 2. Metrik evaluasi terhadap hasil segmentasi K-means dan AFWA



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.

4.2 Analisis Hasil Pengujian

Pada Tabel 1 dapat diamati bahwa hasil clustering AFWA memiliki nilai Quantization Error yang lebih rendah dibandingkan K-means. Dengan kata lain, cluster yang dihasilkan AFWA memiliki tingkat kepadatan yang lebih tinggi dibandingkan K-means. Hal ini membuktikan bahwa AFWA mampu menghasilkan cluster yang lebih baik dibandingkan K-means.

Hasil segmentasi AFWA dan K-means terhadap enam citra udara dari data set dapat dilihat pada Gambar 2 dimana setiap region diwarnai secara acak. Dapat dilihat secara keseluruhan hasil AFWA memiliki jumlah region yang lebih sedikit dibandingkan hasil K-means. Hal ini membuktikan bahwa AFWA mampu mengurangi masalah oversegmentation yang biasa dialami oleh metode berbasis clustering. Akan tetapi, masalah ini masih jauh dari kata selesai. 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 2 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 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. Namun, dengan membandingkan kedua hasil segmentasi, kita dapat mengukur seberapa besar kontribusi AFWA dalam mencapai kemampuan segmentasi yang mendekati kemampuan manusia.

Dari hasil yang didapatkan, dapat disimpulkan bahwa peningkatan kualitas yang diberikan AFWA terhadap metode segmentasi K-means Clustering bisa dibilang relatif kecil dan belum cukup signifikan. Walaupun pada pembahasan sebelumnya, AFWA terbukti mampu memberikan peningkatan yang signifikan dalam mengoptimalkan proses clustering. Diduga, peningkatan kualitas yang kurang signifikan ini disebabkan oleh metode segmentasi yang hanya terbatas pada clustering warna. Diperkirakan, hasil segmentasi masih dapat ditingkatkan dengan cara memperhitungkan informasi lain pada proses clustering, seperti halnya koordinat ruang dan pola tekstur pada citra,

5. Kesimpulan

Pada penelitian ini, telah dipaparkan teknik clustering menggunakan AFWA dan mengaplikasikannya untuk permasalahan segmentasi citra udara. Hasil segmentasi AFWA terhadap citra udara ASD telah dibandingkan dengan K-means. Berdasarkan perbandingan QE, AFWA terbukti dapat melakukan clustering dengan kualitas yang lebih baik dibandingkan K-means. Selain itu, berdasarkan perbandingan metrik evaluasi PRI dan VI, AFWA secara keseluruhan menghasilkan kualitas segmentasi yang lebih baik. Dengan kata lain, AFWA mampu menghasilkan

segmentasi yang secara objektif lebih baik dibandingkan K-means meskipun menggunakan metode segmentasi yang sama.

Perlu diingat bahwa pada penelitian ini, AFWA diaplikasikan pada metode segmentasi berbasis clustering yang hanya memperhitungkan informasi warna dari citra udara. Kedepannya, masih banyak metode segmentasi lain yang dapat dioptimasi oleh AFWA, contohnya metode berbasis edge-detection dan region-merging. Bahkan, metode berbasis clustering yang digunakan AFWA pada penelitian ini masih dapat ditingkatkan. Caranya adalah dengan mempertimbangkan informasi koordinat ruang dan pola tekstur citra pada saat melakukan proses clustering.

Daftar 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] M. Meila. 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] 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.
- [7] W. M. Rand. Objective criteria for the evaluation of clustering methods. *Journal of the American Statistical Association*, 66(336):846–850, 1971.
- [8] Shivali, E. Sharma, P. Mahapatra, and A. Doegar. Image thresholding based on swarm intelligence technique for image segmentation. In *2016 International Conference on Information Technology (InCITe) - The Next Generation IT Summit on the Theme - Internet of Things: Connect your Worlds*, pages 251–255, Oct 2016.
- [9] Y. Tan and Y. Zhu. *Fireworks Algorithm for Optimization*, pages 355–364. Springer Berlin Heidelberg, Berlin, Heidelberg, 2010.
- [10] 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.
- [11] 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.
- [12] S. Zheng, A. Janecek, and Y. Tan. Enhanced fireworks algorithm. In *2013 IEEE Congress on Evolutionary Computation*, pages 2069–2077, June 2013.