

Segmentasi Warna Citra Bunga Daisy dengan Algoritma K-Means pada Ruang Warna Lab

Derry Alamsyah¹, Dicky Pratama²

^{1,2}Program Studi Teknik Informatika¹, Sistem Informasi²
STMIK Global Informatika MDP

Jl. Rajawali No. 14 Palembang, Sumatera Selatan, Indonesia

Email: ¹derry@mdp.ac.id, ²dqpratama@mdp.ac.id

Diterima: 06 September 2019 Direvisi: 25 Oktober 2019 Diterima: 28 Oktober 2019

Abstract. *Segmentation in images of flowers or plants is an important pre-process in the field of botany, one of which is for identifying diseases of flowers or other plants. One of the problems in the image segmentation is the segmented images produced automatically. It is due to the long period of time needed to produce segmented images manually. To overcome these issues, a clustering process was carried out using the k-means algorithm. In this study segmentation is done by using Lab color space and RGB as a comparison to K-means in clustering the image of daisy flowers. Good results are showed by the Lab color space in the clustering process that 60% of the data has lower silhouette coefficient than RGB color space and 3.94% as the mean of s negative.*

Keywords: *Segmentation, Lab, K-Means*

Abstrak. *Segmentasi pada citra bunga atau tanaman merupakan pra proses yang penting dalam bidang botani, salah satunya untuk mengidentifikasi penyakit pada bunga atau tanaman lainnya. Salah satu permasalahan dalam segmentasi citra adalah menghasilkan citra tersegmentasi secara otomatis. Hal tersebut dikarenakan kebutuhan akan waktu yang tidak sebentar untuk menghasilkan citra tersegmentasi secara manual. Untuk mengatasi kendala tersebut dilakukan proses klasterisasi dengan menggunakan algoritma K-means. Pada penelitian ini segmentasi dilakukan dengan menggunakan ruang warna Lab dan RGB sebagai pembandingan kinerja k-means dalam mengklasterisasi citra bunga Desi. Hasil yang baik dimiliki oleh ruang warna Lab dalam proses klasterisasinya, yaitu dengan 60% data memiliki nilai silhouette coefficient (s) yang lebih kecil dari ruang warna RGB dan memiliki rata-rata sebesar 3.94% s negatif.*

Kata Kunci: *Segmentasi, Lab, k-Means*

1. Pendahuluan

Segmentasi citra merupakan proses untuk mendapatkan objek dengan lebih spesifik tanpa melibatkan objek lain [1]. Hal tersebut berbeda dengan proses deteksi objek pada citra, dimana objek dilokalisasi kemudian dikenali keberadaannya. Untuk melakukan segmentasi, proses dapat dilakukan dengan menggunakan *raw image* [2] ataupun *grouped image* [3] (seperti penggunaan superpixel). Penerapan segmentasi digunakan pada beberapa bidang diantaranya adalah bidang medis dengan data citra berupa citra MRI [4] dan X-Ray [5], bidang informasi geografis [6][7] dan robotika, seperti yang dilakukan [8] dalam mengenali objek.

Segmentasi citra itu sendiri dapat dihasilkan dengan menggunakan kaidah statistik seperti korelasi [9] dan distribusi [10]. Selain itu, segmentasi dapat dilakukan dengan memanfaatkan struktur morfologi citra [11], pengelompokan hirarkie [12] ataupun menggunakan *deep learning* [13]. Sementara itu, segmentasi citra memiliki beberapa kendala, dimulai dari kesulitan dalam mendapatkan data *ground truth* dan menghasilkan segmentasi yang akurat seperti gangguan derau [14]. Dalam penelitian ini kendala yang dibahas adalah mendapatkan data *ground truth*. Data *ground truth* itu sendiri adalah data citra yang telah dilakukan segmentasi secara manual untuk kemudian dipelajari ciri apa yang terdapat didalamnya sehingga proses segmentasi dapat

dilakukan dengan mengklasifikasi setiap pixelnya. Untuk menghasilkan data *ground truth* yang *autogenerated* maka proses yang dilakukan adalah klusterisasi (*clustering*).

Segmentasi bunga ataupun tanaman lain merupakan salah satu topik dalam segmentasi citra yang penting. Beberapa penelitian terkait segmentasi diantaranya Segmentasi sebagai pra proses untuk mengetahui perkembangan dari pohon mangga, dimana proses segmentasi dicapai melalui *color thresholding* [15]. Selanjutnya, Segmentasi bunga melati dengan menggunakan algoritma DBSCAN dimana pada pra prosesnya menggunakan superpixel [16][17][18]. Selanjutnya, segmentasi citra bunga dengan latar belakang yang cukup kompleks dapat dilakukan dengan menggunakan algoritma *k-means* [19]. Pada penelitiannya [19] menggunakan bunga anggrek sebagai citra masukannya. Maka, berdasarkan uraian yang telah dijelaskan maka dalam penelitian ini segmentasi dilakukan menggunakan algoritma *k-means* dengan citra masukkan berupa citra bunga Daisy, dimana pra-proses dilakukan pada ruang warna citra.

2. Tinjauan Pustaka

2.1. Ruang Warna Citra

Citra digital dihasilkan oleh susunan blok warna yang disebut pixel, dimana terdapat beberapa format warna (ruang warna) dari citra diantaranya RGB, HSV, XYZ, LAB dan sebagainya. Pada penelitian ini ruang warna yang digunakan adalah RGB dan LAB.

1. RGB – merupakan jenis (model) ruang warna additive pada citra yang menghasilkan warna pada setiap pixel melalui penambahan warna merah (Red), hijau (Green) dan biru (Blue) dengan proporsi yang bersesuaian. Nilai maksimum dari ruang warna ini menghasilkan warna putih, sementara itu nilai minimum menghasilkan warna hitam. Ruang warna ini umumnya digunakan untuk peralatan elektronik seperti tv dan monitor komputer.
2. LAB – merupakan jenis ruang warna color-opponent pada citra (red vs green dan yellow vs blue) berdasarkan ruang warna XYZ. Ruang warna ini menggambarkan semua warna yang terlihat oleh mata manusia, dimana L mengindikasikan cahaya, A mengindikasikan posisi dari merah (red) ke hijau (green) dan B mengindikasikan posisi antara kuning (yellow) dan biru (blue). Ruang warna ini umumnya digunakan untuk penglihatan (vision).

Konversi dari warna RGB ke LAB dapat dilakukan dengan menggunakan persamaan (1)-(6) berikut:

$$L = 116 \sqrt[3]{\frac{Y}{Y_n}} - 16 \quad (1)$$

dengan kondisi $\frac{Y}{Y_n} > 0.008856$, sementara itu untuk sebaliknya

$$L = 116 \left(7.787 \frac{Y}{Y_n} + 0.138 \right) + 16 \quad (2)$$

Selanjutnya,

$$a = 500 \left[\sqrt[3]{\frac{X}{X_n}} - \sqrt[3]{\frac{Y}{Y_n}} \right] \quad (3)$$

Dengan kondisi $\frac{X}{X_n} > 0.008856$, sementara itu untuk sebaliknya

$$a = 500 \left[\left(7.787 \frac{X}{X_n} + 0.138 \right) - \left(7.787 \frac{Y}{Y_n} + 0.138 \right) \right] \quad (4)$$

Terakhir,

$$a = 200 \left[\sqrt[3]{\frac{Y}{Y_n}} - \sqrt[3]{\frac{Z}{Z_n}} \right] \quad (5)$$

Dengan kondisi $\frac{Z}{Z_n} > 0.008856$, sementara itu untuk sebaliknya

$$a = 500 \left[\left(7.787 \frac{Y}{Y_n} + 0.138 \right) - \left(7.787 \frac{Z}{Z_n} + 0.138 \right) \right] \quad (6)$$

Sedangkan nilai X , Y dan Z serta nilai normalisasinya (X_n, Y_n, Z_n) merupakan ruang warna XYZ yang didapatkan melalui persamaan (7)-(12).

$$X = 0.723R + 0.273G + 0.166B \quad (7)$$

$$Y = 0.265R + 0.717G + 0.008B \quad (8)$$

$$Z = 0.000R + 0.008G + 0.824B \quad (9)$$

$$X_n = \frac{X}{X+Y+Z} \quad (10)$$

$$Y_n = \frac{Y}{X+Y+Z} \quad (11)$$

$$Z_n = 1 - X_n - Y_n \quad (12)$$

2.2. K-Means

Metode *k-means* merupakan metode yang sangat populer dikalangan praktisi sekaligus merupakan metode tertua dalam klusterisasi. Hal itu didasarkan pada kemudahan implementasi dan kecepatan prosesnya. Konsep *k-means* telah ditemukan para peneliti sejak tahun 1950an, diantaranya adalah Lloyd (1957, 1982), Forgey (1965), Friedman dan Rubin (1967), serta MacQueen (1967). *k-means* bertujuan meminimasi *Sum of Squared Error* (SSE) antara objek-objek data dengan sejumlah *k-centroid* [20].

Algoritma *k-Means Clustering*

k-means (D, k)

Pilih sejumlah k objek secara acak dari himpunan D sebagai *centroid* awal

Repeat

For semua objek di dalam D

 Masukkan setiap objek yang bukan *centroid* ke klaster yang paling dekat di antara k klaster yang ada

End

Perbaharui setiap *centroid* dengan menghitung rata-rata dari semua objek yang berada di dalam klaster tersebut

Until tidak ada perubahan *centroid*.

2.3. Silhouette Coefficient

Untuk sebuah himpunan D yang berisi n objek, misalkan D dipartisi ke dalam k klaster, C_1, \dots, C_k . Untuk setiap objek $o \in D$ hitung $a(o)$ sebagai rata-rata jarak antara objek o dengan semua objek lain dalam klaster tersebut dan $b(o)$ sebagai rata-rata jarak minimum dari objek o ke semua klaster lain (bukan klasternya o). Jika $o \in C_i (1 \leq i \leq k)$, maka

$$a(o) = \frac{\sum_{o' \in C_i, o \neq o'} \text{dist}(o, o')}{|C_i| - 1} \quad (13)$$

Dan

$$b(o) = \min_{C_j; 1 \leq j \leq k, j \neq i} \left\{ \frac{\sum_{o' \in C_j} \text{dist}(o, o')}{|C_j|} \right\} \quad (14)$$

Serta *silhouette coefficient* dari o didefinisikan sebagai

$$s(o) = \frac{b(o) - a(o)}{\max\{a(o), b(o)\}} \quad (15)$$

Nilai $a(o)$ menyatakan kepadatan klaster yang mengandung objek o . Semakin kecil nilai $a(o)$, semakin padat klaster tersebut. Sementara itu, nilai $b(o)$ menggambarkan seberapa jauh objek o terpisah dari klaster-klaster lain. Semakin besar nilai $b(o)$, semakin jauh objek o terpisah dari klaster-klaster lain. Jadi, jika $a(o)$ bernilai sangat kecil dan $b(o)$ bernilai sangat besar, maka *silhouette coefficient* dari o akan mendekati 1. Sebaliknya, jika $a(o)$ bernilai sangat besar dan $b(o)$ bernilai sangat kecil, maka *silhouette coefficient* dari o akan mendekati -1 [20].

3. Metodologi Penelitian

3.1. Pengumpulan Data

Penelitian ini mengambil data dari *Kaggle Dataset*. Sebagai dasar analisis untuk sistem segmentasi citra, dataset dari citra bunga daisy yang diambil berjumlah 10 citra yang ditunjukkan oleh Gambar 1.

3.2. Studi Literatur

Setelah Data terkumpul dilakukan studi mengenai proses segmentasi citra berdasarkan jurnal dan buku terkait.

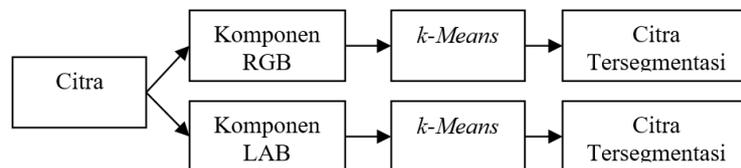


Gambar 1. Dataset Citra Bunga Daisy.

3.3. Rancangan Sistem

Segmentasi dilakukan dengan cara mengelompokkan setiap warna pada pixel ke dalam 3 kelompok. Pengelompokkan dilakukan dengan menggunakan algoritma *k-means*, dimana pengukuran jarak dilakukan dengan menggunakan *euclidean distance*. Untuk warna RGB, data yang digunakan sebagai masukan algoritma *k-means* berdimensi 3. Sementara itu, untuk warna LAB, nilai yang dipilih sebagai masukan data adalah *a* dan *b*, sementara *L* yang merupakan nilai kecerahan tidak dimasukkan kedalam pengelompokkan (klasterisasi) data dengan algoritma *k-means*.

Secara keseluruhan sistem ditunjukkan Gambar 2 dan hasil segmentasi menggunakan warna RGB ditunjukkan oleh Gambar 3.a Sedangkan klasterisasi dengan menggunakan warna LAB ditunjukkan oleh Gambar 3.b



Gambar 2. Rancangan Sistem



Gambar 3. a. Segmentasi terhadap warna RGB b. Segmentasi terhadap warna LAB

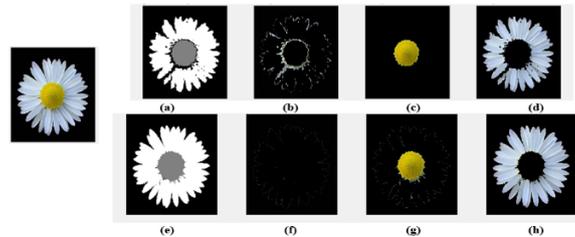
3.4. Evaluasi

Evaluasi sistem pada penelitian ini menggunakan nilai dari *silhouette coefficient (s)*, yaitu dengan menghitung rata-rata *s*. Jika *s* mendekati 1, berarti klaster tersebut sangat padat dan terpisah jauh dari klaster-klaster lain. Sebaliknya, jika *s* mendekati -1, maka hal ini berarti klaster tersebut tidak padat dan bahkan tumpang tindih dengan klaster-klaster lain. Jumlah *s* untuk setiap citra adalah 76800 nilai. Masing-masing nilai tersebut merupakan nilai *s* pada setiap pixel terklasterisasi.

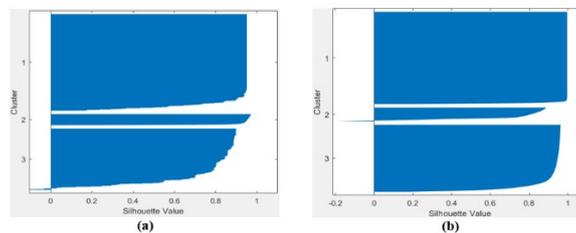
4. Hasil dan Diskusi

Jumlah *silhouette coefficient (s)* untuk setiap citra adalah 76800 nilai. Masing-masing nilai tersebut merupakan nilai *s* pada setiap pixel terklasterisasi. Hasil setiap citra klaster terhadap dua

jenis warna ditunjukkan oleh Gambar 4.1 s/d 4.1 sementara hasil nilai s ditunjukkan oleh Gambar 4.2 s/d 4.2. Hasil yang pertama ditunjukkan oleh Gambar 4.1, dimana jumlah nilai s yang bernilai negatif untuk warna Lab adalah 659 atau 0.86% ditunjukkan oleh Gambar 4.2(a), sedangkan untuk RGB adalah 309 atau 0.40% yang ditunjukkan oleh Gambar 4.2(b). Kluster yang terbentuk pada warna RGB lebih padat dibandingkan dengan warna Lab, hal ini memunculkan hasil kluster yang ditunjukkan oleh Gambar 4.1(e-h). Kepadatan tersebut dapat dilihat dari grafik pada Gambar 4.2(b) yang memiliki nilai kepadatan lebih merata.

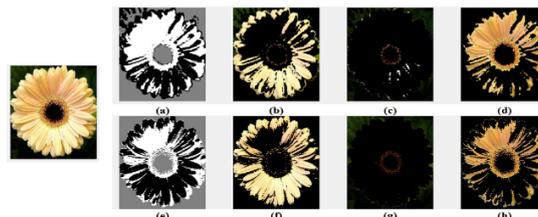


Gambar 4.1 Bunga *daisy-1* dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)

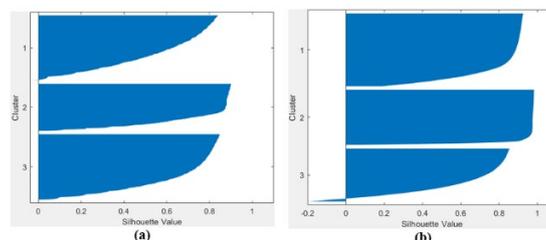


Gambar 4.2 Hasil *Silhouette Coefficient* untuk Bunga *daisy-1*

Sementara itu, peningkatan jumlah nilai s negatif yang lebih besar terjadi pada warna RGB mengakibatkan kluster yang kurang rapi (padat) seperti ditunjukkan oleh perbandingan Gambar 5.1(d) dan (h). Nilai tersebut terlihat pada Gambar 5.2(a) dimana nilai negatif warna Lab sebesar 220 atau 0.29%, sedangkan untuk RGB adalah 1177 atau 1.53% pada Gambar 5.2(b). Secara keseluruhan hasil terlihat pada Gambar 5.1.



Gambar 5.1 Bunga *daisy-2* dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)

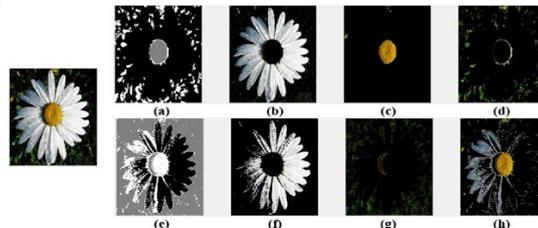


Gambar 5.2 Hasil *Silhouette Coefficient* untuk Bunga *daisy-2*

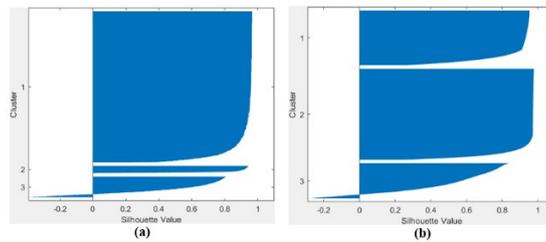
Kembali nilai s yang lebih besar dari 1% dialami oleh kedua warna (Lab dan RGB) yang menghasilkan citra seperti ditunjukkan pada Gambar 6.1. Jumlah nilai s yang bernilai negatif untuk warna Lab adalah 1350 atau 1.76% ditunjukkan oleh Gambar 6.2(a), sedangkan untuk RGB

adalah 1583 atau 2.06% yang ditunjukkan oleh Gambar 6.2(b). Namun, hasil yang kurang padat ditunjukkan oleh Gambar 6.1(h), dimana warna kuning dari bunga *daisy* masih termasuk dalam kluster lain.

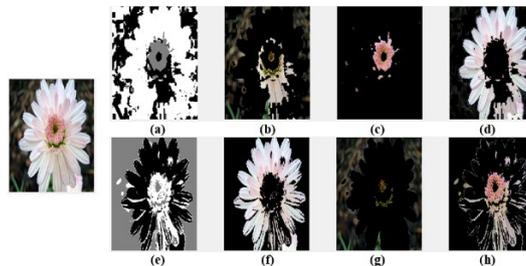
Selanjutnya, berdasarkan Gambar 7.2(a) jumlah nilai s yang bernilai negatif tetap lebih besar dari 1% bahkan naik signifikan untuk warna Lab adalah 9171 atau 11.94%. Sedangkan, pada Gambar 7.2(b) menunjukan untuk RGB adalah 2298 atau 2.99% dengan hasil secara keseluruhan ditunjukkan oleh Gambar 7.1, dimana peningkatan yang signifikan dari nilai s negatif untuk warna Lab menghasilkan kluster seperti yang ditunjukkan oleh Gambar 7.1(b) dan (d).



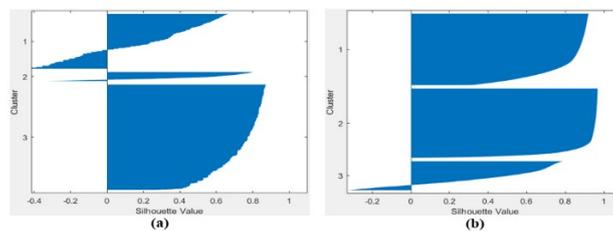
Gambar 6.1. Bunga *daisy*-3 dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)



Gambar 6.2. Hasil *Silhouette Coefficient* untuk Bunga *daisy*-3

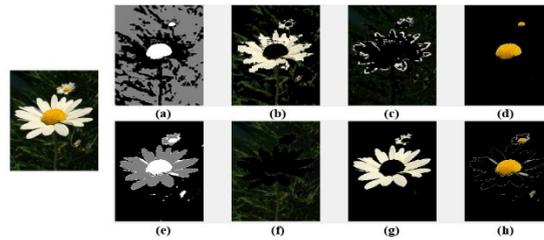


Gambar 7.1 Bunga *daisy*-4 dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)

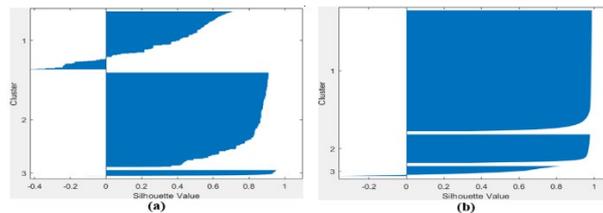


Gambar 7.2. Hasil *Silhouette Coefficient* untuk Bunga *daisy*-4

Selanjutnya, penurunan jumlah s negatif dari kedua warna menghasilkan bentuk kluster yang lebih rapi yang secara keseluruhan hasil segmentasinya ditunjukkan oleh Gambar 8.1. Penurunan tersebut terlihat pada Gambar 8.2(a) dan (b) dimana jumlah nilai s yang bernilai negatif untuk warna Lab adalah 6065 atau 7.90%, sedangkan untuk RGB adalah 622 atau 0.81%.

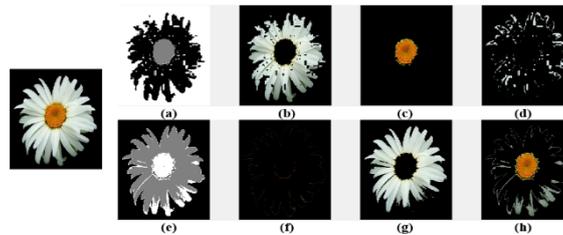


Gambar 8.1. Bunga *daisy-5* dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)

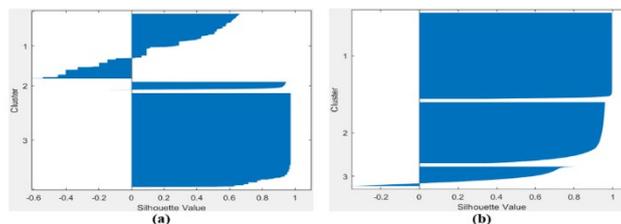


Gambar 8.2. Hasil *Silhouette Coefficient* untuk Bunga *daisy-5*

Sementara itu, peningkatan jumlah nilai s yang bernilai negatif kembali terjadi yaitu untuk warna Lab adalah 9447 atau 12.30%, sedangkan untuk RGB adalah 1275 atau 1.67% ditunjukkan oleh Gambar 9.2(a) dan (b). Jumlah s negatif yang besar pada warna Lab, menghasilkan gambar 9.1. dan bentuk kerapatan yang rendah oleh warna Lab itu sendiri ditunjukkan oleh Gambar 9.2(a).

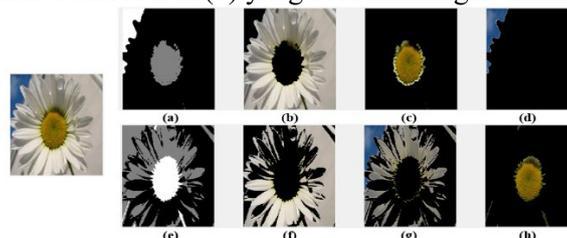


Gambar 9.1. Bunga *daisy-6* dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)

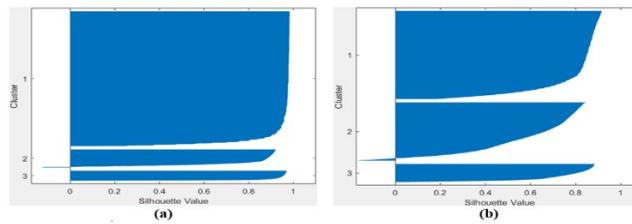


Gambar 9.2. Hasil *Silhouette Coefficient* untuk Bunga *daisy-6*

Selanjutnya, berdasarkan Gambar 10.2(a), jumlah nilai s yang bernilai negatif untuk warna Lab adalah 259 atau 0.34%, sedangkan untuk RGB adalah 1105 atau 1.44% yang ditunjukkan oleh Gambar 10.2(b). Sehingga, hasil yang lebih baik ditunjukkan oleh citra segmentasi menggunakan warna Lab pada Gambar 10.1. Hasil yang lebih baik itu ditunjukkan oleh terpisahnya warna latar belakang yang ditunjukkan Gambar 10.1(d) yang berbeda dengan Gambar 10.1(g).

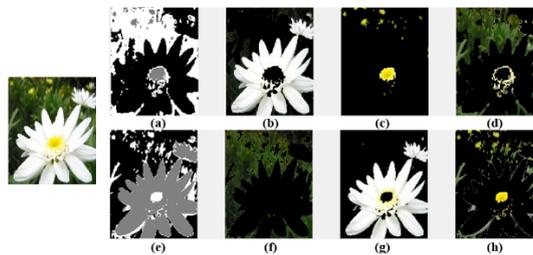


Gambar 10.1. Bunga *daisy-7* dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)

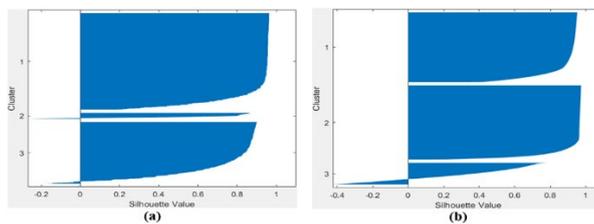


Gambar 10.2. Hasil *Silhouette Coefficient* untuk Bunga *daisy-7*

Kemudian, adanya peningkatan nilai s negatif untuk warna RGB menghasilkan kluster yang masih saling tumpang tindih seperti yang ditunjukkan oleh Gambar 11.1(e), dimana warna kuning dari bunga *daisy* masih tercampur dengan warna hijau. Hasil berbeda ditunjukkan oleh Gambar 11.1.(c). Hasil tersebut berdasarkan Gambar 1212 (a), dan (b) jumlah nilai s yang bernilai negatif untuk warna Lab adalah 1305 atau 1.70%, sedangkan untuk RGB adalah 2481 atau 3.23%. Secara keseluruhan hasil terlihat pada Gambar 11.1.

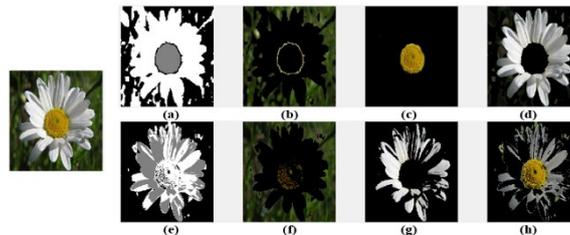


Gambar 11.1. Bunga *daisy-8* dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)

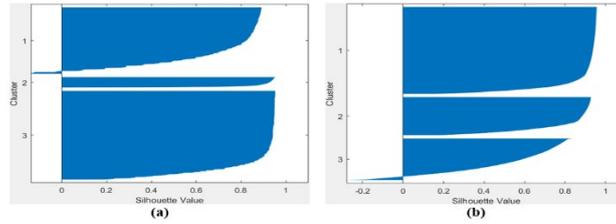


Gambar 11.2. Hasil *Silhouette Coefficient* untuk Bunga *daisy-8*

Kembali hasil kluster yang kurang baik ditunjukkan oleh warna RGB pada Gambar 12.1(h). Seperti sebelumnya (pada Gambar 11.1.(h)). Hal tersebut berdasarkan Gambar 12.2(a) dan b, yaitu jumlah nilai s yang bernilai negatif untuk warna Lab adalah 1347 atau 1.75%, sedangkan untuk RGB adalah 1658 atau 2.16%. Hasil tersebut juga ditunjukkan oleh Gambar 12.2(b), meskipun cenderung padat namun ada jumlah s negatif yang cukup besar mengakibatkan warna kuning masih tercampur dengan warna lain (putih). Hasil secara keseluruhan ditunjukkan oleh Gambar 12.1

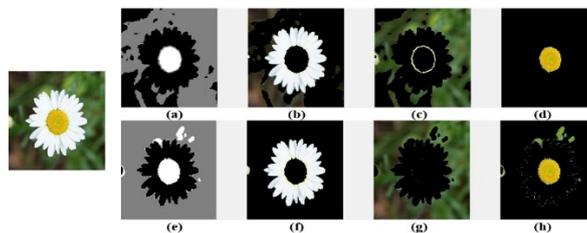


Gambar 13.1. Bunga *daisy-9* dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)

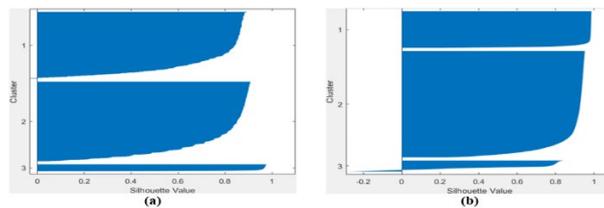


Gambar 13.2. Hasil *Silhouette Coefficient* untuk Bunga *daisy-9*

Terakhir, berdasarkan Gambar 14.2(a) dan (b), jumlah nilai s yang bernilai negatif untuk warna Lab adalah 424 atau 0.55%, sedangkan untuk RGB adalah 793 atau 1.03%. Hasil ini menunjukkan kluster yang lebih baik untuk kedua warna, akan tetapi nilai s negatif yang lebih besar pada warna RGB menghasilkan sedikit kluster yang tumpang tindih (Gambar 14.1.(h)). Hasil secara keseluruhan ditunjukkan oleh Gambar 14.1.



Gambar 14.1. Bunga *daisy-10* dengan Hasil Kluster Warna Lab (a-d) dan RGB (e-h)



Gambar 14.2. Hasil *Silhouette Coefficient* untuk Bunga *daisy-10*

Secara keseluruhan nilai rerata s untuk setiap citra data ditunjukkan oleh Tabel 1. Berdasarkan hasil Tabel 1, citra dengan warna Lab memiliki rerata s negatif yang lebih besar dibandingkan dengan citra dengan warna RGB. Hanya saja, jika dilihat per-citra, jumlah s negatif citra warna Lab yang lebih kecil dari citra warna RGB berjumlah 60% dari data. Hal tersebut menunjukkan kemampuan *k-means* dalam mengelompokkan (klusterisasi) lebih baik untuk data citra warna Lab dengan citra-citra yang latar belakang lebih kompleks seperti citra 7-10.

Tabel 1. Hasil *Silhouette Coefficient* untuk Masing-masing Fitur Warna

Bunga	Lab	RGB	$s\text{-Lab} < s\text{-RGB}$
Daisy-1	659 (0.86%)	309 (0.40%)	0
Daisy-2	220 (0.29%)	1177 (1.53%)	1
Daisy-3	1350 (1.76%)	1583 (2.06%)	1
Daisy-4	9171 (11.94%)	2298 (2.99%)	0
Daisy-5	6065 (7.90%)	622 (0.81%)	0
Daisy-6	9447 (12.30%)	1275 (1.67%)	0
Daisy-7	259 (0.34%)	1105 (1.44%)	1
Daisy-8	1305 (1.70%)	2481 (3.23%)	1
Daisy-9	1347 (1.75%)	1658 (2.16%)	1
Daisy-10	424 (0.55%)	793 (1.03%)	1
rerata	3024.7 (3.94%)	13301.1 (1.73%)	6 (60%)

5. Kesimpulan dan Saran

Jumlah nilai rerata *silhouette coefficient* (s) pada citra warna Lab dan RGB masing-masing sebesar 3.94% dan 1.73% dari seluruh data. Akan tetapi, sebanyak 60% data, citra warna Lab memiliki nilai negatif s yang lebih sedikit. Nilai s negatif yang lebih sedikit menunjukkan padatnya klaster yang dimiliki. Dengan padatnya suatu klaster maka klaster yang terbentuk lebih tersusun rapi. Hasil klaster yang padat tersebut didukung dengan hasil segmentasi dimana secara perspektif hasil segmentasi untuk citra warna Lab lebih baik dari pada RGB. Hasil ini dapat digunakan untuk menghasilkan citra *ground truth* untuk proses segmentasi citra secara otomatis.

Referensi

- [1] Rupinder and Shruti Porwal. "An Optimized Computer Vision Approach to Precise Well-Bloomed Flower Yielding Prediction using Image Segmentation". *International Journal of Computer Application*, vol.119. 2015.
- [2] L. Chen, G. Papandreou, I. Kokkinos, K. Murphy and A. L. Yuille, "DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 40, no. 4, pp. 834-848, 1 April 2018.
- [3] Tian, L. Liu, Z. Zhang dan B. Fei, "Superpixel-Based Segmentation for 3D Prostate MR Images," in *IEEE Transactions on Medical Imaging*, vol. 35, no. 3, pp. 791-801, March 2016.
- [4] A. Gubern-Mérida, M. Kallenberg, R. M. Mann, R. Martí and N. Karssemeijer, "Breast Segmentation and Density Estimation in Breast MRI: A Fully Automatic Framework," in *IEEE Journal of Biomedical and Health Informatics*, vol. 19, no. 1, pp. 349-357, Jan. 2015.
- [5] P. H. M. Lira, G. Antonio Giraldo, L. Antonio Pereira Neves and R. Antonino Feijoo, "Dental R-Ray Image Segmentation Using Texture Recognition," in *IEEE Latin America Transactions*, vol. 12, no. 4, pp. 694-698, June 2014.
- [6] S. K. Mylonas, D. G. Stavrakoudis, J. B. Theocharis, G. C. Zalidis and I. Z. Gitas, "A Local Search-Based GeneSIS algorithm for the Segmentation and Classification of Remote-Sensing Images," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 9, no. 4, pp. 1470-1492, April 2016.
- [7] S. K. Mylonas, D. G. Stavrakoudis, J. B. Theocharis and P. A. Mastorocostas, "Classification of Remotely Sensed Images Using the GeneSIS Fuzzy Segmentation Algorithm," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 10, pp. 5352-5376, Oct. 2015.
- [8] K. Li, W. Tao and L. Liu, "Online Semantic Object Segmentation for Vision Robot Collected Video," in *IEEE Access*, vol. 7, pp. 107602-107615, 2019.
- [9] A. Alush and J. Goldberger, "Hierarchical Image Segmentation Using Correlation Clustering," in *IEEE Transactions on Neural Networks and Learning Systems*, vol. 27, no. 6, pp. 1358-1367, June 2016.
- [10] E. Erdil *et al.*, "Nonparametric Joint Shape and Feature Priors for Image Segmentation," in *IEEE Transactions on Image Processing*, vol. 26, no. 11, pp. 5312-5323, Nov. 2017.
- [11] T. Lei, X. Jia, T. Liu, S. Liu, H. Meng and A. K. Nandi, "Adaptive Morphological Reconstruction for Seeded Image Segmentation," in *IEEE Transactions on Image Processing*, vol. 28, no. 11, pp. 5510-5523, Nov. 2019.
- [12] M. Seyedhosseini and T. Tasdizen, "Semantic Image Segmentation with Contextual Hierarchical Models," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 5, pp. 951-964, 1 May 2016.
- [13] A. Van Opbroek, H. C. Achterberg, M. W. Vernooij and M. De Bruijne, "Transfer Learning for Image Segmentation by Combining Image Weighting and Kernel Learning," in *IEEE Transactions on Medical Imaging*, vol. 38, no. 1, pp. 213-224, Jan. 2019.
- [14] F. Hosotani, Y. Inuzuka, M. Hasegawa, S. Hirobayashi and T. Misawa, "Image Denoising With Edge-Preserving and Segmentation Based on Mask NHA," in *IEEE Transactions on Image Processing*, vol. 24, no. 12, pp. 6025-6033, Dec. 2015.

- [15] Z. Wang, B. Verma, K. B. Walsh, P. Subedi and A. Koirala, "Automated mango flowering assessment via refinement segmentation," *2016 International Conference on Image and Vision Computing New Zealand (IVCNZ)*, Palmerston North, 2016, pp. 1-6.
- [16] A. Abinaya and S. M. M. Roomi, "Jasmine flower segmentation: A superpixel based approach," *2016 International Conference on Communication and Electronics Systems (ICCES)*, Coimbatore, 2016, pp. 1-4.
- [17] S. Ramjitham and K. Padmavathi, "Superpixel Based Color Image Segmentation Techniques: A Review". in *International Journal of Advanced Research in Computer Science and Software Engineering*, vol. 4, 2014.
- [18] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua and S. Ssstrunk, "SLIC Superpixels Compared to State-of-the-Art Superpixel Methods," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, no. 11, pp. 2274-2282, Nov. 2012.
- [19] N. Sabri, Z. Ibrahim and N. N. Rosman, "K-means vs. fuzzy C-means for segmentation of orchid flowers," *2016 7th IEEE Control and System Graduate Research Colloquium (ICSGRC)*, Shah Alam, 2016, pp. 82-86.
- [20] Suyanto, *Machine Learning Tingkat Dasar dan Lanjut*, Bandung, Informatika, 2018.