

Implementasi *Singular Value Decomposition* (SVD) pada Optimasi *Background Separation* Berbasis *Color Distribution Analysis*

Rafif Farras - 13523095¹

Program Studi Teknik Informatika

Sekolah Teknik Elektro dan Informatika

Institut Teknologi Bandung, Jl. Ganesha 10 Bandung 40132, Indonesia

¹rafiffarras023@gmail.com, 13523095@std.stei.itb.ac.id

Abstrak— Penelitian ini membahas implementasi *Singular Value Decomposition* (SVD) untuk mengoptimasi proses *background separation* pada citra digital dengan pendekatan analisis distribusi warna. Hasil pengujian menunjukkan bahwa penggunaan SVD memberikan peningkatan signifikan dalam kualitas dan konsistensi hasil pemisahan *background* dibandingkan dengan metode tanpa SVD. Metode dengan SVD menghasilkan ekstraksi *foreground* yang lebih bersih, akurat, dan mampu mempertahankan detail objek dengan baik pada berbagai jenis gambar input. Penelitian ini membuktikan bahwa integrasi SVD dalam proses *background separation* berbasis analisis distribusi warna merupakan pendekatan yang efektif untuk meningkatkan kualitas hasil pemisahan *background* pada pengolahan citra digital.

Kata Kunci— *Singular Value Decomposition*, *Background Separation*, *Color Distribution Analysis*

I. PENDAHULUAN

Pemrosesan citra digital merupakan bidang yang terus berkembang dalam dunia komputasi. Salah satu tahap penting dalam pemrosesan citra digital adalah *Background Separation*. Ketika *Background Separation* dilakukan dengan baik, pemrosesan citra selanjutnya akan lebih mudah dan akurat. Oleh karena itu, teknik dan pendekatan yang digunakan dalam *Background Separation* dapat secara signifikan meningkatkan kualitas analisis citra.

Salah satu pendekatan dalam *Background Separation* adalah dengan *Color Distribution Analysis*. Pendekatan ini memanfaatkan perbedaan karakteristik warna antara *foreground* (objek utama) dan *background* untuk melakukan pemisahan. Pendekatan ini dapat menangani berbagai variasi warna pada citra dan membantu mengidentifikasi pola *background* yang konsisten dan membedakannya dengan pola *foreground*. Namun, pendekatan ini akan memiliki keterbatasan Ketika berhadapan dengan variasi pencahayaan yang tinggi atau Ketika adanya kemiripan warna yang tinggi antara *foreground* dan *background*.

Untuk mengatasi keterbatasan tersebut, *Singular Value Decomposition* (SVD) dapat diimplementasikan untuk mengoptimalkan *Background Separation Process*. SVD merupakan teknik matematika dalam aljabar linear yang

dapat mendekomposisi matriks citra menjadi komponen-komponen yang lebih sederhana. Dengan menggunakan SVD, *Background Separation Process* dapat dilakukan dengan lebih efektif karena mampu mengekstrak fitur-fitur penting dari citra dan mengurangi noise yang ada.

II. LANDASAN TEORI

A. *Singular Value Decomposition* (SVD)

Singular Value Decomposition (SVD) adalah salah satu metode dalam aljabar linier yang digunakan untuk memecah suatu matriks menjadi 2 matriks ortogonal dan 1 matriks diagonal.

Matriks Ortogonal adalah matriks yang memiliki sifat khusus dimana kolom-kolomnya saling orthogonal satu sama lain. Secara formal, sebuah matriks A berukuran $m \times n$ dikatakan orthogonal jika memenuhi kondisi berikut:

$$A^T A = I$$

Di mana A^T merupakan transpose dari matriks A , I adalah matriks identitas berukuran $n \times n$. Ini berarti bahwa hasil kali titik (*dot product*) antara setiap pasangan kolom dari matriks tersebut adalah nol, yang menunjukkan bahwa kolom-kolom tersebut saling tegak lurus. Selain itu, norma/panjang dari setiap kolom matriks ortogonal adalah satu. Matriks ini sering digunakan dalam transformasi geometris karena sifatnya yang tetap menjaga panjang vector dan sudut antara vector setelah transformasi.

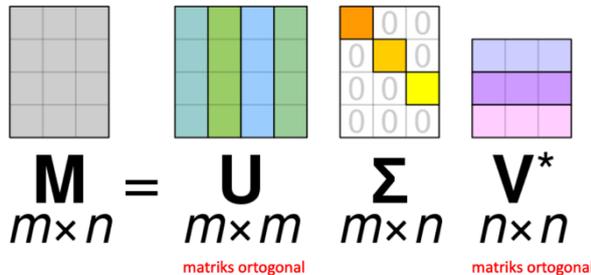
Matriks diagonal adalah jenis matriks persegi di mana semua elemen di luar diagonal utama adalah nol. Secara matematis, sebuah matriks diagonal D dapat digambarkan sebagai berikut

$$D = \begin{pmatrix} d_1 & 0 & 0 & \cdots & 0 \\ 0 & d_2 & 0 & \cdots & 0 \\ 0 & 0 & d_3 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & d_n \end{pmatrix}$$

Gambar 1: Contoh Matriks Diagonal (Sumber:)

Pada gambar 1, elemen d_1, d_2, \dots, d_n merupakan elemen diagonal. Matriks diagonal memiliki beberapa keunggulan dalam perhitungan matematis karena operasi seperti perkalian dapat dilakukan dengan lebih sederhana dibandingkan matriks lainnya.

Kedua jenis matriks ini memiliki sifat-sifat yang sangat berguna dalam penerapan *Singular Value Decomposition (SVD)*. Dalam SVD, suatu matriks M akan dipecah menjadi 3 matriks sesuai dengan ilustrasi berikut



Gambar 2: Ilustrasi Pemfaktoran Matriks menggunakan SVD (Sumber: [6])

Di mana:

- U adalah matriks ortogonal berukuran $m \times m$ yang kolom-kolomnya adalah vector singular kiri dari M .
- Σ adalah matriks diagonal berukuran $m \times n$ yang berisi nilai singular dari M . Nilai-nilai ini adalah akar kuadrat dari nilai eigen matriks $M^T M$ dan diurutkan dari yang terbesar hingga terkecil.
- V^* atau V^T adalah transpos dari matriks orthogonal berukuran $n \times n$ yang kolom-kolomnya adalah vector singular kanan dari M .

Nilai Singular dalam matriks Σ memberikan informasi tentang seberapa pentingnya setiap komponen dalam matriks asli/sebenarnya. Nilai-nilai ini menunjukkan seberapa banyak varians yang dijelaskan oleh masing-masing komponen. Dengan memilih beberapa nilai singular terbesar, dapat didekati nilai matriks sebenarnya dengan akurasi yang cukup baik, dan itu merupakan dasar dari teknik pengurangan dimensi pada SVD.

Proses perhitungan SVD mencakup beberapa tahapan sebagai berikut

- Untuk vektor singular kiri, hitung nilai-nilai eigen dari MM^T . $\text{Rank}(M) = k =$ banyaknya nilai-nilai eigen tidak nol dari MM^T .
- Tentukan vektor-vektor eigen u_1, u_2, \dots, u_m yang berkoresponden dengan nilai-nilai eigen dari MM^T . Normalisasi u_1, u_2, \dots, u_m dengan cara setiap komponen vektornya dibagi dengan panjang vektor. Diperoleh matriks U .
- Untuk vektor singular kanan, hitung nilai-nilai eigen dari MM^T lalu tentukan nilai-nilai singularnya.
- Tentukan vektor-vektor eigen v_1, v_2, \dots, v_n yang berkoresponden dengan nilai-nilai eigen dari $M^T M$. Normalisasi v_1, v_2, \dots, v_n dengan cara setiap

komponen vektornya dibagi dengan panjang vektor. Diperoleh matriks V . Transpose-kan matriks V sehingga menjadi V^T .

- Bentuklah matriks Σ berukuran $m \times n$ dengan elemen-elemen diagonalnya adalah nilai-nilai singular tidak nol dari matriks M dengan susunan dari besar ke kecil. Nilai singular di dalam Σ adalah akar pangkat dua dari nilai-nilai eigen yang tidak nol dari $M^T M$.
- Maka, $M = U \Sigma V^T$

B. Background Separation

Background Separation adalah salah satu Teknik fundamental dalam pengolahan citra digital yang bertujuan untuk memisahkan sebuah citra menjadi dua komponen utama yaitu *foreground* dan *background*. Secara matematis, sebuah citra I dapat direpresentasikan sebagai gabungan dari komponen *foreground* F dan *background* B .

$$I(x, y) = B(x, y) + F(x, y)$$

Di mana (x, y) merepresentasikan posisi piksel dalam citra. Hal ini menjadi dasar penting dalam pengembangan teknik *background separation* yang efektif.

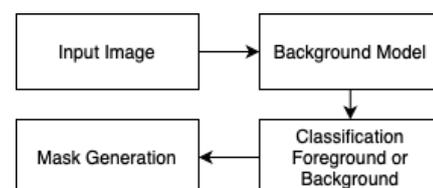
Proses *background separation* secara umum terdiri dari 2 tahapan utama. Pertama, pembentukan model *background* yang dapat mewakili karakteristik *background* dari citra yang akan di proses. Model ini biasanya berupa frame referensi ataupun model statistic yang dibangun dari sekumpulan frame. Kedua, proses klasifikasi piksel, di mana setiap piksel dalam citra dibandingkan dengan model *background* untuk menentukan apakah piksel tersebut merupakan bagian dari *foreground* atau *background*.

Proses klasifikasi piksel sebagai *background* dan *foreground* dilakukan melalui proses thresholding. Jika perbedaan antara nilai piksel pada citra input dengan model *background* melebihi nilai threshold tertentu, maka piksel tersebut diklasifikasikan sebagai *foreground*. Proses ini menghasilkan *mask* biner yang memisahkan region *foreground* dari *background*. Pemilihan nilai threshold yang tepat menjadi sangat kritis karena akan mempengaruhi akurasi hasil pemisahan.

$$M(x, y) = \begin{cases} 1, & \text{if } |I(x, y) - B(x, y)| > T \\ 0, & \text{others condition} \end{cases}$$

Di mana:

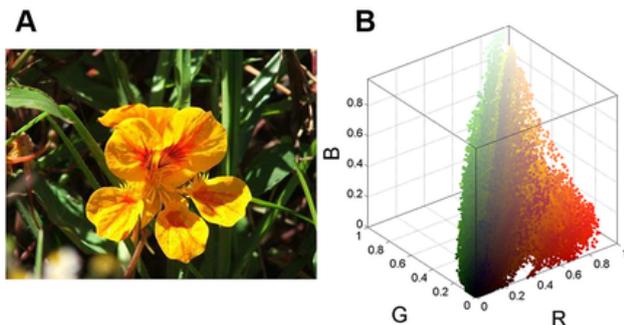
- $M(x, y)$ adalah mask hasil separation
- T adalah nilai threshold
- $I(x, y)$ adalah citra input
- $B(x, y)$ adalah model background



Gambar 3: Ilustrasi Tahapan Background Separation (Sumber: [3])

C. Color Distribution Analysis

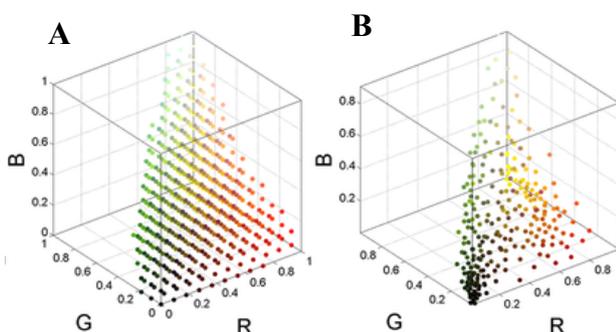
Color Distribution Analysis merupakan salah satu teknik/pendekatan yang dimanfaatkan dalam proses *background separation*. Teknik ini memanfaatkan karakteristik distribusi warna pada suatu citra untuk membedakan objek *foreground* dan *background*. Pendekatan ini memberikan kesimpulan bahwa setiap pixel dalam citra digital memiliki representasi warna tertentu yang dapat dianalisis dalam ruang warna tertentu juga. Ruang RGB adalah yang paling umum digunakan. Setiap piksel direpresentasikan oleh 3 nilai intensitas yang menunjukkan komponen warna merah (R), hijau (G), dan biru (B).



Gambar 4: Distribusi ruang warna. (A). Citra input (B). Distribusi warna asli dalam ruang warna RGB (Sumber: [5])

Berdasarkan gambar 4, sebuah citra memiliki distribusi warna yang sangat kompleks dalam ruang RGB. Gambar 4(B) memperlihatkan bagaimana setiap piksel dari citra gambar tersebut terdistribusi dalam ruang warna 3D RGB yang setiap titiknya merepresentasikan kombinasi nilai R, G, dan B dari piksel-piksel dalam citra. Visualisasi ini menunjukkan bahwa warna-warna dalam citra natural memiliki pola distribusi tertentu yang dapat dianalisis.

Untuk menganalisis distribusi warna secara efektif, diperlukan proses kuantisasi warna yang dapat menyederhanakan representasi warna dengan tetap mempertahankan informasi penting dari citra yang diproses.

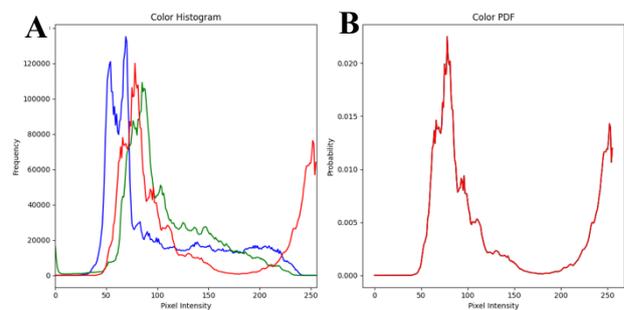


Gambar 5: Kuantisasi Warna. (A). Distribusi warna setelah kuantisasi uniform. (D) Distribusi warna setelah kuantisasi minimum variance. (Sumber: [5])

Gambar 5(A) menunjukkan hasil kuantisasi uniform di mana ruang warna dibagi menjadi interval yang seragam, sementara Gambar 5(B) memperlihatkan hasil kuantisasi dengan metode *minimum variance* yang lebih adaptif

terhadap distribusi warna aktual. Perbedaan hasil kedua metode kuantisasi ini menunjukkan pentingnya pemilihan metode yang tepat dalam *Color Distribution Analysis*.

Dalam konteks *background separation*, *Color Distribution Analysis* dimulai dengan pembentukan model statistik dari warna background. Model ini dapat direpresentasikan dalam bentuk histogram warna yang memperlihatkan frekuensi kemunculan nilai intensitas untuk setiap channel warna atau *probability density function* (PDF) yang merepresentasikan probabilitas dari distribusi intensitas warna.



Gambar 6: Representasi Model Statistik Warna. (A). Histogram. (B). *probability density function* (PDF)

Kedua representasi ini sangat berperan dalam proses *background separation*. Histogram warna membantu mengidentifikasi pola-pola dominan dalam distribusi warna background, sementara *probability density function* (PDF) memungkinkan pendekatan probabilistik dalam klasifikasi piksel. Dalam pengaplikasiannya di proses *background separation*, proses klasifikasi piksel melibatkan perhitungan jarak atau *similarity* antara warna piksel dengan model distribusi warna *background*. Piksel-piksel dengan karakteristik warna yang jauh berbeda dari model background dengan angka patokan tertentu akan diklasifikasikan sebagai bagian dari *foreground*.

Penggunaan *color distribution analysis* dalam *background separation* memiliki beberapa keuntungan. Pertama, metode ini dapat menangani variasi warna yang kompleks dalam citra natural. Kedua, *color distribution analysis* cenderung lebih efektif dalam menghadapi *noise* dibandingkan dengan metode berbasis intensitas. Ketiga, pendekatan ini dapat dikombinasikan dengan teknik lain seperti SVD untuk meningkatkan akurasi *pemisahan background*.

III. PEMBAHASAN

A. Perancangan Kode Dengan dan Tanpa SVD sebagai Pembanding

Implementasi *background separation* dalam makalah ini dilakukan dengan dua pendekatan yang berbeda untuk melihat adanya optimasi dalam penerapan SVD pada pemisahan *foreground* dan *background*. Pendekatan pertama mengintegrasikan teknik *Singular Value Decomposition* (SVD) dalam pemrosesan histogram warna, sementara pendekatan kedua dilakukan tanpa adanya reduksi dimensi. Pada tahap awal, kedua pendekatan memulai dengan membaca citra input menggunakan library OpenCV dan memisahkan

komponen warna ke dalam kanal RGB (Red, Green, Blue). Selanjutnya, dilakukan perhitungan dan normalisasi histogram untuk setiap kanal warna.

Dalam pendekatan pertama, proses dilanjutkan dengan penerapan SVD untuk mereduksi dimensi histogram. Matriks histogram yang sudah dipisahkan sebelumnya digabungkan menjadi satu matriks tunggal, kemudian didekomposisi menggunakan SVD menjadi matriks U, S, dan Vt. Pada proses reduksi, diambil nilai k=10, yang kemudian digunakan untuk mengubah histogram menjadi lebih sederhana. Hasil perubahan ini dinormalisasi dan digunakan untuk membangun model background berdasarkan rata-rata distribusi warna yang telah direduksi.

```
# SVD
U, S, Vt = np.linalg.svd(hist_matrix,
full_matrices=False)

num_components = 10
U_reduced = U[:, :num_components]
S_reduced = np.diag(S[:num_components])
Vt_reduced = Vt[:num_components, :]

# Rekonstruksi histogram yang lebih sederhana
hist_reconstructed = np.dot(U_reduced,
np.dot(S_reduced, Vt_reduced))

# Normalisasi hasil rekonstruksi
hist_reconstructed = np.clip(hist_reconstructed, 0,
1)
hist_reconstructed = hist_reconstructed.flatten() *
255

avg_r = np.sum(hist_reconstructed[0:256]) / 256
avg_g = np.sum(hist_reconstructed[256:512]) / 256
avg_b = np.sum(hist_reconstructed[512:768]) / 256

# Model background dengan rata-rata warna histogram
model_background = np.zeros_like(image,
dtype=np.uint8)
model_background[:, :, 0] = avg_b
model_background[:, :, 1] = avg_g
model_background[:, :, 2] = avg_r
```

Sementara itu, pendekatan kedua menggunakan metode yang lebih sederhana dalam pembentukan model *background*. Setelah normalisasi histogram, langsung dihitung rata-rata intensitas warna untuk setiap kanal tanpa melalui proses reduksi dimensi. Model *background* dibentuk berdasarkan nilai rata-rata ini.

```
avg_r = np.sum(hist_r * np.arange(256)) / 256
avg_g = np.sum(hist_g * np.arange(256)) / 256
avg_b = np.sum(hist_b * np.arange(256)) / 256

# Model background dengan rata-rata warna histogram
model_background = np.zeros_like(image,
dtype=np.uint8)
model_background[:, :, 0] = avg_b
model_background[:, :, 1] = avg_g
model_background[:, :, 2] = avg_r
```

Kedua pendekatan kemudian menggunakan prosedur yang sama untuk tahap pemisahan *foreground* dan *background* dan juga untuk melihat apakah ada perbedaan yang signifikan dari penerapan SVD pada salah satunya. Proses ini melibatkan perhitungan perbedaan antara citra input dengan model background yang telah dibentuk, penerapan *Gaussian Blur* untuk reduksi *noise*, dan *thresholding* berdasarkan nilai rata-rata dan standar deviasi dari perbedaan intensitas pada setiap kanal warna. Mask yang dihasilkan dari proses *thresholding* kemudian digunakan untuk memisahkan komponen *foreground* dan *background* dari citra asli.

Perbedaan utama dari kedua pendekatan terletak pada kompleksitas dan kedalaman analisis distribusi warna. Pendekatan dengan SVD menawarkan kemampuan untuk menangkap pola warna yang lebih kompleks melalui reduksi dimensi dan pemilihan komponen utama, yang berpotensi menghasilkan segmentasi yang lebih akurat pada citra dengan variasi warna yang kompleks. Di sisi lain, pendekatan tanpa SVD menawarkan solusi yang lebih efisien secara komputasional dan dapat memberikan hasil yang baik pada citra dengan distribusi warna yang relatif sederhana.

B. Pengujian

Pengujian dilakukan pada beberapa kelas gambar dan didapatkan hasil pengujian sebagai berikut

Tabel 1: Hasil Pengujian Kode Background Separation dengan SVD dan Tanpa SVD

Gambar Input	Hasil Foreground dengan SVD	Hasil Foreground tanpa SVD
		
		
		
		

Pengujian dilakukan pada 4 gambar yang masing-masing gambar memiliki tingkat kesulitan yang berbeda dalam hal *background separation*. Dimulai dari gambar dengan *background* yang polos hingga pada gambar dengan *background* yang sudah mulai kompleks. Hasilnya menunjukkan bahwa penggunaan SVD pada algoritma menunjukkan kekonsistenan yang lebih dibanding tanpa SVD. Hasil pada algoritma tanpa SVD menunjukkan hasil yang sangat tidak konsisten, di mana hasil pada *background* yang lebih kompleks bisa dikatakan lebih baik daripada hasil di *background* polos. Hal ini menjadi bukti bahwa algoritma yang digunakan masih bisa di *improve* lebih jauh lagi.

C. Analisis Hasil

Berdasarkan hasil pengujian yang dilakukan terhadap implementasi *background separation* berbasis *color distribution analysis* dengan dan tanpa menggunakan *Singular Value Decomposition* (SVD), terdapat perbedaan yang signifikan dalam kualitas hasil pemisahan *foreground* dari *background*. Implementasi dengan SVD menunjukkan performa yang lebih baik dan konsisten dibandingkan dengan metode tanpa SVD. Hal ini dapat diamati dari hasil ekstraksi *foreground* yang lebih bersih dan akurat pada berbagai jenis gambar input yang diuji.

Pada implementasi dengan SVD, proses reduksi dimensi histogram warna menggunakan 10 komponen utama berhasil menyederhanakan representasi distribusi warna sambil tetap mempertahankan informasi penting dari gambar. Hal ini menghasilkan model *background* yang lebih kuat dan fleksibel dalam menangani variasi warna yang lebih kompleks. Sebagai contoh, pada gambar bunga matahari dengan *background* langit biru, metode SVD berhasil menghapus *background* secara hampir sempurna sambil mempertahankan detail dari objek bunga dan batangnya. Demikian pula pada gambar mawar, detail-detail halus seperti tekstur kelopak dan gradasi warna dapat dipertahankan dengan baik.

Sebaliknya, implementasi tanpa SVD menunjukkan hasil yang tidak konsisten dan cenderung tidak stabil. Hal ini disebabkan oleh beberapa faktor. Pertama, tanpa proses reduksi dimensi, model menjadi sangat sensitif terhadap variasi kecil dalam distribusi warna, yang mengakibatkan *threshold* yang tidak stabil dalam proses pemisahan *foreground* dan *background*. Kedua, penggunaan histogram yang langsung tanpa diolah terlebih dahulu dengan dimensi tinggi (256 bins per kanal warna) membuat model harus memproses terlalu banyak informasi, termasuk *noise* yang sebenarnya tidak relevan. Ketiga, model tanpa SVD cenderung terlalu spesifik dalam memproses semua informasi pada citra termasuk *noise* dan distribusi warna spesifik, sehingga tidak dapat menangani variasi *background* dengan baik.

Keunggulan implementasi SVD juga terlihat dari konsistensi hasil pemisahan *background* pada berbagai jenis gambar. Pada gambar dengan *background* kompleks seperti langit berawan atau *background* blur, metode SVD tetap mampu menghasilkan ekstraksi *foreground* yang cenderung bersih. Sementara itu, metode tanpa SVD sering menghasilkan sisa-sisa *background* yang tidak diinginkan dan *noise* yang masih banyak pada hasil ekstraksi, seperti

yang terlihat pada gambar bunga dengan *background* yang kompleks.

Hasil pengujian ini membuktikan bahwa penggunaan SVD dalam proses *background separation* berbasis *color distribution analysis* memberikan peningkatan signifikan dalam kualitas hasil. Hal ini menghasilkan proses pemisahan *foreground* yang lebih akurat dan konsisten, dengan tetap mempertahankan detail-detail penting dari objek yang diinginkan.

IV. KESIMPULAN

Berdasarkan hasil pengujian implementasi *Singular Value Decomposition* (SVD) pada optimasi *background separation* berbasis *color distribution analysis*, dapat disimpulkan bahwa penggunaan SVD memberikan peningkatan yang cukup signifikan dalam kualitas hasil pemisahan *background*. Implementasi dengan SVD menghasilkan ekstraksi *foreground* yang lebih bersih dan akurat, mampu mempertahankan detail objek dengan baik, serta menghilangkan *background* secara baik pada berbagai jenis gambar input. Hal ini dicapai melalui reduksi dimensi histogram warna menggunakan 10 komponen utama yang berhasil menyederhanakan representasi distribusi warna sambil mempertahankan informasi esensial.

Sementara itu, implementasi tanpa SVD menunjukkan hasil yang tidak konsisten dan cenderung mengalami *overfitting* terhadap distribusi warna spesifik. Hal ini disebabkan oleh sensitivitas yang tinggi terhadap variasi dalam distribusi warna dan kompleksitas data histogram yang tidak tereduksi. Hasil pengujian membuktikan bahwa integrasi SVD dalam proses *background separation* merupakan cara yang efektif untuk menghasilkan pemisahan yang lebih akurat dan konsisten, dengan pendekatan yang lebih *robust* dalam menangani berbagai variasi gambar input.

Untuk pengembangan lebih lanjut, penelitian dapat difokuskan pada eksperimen dengan algoritma pemisahan *background* yang lebih canggih seperti Deep Learning-based methods (U-Net, DeepLab), atau kombinasi SVD dengan algoritma segmentasi modern seperti Mask R-CNN atau GrabCut untuk meningkatkan akurasi pemisahan *background*. Pengujian juga dapat dilakukan dengan berbagai jenis *background* yang lebih kompleks seperti *background* dengan tekstur atau gradien warna yang beragam untuk menguji ketahanan metode dalam situasi yang lebih menantang.

V. UCAPAN TERIMAKASIH

Puji syukur penulis panjatkan kepada Tuhan Yang Maha Esa yang telah memberikan karunia, sehingga penulis dapat menyelesaikan makalah yang berjudul "Implementasi *Singular Value Decomposition* (SVD) pada Optimasi *Background Separation* Berbasis *Color Distribution Analysis*" yang selesai tepat pada waktunya. Penulis juga mengucapkan terima kasih kepada diri sendiri yang telah berhasil menyelesaikan makalah ini dengan baik. Penulis mengucapkan terima kasih kepada Bapak Ir. Rila Mandala, M.Eng., Ph.D. sebagai dosen pengampu dan Bapak Dr. Ir. Rinaldi Munir, MT. sebagai dosen yang

sekaligus telah memberikan referensi dan sumber pembelajaran melalui situs beliau. Terakhir, penulis mengucapkan terima kasih kepada orang tua, keluarga, teman-teman terdekat, dan seluruh pihak yang membantu penulis dalam menyelesaikan makalah ini.

REFERENSI

- [1] A. A. Majid, Y. Yanita, and N. N. Bakar, "SIFAT-SIFAT MATRIKS ORTOGONAL DAN TRANSFORMASI ORTOGONAL," *Jurnal Matematika UNAND*, 2019.
- [2] J. José, Chavarría-Molina, and J. Soto-Quiros, "singular value decomposition: a review on the theoretical background and its applications in image processing," 2022.
- [3] T. Xue, J. Jia, H. Xie, C. Zhang, X. Deng, and Y. Wang, "Kernel Minimum Noise Fraction Transformation-Based Background Separation Model for Hyperspectral Anomaly Detection," *Remote. Sens.*, vol. 14, p. 5157, 2022.
- [4] Q. Zhang, "Exemplar-Based Image Inpainting Using Color Distribution Analysis," ResearchGate, 2014. [Online]. Available: https://www.researchgate.net/profile/Qing-Zhang-52/publication/267199333_Exemplar-Based_Image_Inpainting_Using_Color_Distribution_Analysis/links/58da0d7c92851ce5e92bafc9/Exemplar-Based-Image-Inpainting-Using-Color-Distribution-Analysis.pdf
- [5] J. Lou, M. Ren, and H. Wang, "Regional Principal Color Based Saliency Detection," *PloS one*, vol. 9, p. e112475, 2014, doi: 10.1371/journal.pone.0112475.
- [6] Rinaldi Munir, "Singular Value Decomposition (SVD) (Bagian 1) (Update 2023)", <https://informatika.stei.itb.ac.id/~rinaldi.munir/AljabarGeometri/2023-2024/Algeo-21-Singular-value-decomposition-Bagian1-2023.pdf>, diakses 30 Desember 2024 pukul 04.58 .
- [7] Rinaldi Munir, "Singular Value Decomposition (SVD) (Bagian 2) (Update 2023)", <https://informatika.stei.itb.ac.id/~rinaldi.munir/AljabarGeometri/2023-2024/Algeo-22-Singular-value-decomposition-Bagian2-2023.pdf>, diakses 30 Desember 2024 pukul 05.20 .

PERNYATAAN

Dengan ini saya menyatakan bahwa makalah yang saya tulis ini adalah tulisan saya sendiri, bukan saduran, atau terjemahan dari makalah orang lain, dan bukan plagiasi.

Bandung, 1 Januari 2025



Rafif Farras
13523095