

Klasifikasi Gambar Perkotaan dengan Lahan Hijau Menggunakan SVD dan KNN

Classification of Urban Images vs. Green Spaces Images Using SVD and KNN

Ryan Satria¹⁾, Dyah Erny Herwindiati¹⁾

¹⁾Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara

Diajukan 12 November 2025 / Disetujui 30 Maret 2026

Abstrak

Penelitian ini bertujuan untuk mengklasifikasikan citra perkotaan dan lahan hijau dengan memanfaatkan metode *Singular Value Decomposition* (SVD) untuk reduksi dimensi dan *K-Nearest Neighbors* (KNN) sebagai algoritma klasifikasi. Dataset yang digunakan terdiri dari 600 gambar (300 perkotaan dan 300 lahan hijau) berukuran 256x256 piksel, yang berasal dari dataset Kaggle "*Aerial Landscape Images*". Setiap citra diubah menjadi vektor fitur, kemudian direduksi menggunakan SVD, di mana penelitian ini membandingkan penggunaan 5 komponen dan 20 komponen. Dataset kemudian dibagi menjadi 80% data latih dan 20% data uji untuk klasifikasi menggunakan KNN dengan parameter $k=3$. Evaluasi kinerja dilakukan melalui confusion matrix serta perhitungan akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model dengan 5 komponen SVD mencapai akurasi tertinggi sebesar 95.00%, mengungguli model 20 komponen (91.67%). Temuan ini membuktikan efektivitas SVD-KNN, namun memperlihatkan bahwa jumlah komponen yang lebih banyak dapat menurunkan performa. Keterbatasan metode yang murni berbasis warna juga teridentifikasi saat pengujian pada citra "area perumahan" yang memiliki fitur tumpang tindih antar "Perkotaan" dan "Lahan Hijau".

Kata kunci—Klasifikasi, Lahan Hijau, Perkotaan, SVD, KNN

Abstract

This study aims to classify urban and green land images by employing the Singular Value Decomposition (SVD) method for dimensionality reduction and the K-Nearest Neighbors (KNN) algorithm for classification. The dataset used consists of 600 images (300 urban and 300 green land) with a resolution of 256x256 pixels, sourced from the Kaggle "Aerial Landscape Images" dataset. Each image was transformed into a feature vector, then reduced using SVD, where this study compares the use of 5 components and 20 components. The dataset was subsequently divided into 80% training data and 20% testing data for classification using KNN with $k=3$. Performance evaluation was conducted via confusion matrix and the calculation of accuracy, precision, recall, and F1-score. The results showed that the model with 5 SVD components achieved the highest accuracy of 95.00%, outperforming the 20-component model (91.67%). This finding demonstrates the effectiveness of SVD-KNN, but shows that a higher number of components can degrade performance. The limitation of the purely color-based method was also identified during testing on "residential area" images, which possess overlapping features between "Urban" and "Green Spaces".

Keywords—Classification, Green spaces, Urban, SVD, KNN

Pendahuluan

Latar Belakang

Gambar atau citra sudah menjadi bagian dari kehidupan manusia sehari-hari. Gambar atau citra

banyak digunakan untuk berbagai macam kebutuhan manusia terutama untuk memudahkan visualisasi suatu hal (Aguero, 2022). Gambar banyak digunakan pada berbagai bidang seperti komunikasi, hiburan, seni, pendidikan, penelitian, teknologi, dan masih banyak lagi. Gambar dapat digunakan dalam analisis data dengan mendapatkan informasi-informasi pada gambar tersebut menggunakan teknik analisis gambar (mengukur, merekam, merepresentasikan, dan menganalisa) (Kalluri et al., 2025). Gambar dapat digunakan dalam berbagai aplikasi analisis gambar seperti pengenalan wajah, deteksi objek seperti kendaraan, pejalan kaki, dll serta klasifikasi objek tertentu (Wang et al., 2021). Dalam konteks ini, analisis yang akan dilakukan adalah klasifikasi gambar perkotaan dengan gambar alam berupa lahan hijau.

Perkotaan dan lahan hijau memiliki ciri khasnya masing-masing yang dapat membedakan keduanya. Perkotaan biasanya dipenuhi oleh bangunan-bangunan seperti gedung perkantoran, perumahan, apartemen, fasilitas umum, tempat hiburan, dan sebagainya (Wijayanti & Khoirunurrofik, 2022). Perkotaan juga dihuni oleh manusia yang merancang adanya jalur dan alat transportasi seperti jalanan, sepeda, sepeda motor, mobil, truk, dan lainnya. Gambar perkotaan umumnya memiliki komposisi warna yang lebih monokromatik seperti abu-abu, coklat, putih, dan hitam. Hal ini disebabkan terbatasnya warna-warna yang ada pada material yang banyak digunakan pada perkotaan (Jaglarz, 2023). Lahan hijau biasa berisikan rerumputan, pepohonan, semak-semak, tanah, dan terkadang pasir. Hal-hal tersebut umumnya memberikan warna hijau, kuning, dan hijau kecoklatan pada gambar seputar lahan hijau (Pindo et al., 2025). Perbedaan komposisi warna perkotaan dan lahan hijau dapat digunakan sebagai salah satu faktor analisis klasifikasi gambar untuk membedakan kedua gambar tersebut.

Untuk menganalisis data gambar yang kompleks dan berdimensi tinggi, diperlukan teknik untuk mengekstraksi fitur-fitur penting secara efisien. Salah satu teknik yang sangat efektif untuk reduksi dimensi dan ekstraksi fitur pada data gambar adalah Singular Value Decomposition (SVD). SVD bekerja dengan cara memecah sebuah matriks menjadi tiga komponen matriks utama, yang memungkinkan untuk menangkap informasi paling signifikan dari gambar dalam bentuk yang lebih ringkas (Xing, 2024). Dalam penelitian ini, SVD akan digunakan untuk mereduksi dimensi data gambar. Setelah fitur-fitur relevan diekstraksi, proses klasifikasi akan dilakukan menggunakan metode K-Nearest Neighbors (KNN). Metode KNN dipilih karena kemampuannya yang efektif walaupun sederhana dalam mengelompokkan data berdasarkan kedekatan fitur, yang dalam hal ini adalah fitur warna yang telah direduksi oleh SVD (B & Gangula, 2024).

Tujuan dan Manfaat

Penelitian ini memiliki tujuan dan manfaat yang dirancang untuk memberikan kontribusi terhadap pengembangan metode klasifikasi citra berbasis teknik reduksi dimensi dan algoritma pembelajaran sederhana. Tujuan Penelitiannya adalah sebagai berikut:

1. Mengembangkan model klasifikasi citra sederhana namun efektif untuk membedakan antara gambar perkotaan dan lahan hijau menggunakan kombinasi metode *Singular Value Decomposition* dan K-Nearest Neighbors
2. Menganalisis efektivitas metode SVD dalam mereduksi dimensi data citra tanpa menghilangkan informasi penting yang dibutuhkan untuk klasifikasi.
3. Menguji kinerja algoritma KNN terhadap hasil ekstraksi fitur dari SVD, dengan mengevaluasi akurasi, presisi, F1-score, dan ketepatan prediksi model dalam membedakan citra tersebut.

Manfaat penelitiannya adalah sebagai berikut:

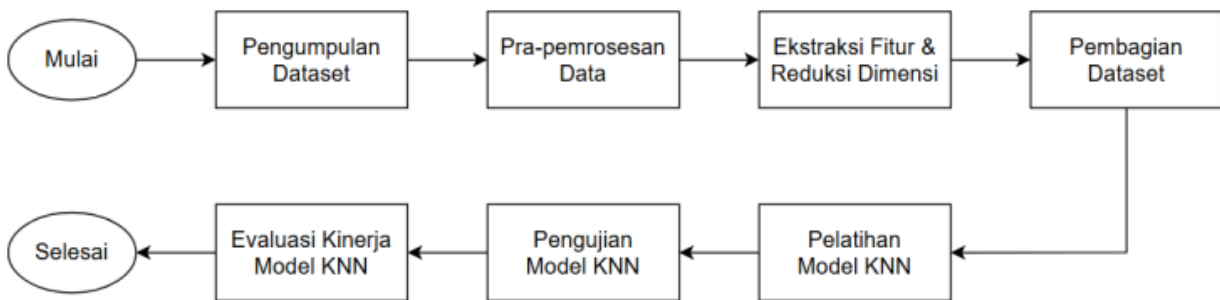
1. Memberikan kontribusi terhadap pengembangan metode klasifikasi citra berbasis warna, yang dapat diterapkan pada berbagai kasus analisis citra.
2. Menjadi referensi penelitian selanjutnya yang ingin menggabungkan teknik reduksi dimensi dengan algoritma klasifikasi sederhana.

3. Mendukung otomatisasi analisis spasial dan pemetaan lahan, khususnya dalam membedakan area terbangun (perkotaan) dengan area hijau.

METODE PENELITIAN

Alur Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan yang sistematis untuk memastikan proses analisis berjalan dengan terstruktur. Secara garis besar, alur kerja ini mencakup tiga fase utama: persiapan data, penerapan model, dan evaluasi hasil. Setiap tahap memiliki peran penting dan saling berkesinambungan untuk mencapai tujuan akhir, yaitu mengklasifikasikan gambar perkotaan dan lahan hijau secara akurat. Keseluruhan tahapan penelitian ini digambarkan secara visual pada diagram dibawah.




Gambar 1 Diagram Alur Penelitian

Mengacu pada diagram alur, penelitian ini diawali dengan tahap pengumpulan dan pra-pemrosesan, di mana setiap citra RGB berukuran 256x256 piksel diubah menjadi sebuah vektor fitur tunggal berdimensi 256x256x3 (19,608). Vektor fitur berdimensi sangat tinggi ini kemudian diproses menggunakan Singular Value Decomposition (SVD) untuk mereduksi dimensi dengan cara mengekstraksi komponen-komponen paling signifikan yang mewakili karakteristik utama dari setiap gambar. Setelah menghasilkan set fitur yang lebih ringkas, dataset dibagi secara proporsional menjadi 80% data latih dan 20% data uji (Shujaaddeen et al., 2024). Model K-Nearest Neighbors (KNN) kemudian dilatih menggunakan data latih untuk membangun pemetaan antara fitur dan kelas, yang selanjutnya digunakan untuk melakukan prediksi kelas pada data uji. Sebagai tahap akhir, evaluasi kinerja dilakukan dengan membandingkan hasil prediksi model terhadap label asli dari data uji, di mana keberhasilannya diukur secara kuantitatif melalui pembuatan confusion matrix serta penghitungan metrik performa seperti akurasi, presisi, *recall*, dan *F1-score*.


Dataset

Dataset yang digunakan dalam penelitian ini berasal dari Kaggle dengan judul “Aerial Landscape Images”, yang berisi kumpulan citra dari berbagai wilayah seperti perkotaan, pegunungan, lahan rerumputan, pantai, sungai, dan area perumahan (Bhardwaj & Yessica, n.d.). Dataset ini terdiri atas total 15 kategori, namun penelitian ini hanya menggunakan empat kategori, yaitu perkotaan, perhutanan, lahan rerumputan, dan area perumahan. Setiap kategori memiliki 800 gambar dengan ukuran masing-masing 256x256 piksel. Untuk proses klasifikasi, penelitian ini membatasi kelas menjadi dua, yaitu perkotaan dan lahan hijau, di mana lahan hijau mencakup kategori perhutanan dan lahan rerumputan. Sementara itu, area perumahan tidak digunakan dalam tahap pelatihan karena citranya mengandung campuran fitur antara perkotaan dan lahan hijau.

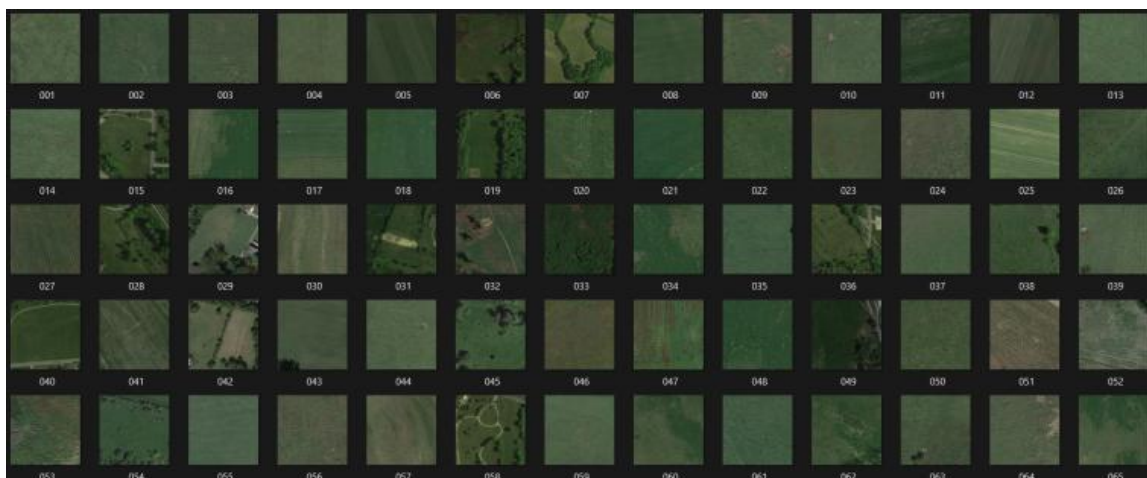


Gambar 2 Dataset Gambar Perkotaan (Bhardwaj & Yessica, n.d.)

Sebanyak 300 gambar perkotaan dan 300 gambar lahan hijau (masing-masing 150 perhutanan dan 150 rerumputan) digunakan untuk pelatihan dan pengujian internal, sedangkan 100 gambar area perumahan digunakan sebagai dataset eksternal untuk menguji performa algoritma KNN. Contoh citra dari setiap kategori dapat dilihat pada Gambar 2, 3, 4, dan 5.



Gambar 3 Dataset Gambar Perhutanan (Bhardwaj & Yessica, n.d.)



Gambar 4 Dataset Gambar Lahan Rerumputan (Bhardwaj & Yessica, n.d.)



Gambar 5 Dataset Gambar Area Perumahan (Bhardwaj & Yessica, n.d.)

Singular Value Decomposition

SVD atau *Singular Value Decomposition* adalah sebuah metode dekomposisi matriks yang bertujuan meringkas matriks berukuran apa saja (umumnya matriks yang berukuran sangat besar) dengan memecah matriks tersebut menjadi tiga matriks, dimana masing-masing matriks tersebut memiliki karakteristik berbeda (Sitanggung et al., 2023). Proses dekomposisi ini dikenal dengan istilah faktorisasi (Setiawan, 2021). Ketiga pecahan matriks tersebut disebut, matriks vektor singular kiri, matriks singular, dan matriks vektor singular kanan (Hadiyanto et al., 2020). Persamaan pada metode SVD pada sebuah matriks X adalah sebagai berikut (Nagaria et al., 2016):

$$X = U \cdot S \cdot V^t \quad (1)$$

Keterangan:

- U : matriks berukuran $m \times m$ yang memiliki kolom yang ortonormal
- S : matriks diagonal berukuran $m \times n$ berisikan singular value dari matriks X
- V : matriks berukuran $n \times n$ yang memiliki kolom yang ortonormal

Tahapan dari metode SVD adalah sebagai berikut:

1. Membentuk dan menghitung matriks $X \cdot X^T$
2. Membentuk dan menghitung matriks $X^T \cdot X$
3. Menghitung nilai eigen dari $X \cdot X^T$ untuk mendapatkan matriks U dan S

$$(X \cdot X^T) \cdot u_i = \lambda_i \cdot u_i \quad (2)$$

$$U = [u_1 \ u_2 \ \dots \ u_m] \quad (3)$$

$$s_i = \sqrt{\lambda_i} \quad (4)$$

$$S = \text{diag}[s_1, s_2, \dots, s_n] \quad (5)$$

4. Menghitung nilai eigen dari $X^T \cdot X$ untuk mendapatkan matriks V

$$(X^T \cdot X) \cdot v_i = \gamma_i \cdot v_i \quad (6)$$

$$V = [v_1 \ v_2 \ \dots \ v_n] \quad (7)$$

K-Nearest Neighbors

KNN atau *K-Nearest Neighbors* adalah metode yang digunakan untuk mengklasifikasikan dataset berdasarkan fitur-fitur yang dicek dengan tetangganya (Fa et al., 2024). KNN menggunakan prosedur matematika untuk mengevaluasi nilai-nilai kriteria dalam proses klasifikasi. KNN bekerja dengan mencari titik K dalam dataset pelatihan yang paling dekat dengan sampel yang sedang

diklasifikasikan berdasarkan jarak Euclidean (Lubis et al., 2020; Prasetyo et al., 2023). Kemudian berdasarkan jarak terdekat, sampel yang diuji akan diberikan label kelas terdekat. Berikut adalah tahapan yang dilakukan untuk metode KNN:

1. Tentukan jumlah tetangga yang akan menentukan kelas dari data uji (parameter K)
2. Data baru atau data uji akan dihitung jarak euclideannya terhadap masing-masing data pelatihan atau training menggunakan rumus jarak Euclidean. Rumus *Euclidean distance* (Anggela et al., 2022):

$$dist(x_1, x_2) = \sqrt{\sum_{i=0}^n (x_{1i} - x_{2i})^2} \quad (8)$$

3. Urutkan jarak berdasarkan jarak minimum, kemudian berdasarkan parameter K kelas yang terbanyak akan menentukan kelas dari data uji tersebut.

Evaluasi

Untuk mengukur kinerja model klasifikasi SVD dan KNN yang diusulkan, dilakukan evaluasi kuantitatif menggunakan beberapa metrik standar. Evaluasi ini didasarkan pada *confusion matrix* (dapat dilihat pada Tabel 1), sebuah tabel yang merangkum hasil prediksi model terhadap data uji (Normawati & Prayogi, 2021).

Confusion matrix menyajikan empat keluaran utama: *True Positive* (TP) yaitu data positif yang diprediksi benar, *True Negative* (TN) yaitu data negatif yang diprediksi benar, *False Positive* (FP) yaitu data negatif yang salah diprediksi sebagai positif, dan *False Negative* (FN) yaitu data positif yang salah diprediksi sebagai negatif (Obi, 2023). Berdasarkan nilai-nilai ini, metrik performa utama dihitung: Akurasi, Presisi, *Recall*, dan *F1-Score*.

Tabel 1 Confusion Matrix (Obi, 2023)

		Kelas Sebenarnya	
		P	N
Kelas Prediksi	P	TP (<i>True Positive</i>)	FP (<i>False Positive</i>)
	N	FN (<i>False Negative</i>)	TN (<i>True Negative</i>)

Akurasi mengukur proporsi prediksi yang benar secara keseluruhan (TP dan TN) terhadap total data. Akurasi dihitung menggunakan persamaan (Fajrianti et al., 2022):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

Presisi mengukur seberapa banyak data yang diprediksi sebagai positif yang benar-benar positif. Metrik ini penting untuk memahami keandalan prediksi positif (Arisandi et al., 2022). Presisi dihitung dengan persamaan:

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

Recall (atau sensitivitas) mengukur kemampuan model untuk menemukan kembali semua data positif yang sebenarnya. Metrik ini berfokus pada minimalisasi *False Negative* (Arisandi et al., 2022). *Recall* dihitung dengan persamaan:

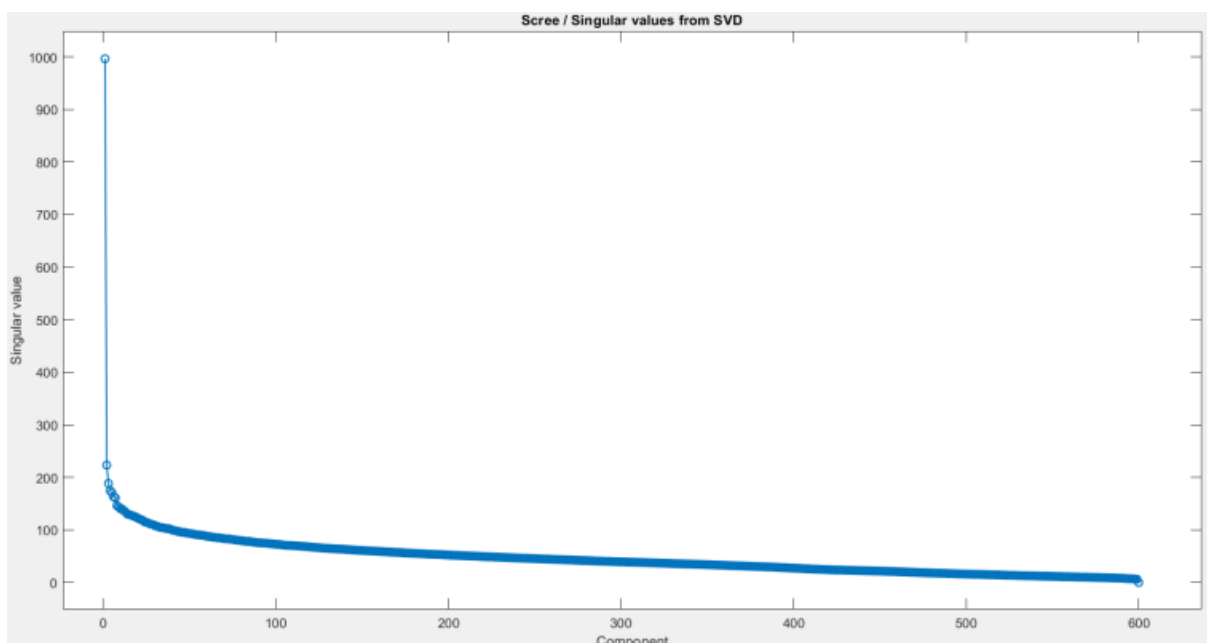
$$Recall = \frac{TP}{TP + FN} \quad (11)$$

F1-Score adalah rata-rata harmonis dari Presisi dan *Recall*. Metrik ini memberikan sebuah nilai tunggal yang menyeimbangkan kedua metrik tersebut, dan sering digunakan sebagai metrik evaluasi utama ketika terdapat ketidakseimbangan kelas. *F1-Score* dihitung dengan persamaan:

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (12)$$


HASIL DAN PEMBAHASAN

Analisis hasil penelitian dilakukan dengan menggunakan metode reduksi dimensi Singular Value Decomposition (SVD) dan klasifikasi K-Nearest Neighbor (KNN). Proses diawali dengan meninjau distribusi nilai singular dari hasil dekomposisi matriks citra untuk menentukan jumlah komponen utama yang relevan. Data yang telah direduksi kemudian diproyeksikan ke ruang berdimensi rendah dan diklasifikasikan menggunakan algoritma KNN dengan parameter jumlah tetangga $k=3$. Hasil klasifikasi divisualisasikan dalam bentuk grafik sebaran data uji terhadap data latih, serta dievaluasi melalui tabel perbandingan kelas dan confusion matrix untuk mengukur tingkat akurasi model.




Gambar 6 Scree Plot Nilai Singular dari SVD

Grafik pada Gambar 6 menunjukkan distribusi nilai singular dari hasil dekomposisi matriks data gambar perkotaan dan lahan hijau menggunakan metode *Singular Value Decomposition* (SVD). Sumbu horizontal merepresentasikan urutan komponen hasil dekomposisi, sedangkan sumbu vertikal menunjukkan nilai singular dari masing-masing komponen tersebut. Berdasarkan grafik, tampak bahwa nilai singular pada beberapa komponen awal memiliki nilai yang jauh lebih tinggi dibandingkan komponen-komponen berikutnya, kemudian menurun secara bertahap hingga mencapai nilai yang relatif stabil setelah sekitar komponen ke-50. Hal ini menunjukkan bahwa sebagian besar informasi atau variansi dalam data terkandung pada komponen-komponen awal, sementara komponen setelahnya memberikan kontribusi informasi yang semakin kecil. Pola penurunan yang halus ini juga mengindikasikan bahwa data memiliki kompleksitas yang lebih tinggi dibandingkan dataset berukuran kecil, sehingga diperlukan lebih banyak komponen untuk mempertahankan informasi penting. Dengan demikian, pemilihan jumlah komponen optimal dapat ditentukan berdasarkan titik di mana penurunan nilai singular mulai melandai, agar reduksi dimensi tetap efisien tanpa kehilangan informasi signifikan.




Gambar 7 Scatter Plot Klasifikasi KNN (20 Komponen)




Gambar 8 Scatter Plot Klasifikasi KNN (5 Komponen)

Pengujian dilakukan dengan menggunakan jumlah komponen yang berbeda berdasarkan hasil scree plot dari dekomposisi SVD. Jumlah komponen yang diuji adalah 5 dan 20 komponen untuk membandingkan tingkat akurasi dan kestabilan model. Proses klasifikasi menggunakan algoritma K-Nearest Neighbors (KNN) dapat dilihat pada Gambar 7 dan Gambar 8. Pada visualisasi tersebut, citra lahan hijau direpresentasikan dengan titik berwarna hijau, sedangkan citra perkotaan dengan titik berwarna hitam. Data uji yang terdiri dari 120 citra digambarkan sebagai simbol segitiga merah dan diklasifikasikan berdasarkan tiga tetangga terdekatnya. Prediksi kelas ditentukan oleh mayoritas dari tiga tetangga tersebut. Pemilihan nilai k pada algoritma KNN dilakukan menggunakan bilangan ganjil untuk menghindari kondisi tie atau hasil prediksi yang seimbang antara dua kelas, sehingga keputusan klasifikasi dapat diambil secara lebih tegas dan akurat (Boateng et al., 2020).

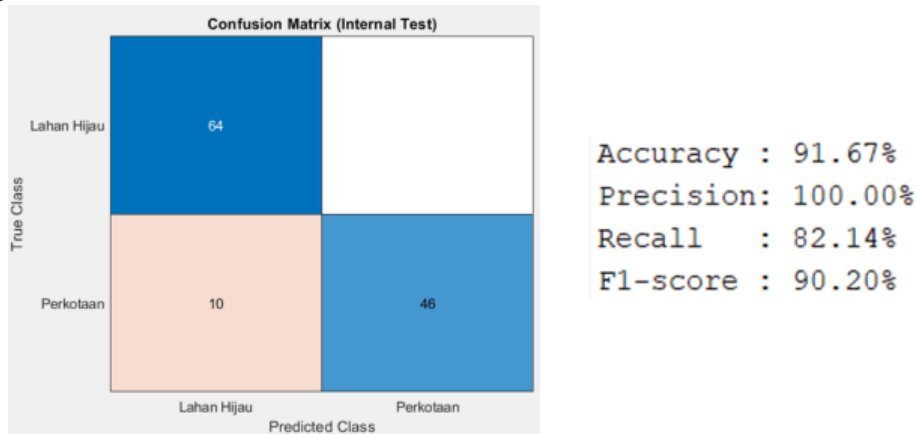


Gambar 9 Scatter Plot Uji Dengan Gambar Perumahan (20 Komponen)




Gambar 10 Scatter Plot Uji Dengan Gambar Perumahan (5 Komponen)

Pengujian menggunakan dataset eksternal dilakukan dan hasilnya ditunjukkan pada Gambar 9 dan Gambar 10. Dataset ini terdiri dari citra area perumahan yang memiliki karakteristik campuran antara elemen perkotaan dan lahan hijau, sehingga menjadi data uji yang menantang bagi model. Seluruh citra perumahan direpresentasikan dengan simbol segitiga pada grafik hasil klasifikasi. Segitiga merah melambangkan gambar perumahan yang diprediksi sebagai perkotaan dan segitiga biru melambangkan gambar perumahan yang diprediksi sebagai lahan hijau. Berdasarkan hasil pengujian, algoritma dengan 20 komponen cenderung lebih sering mengklasifikasikan citra perumahan sebagai lahan hijau, sedangkan algoritma dengan 5 komponen menunjukkan hasil klasifikasi yang lebih seimbang antara kelas perkotaan dan lahan hijau.



Gambar 11 Hasil Evaluasi (Komponen=20)



Gambar 12 Hasil Evaluasi (Komponen=5)

Perbandingan hasil evaluasi pada Gambar 11 (20 komponen) dan Gambar 12 (5 komponen) menunjukkan bahwa model dengan 5 komponen SVD berkinerja lebih unggul dengan akurasi 95.00%, dibandingkan 91.67% pada model 20 komponen. Kelemahan utama model 20 komponen terletak pada tingginya nilai False Negative (FN=10), yang berarti model tersebut sering salah mengklasifikasikan "Perkotaan" sebagai "Lahan Hijau" dan menghasilkan recall yang rendah (82.14%). Sebaliknya, model 5 komponen jauh lebih seimbang; model ini berhasil mengurangi FN secara drastis (FN=4), yang secara signifikan meningkatkan recall (92.86%) dan F1-score (94.55%), meskipun dengan sedikit penurunan presisi.

Temuan ini membuktikan bahwa jumlah komponen yang lebih banyak tidak selalu menghasilkan akurasi yang lebih baik. Lima komponen tampaknya sudah cukup untuk menangkap fitur inti yang paling relevan untuk membedakan kedua kelas. Penambahan komponen (dari 6 hingga 20) kemungkinan besar justru memasukkan *noise* atau variasi data yang tidak relevan, yang akhirnya mengganggu kemampuan klasifikasi KNN dan menurunkan performa generalisasinya.

Bukti atas generalisasi yang lebih buruk ini diperkuat oleh hasil pengujian menggunakan dataset eksternal (area perumahan) yang memiliki karakteristik visual campuran. Model dengan 20 komponen menunjukkan bias yang sangat kuat, mengklasifikasikan mayoritas citra "Perumahan" sebagai "Lahan Hijau" sebanyak 83 gambar dan hanya 17 sebagai "Perkotaan". Sebaliknya, model 5 komponen menghasilkan prediksi yang jauh lebih seimbang (57 "Lahan Hijau" dan 43 "Perkotaan"). Hal ini mengindikasikan bahwa model 5 komponen telah mempelajari representasi fitur yang lebih robust dan tidak overfitting pada data latih.

Hasil pengujian eksternal pada citra "area perumahan" ini juga memperlihatkan keterbatasan fundamental dari pendekatan yang digunakan dalam penelitian ini. Metode SVD yang diterapkan

langsung pada data piksel RGB pada dasarnya adalah ekstraktor fitur yang sangat bergantung pada karakteristik warna dominan dan intensitas. Model ini tidak memiliki kemampuan untuk memahami konteks spasial, bentuk objek, atau fitur tekstur. Area perumahan adalah contoh sempurna dari citra hibrida yang ambigu secara kromatik (warna), karena ia mengandung elemen warna dari kedua kelas (misalnya, abu-abu/coklat dari atap dan jalan, serta hijau dari vegetasi). Tanpa kemampuan untuk menganalisis fitur lain dari gambar, seperti pola terstruktur dan garis lurus bangunan (khas perkotaan) dengan pola organik dan acak dari vegetasi (khas lahan hijau), model yang hanya berbasis warna ini akan kesulitan melakukan klasifikasi yang benar saat dihadapkan pada gambar yang tumpang tindih secara visual.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat ditarik kesimpulan bahwa kombinasi metode *Singular Value Decomposition* (SVD) untuk reduksi dimensi dan K-Nearest Neighbors (KNN) untuk klasifikasi terbukti efektif untuk membedakan citra "Perkotaan" dan "Lahan Hijau", dengan model terbaik (5 komponen) mencapai akurasi 95.00%. Jumlah komponen SVD yang digunakan memiliki dampak kritis terhadap kinerja. Penelitian ini membuktikan bahwa jumlah komponen yang lebih banyak tidak menjamin akurasi yang lebih baik. Model dengan 5 komponen (Akurasi 95.00%) berkinerja lebih unggul daripada 20 komponen (Akurasi 91.67%), kemungkinan besar karena 20 komponen mulai menyertakan *noise* atau variansi data yang tidak relevan sehingga mengganggu generalisasi model. Keterbatasan fundamental dari metode SVD+KNN yang murni berbasis piksel warna teridentifikasi dengan jelas. Model ini sangat bergantung pada karakteristik warna dominan dan tidak mampu menganalisis fitur tekstur (misalnya, pola terstruktur bangunan vs. pola acak vegetasi). Hal ini terbukti pada pengujian data eksternal "Area Perumahan", di mana model kesulitan mengklasifikasikan citra hibrida yang ambigu secara visual.

DAFTAR PUSTAKA

- Aguero, H. P. (2022). Review of the Current Technologies and Applications of Digital Image Processing. *Journal of Biomedical and Sustainable Healthcare Applications*, 2(2), 148–158. <https://doi.org/10.53759/0088/JBSHA202202016>
- Anggela, S. H., Santoso, L. W., & Andjarwirawan, J. (2022). Sistem Rekomendasi Pembelian Laptop dengan K-Nearest Neighbor (KNN). *Jurnal Infra*, 6(2). <https://doi.org/10.32528/jasie.v3i1>
- Arisandi, R. R. R., Warsito, B., & Hakim, A. R. (2022). Aplikasi Naïve Bayes Classifier (NBC) pada Klasifikasi Status Gizi Balita Stunting dengan Pengujian K-Fold Cross Validation. *Jurnal Gaussian*, 11(1), 130–139. <https://doi.org/10.14710/j.gauss.v11i1.33991>
- B, V., & Gangula, R. (2024). Exploring the Power and Practical Applications of K-Nearest Neighbours (KNN) in Machine Learning. *Journal of Computer Allied Intelligence*, 2(1), 8–15. <https://doi.org/10.69996/jcai.2024002>
- Bhardwaj, A., & Yessica. (n.d.). *Aerial Landscape Images*.
- Boateng, E. Y., Otoo, J., & Abaye, D. A. (2020). Basic Tenets of Classification Algorithms K-Nearest-Neighbor, Support Vector Machine, Random Forest and Neural Network: A Review. *Journal of Data Analysis and Information Processing*, 8(4), 341–357. <https://doi.org/10.4236/jdaip.2020.84020>
- Fa, N., Saputra, R. A., & Nangi, J. (2024). Classification of apple maturity based on color using the K-Nearest Neighbor (KNN) method. *Telematika*, 21(1), 55. <https://doi.org/10.31315/telematika.v21i1.11773>
- Fajrianti, E. D., Pratama, A. A., Nasyir, J. A., Rasyid, A., Winarno, I., & Sukaridhoto, S. (2022). High-Performance Computing on Agriculture: Analysis of Corn Leaf Disease. *JOIV: International Journal on Informatics Visualization*, 6(2), 411. <https://doi.org/10.30630/joiv.6.2.793>
- Hadiyanto, Lauro, M. D., & Herwindiati, D. E. (2020). Classification of historic buildings in Indonesia with SVD algorithm based on texture and color characteristics (case: temples, historic mosques, historic churches, and historic Confucian temples). *IOP Conference Series: Materials Science and Engineering*, 1007(1), 12130. <https://doi.org/10.1088/1757-899X/1007/1/012130>
- Jaglarz, A. (2023). Perception of Color in Architecture and Urban Space. *Buildings*, 13(8), 2000. <https://doi.org/10.3390/buildings13082000>

- Kalluri, P. R., Agnew, W., Cheng, M., Owens, K., Soldaini, L., & Birhane, A. (2025). Computer-Vision Research Powers Surveillance Technology. *Nature*, 643(8070), 73–79. <https://doi.org/10.1038/s41586-025-08972-6>
- Lubis, A. R., Lubis, M., & Khowarizmi, A. (2020). Optimization of Distance Formula in K-Nearest Neighbor Method. *Bulletin of Electrical Engineering and Informatics*, 9(1), 326–338. <https://doi.org/10.11591/eei.v9i1.1464>
- Nagaria, G. L., Herwindiati, D. E., & Mulyono, S. (2016, November). Klasifikasi Lahan Mangrove Menggunakan Metode Singular Value Decomposition. *Seminar Nasional Sistem Informasi Indonesia*.
- Normawati, D., & Prayogi, S. A. (2021). Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 5(2). <https://doi.org/10.30645/J-SAKTI.V5I2.369>
- Obi, J. C. (2023). A Comparative Study of Several Classification Metrics and Their Performances on Data. *World Journal of Advanced Engineering Technology and Sciences*, 8(1), 308–314. <https://doi.org/10.30574/wjaets.2023.8.1.0054>
- Pindo, T., Nurul, A., Adisti, S., Aditya, G. S., & Respati, W. (2025). The Calculation of Green Open Space Patterns in The Cities in Indonesia. *International Review for Spatial Planning and Sustainable Development*, 13(2), 179–192. https://doi.org/10.14246/irspsd.13.2_179
- Prasetyo, S. D., Hilabi, S. S., & Nurapriani, F. (2023). Analisis Sentimen Relokasi Ibukota Nusantara Menggunakan Algoritma Naïve Bayes dan KNN. *Jurnal KomtekInfo*, 10(1), 1–7. <https://doi.org/10.35134/komtekinfo.v10i1.330>
- Setiawan, D. (2021). Analisis Curah Hujan di Indonesia untuk Memetakan Daerah Potensi Banjir dan Tanah Longsor dengan Metode Cluster Fuzzy C-Means dan Singular Value Decomposition (SVD). *Engineering, Mathematics and Computer Science (EMACS) Journal*, 3(3), 115–120. <https://doi.org/10.21512/emacsjournal.v3i3.7428>
- Shujaaddeen, A. A., Ba-Alwi, F. M., Zahary, A. T., & Alhegami, A. S. (2024). A Model for Measuring the Effect of Splitting Data Method on the Efficiency of Machine Learning Models: A Comparative Study. *2024 4th International Conference on Emerging Smart Technologies and Applications (ESmarTA)*, 1–13. <https://doi.org/10.1109/eSmarTA62850.2024.10639022>
- Sitanggang, A., Harahap, A. D., Karimullah, A., Dewantara, Y. A., & Rozikin, C. (2023). Sistem Rekomendasi Anime Menggunakan Metode Singular Value Decomposition (SVD) dan Cosine Similarity. *Jurnal Teknologi Informasi UTU*, 2(2). <https://doi.org/10.35308/jti.v2i2.7787>
- Wang, J., Zhang, T., Cheng, Y., & Al-Nabhan, N. (2021). Deep Learning for Object Detection: A Survey. *Computer Systems Science and Engineering*, 38(2), 165–182. <https://doi.org/10.32604/csse.2021.017016>
- Wijayanti, D. C., & Khoirunurrofik, K. (2022). Strategic Interaction Between the Agglomeration of High-Rise Buildings and the Economy of DKI Jakarta. *International Journal of Sustainable Development and Planning*, 17(5), 1449–1459. <https://doi.org/10.18280/ijspd.170509>
- Xing, K. (2024). Singular Value Decomposition: A Useful Technique for Image Denoising. *Theoretical and Natural Science*, 39(1), 226–231. <https://doi.org/10.54254/2753-8818/39/20240610>