

Kombinasi Metode Discrete Wavelet Transform dan Random Forest untuk Steganalisis Citra Digital

1st Andika Putra Ariansyah
 Program Studi Informatika
 Universitas Telkom, Kampus Surabaya
 Surabaya, Indonesia
andikaariansyah@student.telkomuniversity.ac.id

2nd Rizky Fenaldo Maulana
 Program Studi Informatika
 Universitas Telkom, Kampus Surabaya
 Surabaya, Indonesia
rizkyfenaldo@telkomuniversity.ac.id

3rd Tanzilal Mustaqim
 Program Studi Informatika
 Universitas Telkom, Kampus Surabaya
 Surabaya, Indonesia
tanzilal@telkomuniversity.ac.id

Abstrak — Steganografi merupakan teknik penyisipan informasi rahasia ke dalam media digital seperti citra, sehingga keberadaan informasi tersebut tidak terdeteksi secara visual. Untuk mengidentifikasi adanya pesan tersembunyi, diperlukan proses steganalisis yang efektif. Penelitian ini mengusulkan kombinasi metode *Discrete Wavelet Transform* (DWT) dan *Random Forest* sebagai pendekatan untuk membedakan citra stego dari citra cover. DWT digunakan untuk mengekstraksi fitur dari domain frekuensi melalui dekomposisi multi-level menjadi empat sub-band frekuensi (LL, LH, HL, HH). Fitur statistik dari sub-band tersebut kemudian diklasifikasikan menggunakan algoritma Random Forest. Eksperimen dilakukan pada dataset IStego100K yang terdiri atas 1.250 citra cover dan 1.250 citra stego, dengan rasio pelatihan dan pengujian 80:20. Citra stego dibentuk melalui teknik *Least Significant Bit* (LSB) replacement. Empat jenis wavelet digunakan dalam pengujian, yaitu Haar, Symlet (Sym4), Coiflet (Coif1), dan Daubechies (Db4). Hasil menunjukkan bahwa model menggunakan wavelet Db4 memberikan performa terbaik dengan akurasi 91,4%, presisi 94,0%, recall 88,4%, dan F1-score 91,1%. Temuan ini menunjukkan bahwa kombinasi DWT dan Random Forest efektif digunakan untuk mendeteksi steganografi dalam citra digital dan berpotensi diaplikasikan dalam sistem keamanan serta forensik digital.

Kata kunci — citra digital, discrete wavelet transform, LSB, random forest, steganalisis

I. PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi yang pesat telah membawa dampak signifikan dalam berbagai aspek kehidupan manusia. Salah satu dampak positifnya adalah kemudahan berbagi dan menyimpan data digital, termasuk citra digital yang semakin banyak digunakan dalam komunikasi sehari-hari. Namun, kemudahan ini juga membawa tantangan baru dalam hal keamanan informasi, khususnya terkait dengan teknik

steganografi yang dapat digunakan untuk menyembunyikan informasi rahasia di dalam citra digital [1]. Seiring dengan berkembangnya teknik steganografi, muncul pula kebutuhan akan metode untuk mendeteksi keberadaan informasi tersembunyi dalam citra digital, yang dikenal sebagai steganalisis.

Dalam era digital saat ini, steganalisis menjadi sangat penting untuk berbagai keperluan, mulai dari keamanan siber, digital forensik, hingga pencegahan penyalahgunaan teknologi untuk aktivitas ilegal. Tantangan utama dalam steganalisis adalah bahwa perubahan yang dilakukan umumnya sangat kecil dan sulit dideteksi secara visual [2]. Oleh karena itu, diperlukan metode komputasi yang dapat menganalisis karakteristik statistik dan struktural dari citra untuk mengidentifikasi adanya modifikasi yang mengindikasikan keberadaan informasi tersembunyi. Berbagai pendekatan telah dikembangkan untuk mengatasi tantangan ini, mulai dari analisis histogram, analisis tekstur, hingga metode berbasis pembelajaran mesin (*machine learning*).

Discrete Wavelet Transform (DWT) telah banyak digunakan dalam berbagai penelitian analisis citra digital. Metode ini bekerja dengan mendekomposisi citra ke dalam domain frekuensi yang memungkinkan analisis pada berbagai tingkat resolusi dan frekuensi [3]. Di sisi lain, *Random Forest* merupakan salah satu algoritma pembelajaran mesin yang banyak diterapkan untuk berbagai tugas klasifikasi, termasuk dalam bidang steganalisis [4]. Algoritma ini dapat mempelajari pola-pola dari fitur-fitur yang diekstrak dari citra untuk membedakan antara citra yang mengandung informasi tersembunyi dengan citra yang tidak mengandung informasi tersembunyi.

Meskipun baik DWT maupun Random Forest telah digunakan secara terpisah dalam berbagai penelitian steganalisis, kombinasi keduanya belum dieksplorasi secara mendalam. Kombinasi DWT sebagai metode ekstraksi fitur dan Random Forest sebagai algoritma klasifikasi berpotensi menghasilkan sistem steganalisis yang lebih akurat dan tangguh. DWT dapat mengekstrak fitur-fitur informatif dari domain frekuensi yang sensitif terhadap perubahan steganografi [5], sementara Random Forest dapat

mengklasifikasikan fitur-fitur tersebut dengan akurasi yang tinggi berdasarkan pola-pola yang dipelajari dari data latih [6]. Dengan demikian, penelitian ini diharapkan dapat memberikan gambaran konkret mengenai implementasi dan performa kombinasi DWT dan Random Forest dalam proses steganalisis pada citra digital.

II. KAJIAN TEORI

A. Citra Digital

Citra digital merupakan representasi gambar dari suatu objek atau pemandangan yang dikonversi ke dalam bentuk digital sehingga dapat dipahami dan diolah oleh komputer. Citra ini terdiri dari sekumpulan piksel yang masing-masing menyimpan informasi tentang warna atau intensitas cahaya di suatu titik. Citra digital dapat berupa citra skala abu-abu (grayscale), yang hanya mengandung nilai intensitas cahaya, atau citra berwarna yang menyimpan informasi tentang berbagai kanal warna seperti merah, hijau, dan biru (RGB). Citra digital dapat disimpan dalam berbagai format file yang mempengaruhi cara data tersebut diolah dan disimpan [7].

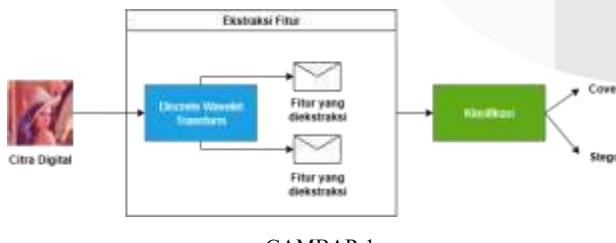
B. Steganografi

Steganografi merupakan teknik untuk menyembunyikan keberadaan informasi rahasia di dalam media lain seperti citra, audio, atau video, sehingga tidak terdeteksi oleh pihak ketiga selain penerima yang dituju. Istilah ini berasal dari bahasa Yunani, yaitu kata steganos (tersembunyi) dan graphein (menulis), yang secara harfiah berarti "tulisan tersembunyi" [8].

C. Steganalisis

Steganalisis merupakan proses yang bertujuan untuk mendeteksi keberadaan pesan tersembunyi dalam media digital, yang telah dimodifikasi menggunakan teknik steganografi. Dalam konteks citra digital, steganalisis digunakan untuk membedakan antara citra asli (*cover*) dan citra yang telah disisipi pesan (*stego*) [9].

Gambar 1 menunjukkan proses steganalisis yang terdiri atas empat tahapan utama, yaitu input citra digital, ekstraksi fitur, klasifikasi, dan hasil output. Setelah fitur diperoleh baik dari domain spasial maupun transformasi, data tersebut dianalisis menggunakan model pembelajaran mesin untuk mengklasifikasikan apakah sebuah citra termasuk cover atau stego [10].

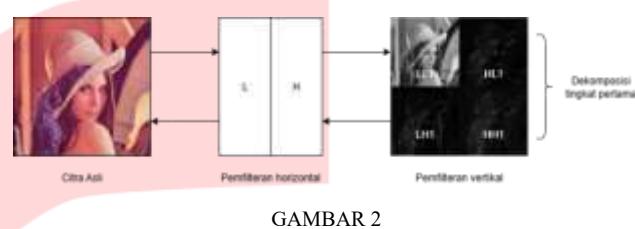


GAMBAR 1
(ALUR PROSES STEGANALISIS)

D. Discrete Wavelet Transform (DWT)

DWT merupakan teknik transformasi yang digunakan untuk menganalisis sinyal atau citra dalam domain waktu dan frekuensi secara bersamaan. Metode ini diperkenalkan oleh Grossman dan Morlet pada awal 1980-an dan berkembang pesat dalam berbagai aplikasi pengolahan citra, termasuk steganalisis [11].

DWT bekerja dengan memecah citra menjadi beberapa sub-band frekuensi melalui proses pemfilteran dan downampling. Gambar 2 menampilkan proses dekomposisi dilakukan dalam dua tahap: pertama secara horizontal, kemudian vertikal. Hasilnya adalah empat sub-band pada level pertama, yaitu LL (Low-Low), LH (Low-High), HL (High-Low), dan HH (High-High). Sub-band LL dapat didekomposisi ulang untuk menghasilkan level-level DWT selanjutnya, menghasilkan representasi hierarkis yang sangat berguna dalam ekstraksi fitur untuk mendeteksi anomali akibat penyisipan pesan [12]. Dalam praktiknya, pemilihan jenis wavelet sangat mempengaruhi performa DWT. Beberapa jenis wavelet umum yang digunakan dalam steganalisis antara lain Haar, Daubechies, Symlet, dan Coiflet [11].

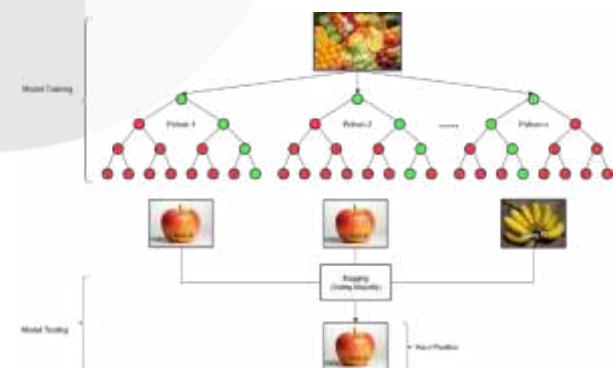


GAMBAR 2
(CARA KERJA DWT)

E. Random Forest

Random Forest merupakan algoritma pembelajaran mesin berbasis ansambel yang digunakan untuk tugas klasifikasi dan regresi. Algoritma ini terdiri atas kumpulan pohon keputusan yang dibangun secara independen, kemudian digabungkan untuk menghasilkan prediksi yang lebih stabil dan akurat [13]. Proses pembentukan forest dilakukan secara acak (*random*), baik dalam pemilihan subset data menggunakan teknik *bootstrapping*, maupun pemilihan subset fitur pada setiap simpul pohon [14].

Dalam proses pelatihan pada Gambar 3, Random Forest membagi dataset menjadi beberapa subset acak yang digunakan untuk melatih pohon keputusan secara paralel. Setiap pohon akan menghasilkan prediksi kelas berdasarkan pola yang ditemukan dari data latihnya masing-masing. Pada tahap pengujian, hasil prediksi dari seluruh pohon digabungkan menggunakan pendekatan *bagging* dengan metode *voting majority* untuk klasifikasi, atau rata-rata untuk regresi [15].



GAMBAR 3
(CARA KERJA RANDOM FOREST)

F. Metrik Evaluasi

Metrik evaluasi merupakan ukuran kuantitatif yang digunakan untuk menilai kinerja model pembelajaran mesin, khususnya pada tugas klasifikasi. Pemilihan metrik yang

tepat sangat penting untuk memastikan bahwa model yang dikembangkan mampu menghasilkan prediksi yang akurat dan relevan terhadap konteks permasalahan yang dihadapi [16].

Dalam metrik ini terdapat empat komponen utama, yakni True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN). True Positive merujuk pada jumlah citra stego yang berhasil dikenali dengan benar sebagai stego oleh model, sedangkan False Positive adalah jumlah citra cover yang secara keliru diklasifikasikan sebagai stego. Sebaliknya, True Negative mencakup jumlah citra cover yang berhasil dikenali dengan benar, dan False Negative adalah citra stego yang salah diklasifikasikan sebagai cover [17]. Beberapa metrik yang digunakan dalam penelitian ini antara lain:

- Akurasi mengukur proporsi prediksi yang benar dari seluruh data yang diuji. Meskipun dapat menjadi kurang representatif pada dataset yang sering digunakan sebagai metrik utama, akurasi tidak seimbang [18].

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Dalam penelitian ini, akurasi digunakan untuk mengukur sejauh mana kombinasi DWT dan Random Forest mampu membedakan citra cover dan citra stego.

- Presisi menunjukkan seberapa akurat model dalam mengklasifikasikan data ke kelas positif. Nilai presisi yang tinggi menunjukkan rendahnya kesalahan prediksi positif [19].

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

Dalam konteks steganalisis, Presisi menunjukkan seberapa akurat model dalam mendekripsi citra stego dari semua citra yang diprediksi sebagai stego.

- Recall mengukur kemampuan model dalam menemukan seluruh data yang termasuk dalam kelas positif [20].

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

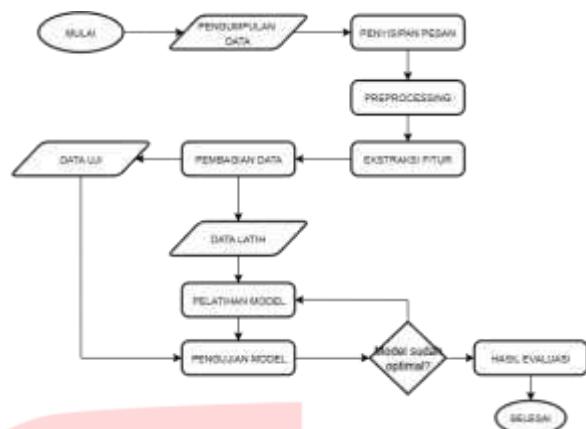
Dalam penelitian ini, recall digunakan untuk mengetahui seberapa baik model dapat menemukan citra stego dari seluruh citra yang benar-benar mengandung pesan tersembunyi.

- F1-score adalah rata-rata harmonis dari presisi dan recall, memberikan gambaran yang seimbang terutama saat dataset tidak seimbang [21].

$$F1 - Score = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Dalam konteks penelitian ini, F1-score memberikan gambaran kinerja model dalam mendekripsi citra stego secara akurat tanpa terlalu banyak kesalahan klasifikasi.

III. METODE



GAMBAR 4
(RANCANGAN SISTEM)

Gambar 4 menunjukkan rancangan sistem pada penelitian ini yang bertujuan untuk memetakan alur proses steganalisis citra digital. Rancangan tersebut dirangkum menjadi beberapa tahapan utama, antara lain Dataset, Penyisipan Pesan, Preprocessing, Ekstraksi Fitur, dan Klasifikasi. Setiap tahapan dijelaskan sebagai berikut:

A. Dataset

Penelitian ini menggunakan subset citra dari dataset IStego100K, dengan hanya memanfaatkan citra cover yang tersedia di dalamnya, sedangkan citra stego tidak dipakai karena proses pembentukan citra stego dilakukan secara mandiri menggunakan teknik penyisipan pesan. Struktur asli dataset terbagi ke dalam direktori train/ dan test/, masing-masing memiliki subdirektori cover/ dan stego/. Sebanyak 2.500 citra digunakan dalam eksperimen, dengan rasio 80:20 untuk data latih dan uji. Komposisi data mencakup 1.000 citra cover dan 1.000 citra stego untuk pelatihan, serta 250 citra cover dan 250 citra stego untuk pengujian.

B. Penyisipan Pesan

Proses menghasilkan citra stego yang digunakan dalam steganalisis, dilakukan penyisipan pesan menggunakan metode *Least Significant Bit (LSB) replacement*, yaitu dengan menggantikan bit paling tidak signifikan pada setiap kanal warna dengan bit pesan biner. Pesan yang disisipkan berupa teks acak yang dikonversi ke dalam format biner 8-bit ASCII, dan diakhiri dengan karakter penanda ETX (00000011) untuk menandai batas akhir pesan.

Kapasitas penyisipan ditetapkan sebesar 20% dari kapasitas total bit citra, yang dihitung dari perkalian tinggi, lebar, dan 3 kanal warna. Konfigurasi ini digunakan untuk menjaga kualitas visual citra dengan membatasi modifikasi terhadap bit LSB. Proses penyisipan dilakukan secara linier pada setiap piksel, dimulai dari kanal merah (R), lalu hijau (G), dan biru (B), kemudian dilanjutkan ke piksel berikutnya. Dengan urutan R1, G1, B1, R2, G2, B2, ..., proses ini menjamin distribusi bit pesan merata pada seluruh kanal warna.



GAMBAR 5

(MEKANISME PENYISIPAN BIT KE KANAL)

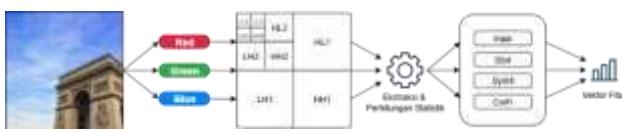
C. Preprocessing

Tahap preprocessing dilakukan untuk menyiapkan citra sebelum memasuki proses ekstraksi fitur. Proses ini mencakup pembacaan file, validasi format, normalisasi nilai piksel, dan manajemen label serta metadata. Setiap citra dalam dataset dibaca dari direktori yang telah dipisahkan berdasarkan kedua kelas. Validasi dilakukan terhadap format file untuk memastikan bahwa hanya citra dengan ekstensi umum seperti PNG, JPG, JPEG, dan BMP yang diproses. Selain itu, sistem memastikan bahwa citra memiliki tiga kanal warna dan dimensi yang sesuai agar kompatibel dengan proses transformasi lanjutan. Citra yang valid kemudian diberi label numerik berdasarkan kelasnya, yaitu 0 untuk cover dan 1 untuk stego. Label ini disimpan bersama nama file sebagai metadata penting untuk pelacakan prediksi dan evaluasi kinerja model. Setelah proses validasi, nilai intensitas piksel citra dinormalisasi ke dalam rentang 0–1 untuk menjaga stabilitas numerik dalam komputasi koefisien wavelet. Distribusi data antar kelas juga dipantau selama tahap preprocessing untuk memastikan keseimbangan jumlah antara citra cover dan stego. Informasi statistik dasar dicatat untuk keperluan analisis dan validasi integritas dataset.

D. Ekstraksi Fitur

Proses ekstraksi fitur pada Gambar 6 dilakukan terhadap setiap kanal warna (R, G, B) secara terpisah menggunakan dekomposisi wavelet hingga level 3, menghasilkan struktur sub-band frekuensi seperti LL3, LH3, HL3, HH3, dan detail level sebelumnya (LH2, HL2, HH2, LH1, HL1, HH1). Total terdapat 10 sub-band per kanal, menghasilkan 30 sub-band per citra. Seluruh sub-band ini digunakan untuk menghitung 13 jenis fitur statistik, yang mencakup statistik dasar (*mean*, standar deviasi, minimum, maksimum, *median*), statistik distribusi (*skewness*, *kurtosis*), statistik *robust* (percentile ke-25, ke-75, *interquartile range*), analisis frekuensi (*energy*, *entropy*), serta analisis tekstur (*zero crossing rate/ZCR*).

Hasil dari perhitungan statistik dari semua sub-band dan kanal warna digabungkan menjadi satu vektor fitur berdimensi 390 fitur per citra untuk satu jenis wavelet. Dalam penelitian ini, digunakan empat jenis wavelet yang berbeda, yaitu Db4, Haar, Sym4, dan Coif1, yang masing-masing memproses citra secara independen. Dengan demikian, sistem menghasilkan empat set fitur berbeda untuk setiap citra. Vektor fitur inilah yang menjadi input bagi model klasifikasi Random Forest untuk membedakan citra cover dan citra stego.

GAMBAR 6
(PROSES EKSTRAKSI FITUR)

E. Klasifikasi

Tahap klasifikasi dalam sistem steganalisis ini mengadopsi pendekatan individual wavelet models, di mana setiap jenis wavelet dikembangkan menjadi model klasifikasi Random Forest terpisah. Setiap jenis wavelet diinisialisasi dengan struktur *pipeline* yang terdiri atas dua komponen utama, yaitu *StandardScaler* untuk normalisasi fitur dan *RandomForestClassifier* sebagai algoritma utama klasifikasi. Pipeline ini dibentuk secara modular menggunakan pustaka Scikit-learn agar proses pelatihan dan evaluasi lebih terstruktur dan efisien. Sebelum pelatihan model, sistem melakukan proses seleksi fitur menggunakan metode *Recursive Feature Elimination* (RFE) secara terpisah untuk setiap wavelet. RFE bekerja dengan mengevaluasi kontribusi masing-masing fitur terhadap akurasi model dan menghilangkan fitur-fitur yang kurang relevan. Untuk mendapatkan konfigurasi model yang optimal, dilakukan pencarian *hyperparameter* menggunakan *Grid Search* dengan validasi silang *StratifiedKFold* pada Tabel 1.

TABEL 1
(PENCARIAN HYPERPARAMETER)

| Hyperparameter | Nilai yang Diuji |
|-------------------|------------------|
| n estimators | 100, 150 |
| max depth | 10, 15 |
| min samples split | 10, 20 |
| min samples leaf | 5, 10 |
| max features | sqrt, log2 |
| max samples | 0.8, 0.9 |

Setelah itu, masing-masing model dilatih menggunakan data fitur yang telah diseleksi. Proses pelatihan dilakukan secara individual untuk setiap jenis wavelet, sehingga menghasilkan model klasifikasi yang terfokus pada karakteristik statistik spesifik dari transformasi wavelet yang digunakan. Model yang telah dilatih kemudian disimpan dalam format .pkl bersama dengan objek seleksi fitur masing-masing, dan dapat digunakan untuk prediksi melalui dua pendekatan, yaitu prediksi tunggal berdasarkan model wavelet tertentu (*individual prediction*) dan perbandingan hasil dari seluruh model wavelet (*multi-wavelet comparison*), dengan keluaran berupa label klasifikasi dan probabilitas.

IV. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan Model

Setelah dilakukan proses pelatihan terhadap empat model klasifikasi individual berdasarkan jenis wavelet yang berbeda, diperoleh konfigurasi parameter terbaik melalui proses Grid Search seperti ditunjukkan pada Tabel 2.

TABEL 2
(KONFIGURASI PARAMETER TERBAIK)

| Hyperparameter | Db4 | Haar | Sym4 | Coif1 |
|-------------------|------|------|------|-------|
| n estimators | 100 | 150 | 100 | 150 |
| max depth | 15 | 10 | 10 | 10 |
| min samples split | 10 | 10 | 10 | 20 |
| min samples leaf | 10 | 10 | 10 | 5 |
| max features | log2 | sqrt | sqrt | sqrt |
| max samples | 0.8 | 0.9 | 0.8 | 0.8 |

Selanjutnya, evaluasi awal menggunakan metrik F1-score terhadap hasil pelatihan ditampilkan pada Tabel 3.

TABEL 3
(F1-SCORE HASIL PELATIHAN)

| Model Wavelet | F1-score |
|---------------|----------|
| Db4 | 0.9127 |
| Haar | 0.4556 |
| Sym4 | 0.8578 |
| Coif1 | 0.8638 |

B. Performa Model

TABEL 4
(PERBANDINGAN PERFORMA WAVELET)

| Wavelet | Akurasi | Presisi | Recall | F1-score |
|---------|---------|---------|--------|----------|
| Db4 | 0.914 | 0.940 | 0.884 | 0.911 |
| Haar | 0.668 | 0.686 | 0.620 | 0.651 |
| Sym4 | 0.850 | 0.866 | 0.828 | 0.847 |
| Coif1 | 0.850 | 0.851 | 0.848 | 0.850 |

Setelah dilakukan pelatihan dan evaluasi terhadap masing-masing model klasifikasi berbasis empat jenis wavelet, hasil pengujian menunjukkan perbedaan signifikan pada performa antar model. Penilaian dilakukan menggunakan empat metrik utama, yaitu akurasi, presisi, recall, dan F1-score, seperti ditunjukkan pada Tabel 4. Model Db4 menghasilkan performa terbaik dengan akurasi sebesar 0.914, presisi 0.940, recall 0.884, dan F1-score 0.911. Hasil ini menunjukkan bahwa wavelet Db4 mampu menangkap ciri statistik dari citra stego dan cover secara lebih efektif dibandingkan model Haar, Sym4, dan Coif1. Sementara itu, model Haar menghasilkan performa paling rendah dengan akurasi 0.668, presisi 0.686, recall 0.620, dan F1-score 0.651, yang menunjukkan keterbatasannya dalam mengextraksi fitur penting dalam konteks steganalisis.

C. Kurva Receiver Operating Characteristic (ROC)

TABEL 5
(NILAI AUC ROC WAVELET)

| Wavelet | AUC ROC |
|---------|---------|
| Db4 | 0.973 |
| Haar | 0.729 |
| Sym4 | 0.935 |
| Coif1 | 0.936 |

Evaluasi lanjutan dilakukan melalui analisis kurva ROC untuk mengukur kemampuan diskriminatif dari setiap model wavelet. Nilai *Area Under Curve* (AUC) ROC memberikan gambaran seberapa baik model mampu membedakan antara kelas cover dan stego tanpa memperhatikan ambang batas klasifikasi. Berdasarkan Tabel 5, model Db4 kembali menunjukkan performa unggul dengan nilai AUC sebesar 0,973, diikuti oleh Coif1 dan Sym4 yang juga memiliki AUC tinggi di atas 0,93. Sebaliknya, model Haar mencatat nilai AUC terendah sebesar 0,729, mengindikasikan performa diskriminatif yang kurang optimal.

D. Confusion Matrix

TABEL 6
(CONFUSION MATRIX UNTUK WAVELET DB4)

| Label Asli | Prediksi Cover | Prediksi Stego |
|------------|----------------|----------------|
| Cover | 236 (TN) | 14 (FP) |
| Stego | 29 (FN) | 221 (TP) |

Untuk mengevaluasi performa prediktif model secara lebih rinci, digunakan *confusion matrix* yang menunjukkan distribusi prediksi benar dan salah dari model terhadap label sebenarnya. Tabel 6 menunjukkan hasil matrik untuk model Db4, yang merupakan model terbaik. Dari total 500 data uji, sebanyak 236 citra cover berhasil diklasifikasikan dengan benar (True Negative), sedangkan 221 citra stego berhasil dikenali (True Positive). Sementara itu, terdapat 14 kasus False Positive (cover diklasifikasi sebagai stego) dan 29 kasus False Negative (stego diklasifikasi sebagai cover). Proporsi prediksi yang akurat ini menunjukkan bahwa model Db4 memiliki tingkat kesalahan yang cukup rendah dan dapat diandalkan dalam membedakan citra cover dan stego.

E. Distribusi Probabilitas

TABEL 7
(DISTRIBUSI PROBABILITAS UNTUK WAVELET DB4)

| Kelas | Cover | Stego |
|------------------------|-------------|-------------|
| Rata-rata probabilitas | 0.05 | 0.91 |
| Median | 0.04 | 0.93 |
| Rentang Dominan | 0.00 – 0.20 | 0.80 – 1.00 |

Distribusi probabilitas prediksi memberikan wawasan mengenai keyakinan model terhadap klasifikasi yang diberikan. Analisis ini penting untuk menilai apakah model menghasilkan prediksi dengan margin probabilitas yang besar antara kelas cover dan stego. Tabel 7 memperlihatkan bahwa untuk citra cover, rata-rata probabilitas prediksi model adalah 0,05 dengan median 0,04, menunjukkan bahwa model dengan yakin mengklasifikasikan data cover sebagai negatif. Sebaliknya, citra stego memiliki rata-rata probabilitas 0,91 dan median 0,93, menunjukkan keyakinan tinggi dalam klasifikasi positif. Rentang dominan probabilitas juga memperlihatkan pemisahan yang jelas: 0,00 – 0,20 untuk cover dan 0,80 – 1,00 untuk stego. Distribusi ini menegaskan bahwa model Db4 tidak hanya akurat, tetapi juga konsisten dalam memberikan prediksi dengan tingkat keyakinan yang tinggi, yang memperkuat keandalan model dalam aplikasi steganalisis.

V. KESIMPULAN

Penelitian ini mengusulkan kombinasi metode Discrete Wavelet Transform (DWT) dan algoritma Random Forest untuk mendeteksi keberadaan pesan tersembunyi dalam citra digital melalui proses steganalisis. DWT digunakan sebagai metode ekstraksi fitur dari domain frekuensi dengan menghasilkan sub-band multi-level yang mencerminkan karakteristik statistik citra, sedangkan Random Forest bertindak sebagai algoritma klasifikasi untuk membedakan citra cover dan stego berdasarkan fitur-fitur yang telah diekstrak. Eksperimen dilakukan dengan membandingkan empat jenis wavelet, yaitu Haar, Symlet (Sym4), Coiflet (Coif1), dan Daubechies (Db4). Hasil evaluasi menunjukkan bahwa model yang menggunakan wavelet Db4 memiliki performa terbaik, dengan nilai akurasi sebesar 0,914, presisi

0.940, recall 0.884, dan F1-score 0.911. Selain itu, model Db4 juga menunjukkan nilai AUC ROC tertinggi sebesar 0,973 dan distribusi probabilitas klasifikasi yang tegas antara citra cover dan stego, menandakan keandalan dan konsistensi model dalam mendeteksi keberadaan pesan tersembunyi. Dari hasil tersebut, dapat disimpulkan bahwa kombinasi DWT dan Random Forest efektif digunakan untuk steganalisis citra digital, dengan potensi penerapan lebih lanjut dalam bidang keamanan data dan forensik digital.

REFERENSI

- [1] M. Ahmad Bamanga, A. Kamalu Babando, and M. Ahmed Shehu, “Recent Advances in Steganography,” in *Steganography - The Art of Hiding Information*, IntechOpen, 2024, ch. 2, pp. 1–22. doi: 10.5772/intechopen.1004521.
- [2] S. Kumar and S. Chakraborty, “Digital Image Steganography and Steganalysis: A Comprehensive Review of Evolution of Advanced Techniques,” 2023, *Seventh Sense Research Group*. doi: 10.14445/22315381/IJETT-V7I11P229.
- [3] I. H. Latif, S. H. Abdulredha, and S. K. A. Hassan, “Discrete Wavelet Transform-Based Image Processing: A Review,” *Al-Nahrain Journal of Science*, vol. 27, no. 3, pp. 109–125, 2024.
- [4] H. Tan, “Machine Learning Algorithm for Classification,” in *Journal of Physics: Conference Series*, Chongqing: IOP Publishing Ltd, Aug. 2021, pp. 1–5. doi: 10.1088/1742-6596/1994/1/012016.
- [5] G. A. Simanungkalit, D. Syahputra Tarigan, and D. R. Simangunsong, “Discrete Wavelet Transform (DWT) Based Steganography Implementation,” *Jurnal Teknik Indonesia*, vol. 2, no. 01, pp. 13–17, Jun. 2023, [Online]. Available: <https://jurnal.seaninstitute.or.id/index.php/jutip13>
- [6] A. Dehdar, A. Keshavarz, and N. Parhizgar, “Image steganalysis using modified graph clustering based ant colony optimization and Random Forest,” *Multimed Tools Appl*, vol. 82, no. 5, pp. 7401–7418, Feb. 2023, doi: 10.1007/s11042-022-13599-0.
- [7] J. Narasimharao, A. Kalra, A. Noori, and V. Bhatia, “Representation,” in *Digital Image Processing*, Bhopal: AGPH Books (Academic Guru Publishing House), 2022, ch. 1, pp. 1–34.
- [8] F. Şahin, T. Çevik, and M. Takaoğlu, “Review of the Literature on the Steganography Concept,” *Int J Comput Appl*, vol. 975, p. 8887, 2021.
- [9] C. V. Priscilla and V. HemaMalini, “Steganalysis Techniques: A Systematic Review,” *J Surv Fish Sci*, vol. 10, no. 2S, pp. 244–263, 2023.
- [10] D. A. Shehab and M. J. Alhaddad, “Comprehensive survey of multimedia steganalysis: Techniques, evaluations, and trends in future research,” *Symmetry (Basel)*, vol. 14, no. 1, p. 117, 2022.
- [11] C. M. Akjuobi, *Wavelets and Wavelet Transform Systems and Their Applications: A Digital Signal Processing Approach*. Springer International Publishing, 2022. doi: 10.1007/978-3-030-87528-2.
- [12] N. Alaoui, “DWT-based digital watermarking for various attacks,” *Acadlore Trans. Mach. Learn*, vol. 2, no. 4, pp. 226–234, 2023.
- [13] I. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions,” *SN Comput Sci*, vol. 2, Jan. 2021, doi: 10.1007/s42979-021-00592-x.
- [14] N. Mahdi Abdulkareem and A. Mohsin Abdulazeez, “Machine Learning Classification Based on Radom Forest Algorithm: A Review,” *International Journal of Science and Business*, vol. 5, no. 2, pp. 128–142, Jan. 2021, doi: 10.5281/zenodo.4471118.
- [15] H. A. Salman, A. Kalakech, and A. Steiti, “Random Forest Algorithm Overview,” *Babylonian Journal of Machine Learning*, vol. 2024, pp. 69–79, Jun. 2024, doi: 10.58496/bjml/2024/007.
- [16] O. Rainio, J. Teuho, and R. Klén, “Evaluation metrics and statistical tests for machine learning,” *Sci Rep*, vol. 14, no. 1, p. 6086, 2024.
- [17] S. Sathyaranayanan, “Confusion Matrix-Based Performance Evaluation Metrics,” *African Journal of Biomedical Research*, vol. 27, no. 4s, pp. 4023–4031, Nov. 2024, doi: 10.53555/AJBR.v27i4S.4345.
- [18] A. Febrisida Sidabutar, R. Habibi, W. Istri, and R. Vokasi, “PERBANDINGAN METODE KLASIFIKASI UNTUK PENGELOMPOKAN RISIKO MAGANG MAHASISWA,” *Jurnal Mahasiswa Teknik Informatika*, vol. 7, no. 3, pp. 2071–2076, Jun. 2023.
- [19] N. Hijriani and E. Ermatita, “Perbandingan Naive Bayes Classifier dan Support Vector Machine untuk Analisis Sentimen terhadap Penyebaran Nyamuk Wolbachia di Indonesia,” *Jurnal Pendidikan dan Teknologi Indonesia*, vol. 4, no. 11, pp. 391–403, Dec. 2024, doi: 10.52436/1.jpti.499.
- [20] R. R. Adhitya, Wina Witanti, and Rezki Yuniarti, “PERBANDINGAN METODE CART DAN NAÏVE BAYES UNTUK KLASIFIKASI CUSTOMER CHURN,” *INFOTECHjournal*, vol. 9, no. 2, pp. 307–318, Jul. 2023, doi: 10.31949/infotech.v9i2.5641.
- [21] P. Christen, D. J. Hand, and N. Kirielle, “A Review of the F-Measure: Its History, Properties, Criticism, and Alternatives,” *ACM Comput Surv*, vol. 56, no. 3, pp. 1–24, Mar. 2023, doi: 10.1145/3606367.