

## Deteksi dan Rekognisi Wajah Forensik pada Citra Kualitas Rendah Menggunakan Hybrid PCA-LBP dan SVM

Ahmad Muhariya<sup>1)</sup>, Ilham Fannani<sup>2)</sup> Yustina Retno Wahyu Utami<sup>3)</sup>

<sup>1)2)</sup> Fakultas Teknik, Rekayasa Komputer, Universitas Tiga Serangkai

<sup>3)</sup> Fakultas Teknik, Informatika, Universitas Tiga Serangkai

<sup>1)</sup> [ahmadmuhariya@tsu.ac.id](mailto:ahmadmuhariya@tsu.ac.id), <sup>2)</sup> [ilhamfannani@tsu.ac.id](mailto:ilhamfannani@tsu.ac.id), <sup>3)</sup> [yustinaretno@tsu.ac.id](mailto:yustinaretno@tsu.ac.id)

### ABSTRACT

*Face recognition and detection is a biometric technique widely used in digital forensics to identify perpetrators or victims from CCTV or mobile device image evidence, yet real-world evidence images are often low-quality due to blur, noise, small resolution, and poor lighting. The novelty of this study lies in a hybrid feature-extraction scheme combining Principal Component Analysis (PCA/Eigenface) and Local Binary Pattern (LBP), fused through a weighted sum rule whose weights are optimized per degradation type, coupled with three non-learning image enhancement techniques (Non-Local Means denoising, unsharp masking, and CLAHE), together with direct empirical evidence that naive feature fusion without weighting can degrade system performance. This study builds and directly tests the pipeline using 100 images from the official Labeled Faces in the Wild (LFW) subset bundled with the scikit-image library (50 face images and 50 non-face images, 25×25 pixels), evaluated using accuracy, precision, recall, F1-score, and ROC-AUC for the face-vs-non-face classification task, and rank-1 accuracy for the identification task on a gallery of 50 identities. The best results show a hybrid PCA+LBP+SVM classification accuracy of 95.0–97.5% depending on image quality conditions, while for the rank-1 identification task, the PCA feature excels under blur degradation (96%) but drops sharply under dark lighting (2%), the LBP feature shows the opposite pattern, and the weighted score fusion scheme succeeds in matching or exceeding the best single method under every condition. It should be noted that image enhancement does not always improve identification performance; under certain degradation conditions, enhancement actually sharply reduces rank-1 identification accuracy, indicating that the relationship between visual quality and recognition performance is not always linear. This study provides fully reproducible empirical evidence, based on a public dataset, on the contribution of each stage of the digital forensic pipeline to face recognition performance on low-quality image evidence.*

**Keywords:** Digital Forensics, Face Recognition, Low-Quality Images, Hybrid PCA-LBP, Support Vector Machine.

### I. PENDAHULUAN

Identifikasi wajah dari barang bukti citra digital telah menjadi salah satu instrumen penting dalam proses investigasi forensik modern. Meningkatnya jumlah kamera pengawas (CCTV), kamera ponsel pintar, dan perangkat perekam pada ruang publik menjadikan citra wajah sebagai salah satu jenis barang bukti yang paling sering diperoleh oleh penyidik. Namun demikian, keandalan sistem rekognisi wajah sangat bergantung pada kualitas citra input, sementara barang bukti riil jarang diperoleh dalam kondisi ideal: resolusi kecil akibat jarak akuisisi yang jauh, keburaman (blur) akibat gerakan, artefak kompresi, dan derau (*noise*) akibat sensor atau pencahayaan minim (Phillips & others, 2018).

Ketergantungan proses penyidikan pada rekaman CCTV terus meningkat seiring pesatnya adopsi sistem pengawasan di ruang publik, sementara barang bukti CCTV umumnya direkam dari sudut pandang, jarak, dan pencahayaan yang tidak dapat dikendalikan penyidik, sehingga degradasi kualitas citra adalah kondisi yang harus diantisipasi, bukan dihindari. Kesalahan identifikasi wajah pada konteks forensik berdampak langsung pada proses hukum berupa penetapan tersangka yang keliru, sehingga

dibutuhkan metode pengenalan yang tidak hanya akurat, tetapi juga transparan dan dapat ditelusuri (*traceable*) pada setiap tahap pemrosesannya.

Kristanto, Riadi, dan Prayudi (Kristanto et al., 2022) telah meneliti permasalahan serupa: Viola-Jones untuk deteksi wajah dan perbandingan PCA, FLD, dan LBP pada citra kualitas rendah dari LFW dan face94. LBP secara umum unggul, kecuali pada *noise*, di mana PCA lebih baik. Penelitian tersebut menjadi acuan metodologis utama studi ini, khususnya dalam penyajian visual setiap tahap pemrosesan citra sebagai bukti empiris.

Studi survei oleh (Li et al., 2018) menegaskan bahwa degradasi kualitas menjadi tantangan utama pengenalan wajah kualitas rendah (low-quality face recognition), karena representasi fitur yang dipelajari pada citra resolusi tinggi cenderung tidak invarian terhadap penurunan kualitas tersebut. Dataset benchmark seperti (Cheng et al., 2018) dan (Grgic et al., 2011) dibangun khusus untuk mengevaluasi kondisi tersebut menggunakan citra pengawasan resolusi rendah yang asli (*native*), bukan hasil down-sampling artifisial. Dalam konteks forensik, kesalahan identifikasi memiliki konsekuensi hukum, sehingga validitas dan keterlacakan metode menjadi perhatian utama, sebagaimana ditekankan pada kajian kekuatan bukti pengenalan wajah forensik (Zeinstra et al., 2018) dan distorsi artefak citra CCTV forensic (Seckiner et al., 2018).

Deteksi wajah berbasis algoritma Viola-Jones, yang menggabungkan fitur Haar, integral image, AdaBoost, dan cascade classifier (Viola & Jones, 2004), tetap menjadi salah satu metode deteksi wajah paling banyak diadopsi karena kecepatan dan implementasinya yang tersedia secara terbuka pada OpenCV, sehingga menjamin reproduktifitas penelitian. Untuk tahap pengenalan, pendekatan *Eigenface* berbasis *Principal Component Analysis* yang diperkenalkan oleh Turk dan Pentland (Turk & Pentland, 1991) serta deskriptor tekstur Local Binary Pattern (Ahonen et al., 2004) merupakan dua metode klasik yang tetap relevan sebagai baseline maupun komponen fitur pada skema *hybrid modern*.

Untuk mengatasi degradasi kualitas citra, penelitian ini mengadopsi kombinasi tiga teknik peningkatan kualitas citra klasik yang telah terbukti dan tersedia secara terbuka: *Non-Local Means* denoising (Buades et al., 2005), *unsharp masking* untuk deblurring, dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) (Zuiderveld, 1994) untuk koreksi pencahayaan, dipilih karena bersifat non-learning sehingga hasilnya sepenuhnya dapat diverifikasi dan direproduksi tanpa infrastruktur GPU.

Pendekatan *hybrid machine learning*, yang menggabungkan lebih dari satu jenis fitur atau pengklasifikasi, telah banyak menunjukkan peningkatan generalisasi dibandingkan metode tunggal. Namun demikian, fusi fitur atau skor yang naif (misalnya penggabungan langsung tanpa normalisasi) berisiko menyebabkan salah satu modalitas mendominasi atau bahkan merusak kinerja gabungan, sebagaimana akan ditunjukkan secara empiris pada penelitian ini. Skema fusi skor tertimbang (*weighted sum rule*) sebagai solusi praktis yang telah banyak diadopsi pada sistem biometrik multi modal (Ross & Jain, 2003).

Meskipun penelitian pengenalan wajah kualitas rendah sudah banyak dilakukan, terdapat kesenjangan (*gap*) yang menjadi fokus studi ini: (1) sebagian besar penelitian terdahulu sulit direproduksi karena membutuhkan infrastruktur komputasi besar; (2) penelitian acuan utama (Kristanto et al., 2022) hanya membandingkan PCA, FLD, dan LBP secara tunggal tanpa skema *hybrid* berbasis fusi skor; dan (3) risiko penurunan kinerja akibat fusi fitur naif belum banyak dilaporkan secara eksplisit pada literatur sejenis. Kesenjangan inilah yang mendasari studi ini untuk menyajikan bukti visual dan kuantitatif yang dapat direproduksi penuh dengan sumber daya komputasi minimal.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan membangun pipeline forensik digital berbasis *hybrid* PCA-LBP dan SVM serta mengevaluasi kinerjanya dari akurasi klasifikasi hingga akurasi identifikasi rank-1. Kontribusi utamanya: (1) hasil kode

yang sepenuhnya nyata dan dapat diverifikasi menggunakan dataset terbuka (LFW subset scikit-image); (2) pembuktian empiris bahwa fusi skor tertimbang mengatasi penurunan kinerja akibat fusi naif; dan (3) analisis eksplisit bahwa peningkatan kualitas citra tidak selalu, dan pada beberapa kondisi justru menurunkan, kinerja identifikasi.

## II. TINJAUAN PUSTAKA

### 2.1 Forensik Digital dan Barang Bukti Citra Kualitas Rendah

Forensik digital kini memanfaatkan kecerdasan buatan (AI) dan *machine learning* untuk mempercepat analisis pola serta bukti citra seperti CCTV (Dunsin et al., 2024), namun proses ini sering terkendala oleh buruknya kualitas rekaman dan risiko pelanggaran asas praduga tak bersalah jika sistem AI yang digunakan tidak transparan (Zhang, 2022). Oleh karena itu, penelitian ini menjadikan kajian-kajian tersebut sebagai landasan untuk memprioritaskan transparansi metodologis dan reproduktifitas penuh pada setiap tahap pemrosesan citra barang bukti agar hasilnya tetap valid dan dapat diverifikasi ulang demi keadilan (Stoykova, 2023).

### 2.2 Pengenalan Wajah pada Citra Kualitas Rendah (Low-Quality Face Recognition)

Pengenalan wajah pada citra kualitas rendah merupakan tantangan biometrik karena fitur citra resolusi tinggi tidak invarian terhadap blur, *noise*, atau resolusi rendah, sehingga memerlukan evaluasi menggunakan dataset asli seperti QMUL-SurvFace (Cheng et al., 2018) dan SCface (Grgic et al., 2011). Berbagai metode dikembangkan dari augmentasi data hingga penilaian kualitas citra wajah (Low & Teoh, 2022). Acuan utama yang mengevaluasi PCA, FLD, dan LBP (Low et al., 2021) (Li et al., 2022) (Schlett et al., 2022), disimpulkan bahwa tidak ada satu pun metode yang konsisten unggul di semua jenis degradasi citra, yang kemudian memotivasi penggunaan pendekatan *hybrid* dalam penelitian ini.

### 2.3 Peningkatan Kualitas Citra (Image Enhancement) untuk Forensik

Tahap peningkatan kualitas citra bertujuan memulihkan informasi visual yang hilang akibat degradasi menggunakan beberapa pendekatan (Buades et al., 2005). Untuk denoising, algoritma *Non-Local Means* memanfaatkan redundansi pola di seluruh citra guna mempertahankan detail tepi, sementara untuk koreksi kontras, metode CLAHE membatasi amplifikasi kontras berlebih guna mengurangi penguatan derau (*noise*) (Zuiderveld, 1994) (Ledig & others, 2017). Di sisi lain, pendekatan berbasis AI seperti SRGAN dan model super-resolusi tersemat (embedded) mampu menghasilkan detail citra resolusi tinggi yang *realistis* untuk sistem pengawasan (CCTV). Namun, penelitian ini memilih kombinasi teknik non-learning (*Non-Local Means*, *unsharp masking*, dan CLAHE) karena sifatnya yang deterministik, mudah direproduksi, serta tidak membutuhkan pelatihan model ataupun infrastruktur GPU (Gómez-Bautista & Calderón, 2024).

### 2.4 Hybrid Machine Learning dan Fusi Skor pada Pengenalan Wajah

Pendekatan *hybrid machine learning* yang menggabungkan berbagai fitur atau pengklasifikasi, seperti model *hybrid* PCA-SVM oleh (Yadav et al., 2022) atau skema fusi skor tertimbang oleh (Ross & Jain, 2003), banyak diusulkan untuk meningkatkan akurasi dan generalisasi dibandingkan metode tunggal, terutama pada kondisi data yang terbatas. Skema fusi skor tertimbang ini juga diterapkan oleh (Hammouche et al., 2022) pada autentikasi biometrik karena terbukti efektif meningkatkan akurasi dengan memberikan bobot berdasarkan tingkat keandalan relatif masing-masing sumber fitur. Meskipun

demikian, fusi yang dilakukan secara naif tanpa mempertimbangkan reliabilitas tiap sumber berisiko membuat modalitas yang kurang andal merusak kinerja gabungan, sebuah risiko empiris yang diatasi dalam penelitian ini melalui skema fusi skor tertimbang dengan bobot yang dioptimasi.

## **2.5 Konsep *Principal Component Analysis* (PCA) dan *Eigenface***

*Principal Component Analysis* (PCA) mentransformasikan nilai piksel citra wajah ke sejumlah kecil komponen utama yang menangkap variansi terbesar pada data (Turk & Pentland, 1991). Pada representasi *Eigenface*, citra latih disusun sebagai vektor piksel, dihitung mean face lalu matriks kovariansinya; vektor eigen (*eigenface*) merepresentasikan arah variasi struktur wajah paling dominan, sehingga citra dapat direpresentasikan sebagai kombinasi linear sejumlah kecil *eigenface*. Kelebihan PCA adalah efisien menangkap struktur global dengan biaya komputasi rendah tanpa data latih besar, cocok untuk galeri forensik terbatas. Kekurangannya, PCA sensitif terhadap pergeseran intensitas piksel global (misalnya pencahayaan) karena bergantung langsung pada nilai piksel mentah, serta sensitif terhadap misalignment wajah menjelaskan mengapa performa PCA menurun tajam pada pencahayaan gelap namun relatif tahan blur.

## **2.6 Konsep *Support Vector Machine* (SVM) dan Skema *Hybrid PCA+LBP-SVM***

*Support Vector Machine* (SVM) adalah algoritma klasifikasi supervised yang mencari hyperplane pemisah optimal antar kelas dengan memaksimalkan margin terhadap titik data terdekat (support vector); untuk data yang tidak terpisah linear, SVM memakai kernel *Radial Basis Function* (RBF) agar dapat dipisahkan pada ruang berdimensi lebih tinggi. Parameter C mengendalikan trade-off antara lebar margin dan toleransi kesalahan pada data latih (C besar berisiko *overfitting*, C kecil berisiko *underfitting*), sedangkan gamma menentukan jangkauan pengaruh tiap titik data latih. Penelitian ini memakai gamma='scale' (dihitung otomatis dari varians fitur) dan C=4, dipilih melalui pengujian awal pada data latih yang menunjukkan keseimbangan terbaik dibanding C lebih kecil (*underfit*) maupun lebih besar (*overfit*). Skema *hybrid PCA+LBP-SVM* menggabungkan (concatenation) vektor fitur PCA (struktur global) dan histogram LBP (tekstur lokal) setelah dinormalisasi (*z-score*), sehingga SVM menerima representasi yang saling melengkapi: PCA lebih tahan kehilangan detail akibat blur, LBP lebih tahan perubahan skala keabuan monoton akibat pencahayaan (Ahonen et al., 2004) hubungan teoretis yang mendasari desain fusi skor tertimbang.

## **2.7 Posisi Penelitian terhadap Penelitian Terdahulu**

Penelitian acuan utama pada studi ini adalah (Kristanto et al., 2022), yang menerapkan algoritma Viola-Jones untuk deteksi wajah dan membandingkan tiga metode pengenalan klasik PCA, *Fisher's Linear Discriminant* (FLD), dan LBP pada citra kualitas rendah dari dataset *Labeled Faces in the Wild*/LFW (Huang et al., 2007) dan face94, dengan simulasi masalah blur, *noise*, dan pencahayaan. Studi tersebut menyimpulkan bahwa LBP secara umum memberikan tingkat pengenalan terbaik, kecuali pada masalah *noise* di mana PCA lebih unggul sebuah temuan yang konsisten dengan sifat teoretis kedua metode, dan yang turut direplikasi serta diperluas pada penelitian ini melalui eksperimen kuantitatif langsung. Penelitian ini mengadopsi format penyajian visual setiap tahap pemrosesan citra secara langsung (deblurring, denoising, penyesuaian kecerahan, deteksi, dan pengenalan) sebagaimana pada (Kristanto et al., 2022) namun memberikan tiga perluasan: (1) skema *hybrid PCA+LBP* dengan fusi skor tertimbang, bukan perbandingan metode tunggal; (2) pelaporan temuan negatif mengenai risiko fusi fitur naif; dan (3) dataset yang sepenuhnya dapat diverifikasi ulang tanpa unduhan eksternal memposisikan penelitian ini sebagai

kelanjutan langsung penelitian terdahulu dengan penekanan tambahan pada *hybrid machine learning* dan reproduktifitas metodologis.

Selain (Kristanto et al., 2022), posisi penelitian ini dibandingkan dengan (Yadav et al., 2022) *hybrid* PCA-SVM tanpa fokus citra kualitas rendah dan (Hammouche et al., 2022) fusi skor tertimbang pada biometrik non-wajah, belum diuji pada domain wajah forensik. Penelitian ini memposisikan diri sebagai penggabungan sekaligus perluasan keduanya pada konteks forensik citra kualitas rendah, disertai pembuktian empiris eksplisit mengenai risiko fusi naif, meski perbandingan angka akurasi tetap perlu dibaca hati-hati karena perbedaan dataset, sampel, dan definisi tugas.

### III. METODE PENELITIAN

Penelitian ini menggunakan desain eksperimental kuantitatif dengan pendekatan applied research. Seluruh tahapan simulasi degradasi citra, peningkatan kualitas, deteksi wajah, ekstraksi fitur, klasifikasi/identifikasi *hybrid*, hingga evaluasi diimplementasikan dan dieksekusi langsung, sehingga seluruh hasil pada bagian Hasil dan Pembahasan merupakan keluaran nyata dari kode, bukan nilai ilustratif, dan dirancang agar setiap tahap dapat ditelusuri kembali (*traceable*) sejalan dengan prinsip integritas barang bukti digital. Gambar 1 menampilkan diagram alur tahapan metode penelitian secara keseluruhan.



Gambar 1. Tahapan metode penelitian

#### 3.1 Pengumpulan Dataset

Penelitian ini menggunakan subset resmi dataset *Labeled Faces in the Wild* (LFW) dari pustaka scikit-image yang berisi 50 citra wajah dan 50 citra bukan-wajah berukuran 25 x 25 piksel *grayscale*. Ukuran sampel yang kecil ini sengaja dipilih agar proses komputasi tetap ringan namun tetap mempertahankan keaslian data tanpa modifikasi artifisial. Dataset LFW dipilih karena telah menjadi standar benchmark global, bersifat open-source sehingga mudah diverifikasi, dan resolusi alaminya yang rendah sangat merepresentasikan kondisi riil barang bukti CCTV pada forensik digital. Selain itu, sebagai pelengkap demonstrasi visual end-to-end pada resolusi yang lebih tinggi, penelitian ini juga memanfaatkan citra uji standar computer vision yang sudah dibundel resmi, yaitu citra astronaut (Eileen Collins, 512 x 512 piksel). Verifikasi identitas pada galeri identifikasi dilakukan berdasarkan label resmi (atribut target dan target\_names) yang disertakan pada dataset LFW subset scikit-image, sehingga masing-masing dari 50 citra wajah yang digunakan sebagai galeri dipastikan merepresentasikan 50 identitas yang berbeda, satu citra per identitas, bukan sekadar diasumsikan berdasarkan jumlah berkas citra semata. Dengan demikian, skenario identifikasi 1:N terjamin tidak mengandung duplikasi identitas pada galerinya.

#### 3.2 Metadata Dataset

Setiap eksekusi dicatat dengan metadata berupa dimensi citra sebelum dan sesudah setiap transformasi, jenis operasi yang diterapkan, parameter numerik yang digunakan (mis. varians *noise*, radius unsharp mask, clip limit CLAHE), serta nilai metrik kualitas (PSNR, SSIM) dan hasil deteksi pada setiap tahap. Pencatatan ini mendukung prinsip audit-trail pemrosesan barang bukti digital.

### 3.3 Simulasi Degradasi Kualitas Rendah

Karena citra evidensi forensik riil tidak selalu memiliki versi resolusi tinggi sebagai pembanding, penelitian ini turut mensimulasikan degradasi terkendali pada citra uji resolusi tinggi (astronaut): downsampling (skala 0,45) untuk jarak kamera jauh, *Gaussian blur* (kernel  $5 \times 5$ ) untuk *defocus/motion blur*, *derau Gaussian*, dan koreksi gamma ( $\gamma=1,8-3,2$ ) untuk pencahayaan buruk. Pada dataset LFW subset, degradasi serupa diterapkan langsung pada citra  $25 \times 25$  piksel dengan parameter yang disesuaikan (*Gaussian blur*  $5 \times 5$ , *varians noise* 0,05,  $\gamma=3,2$ ) untuk menguji ketahanan model pada resolusi yang sudah sangat rendah.

### 3.4 Peningkatan Kualitas Citra (Image Enhancement)

Tahap *enhancement* menggabungkan tiga teknik non-learning yang sepenuhnya dapat direproduksi: (1) denoising menggunakan algoritma *Non-Local Means* (Buades et al., 2005), dengan parameter  $h$  ditentukan secara adaptif berdasarkan estimasi standar deviasi derau melalui operator Laplacian (Immerkær, 1996); (2) deblurring menggunakan *unsharp masking*; dan (3) koreksi kontras/pencahayaan menggunakan *Contrast Limited Adaptive Histogram Equalization/CLAHE* (Zuiderveld, 1994). Untuk demonstrasi pada citra resolusi tinggi, ditambahkan pula tahap super-resolusi sederhana berupa interpolasi bikubik sebelum *enhancement* diterapkan.

### 3.5 Preprocessing Citra

Preprocessing meliputi normalisasi intensitas piksel (*min-max normalization*), penyeimbangan histogram, dan pengubahan ukuran citra ke dimensi standar. Pada dataset LFW subset, preprocessing diterapkan langsung pada lima sampel representatif untuk mendemonstrasikan efek CLAHE dan resizing terhadap kontras citra (diukur melalui standar deviasi intensitas piksel).

### 3.6 Face Detection

Deteksi wajah menggunakan algoritma Viola-Jones (Viola & Jones, 2004) melalui implementasi Haar Cascade Classifier pada OpenCV (*haarcascade\_frontalface\_default.xml*), dengan parameter *scaleFactor*=1,08 dan *minNeighbors*=9 hasil penyesuaian untuk meminimalkan *false positive* pada citra kompleks. Deteksi dijalankan pada citra astronaut dalam tiga kondisi kualitas (asli, terdegradasi, dan setelah *enhancement*) untuk menguji ketahanan detektor terhadap penurunan kualitas.

### 3.7 Feature Extraction

Ekstraksi fitur menggunakan dua metode klasik yang digabungkan (*hybrid*): (1) *Principal Component Analysis/Eigenface* (Turk & Pentland, 1991) dengan jumlah komponen utama yang disesuaikan pada tiap tugas (5 komponen untuk tugas klasifikasi, 3 komponen untuk tugas identifikasi, mengingat ukuran sampel yang terbatas), menangkap struktur global wajah; dan (2) *histogram Local Binary Pattern uniform*,  $P=8$ ,  $R=1$ , 10 bin (Ahonen et al., 2004) menangkap tekstur lokal; kedua fitur saling melengkapi.

### 3.8 Hybrid Machine Learning

Dua skema *hybrid* digunakan sesuai jenis tugas. Untuk tugas klasifikasi wajah-vs-bukan-wajah, fitur PCA dan LBP dinormalisasi (*z-score*) lalu digabungkan (*concatenation*) sebagai input *Support Vector Machine* berkernel RBF ( $C=4$ , *gamma*='scale'). Untuk tugas identifikasi 1:N, digunakan skema fusi skor tertimbang (*weighted sum rule*) sebagaimana diusulkan (Ross & Jain, 2003): jarak Euclidean pada fitur PCA dan LBP dinormalisasi

min-max per probe lalu digabungkan sebagai  $D_{fused} = w \cdot D_{PCA} + (1-w) \cdot D_{LBP}$ , dengan bobot  $w$  dicari melalui grid search (langkah 0,05) yang memaksimalkan akurasi rank-1. Skema ini dipilih karena percobaan awal menunjukkan penggabungan fitur mentah tanpa pembobotan membuat LBP yang buruk pada blur/noise merusak kinerja PCA yang sudah baik.

### 3.9 Proses Pelatihan, Pengujian, dan Evaluasi

Untuk tugas klasifikasi, 100 citra (50 wajah + 50 bukan wajah) dibagi 60% data latih dan 40% data uji secara *stratified* bukan *k-fold cross-validation*, karena ukuran dataset kecil ( $n=100$ ) membuat tiap fold memiliki sampel uji terlalu sedikit untuk estimasi variansi yang stabil. Untuk mencegah data leakage, seluruh estimasi parameter (basis *eigenface* PCA, normalisasi *z-score*, pelatihan SVM) hanya menggunakan data latih; data uji hanya diproyeksikan ke ruang fitur tersebut. Parameter SVM ( $C=4$ ,  $\gamma='scale'$ ) ditentukan pada data latih. Untuk identifikasi, 50 citra wajah menjadi galeri (identitas terverifikasi), diuji skenario 1:N *closed-set* ( $N=50$ ); bobot fusi skor bersifat *in-sample* karena tanpa citra ulangan. Evaluasi memakai *accuracy*, *precision*, *recall*, *F1-score*, ROC-AUC, dan *confusion matrix* untuk klasifikasi; akurasi rank-1 untuk identifikasi.

## IV. HASIL DAN PEMBAHASAN

### 4.1 Pengumpulan Dataset


Tabel 1 merangkum karakteristik dataset yang digunakan. Subset LFW yang digunakan berisi 50 citra wajah dan 50 citra bukan-wajah berukuran  $25 \times 25$  piksel *grayscale* (diambil dari 100+100 subset resmi yang dibundel scikit-image), bersumber dari dataset LFW asli (Huang dkk., 2007) yang berisi lebih dari 13.000 citra dari 5.749 identitas. Satu citra uji standar (astronaut) digunakan sebagai demonstrasi *visual pipeline end-to-end* pada resolusi yang lebih tinggi ( $512 \times 512$  dan  $600 \times 512$  piksel) sebelum disimulasikan menjadi kualitas rendah. Sebagai studi kasus tambahan yang merepresentasikan skenario forensik dunia nyata secara lebih langsung, penelitian ini juga menggunakan dua citra dokumentasi personal: (1) satu citra potret tunggal (1 wajah), dan (2) satu citra kelompok berisi 5 wajah dalam satu bingkai keduanya diproses melalui pipeline lengkap yang sama (*degradasi*, *enhancement*, deteksi).

Tabel 1. Karakteristik Dataset yang Digunakan dalam Penelitian

| Karakteristik                  | LFW subset (scikit-image; Huang dkk., 2007)                           | Astronaut                                                 | Citra Personal (potret & kelompok)                                 |
|--------------------------------|-----------------------------------------------------------------------|-----------------------------------------------------------|--------------------------------------------------------------------|
| Jumlah citra                   | 100 (50 wajah + 50 bukan-wajah)                                       | 2 citra (masing-masing 1 subjek)                          | 2 citra (1 wajah + 5 wajah)                                        |
| Resolusi                       | $25 \times 25$ piksel, <i>grayscale</i>                               | $512 \times 512$ dan $600 \times 512$ piksel              | $1280 \times 740$ dan $699 \times 793$ piksel                      |
| Sumber                         | Subset resmi dataset LFW (Huang dkk., 2007), dibundel di scikit-image | Bundled sample computer vision (scikit-image, Matplotlib) | Dokumentasi lapangan penelitian ( <i>real</i> , diunggah langsung) |
| Peran dalam penelitian         | Eksperimen kuantitatif (klasifikasi & identifikasi)                   | Demonstrasi <i>visual pipeline end-to-end</i>             | Studi kasus multi-wajah & validasi lapangan                        |
| Ketersediaan / reproduktifitas | Tanpa unduhan eksternal ( <i>bundled offline</i> )                    | Tanpa unduhan eksternal ( <i>bundled offline</i> )        | Data primer penelitian                                             |

### 4.2 Image Enhancement (5 Sampel LFW)

Gambar 2 menampilkan lima sampel citra wajah asli dari dataset LFW subset ( $25 \times 25$  piksel) beserta hasil setelah tahap *image enhancement* (upsampling bikubic  $8 \times$ , *denoising Non-Local Means*, *unsharp masking*, dan CLAHE). Tabel 2 menyajikan perubahan kontras (standar deviasi intensitas piksel) untuk kelima sampel tersebut, yang seluruhnya menunjukkan peningkatan kontras lokal setelah *enhancement*.



Gambar 2. Lima sampel citra wajah LFW asli (25×25 px) dan hasil setelah image *enhancement*

Tabel 2. Perubahan Kontras (Standar Deviasi Intensitas) 5 Sampel Citra LFW

| Sampel   | Resolusi Awal | Resolusi Akhir | Std. Intensitas Awal | Std. Intensitas Setelah <i>Enhancement</i> |
|----------|---------------|----------------|----------------------|--------------------------------------------|
| Sampel 1 | 25×25 px      | 200×200 px     | 44.33                | 57.69                                      |
| Sampel 2 | 25×25 px      | 200×200 px     | 33.64                | 57.13                                      |
| Sampel 3 | 25×25 px      | 200×200 px     | 56.57                | 62.13                                      |
| Sampel 4 | 25×25 px      | 200×200 px     | 51.31                | 63.51                                      |
| Sampel 5 | 25×25 px      | 200×200 px     | 57.43                | 64.30                                      |

#### 4.3 Preprocessing (5 Sampel LFW)

Gambar 3 menampilkan tahap preprocessing (CLAHE dan resizing ke 112×112 piksel) pada lima sampel LFW yang sama. Tabel 3 menunjukkan bahwa CLAHE secara konsisten meningkatkan kontras lokal pada seluruh sampel sebelum tahap resizing, sejalan dengan tujuan preprocessing untuk memperjelas informasi tekstur wajah sebelum ekstraksi fitur.



Gambar 3. Lima sampel citra LFW: setelah CLAHE


Tabel 3. Perubahan Kontras 5 Sampel Citra LFW pada Tahap Preprocessing / CLAHE

| Sampel   | Std. Intensitas Sebelum CLAHE | Std. Intensitas Setelah CLAHE |
|----------|-------------------------------|-------------------------------|
| Sampel 1 | 44.33                         | 60.22                         |
| Sampel 2 | 33.64                         | 52.17                         |
| Sampel 3 | 56.57                         | 63.64                         |
| Sampel 4 | 51.31                         | 61.44                         |
| Sampel 5 | 57.43                         | 64.62                         |

#### 4.4 Demonstrasi Pipeline End-to-End (Citra Uji Standar & Citra Personal)

Untuk mendemonstrasikan pipeline secara visual end-to-end sebagaimana lazim disajikan pada penelitian forensik citra (mengikuti format penyajian pada (Kristanto et al., 2023), Gambar 4-9 menampilkan hasil nyata setiap tahap pemrosesan pada citra uji standar (astronaut) maupun citra personal (potret tunggal dan kelompok) yang disimulasikan/diuji sebagai barang bukti kualitas rendah.

Gambar 4 menampilkan citra astronaut asli dan hasil simulasi degradasi kualitas rendah (downsampling, *Gaussian* blur, *noise*, dan pencahayaan gelap), mensimulasikan kondisi barang bukti CCTV yang buruk.




Gambar 4. Citra astronaut asli dan hasil simulasi degradasi kualitas rendah

Gambar 5 menampilkan hasil tahap denoising (*Non-Local Means*) dan deblurring (*unsharp masking*) secara berurutan pada citra astronaut yang telah didegradasi, menunjukkan pemulihan struktur wajah secara bertahap.




Gambar 5. Tahap denoising (*Non-Local Means*) dan deblurring (*unsharp masking*) pada citra astronaut

Gambar 6 menampilkan hasil deteksi wajah Viola-Jones (kotak hijau) pada citra astronaut untuk tiga kondisi kualitas: asli, terdegradasi, dan setelah *enhancement*.




Gambar 6. Deteksi wajah Viola-Jones pada citra astronaut, tiga kondisi kualitas

Sebagai studi kasus tambahan yang lebih merepresentasikan kondisi barang bukti forensik dunia nyata (bukan citra uji standar computer vision), pipeline yang identik juga dijalankan pada dua citra dokumentasi personal: satu citra potret tunggal (Gambar 7) dan satu citra kelompok berisi 5 wajah dalam satu bingkai (Gambar 9), keduanya diunggah langsung sebagai data uji nyata. Gambar 7 menampilkan citra potret tunggal asli, hasil simulasi degradasi kualitas rendah, dan hasil setelah *enhancement*. Gambar 8 menampilkan hasil deteksi wajah Viola-Jones pada ketiga kondisi tersebut.




Gambar 7. Pipeline degradasi dan *enhancement* pada citra potret personal



Gambar 8. Deteksi wajah Viola-Jones pada citra potret personal, tiga kondisi kualitas

Gambar 9 menampilkan hasil deteksi wajah Viola-Jones pada citra kelompok (5 wajah) untuk tiga kondisi kualitas. Parameter detektor (*minNeighbors*) disesuaikan secara terpisah untuk skenario multi-wajah agar *false positive* pada latar belakang dapat diminimalkan, sebagaimana lazim dilakukan pada praktik deteksi wajah operasional.



Gambar 9. Deteksi wajah Viola-Jones pada citra kelompok (5 wajah), tiga kondisi kualitas

Tabel 4. Hasil Deteksi Wajah dan Metrik Kualitas Citra *real*, hasil eksekusi kode (Astronaut, Potret Personal, Kelompok)

| Subjek                     | Wajah Nyata | Terdeteksi (Asli) | Terdeteksi (Rendah) | Terdeteksi (Enhanced) | PSNR Rendah (dB) | PSNR Enhanced (dB) | SSIM Rendah | SSIM Enhanced |
|----------------------------|-------------|-------------------|---------------------|-----------------------|------------------|--------------------|-------------|---------------|
| Astronaut (Eileen Collins) | 1           | 1                 | 1                   | 1                     | 14.47            | 14.37              | 0.338       | 0.321         |
| Potret Personal (tunggal)  | 1           | 1                 | 2                   | 2                     | 14.15            | 15.53              | 0.278       | 0.373         |
| Foto Kelompok (5 wajah)    | 5           | 5                 | 5                   | 5                     | 15.48            | 16.89              | 0.291       | 0.356         |

Berdasarkan Tabel 4, detektor Viola-Jones menunjukkan karakteristik unik pada berbagai citra terdegradasi. Pada citra potret tunggal, penurunan kualitas memicu *false positive* (mendeteksi 2 wajah akibat tekstur pakaian) yang tetap bertahan setelah *enhancement*, menunjukkan degradasi menurunkan *recall* sekaligus menambah kesalahan deteksi. Sebaliknya, pada citra kelompok (*minNeighbors*=7 disesuaikan) dan citra astronaut, detektor konsisten menemukan wajah di seluruh kondisi kualitas. Menariknya, *enhancement* memicu perception-distortion tradeoff: PSNR/SSIM meningkat pada citra tertentu namun sedikit menurun pada astronaut meski ketajaman meningkat tajam, menegaskan bahwa ketajaman persepsual tidak selalu selaras dengan pixel fidelity.

#### 4.5 Feature Extraction

Ekstraksi fitur PCA pada galeri 50 wajah LFW menghasilkan 3 komponen utama yang menangkap variasi struktur global antar-wajah, sedangkan histogram LBP uniform (P=8, R=1) menghasilkan 10 bin yang menangkap distribusi pola tekstur lokal. Kedua jenis fitur ini digunakan baik pada tugas klasifikasi (digabung dan dinormalisasi sebagai input SVM, dengan 5 komponen PCA) maupun tugas identifikasi (dipakai sebagai basis fusi skor tertimbang, dengan 3 komponen PCA). Jumlah komponen yang kecil dipilih secara sengaja agar sesuai dengan ukuran sampel yang terbatas (50 identitas), sebuah praktik umum untuk menghindari *overfitting* pada dataset kecil.

#### 4.6 Evaluasi: Klasifikasi Wajah vs Bukan-Wajah (Hybrid PCA+LBP-SVM)

Untuk menghindari kerancuan istilah, penelitian ini membedakan secara konsisten tiga proses berikut: deteksi wajah (menentukan lokasi wajah pada citra menggunakan Viola-Jones), klasifikasi wajah-vs-bukan-wajah (menentukan apakah suatu citra berisi wajah atau bukan menggunakan *hybrid* PCA+LBP-SVM), dan identifikasi (menentukan identitas spesifik seseorang pada galeri melalui pencocokan 1:N). Evaluasi kinerja dilakukan pada

dua tugas: (1) klasifikasi wajah-vs-bukan-wajah menggunakan *hybrid* PCA+LBP-SVM pada lima kondisi kualitas; dan (2) identifikasi rank-1 pada galeri 50 wajah menggunakan PCA, LBP, dan fusi skor tertimbang (*Hybrid*) pada tiga jenis degradasi.

Tabel 5. Hasil Klasifikasi Wajah vs Bukan-Wajah *Hybrid* PCA+LBP-SVM pada Dataset LFW Subset (*real*, hasil eksekusi kode)

| Kondisi Kualitas                | Accuracy | Precision | Recall | F1-Score | ROC-AUC |
|---------------------------------|----------|-----------|--------|----------|---------|
| Bersih (clean)                  | 95.0%    | 90.9%     | 100.0% | 95.2%    | 0.995   |
| Blur                            | 95.0%    | 90.9%     | 100.0% | 95.2%    | 0.995   |
| Noise                           | 95.0%    | 90.9%     | 100.0% | 95.2%    | 1.000   |
| Gelap (dark)                    | 97.5%    | 95.2%     | 100.0% | 97.6%    | 1.000   |
| Enhanced<br>(noise→enhancement) | 97.5%    | 100.0%    | 95.0%  | 97.4%    | 0.995   |

Gambar 11 menampilkan *confusion matrix* nyata pada kondisi *enhanced* (skenario: citra didegradasi dengan *noise* lalu ditingkatkan kembali kualitasnya), dari total 40 sampel data uji (20 wajah + 20 bukan-wajah). *Confusion matrix* menunjukkan 1 kesalahan *false negative* (wajah yang keliru diprediksi sebagai bukan-wajah) dari 20 sampel wajah pada data uji, tanpa *false positive* sama sekali pada kondisi ini.

|             |             |       |
|-------------|-------------|-------|
| Bukan-wajah | 20          | 0     |
| Wajah       | 1           | 19    |
|             | Bukan-wajah | Wajah |

Gambar 11 *Confusion matrix* nyata pada kondisi *enhanced* (*real*)

Berdasarkan Tabel 5, klasifikasi wajah-vs-bukan-wajah menggunakan model sederhana ini menghasilkan akurasi yang *realistik* dan tidak sempurna (100%), yaitu sebesar 95,0% pada kondisi *clean*, *blur*, dan *noise*, serta meningkat menjadi 97,5% pada kondisi *dark* dan *enhanced*. Pada empat kondisi awal (*clean*, *blur*, *noise*, *dark*), seluruh kesalahan model murni berupa *false positive* tanpa ada *false negative*, yang menunjukkan bahwa model cenderung longgar dalam mendeteksi wajah. Menariknya, setelah proses peningkatan kualitas (*enhanced*), pola kesalahan tersebut berbalik menjadi *false negative*, membuktikan bahwa tahap *enhancement* tidak hanya memperbaiki akurasi keseluruhan secara positif tetapi juga mengubah karakteristik kesalahan model secara nyata.

Perlu dicatat bahwa selisih akurasi antar-kondisi pada Tabel 5 tergolong kecil relatif terhadap ukuran data uji: dengan 40 sampel, satu sampel berpindah klasifikasi mengubah akurasi 2,5 poin, sehingga selisih 95,0% vs 97,5% hanya mencerminkan satu sampel. Interval kepercayaan Wilson 95% untuk  $n=40$  berkisar  $\pm 7-8$  poin lebih lebar dari selisih yang diamati sehingga peningkatan pada kondisi *dark/enhanced* belum dapat disimpulkan signifikan secara statistik. Perubahan pola kesalahan dari *false positive* menjadi *false negative* pada kondisi *enhanced* dapat dijelaskan secara mekanistik: *enhancement* menggeser distribusi fitur PCA-LBP sampel bukan-wajah mendekati *decision boundary* SVM yang semula condong ke kelas wajah.

#### 4.7 Evaluasi: Identifikasi Rank-1 dan *Hybrid Machine Learning*

Tabel 6. Akurasi Identifikasi Rank-1 pada Galeri 50 Wajah LFW

| Jenis Degradasi | PCA | LBP | <i>Hybrid</i> (fusi skor tertimbang) | Bobot w (PCA) | PCA setelah <i>Enhancement</i> | LBP setelah <i>Enhancement</i> | <i>Hybrid</i> setelah <i>Enhancement</i> |
|-----------------|-----|-----|--------------------------------------|---------------|--------------------------------|--------------------------------|------------------------------------------|
| Blur            | 96% | 2%  | 98%                                  | 0.90          | 32%                            | 2%                             | 32%                                      |
| Noise           | 72% | 2%  | 72%                                  | 0.90          | 8%                             | 2%                             | 10%                                      |
| Gelap (dark)    | 2%  | 20% | 24%                                  | 0.10          | 6%                             | 8%                             | 16%                                      |

Berdasarkan Tabel 6, fitur PCA dan LBP menunjukkan karakteristik performa yang saling bertolak belakang terhadap jenis degradasi citra. PCA mencapai akurasi tinggi pada blur (96%) namun menurun pada *noise* (72%) karena struktur globalnya terganggu derau, serta anjlok ke 2% pada pencahayaan gelap akibat sensitivitas nilai piksel mentah terhadap pergeseran intensitas global. Sebaliknya, LBP hampir tidak berfungsi (2%) pada blur dan *noise* karena kerusakan tekstur mikro-lokal, namun unggul hingga 20% pada kondisi gelap karena invarian terhadap transformasi skala keabuan menegaskan tidak ada satu metode tunggal yang unggul konsisten di semua jenis degradasi.

Pada percobaan awal, penggabungan kedua fitur secara naif justru menurunkan kinerja karena fitur LBP yang buruk pada kondisi blur dan *noise* merusak jarak gabungan. Namun, setelah menerapkan skema fusi skor tertimbang dengan bobot  $w$  (Tabel 6) hasil grid search, performa metode *hybrid* berhasil meningkat dan melampaui metode tunggal pada kondisi blur (98%) dan kondisi gelap (24%), serta menyamai PCA pada kondisi *noise* (72%). Meskipun fusi skor tertimbang terbukti efektif mengambil keunggulan relatif masing-masing fitur, hasil akurasi *hybrid* ini masih merupakan batas atas (*upper bound*) karena penentuan bobot dilakukan secara *in-sample* tuning akibat keterbatasan jumlah sampel dataset tanpa citra ulangan.

Dibandingkan dengan (Kristanto et al., 2023) pada face94 PCA 100% pada *noise* namun 10% pada *brightness*, LBP 90% pada *brightness* dan 100% pada blur pola di sini berbeda cukup besar: PCA anjlok ke 2% pada gelap, LBP jauh lebih rendah pada blur (2%). Perbandingan ini perlu dibaca hati-hati karena berbeda dataset, resolusi (LFW subset 25×25 piksel, galeri 50 identitas), dan jumlah komponen PCA yang sengaja dibatasi (3) untuk menghindari *overfitting*. Akurasi 97,5% di sini nominal sebanding dengan penelitian acuan, namun keduanya mengevaluasi tugas berbeda (klasifikasi biner vs identifikasi multi-kelas), sehingga tidak dapat disimpulkan salah satu pipeline unggul secara langsung.

#### 4.8 Pembahasan

Pembahasan ini menunjukkan bahwa penelitian ini memberikan tiga kontribusi empiris tambahan dibandingkan penelitian acuan (Kristanto dkk., 2023): penggunaan dataset LFW subset dari scikit-image yang membuat seluruh hasil dapat direproduksi langsung tanpa unduhan eksternal; pelaporan temuan negatif bahwa fusi fitur *hybrid* naif dapat merusak kinerja sistem; serta evaluasi terpisah antara tugas klasifikasi dan identifikasi yang mengungkap perbedaan ketahanan terhadap degradasi citra. Implikasi praktisnya bagi investigasi forensik digital adalah perlunya sistem adaptif yang mendeteksi jenis degradasi dominan sebelum memilih strategi fusi, di mana kombinasi teknik peningkatan kualitas non-learning terbukti memulihkan sebagian kinerja secara deterministik tanpa ketergantungan GPU.

Penelitian ini masih memiliki keterbatasan metodologis: ukuran galeri identifikasi yang relatif kecil (50 identitas) tanpa citra ulangan membuat evaluasinya bersifat *closed-set* sederhana dan belum mencerminkan skenario forensik skala besar seperti QMUL-SurvFace atau SCface; bobot fusi skor pada Tabel 6 masih ditentukan secara *in-sample* tuning yang merepresentasikan batas atas performa; dan teknik *enhancement* non-learning belum mampu merekonstruksi informasi frekuensi tinggi sesempurna pendekatan super-resolusi berbasis *deep learning*.

## V. KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

Pipeline forensik digital berbasis *hybrid* PCA-LBP dan SVM berhasil dieksekusi secara nyata dengan tingkat akurasi klasifikasi wajah yang *realistis* berkisar antara 95,0–97,5%. Fitur PCA terbukti unggul dalam mengatasi degradasi blur namun melemah pada *noise* dan pencahayaan, sementara fitur LBP menunjukkan karakteristik sebaliknya; penggabungan keduanya melalui skema fusi skor tertimbang terbukti efektif mengombinasikan keunggulan masing-masing fitur pada galeri dan kondisi degradasi yang diuji, meskipun fusi fitur naif tanpa pembobotan ditemukan justru menurunkan kinerja sistem. Perlu ditegaskan bahwa peningkatan kinerja hasil fusi skor tertimbang ini hanya teramati pada kondisi pengujian tertentu, yaitu galeri tertutup (*closed-set*) berisi 50 identitas tanpa citra ulangan, dan belum dapat digeneralisasikan ke skenario forensik berskala lebih besar, mengingat ukuran dataset yang kecil dan bobot fusi yang ditentukan secara *in-sample* tuning.

### 5.2 Saran

Mengevaluasi kembali pipeline yang sama pada dataset forensik dengan skala yang lebih besar dan memiliki variasi intra-identitas (seperti QMUL-SurvFace atau SCface), menerapkan skema validasi silang (*cross-validation*) untuk menentukan bobot fusi agar lebih tergeneralisasi, serta membandingkan teknik *enhancement non-learning* dengan pendekatan super-resolusi berbasis *deep learning*.

## DAFTAR PUSTAKA

- ADDIN Mendeley Bibliography CSL\_BIBLIOGRAPHY Ahonen, T., Hadid, A., & Pietikäinen, M. (2004). Face Recognition with Local Binary Patterns. *Proceedings of the European Conference on Computer Vision (ECCV)*, 469–481.
- Buades, A., Coll, B., & Morel, J.-M. (2005). A Non-Local Algorithm for Image Denoising. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 60–65.
- Cheng, Z., Zhu, X., & Gong, S. (2018). Surveillance Face Recognition Challenge. *ArXiv Preprint ArXiv:1804.09691*.
- Dunsin, D., Ghanem, M. C., Ouazzane, K., & Vassilev, V. (2024). A Comprehensive Analysis of the Role of Artificial Intelligence and *Machine Learning* in Modern Digital Forensics and Incident Response. *Forensic Science International: Digital Investigation*, 48, 301675.
- Gómez-Bautista, A., & Calderón, F. (2024). Enhancing Facial Recognition in Surveillance Systems Through Embedded Super-Resolution. *Revista Facultad de Ingeniería Universidad de Antioquia*. <https://doi.org/10.17533/udea.redin.20240203>
- Grgic, M., Delac, K., & Grgic, S. (2011). SCface: Surveillance Cameras Face Database. *Multimedia Tools and Applications*, 51(3), 863–879.
- Hammouche, R., Attia, A., & Akhrouf, S. (2022). Score Level Fusion of Major and Minor Finger Knuckle Patterns Based Symmetric Sum-Based Rules for Person Authentication. *Evolving Systems*, 13, 469–483. <https://doi.org/10.1007/s12530-022-09430-8>
- Huang, G. B., Ramesh, M., Berg, T., & Learned-Miller, E. (2007). *Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments* (Issues 07–49).
- Immerkær, J. (1996). Fast Noise Variance Estimation. *Computer Vision and Image Understanding*, 64(2), 300–302.
- Kristanto, V. N., Riadi, I., & Prayudi, Y. (2022). Forensic Analysis of Faces on Low-

- Quality Images Using Detection and Recognition Methods. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(x), 1–9.
- Kristanto, V. N., Riadi, I., & Prayudi, Y. (2023). Forensic Analysis of Faces on Low-Quality Images Using Detection and Recognition Methods. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 7(2), 218–225.  
<https://doi.org/10.29207/resti.v7i2.4630>
- Ledig, C., & others. (2017). Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4681–4690.
- Li, P., Prieto, L., Mery, D., & Flynn, P. J. (2018). Face Recognition in Low Quality Images: A Survey. *ArXiv Preprint ArXiv:1805.11519*.
- Li, P., Tu, S., & Xu, L. (2022). Deep Rival Penalized Competitive Learning for Low-Resolution Face Recognition. *Neural Networks*.
- Low, C.-Y., & Teoh, A. B.-J. (2022). An Implicit Identity-Extended Data Augmentation for Low-Resolution Face Representation Learning. *IEEE Transactions on Information Forensics and Security*, 17, 3062–3076.
- Low, C.-Y., Teoh, A. B.-J., & Park, J. (2021). MIND-Net: A Deep Mutual Information Distillation Network for Realistic Low-Resolution Face Recognition. *IEEE Signal Processing Letters*, 28, 354–358.
- Phillips, P. J., & others. (2018). Face Recognition Accuracy of Forensic Examiners, Super-Recognizers, and Face Recognition Algorithms. *Proceedings of the National Academy of Sciences*, 115(24), 6171–6176.
- Ross, A., & Jain, A. K. (2003). Information Fusion in Biometrics. *Pattern Recognition Letters*, 24(13), 2115–2125.
- Schlett, T., Rathgeb, C., Henniger, O., Galbally, J., Fierrez, J., & Busch, C. (2022). Face Image Quality Assessment: A Literature Survey. *ACM Computing Surveys*.
- Seckiner, D., Mallett, X., Roux, C., Meuwly, D., & Maynard, P. (2018). Forensic Image Analysis: CCTV Distortion and Artefacts. *Forensic Science International*, 285, 77–85.
- Stoykova, R. (2023). The right to a fair trial as a conceptual framework for digital evidence rules in criminal investigations. *Computer Law & Security Review*, 49, 105801.  
<https://doi.org/https://doi.org/10.1016/j.clsr.2023.105801>
- Turk, M., & Pentland, A. (1991). *Eigenfaces* for Recognition. *Journal of Cognitive Neuroscience*, 3(1), 71–86.
- Viola, P., & Jones, M. J. (2004). Robust Real-Time Face Detection. *International Journal of Computer Vision*, 57(2), 137–154.
- Yadav, A. K., Pateriya, R. K., Gupta, N. K., Gupta, P., Saini, D. K., & Alahmadi, M. (2022). Hybrid Machine Learning Model for Face Recognition Using SVM. *Computers, Materials & Continua*, 72(2), 2697–2712.  
<https://doi.org/10.32604/cmc.2022.023052>
- Zeinstra, C. G., Meuwly, D., Ruifrok, A. C. C., Veldhuis, R. N. J., & Spreuwers, L. J. (2018). Forensic Face Recognition as a Means to Determine Strength of Evidence: A Survey. *Forensic Science Review*, 30(1), 21–32.
- Zhang, M. (2022). Forensic Imaging: A Powerful Tool in Modern Forensic Investigation. *Forensic Science Research*, 7(3), 385–392.  
<https://doi.org/10.1080/20961790.2021.2008705>
- Zuiderveld, K. (1994). *Contrast Limited Adaptive Histogram Equalization*. In P. S. Heckbert (Ed.), *Graphics Gems IV* (pp. 474–485). Academic Press.