

ESTIMASI GENDER BERBASIS SIDIK JARI DENGAN WAVELET DAN SUPPORT VECTOR MACHINES

Sri Suwarno^{*1}, Aditya Wikan Mahastama²

^{1,2} Universitas Kristen Duta Wacana, Yogyakarta
Email: ¹srisuwarno@gmail.com, ²mahas@staff.ukdw.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 13 November 2023, diterima untuk diterbitkan: 30 Oktober 2024)

Abstrak

Estimasi gender berbasis sidik jari sering diperlukan untuk identifikasi jenazah tanpa identitas, sebelum dipastikan dengan tes DNA. Untuk kepentingan tersebut sidik jari jenazah diambil secara digital dan selanjutnya diidentifikasi. Kesulitan yang dihadapi dalam memproses sidik jari secara digital adalah menentukan fitur yang handal dan tidak dipengaruhi oleh kualitas citra dan masalah translasi dan rotasi. Selain itu untuk mendapatkan akurasi yang tinggi diperlukan sejumlah *preprocessing* pada *dataset*. Penelitian ini bertujuan untuk mengestimasi gender berbasis sidik jari dengan fitur yang dibangkitkan dari transformasi *wavelet*. Fitur diambil dari nilai *Energy* yang dihasilkan melalui transformasi *Haar wavelet* sebanyak enam *level*. Selanjutnya fitur tersebut dipakai sebagai data latih bagi *Support Vector Machines (SVM)* untuk diestimasi. Penelitian ini menggunakan *dataset* dari *NIST (National Institute of Standard and Technology)* sebanyak 1000 sampel terdiri dari 500 sidik jari pria dan 500 sidik jari wanita. Berdasarkan hasil percobaan yang dilakukan, metode ini menghasilkan akurasi sampai 70.3% dengan tingkat *TPR (True Positive Rate)* sebesar 80.6% untuk sidik jari wanita dan 60.0% untuk sidik jari pria. Metode ini menunjukkan waktu komputasi yang cepat karena tidak memerlukan *preprocessing*, komputasinya sederhana dan dengan jumlah sampel data yang tidak banyak.

Kata kunci: *gender, sidik jari, Haar wavelet, SVM*

GENDER ESTIMATION BASED ON FINGERPRINT USING WAVELET AND SUPPORT VECTOR MACHINES

Abstract

Gender estimation based on fingerprints is often required to identify unidentified corpses before being confirmed by DNA testing. For this purpose, fingerprints of the body are taken digitally and subsequently identified. The difficulty in digital fingerprint examination is determining reliable features unaffected by translation or rotation. In addition, some preprocessing is required on the dataset to obtain high accuracy. This study aims to estimate gender based on fingerprints using wavelet transform and Support Vector Machines (SVM). The features are the Energy values generated by the Haar wavelet transform of six-level. The features are then used as training data for the SVM to be classified. This study used datasets from NIST (National Institute of Standards and Technology), as many as 1000 samples consisting of 500 male fingerprints and 500 female fingerprints. Based on the experiments' results, this method produces an accuracy of up to 70.3% with a TPR (True Positive Rate) of 80.6% for female fingerprints and 60.0% for male fingerprints. This method shows a fast computational time because it does not require preprocessing; the computation is simple and with a small amount of sample data.

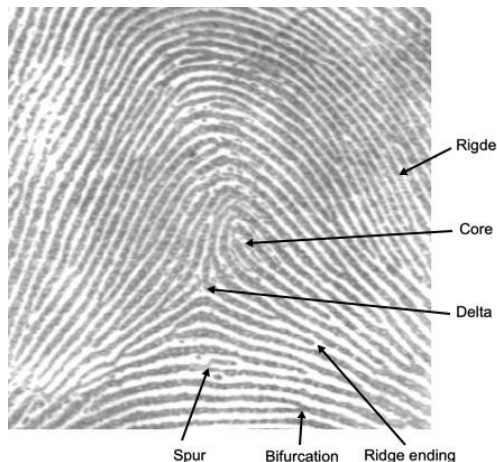
Keywords: *gender, fingerprint, Haar wavelet, SVM*

1. PENDAHULUAN

Sidik jari diyakini memiliki sifat unik yang dapat dipakai sebagai alat pembeda antara pria dengan wanita. Keunikan sidik jari terletak pada fitur yang disebut *minutiae* dalam bentuk *ridge*, *valley*, *core*, *bifurcation*, *delta*, *spur* dan *ridge-ending* seperti terlihat pada Gambar 1. Fitur-fitur tersebut cukup mudah dikenali secara visual oleh mata manusia,

namun sangat rumit kalau dideteksi dengan mesin. Itulah sebabnya banyak penelitian telah dilakukan untuk mencari fitur alternatif untuk mengolah atau meneliti sidik jari secara digital. Penelitian ini bermaksud mengestimasi gender berdasarkan sidik jari secara digital dengan fitur *Energy* dari hasil transformasi *Haar Wavelet* dan estimasinya

dilakukan dengan algoritma *Support Vector Machines (SVM)*.



Gambar 1. *Minutiae* pada sidik jari

Pemanfaatan sidik jari sebagai dasar estimasi gender didasarkan pada sejumlah penelitian sebelumnya yang membuktikan bahwa ada perbedaan yang nyata antara sidik jari pria dengan sidik jari wanita. Salah satu penelitian tersebut dilakukan oleh Jayakala dan Sudha (2021) yang menyimpulkan bahwa sidik jari memiliki fitur yang dapat digunakan untuk membedakan gender.

Untuk membuktikan hal tersebut mereka memanfaatkan *Convolutional Neural Network (CNN)*. Model *CNN* yang mereka bangun terdiri dari 3 *convolutional layers* yang masing-masing diikuti oleh *pooling layers*, dan selanjutnya digunakan *dense layer* untuk mengklasifikasi sampel data. Dengan memanfaatkan *dataset* dari *National Institute of Standards and Technology (NIST)* sebanyak 4000 sidik jari, metode yang mereka usulkan mampu menghasilkan akurasi sampai 99%. Dengan dasar hasil penelitian ini dan juga hasil dari penelitian-penelitian sejenis sebelumnya, dapat dibuat hipotesis bahwa sidik jari dapat digunakan sebagai pembeda gender.

Secara garis besar pembangkitan fitur sidik jari dapat ditempuh dengan mencermati *minutiae*, melalui transformasi matematis pada citra sidik jari, dan juga memanfaatkan *kernel* atau *filter*. Fitur berbasis *minutiae* pada umumnya dalam bentuk *Ridge Density (RD)*, *Ridge Thickness (RT)*, dan *Ridge Thickness To Valley Thickness Ratio (RTVR)*. Fitur *Ridge Density (RD)* dihitung berdasarkan banyaknya *ridge* pada suatu luasan tertentu, atau biasa disebut *Region of Interest (ROI)*. Fitur *RT* dihitung berdasarkan ketebalan *ridge* pada suatu *ROI* yang dipilih, sedangkan *RTVR* membandingkan ketebalan *ridge* dengan *valley*, yaitu alur putih diantara dua *ridge*.

Sejumlah penelitian telah memanfaatkan fitur *RD* untuk mengestimasi gender. Sebagai contoh, Lee dkk. (2020), mencermati *ROI* sidik jari sebesar 25 cm² dan secara manual menghitung banyaknya *ridge* pada luasan tersebut. Mereka berpendapat bahwa

pendekatan ini lebih sesuai dengan kondisi tempat kejadian perkara (*TKP*). Untuk mengestimasi gender berbasis *RD* tersebut mereka memanfaatkan algoritma *Naive Bayes (NB)* dan *Classification and Regression Trees (CART)*. Model yang mereka usulkan diuji pada grup etnis India dan Malaysia. Dari penelitian ini mereka meyakini bahwa banyaknya *ridge* berpotensi sebagai fitur pembeda gender.

Peneliti lain, Gnanasivam & Vijayarajan, (2019), menggabungkan *RD* dan ukuran sidik jari untuk mengklasifikasi gender. Berdasarkan kedua fitur ini mereka mengklasifikasi gender dengan metode yang mereka sebut *Optimal Score Assignment (OSA)*. Nilai *OSA* ini dihitung berdasarkan sampel data yang mereka kumpulkan. Berdasarkan nilai *OSA* tersebut kemudian dipakai sebagai dasar klasifikasi terhadap sampel data uji. Mereka melaporkan bahwa penelitian ini menghasilkan ketepatan maksimum sebesar 88.41% untuk responden berusia 18–25 tahun dan mencapai 90.11% apabila yang diuji adalah jari tangan kanan. Penelitian-penelitian berbasis *RD* tersebut memberikan akurasi yang cukup baik, namun masih melibatkan kerja manual dalam menghitung banyaknya *ridge* pada *ROI*.

Untuk fitur berbasis transformasi pada umumnya memanfaatkan transformasi *wavelet*, seperti pada penelitian yang dilakukan oleh Jalali, dkk. (2022). Dalam penelitiannya mereka melakukan cukup banyak *preprocessing* untuk memperbaiki kualitas citra sebelum dilakukan sejumlah transformasi berupa *Singular Value Decomposition (SVD)*, *Discrete Wavelet Transform (DWT)*, dan kombinasi antara *SVD* dan *DWT*. Mereka melaporkan bahwa metode yang mereka usulkan cukup sukses melebihi metode lain yang mereka bandingkan, dan mencapai ketepatan sampai 91%.

Untuk pembangkitan fitur berbasis *filter* paling banyak menggunakan *Local Binary Pattern (LBP)* dan juga *Convolutional Neural Network (CNN)*, yang akhir-akhir ini sangat populer untuk klasifikasi citra digital. Kruthi, dkk., (2019) memanfaatkan fitur *LBP* yang dikombinasikan dengan *Local Phase Quantization (LPQ)* untuk mengklasifikasi gender dengan algoritma *SVM*. Dengan menggunakan sampel sebanyak 183 sidik jari pria dan 165 sidik jari wanita, penelitian mereka menghasilkan ketepatan sebesar 97%.

Pada penelitian yang dilakukan oleh Iloanusi dan Ejiogu (2020), *CNN* digunakan untuk mengklasifikasi gender dengan memanfaatkan sidik jari dari kelima jari tangan kanan. Mereka memilih pendekatan *CNN* untuk mengurangi proses ekstraksi fitur. Arsitektur *CNN* yang mereka bangun terdiri dari 5 *convolutional layers*, 6 *Rectified Linear Unit (ReLU) layers*, 5 *max pooling layers*, 2 *fully connected layers*, sebuah *softmax layer* dan sebuah *classification layer*. Sampel data latih diambil dari 561 orang dan diambil sebanyak 3 sesi. Pengambilan sesi pertama dipakai sebagai data uji, sedangkan pengambilan pada sesi kedua dan ketiga dipakai

sebagai data latih. Mereka mengambil sampel dari lima jari tangan kanan untuk dibandingkan akurasi. Dari hasil yang diperoleh mereka melaporkan bahwa fitur dari gabungan sidik jari memberikan akurasi sebesar 94.7%.

Model *deep learning* dimanfaatkan oleh Rim dkk. (2020) untuk mengestimasi gender berbasis sidik jari. Mereka menggunakan model-model *VGG-19*, *ResNet-50* dan *EfficientNet-B3*. Sampel sidik jari yang mereka pakai sebagai data latih sebanyak 8000, data validasi sebanyak 1520 dan data uji sebanyak 360. Setelah sampel data yang diujikan pada ketiga model, mereka menyimpulkan bahwa *EfficientNet-B3* memberikan akurasi terbaik, yaitu sebesar 97.89%.

Penelitian berbasis CNN juga dilakukan oleh Hsiao dkk. (2022). Pada penelitian ini mereka menggunakan model *VGG-16*, *Inception-v3*, dan *Resnet-50*. Sampel yang dipakai disediakan oleh *New Taipei City Police Department* sebanyak 1000 sampel terdiri dari 500 pria dan 500 wanita. Setiap orang diambil 10 sidik jari dari masing-masing jarinya, sehingga total sidik jari yang digunakan adalah 1000. Dari penelitian ini mereka menyimpulkan bahwa model *VGG-16* memberikan hasil akurasi terbaik, yaitu mencapai 94.4% untuk sidik jari tangan kanan dan 79.2% untuk sidik jari tangan kiri. Mereka juga menyimpulkan bahwa model *CNN* dapat mengatasi estimasi gender yang sulit ditentukan secara manual.

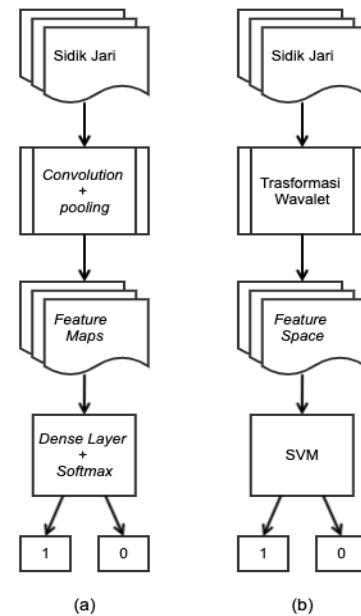
Penyederhanaan model *CNN* untuk klasifikasi gender berbasis sidik jari diusulkan oleh Suwarno dan Kurniawan (2023). Mereka hanya memanfaatkan *pooling layer* untuk membangkitkan fitur. Delapan *pooling layer* disusun secara berurutan untuk menghasilkan fitur yang selanjutnya diklasifikasi dengan algoritma *KNN (K-Nearest Neighbors)*. Dengan *dataset* dari *NIST* sebanyak 100 sidik jari pria dan 100 sidik jari wanita diperoleh akurasi sebesar 66.25%.

2. METODE PENELITIAN

Metode penentuan gender telah berkembang cukup pesat seiring dengan perkembangan penelitian dibidang pengolahan citra digital. Secara garis besar penelitian ini mengikuti pola yang dilakukan pada metode *CNN*, namun dengan pendekatan yang berbeda. Mula-mula nilai-nilai piksel pada citra sidik jari dibaca untuk membentuk fitur. Secara teoritis, pembentukan fitur bertujuan untuk memperkecil dimensi data supaya lebih mudah diklasifikasi. Pada *CNN* pembentukan fitur ini dilakukan melalui serangkaian *convolutional layers* dan *pooling layers*. Setelah dimensi fitur sudah relatif kecil, selanjutnya diklasifikasi dengan *fully connected* atau *dense layer*. Tahap *convolution* pada *CNN* membutuhkan komputasi yang lama, selain karena perhitungannya banyak, juga data latihnya sangat banyak.

Pada penelitian ini pembentukan fitur dilakukan dengan menggunakan *Haar wavelet*. Hasil dari transformasi ini selanjutnya diklasifikasi dengan

Support Vector Machines (SVM). *Haar wavelet* dipilih dengan pertimbangan komputasinya lebih pendek, sedangkan *SVM* dipilih karena banyaknya kelas yang diteliti hanya *biner*, yaitu pria atau wanita. Perbandingan kedua model ini dapat dilihat pada Gambar 2.



Gambar 2. Proses klasifikasi, (a) CNN, (b) Metode pada penelitian ini

2.1 Dataset

Pada penelitian ini *dataset* yang dipakai adalah *dataset* dari *NIST* sebanyak 1000 sampel dengan sidik jari pria dan wanita masing-masing sebanyak 500. *Dataset* ini berformat *grayscale* berukuran 512×512 piksel dan sudah diberi label untuk pria maupun wanita.

2.2 Transformasi Wavelet

Pada penelitian ini transformasi *wavelet* yang dipilih adalah *Haar wavelet*, karena data yang diolah berupa citra digital dan berbentuk diskrit dan komputasinya relatif sederhana. Secara matematis, deretan nilai-nilai piksel pada citra digital dapat ditulis dalam bentuk vektor seperti pada persamaan (1).

$$\mathbf{f} = (f_1, f_2, \dots, f_N) \quad (1)$$

dengan :

N bilangan bulat positif dan f_1, f_2, \dots, f_N nilai intensitas piksel

Pada (Walker, 2008) diuraikan bahwa *Haar transforms* dilakukan dengan mendekomposisi \mathbf{f} menjadi *averages* (a_n) dan *details* (d_n), dengan n adalah *level* atau berapa kali \mathbf{f} didekomposisi. Untuk dekomposisi satu level, a^1 dan d^1 didefinisikan pada persamaan (2), (3), (4) dan (5).

$$\mathbf{a}^1 = (a_1, a_2, \dots, a_{N/2}) \quad (2)$$

$$\mathbf{d}^1 = (d_1, d_2, \dots, d_{N/2}) \quad (3)$$

$$a_m = \frac{f_{2m-1} + f_{2m}}{\sqrt{2}} \quad (4)$$

$$d_m = \frac{f_{2m-1} - f_{2m}}{\sqrt{2}} \quad (5)$$

dengan $m = 1 \dots N/2$.

Dekomposisi pada persamaan (2) sampai persamaan (5) tersebut berlaku untuk data satu dimensi atau vektor. Untuk data dua dimensi atau matrik, maka dekomposisinya dilakukan dalam dua tahap. Tahap pertama dekomposisi dilakukan pada baris matrik terlebih dahulu, selanjutnya hasil dekomposisi tersebut didekomposisi lagi pada kolom matrik.

Proses dekomposisi *Haar wavelet* pada data dua dimensi menghasilkan empat buah komponen yaitu komponen *average* (cA) komponen *horizontal* (cH), komponen *vertical* (cV) dan komponen *detail* (cD). Untuk dekomposisi *level* tertentu, komponen yang didekomposisi hanyalah komponen cA. Dengan proses dekomposisi secara berulang, maka ukuran data akan semakin kecil.

Dalam konteks teori *wavelet*, ada fitur yang disebut *energy*, yang dihitung dengan persamaan (6).

$$E = \sum_{i=1}^N f_i^2 \quad (6)$$

Apabila persamaan (6) diterapkan pada semua komponen hasil dekomposisi *wavelet*, maka secara matematis nilai *energy* akan terpusat pada komponen cA. Nilai *energy* ini pada komponen-komponen lain cukup kecil. Untuk membandingkan nilai *energy* pada semua komponen, pada umumnya dinyatakan dalam bentuk prosentase. Pada penelitian ini fitur yang digunakan adalah nilai-nilai *energy* pada komponen cA yang dihasilkan dari dekomposisi sebanyak 6 *level*. Pada penelitian ini *Energy* cA dari level-1 tidak dimasukkan sebagai fitur karena pada level-1 ukuran matrik citra masih cukup besar.

2.3. Klasifikasi dengan SVM

Dalam konteks *machine learning*, ada sejumlah *classifier* yang dapat digunakan untuk tujuan klasifikasi. Namun dengan mempertimbangkan bentuk data latih yang berdimensi lima (ada 5 fitur) dan target klasifikasinya hanya dua (pria atau wanita) maka pada penelitian ini dipilih *SVM*.

Ada beberapa pilihan *kernel trick* yang dapat dipilih pada *SVM*, namun setelah mencoba beberapa *kernel*, yang memberikan hasil yang stabil adalah *linear kernel*. Dalam konteks teori *SVM*, tujuan dari

kernel trick adalah menambah dimensi data sehingga akan lebih *lineary separable*.

Dengan demikian maka struktur *SVM* yang digunakan terdiri dari empat *predictor*, yaitu nilai-nilai *energy* dari cA *level-2* sampai cA *level-6*, dan labelnya ada dua, yaitu 1 yang mewakili gender pria dan 0 mewakili gender wanita.

3. HASIL DAN PEMBAHASAN

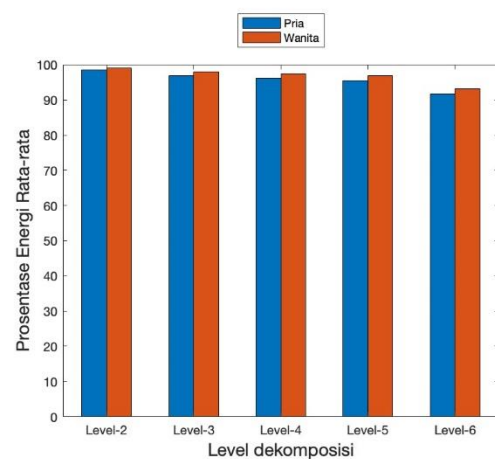
Contoh hasil dari penelitian ini dapat dilihat pada Tabel 1 dan Tabel 2. Tabel yang sebenarnya masing-masing terdiri dari 500 baris dan 5 kolom. Gambar 3 adalah visualisasi dari Tabel 1 dan Tabel 2 tetapi dibentuk dari nilai rata-rata untuk setiap kolom.

Tabel 1. Contoh *Energy* dari sidik jari pria

| File # | Level Dekomposisi | | | | |
|-----------|-------------------|------|------|------|------|
| | 2 | 3 | 4 | 5 | 6 |
| 1 | 98.4 | 96.6 | 95.7 | 95.2 | 91.2 |
| 2 | 98.9 | 97.7 | 97.1 | 96.8 | 95.5 |
| ... | ... | ... | ... | ... | ... |
| 500 | 99.6 | 99.3 | 99.1 | 98.8 | 97.8 |
| Rata-rata | 98.5 | 96.9 | 96.1 | 95.4 | 91.6 |

Tabel 2. Contoh *Energy* dari sidik jari wanita

| File # | Level Dekomposisi | | | | |
|-----------|-------------------|------|------|------|------|
| | 2 | 3 | 4 | 5 | 6 |
| 1 | 99.5 | 99.1 | 98.7 | 98.1 | 94.2 |
| 2 | 99.7 | 99.4 | 99.2 | 98.8 | 97.3 |
| ... | ... | ... | ... | ... | ... |
| 500 | 99.4 | 99.0 | 98.8 | 98.6 | 97.7 |
| Rata-rata | 99.1 | 98.1 | 97.5 | 96.8 | 93.2 |



Gambar 3. Perbandingan rata-rata *Energy* sidik jari pria dengan wanita

Dari Gambar 3 terlihat cukup jelas bahwa *energy* pada sidik jari wanita sedikit lebih tinggi dibandingkan dengan pada sidik jari pria. Namun demikian kalau dicermati pada Tabel 1 dan Tabel 2, ada nilai-nilai yang sebaliknya, dimana *energy* sidik jari pria lebih tinggi dibandingkan sidik jari wanita.

Fakta ini dapat menjelaskan bahwa secara umum kondisinya seperti pada Gambar 3, namun seberapa besar akurasi prediksi ini perlu diuji dengan

perhitungan atau metode tertentu. Dalam penelitian ini metode pengujian akurasi memanfaatkan algoritma SVM.

Dalam penelitian ini seluruh proses komputasi memanfaatkan MATLAB R2022a dengan *toolbox Image Processing, Wavelet dan Statistic and Machine Learning*. Adapun hasil pengolahan data latih dengan metode yang digunakan, diperoleh hasil yang disajikan bentuk *confusion matrix* seperti terlihat pada Gambar 4.



Gambar 4. *Confusion Matrix*

Berdasarkan Gambar 4 terlihat bahwa nilai *TPR* (*True Positive Rate*) sebesar 80.6% untuk wanita dan 60.0% untuk pria. Dengan demikian metode ini dapat memprediksi secara benar bagi sidik jari wanita sebesar 80.6%, dan untuk sidik jari pria sebesar 60.0%. Dalam konteks *confusion matrix* maka akurasi metode ini sebesar $(80.6 + 60.0)/2 = 70.3\%$.

Akurasi sebesar ini masih kalah dibandingkan dengan metode *CNN* yang rata-rata akurasinya diatas 90%. Namun metode ini memiliki kelebihan dalam hal kecepatan komputasi dan tidak memerlukan data latih yang besar. Selain itu, metode ini tidak memerlukan fasilitas perangkat keras yang tinggi.

Berdasarkan data-data yang dihasilkan dari metode ini, tidak dapat disimpulkan secara pasti mengapa *TPR* wanita lebih tinggi dibandingkan *TPR* pria. Namun berdasarkan Gambar 3 ada kesimpulan yang dapat diambil, yaitu sidik jari wanita rata-rata memiliki *energy* yang lebih tinggi dibandingkan sidik jari pria. Nilai *energy* ini terkait langsung dengan nilai-nilai piksel, sehingga akan berpengaruh pada perhitungan *energy*.

4. KESIMPULAN

Berdasarkan hasil eksperimen yang dilakukan, ada sejumlah kesimpulan yang dapat diambil. Hal yang paling menonjol adalah proses komputasinya cepat, karena tidak memerlukan *preprocessing*. Nilai-nilai *energy* hasil dekomposisi *Haar wavelet*, meskipun hanya kecil, memberikan perbedaan yang nyata antara sidik jari pria dengan sidik jari wanita. Fakta ini menguntungkan karena dapat dipakai sebagai fitur yang diolah dengan *SVM. Kernel trick*

linear yang diterapkan pada *SVM* dapat menghasilkan akurasi sampai 70.3% dengan ketepatan prediksi mencapai 80.86% untuk sidik jari wanita dan 60.0% untuk sidik jari pria.

Dengan hasil ini maka dapat disimpulkan bahwa fitur yang dihasilkan melalui dekomposisi *Haar wavelet* pada sidik jari dapat dipakai sebagai fitur pembeda gender. Untuk mempertinggi akurasi, perlu diteliti model-model klasifikasi yang lain, semacam *Naïve Bayes* atau *Multilayer Perceptron*.

DAFTAR PUSTAKA

- GNANASIVAM, P. and VIJAYARAJAN, R. 2019. Gender classification from Fingerprint Ridge Count and fingertip size using optimal score assignment, *Complex & Intelligent Systems*, 5(3), pp. 343–352. doi:10.1007/s40747-019-0099-y.
- HSIAO, C.-T. et al. 2022. Application of convolutional neural network for fingerprint-based prediction of gender, finger position, and height, *Entropy*, 24(4), p. 475. doi:10.3390/e24040475.
- ILOANUSI, O.N. and EJIUGU, U.C. 2020. Gender classification from fused multi-fingerprint types, *Information Security Journal: A Global Perspective*, 29(5), pp. 209–219. doi:10.1080/19393555.2020.1741742.
- JAKALALA, G. and SUDHA, L.R. 2021. Gender Classification Based on Fingerprint Analysis, *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(10), pp. 1249–1256. doi:https://doi.org/10.17762/turcomat.v12i10.4318.
- JALALI, S., Boostani, R. and Mohammadi, M. 2021. Efficient fingerprint features for gender recognition, *Multidimensional Systems and Signal Processing*, 33(1), pp. 81–97. doi:10.1007/s11045-021-00789-6.
- LEE, L.C. et al. 2020. Forensic gender discrimination in Malaysian population using machine learning methods, *2020 International Conference on Innovation and Intelligence for Informatics, Computing and Technologies (3ICT)*[Preprint]. doi:10.1109/3ict51146.2020.9311988.
- RIM, B., KIM, J. and HONG, M. 2020. Gender classification from fingerprint-images using Deep Learning Approach, *Proceedings of the International Conference on Research in Adaptive and Convergent Systems* [Preprint]. doi:10.1145/3400286.3418237.
- KRUTHI, R., PATIL, A. and GORNALE, S. 2019. Fusion of local binary pattern and local phase quantization features set for gender classification using fingerprints, *International Journal of Computer Sciences and Engineering*, 7(1), pp. 22–29. doi:10.26438/ijcse/v7i1.2229.
- SUWARNO, S dan KURNIAWAN, E. 2023. 'Multi-Level Pooling Model for Fingerprint-Based

Gender Classification, *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 22(2), pp. 195-206. doi: 10.30812/matrik.v22i2.2551

TERHORST, P. *et al.* 2018. What can a single Minutia tell about gender?, *2018 International Workshop on Biometrics and Forensics (IWBF)* [Preprint]. doi:10.1109/iwbf.2018.8401554.

WALKER, J.S. 2008. *A Primer on wavelets and their scientific applications*. Boca Raton, FL: Chapman & Hall/CRC.