



Efek Transformasi Geometri Shearing Pada Sistem Pengenalan Biometrik Wajah dan Periocular

Regina Lionnie^{1*}, Mudrik Alaydrus¹

¹*Teknik Elektro, Universitas Mercu Buana,
Jl. Meruya Selatan, Jakarta 11650, Indonesia*
*regina.lionnie@mercubuana.ac.id

Abstrak

Daerah *periocular* mengacu pada atribut di sekitar mata yang kaya akan informasi. Atribut *periocular* yang digunakan pada penelitian ini adalah area mata dan alis. Sistem pengenalan biometrik menggunakan ciri *periocular* dan wajah akan dibangun dengan sebelumnya memberikan transformasi *shearing* pada data gambar input. Input dari sistem adalah gambar *periocular* yang berasal dari dataset UBIPr dan wajah dari dataset EYB. Dengan menggunakan metode *machine learning* yaitu *tree* dan *k-nearest neighbor*, output yang dihasilkan adalah performansi sistem dalam *confusion matrix*. Hasil penelitian memperlihatkan bahwa tanpa menggunakan metode ekstraksi fitur, penggunaan transformasi *shearing* tidak memperbaiki hasil performansi sistem pengenalan dalam meningkatkan nilai akurasi.

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license



Kata Kunci:

*Biometric,
Periocular recognition,
Transformasi shearing,
Face recognition*

Riwayat Artikel:

Diserahkan 21 Juli, 2023
Direvisi 26 Juli, 2024
Diterima 31 Juli, 2024

DOI:

10.22441/incomtech.v14i3.21685

1. PENDAHULUAN

Daerah *periocular* mengacu pada atribut di sekitar mata yang kaya akan informasi [1]. Atribut tersebut meliputi mata, kelopak mata, sklera, sudut mata, bulu mata, tekstur kulit, warna kulit, pembuluh darah, dan alis [2]. Pengenalan wajah menggunakan area *periocular* merupakan alternatif yang populer untuk pengenalan wajah dan iris dalam skenario akuisisi yang kurang ideal, dan penilaian terhadap dua algoritma pengenalan *periocular* yang canggih pada kumpulan data terbaru menunjukkan bahwa setiap algoritma lebih cocok untuk skenario dan aplikasi yang berbeda dari masalah pengenalan biometrik [3].

Dalam area *computer vision*, transformasi *shearing* adalah transformasi geometris yang memiringkan objek di sepanjang sumbu tertentu. Transformasi *shearing* digunakan untuk mengubah bentuk suatu objek dengan memindahkan titik-titiknya sepanjang arah tertentu relatif terhadap bidang referensi. Transformasi ini dapat diterapkan pada objek 2D atau 3D. Gambar 1 berikut memperlihatkan hasil dari contoh transformasi *shearing*.



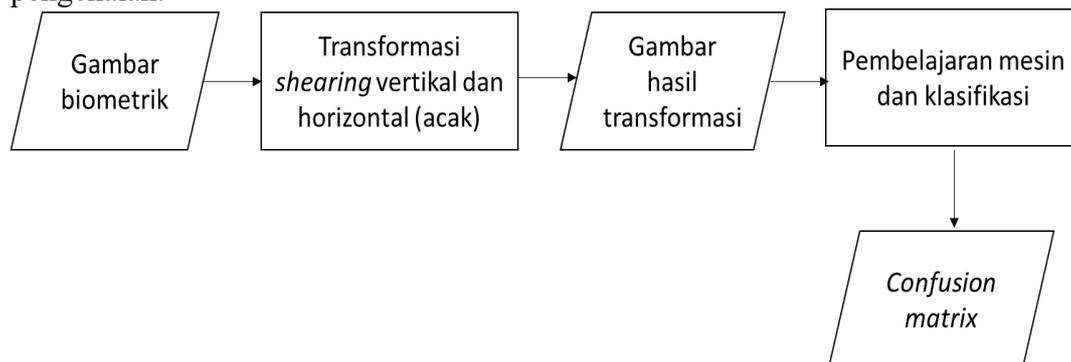
Gambar 1. Contoh transformasi *shearing* pada gambar *periocular* dari dataset UBIPr [4]

Beberapa penelitian terkait mengenai pengenalan wajah menggunakan area *periocular* adalah sebagai berikut. Penelitian [5] mengevaluasi pengenalan *periocular* menggunakan gambar termal dan cahaya tampak sebagai metode yang lebih akurat untuk menghadapi tantangan variasi iluminasi cahaya dan ekspresi wajah dengan menggunakan database NVIE. Penelitian [6] menyelidiki *Learned Label Smoothing Regularization* (L2SR) yang mengungguli metode *Label Smoothing Regularization* dalam mengurangi variasi intra-kelas dan meningkatkan generalisasi. Pendekatan pada penelitian [7] menggunakan *wavelet* dan pola tekstur untuk pengenalan *periocular* dengan hasil mengungguli hasil penelitian yang sudah ada, sebagaimana divalidasi oleh percobaan menggunakan perhitungan metrik seperti *equal error rate*, *genuine acceptance rate*, dan *decidability index*. Penelitian [8] telah melakukan eksperimen terhadap pengenalan *periocular* dengan pendekatan menggunakan transformasi geometri secara artifisial, hasilnya dikemukakan bahwa transformasi geometri memiliki potensi meningkatkan hasil performansi pengenalan.

Penelitian ini mempelajari lebih lanjut mengenai efek dari transformasi *shearing*, terutama pada variasi kemiringan horizontal dan vertikal dan hasilnya pada pengenalan wajah dan *periocular*.

2. DESAIN SISTEM PENGENALAN

Gambar 2 berikut memperlihatkan diagram alir yang dibangun pada sistem pengenalan.



Gambar 2. Diagram alir sistem pengenalan

2.1 Dataset *periocular* dan wajah

Penelitian ini mengevaluasi dua dataset biometrik untuk evaluasi sistem pengenalan, yaitu menggunakan data wajah dan menggunakan data *periocular*. Untuk data wajah, sistem pengenalan menggunakan gambar wajah yang diambil dari dataset *Extended Yale Face Database* (EYB) [9]-[10]. Gambar wajah merupakan gambar *grayscale* yang memperlihatkan wajah responden baik pria dan

wanita dengan posisi menghadap ke kamera dengan variasi pencahayaan yang beragam. Untuk *data periocular*, sistem pengenalan menggunakan gambar *periocular* yang diambil dari dataset UBIPr [4] yang memperlihatkan wajah responden pria dan wanita yang dipotong pada area mata dan alis. Gambar 3 dan 4 memperlihatkan contoh gambar pada masing-masing dataset.



Gambar 3. Contoh gambar wajah pada EYB [9][10]



Gambar 4. Contoh gambar *periocular* pada UBIPr [4]

2.2. Transformasi *Shearing*

Dalam dimensi data 2D, ada dua jenis transformasi *shearing*:

1. *horizontal shearing*: Transformasi *shearing* ini memindahkan setiap titik objek secara horizontal, yaitu sepanjang sumbu x , sambil mempertahankan koordinat y .
2. *vertical shearing*: Transformasi *shearing* ini memindahkan setiap titik objek secara vertikal, yaitu sepanjang sumbu y , sambil mempertahankan koordinat x .

Secara matematis, transformasi *shearing* horizontal dalam dimensi 2D dapat direpresentasikan sebagai:

$$\begin{aligned} x' &= x + shx * y \\ y' &= y \end{aligned} \quad (1)$$

Dimana (x, y) adalah koordinat awal suatu titik pada objek, (x', y') adalah koordinat setelah transformasi horizontal *shearing*, dan shx adalah faktor gusuran yang menentukan berapa besarnya pergusuran sepanjang sumbu x .

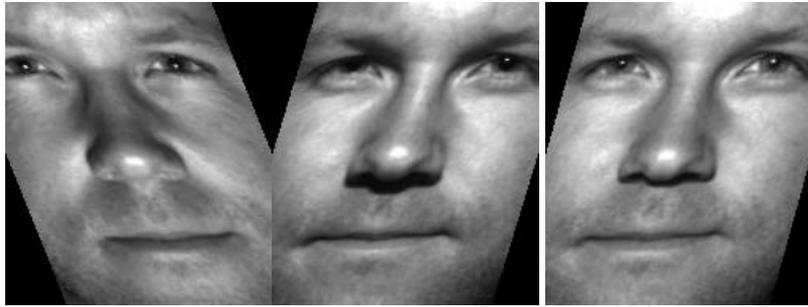
Sedangkan transformasi *shearing* vertical dalam dimensi 2D diperlihatkan pada:

$$\begin{aligned} x' &= x \\ y' &= y + shy * x \end{aligned} \quad (2)$$

Di mana (x, y) adalah koordinat asli suatu titik pada objek, (x', y') adalah koordinat setelah transformasi vertical *shearing*, dan shy adalah faktor gusuran yang menentukan berapa besarnya pergusuran sepanjang sumbu y .

Gambar 5 dan 6 memperlihatkan hasil gambar wajah dan *periocular* yang telah terkena transformasi *shearing*. Penelitian ini akan mengevaluasi sistem pengenalan

dengan menggunakan derajat transformasi *shearing* baik secara vertikal maupun horizontal yang dibuat secara acak.



Gambar 5. Hasil transformasi *shearing* acak pada gambar wajah



Gambar 6. Hasil transformasi *shearing* acak pada gambar *periocular*

2.3. Metode pembelajaran mesin (*machine learning*)

Pada penelitian ini akan dikaji dua metode *machine learning*, yaitu *tree learning* dan *k-nearest neighbor*.

Tree learning (TL) atau dikenal sebagai *decision tree learning* adalah sebuah teknik pembelajaran mesin yang termasuk dalam *supervised learning* yang digunakan untuk tugas klasifikasi dan regresi [11]. TL adalah model prediktif yang memetakan fitur input ke label output yang sesuai dengan membagi data secara rekursif berdasarkan nilai fitur. Struktur pohon menyerupai bagan alir, di mana setiap simpul internal mewakili keputusan berdasarkan fitur, setiap cabang sesuai dengan nilai fitur, dan setiap simpul daun mewakili prediksi atau hasil akhir.

Proses membangun TL melibatkan langkah-langkah berikut. Algoritma memilih fitur terbaik untuk membagi data pada node saat ini. Fitur “terbaik” dipilih berdasarkan beberapa kriteria, seperti *Gini impurity* (untuk klasifikasi) atau *mean squared error* (untuk regresi). Setelah fitur terbaik dipilih, data dipartisi menjadi himpunan bagian berdasarkan nilai yang berbeda dari fitur tersebut. Setiap subset sesuai dengan cabang pohon. Proses pemisahan diulangi untuk setiap subset (node anak) hingga kondisi berhenti tertentu terpenuhi. Kondisi penghentian dapat mencakup pencapaian kedalaman maksimum, minimum sampel dalam sebuah node, atau memiliki sampel yang homogen (semua sampel dalam node memiliki kelas yang sama atau memiliki target regresi serupa). Setelah rekursi berhenti, node akhir (node daun) diberi label keluaran atau prediksi berdasarkan kelas mayoritas (klasifikasi) atau rata-rata/median dari nilai target (regresi) dari sampel di node tersebut.

TL mudah untuk ditafsirkan dan divisualisasikan, menjadikannya metode yang sesuai untuk proses pengambilan keputusan. Namun, metode ini cenderung *overfitting*, terutama ketika tumbuh terlalu dalam dan menjadi terlalu rumit. Secara keseluruhan, TL adalah konsep dasar dalam pembelajaran mesin, dan pohon keputusan, beserta variasinya, memainkan peran penting dalam berbagai aplikasi dunia nyata karena kesederhanaan, interpretasi, dan keefektifannya.

K-nearest neighbor (KNN) adalah algoritma pembelajaran *supervised* [12] yang sederhana namun kuat yang digunakan untuk tugas klasifikasi dan regresi. Ini adalah algoritma non-parametrik, artinya tidak membuat asumsi apa pun tentang distribusi data yang mendasarinya. Sebaliknya, KNN membuat prediksi berdasarkan kesamaan titik data dalam ruang fitur.

Ide dasar di balik KNN dapat diringkas sebagai berikut. Algoritma beroperasi pada kumpulan data berlabel di mana setiap titik data diwakili oleh serangkaian fitur (atribut) dan milik kelas tertentu (dalam kasus klasifikasi) atau memiliki nilai target numerik (dalam kasus regresi). Nilai "*K*" pada KNN mewakili jumlah tetangga terdekat yang perlu dipertimbangkan saat membuat prediksi. Ini adalah *hyperparameter* yang perlu ditentukan pengguna sebelum menerapkan algoritma. Pendekatan umum adalah bereksperimen dengan nilai *K* yang berbeda dan memilih salah satu yang memberikan performa terbaik pada set validasi. Untuk mengukur jarak atau kesamaan antara titik data, KNN biasanya menggunakan metrik seperti jarak Euclidean, jarak Manhattan, atau kesamaan kosinus, bergantung pada sifat datanya. Ketika titik data baru yang tidak berlabel perlu diklasifikasikan atau diregresi, algoritma menemukan *K* titik data berlabel terdekat (tetangga) di ruang fitur berdasarkan metrik kesamaan yang dipilih. Untuk tugas klasifikasi, KNN menetapkan label kelas ke titik data baru berdasarkan kelas mayoritas di antara *K*-tetangga terdekatnya. Dengan kata lain, kelas yang paling sering muncul di antara *K* tetangga ditugaskan ke titik data baru.

2.4 Confusion matrix

Hasil klasifikasi menggunakan metode *machine learning* dan validasi silang, yang output dari performa sistemnya berupa performansi *confusion matrix* yang terdefinisi menjadi beberapa parameter seperti, *precision*, *recall*, *accuracy*, dan *F1-score* berikut. *TP*, *FP*, *TN* dan *FN* adalah *true positive*, *false positive*, *true negative* dan *false negative*. Persamaan (3) berikut adalah persamaan perhitungan *accuracy*, *precision*, *recall* dan *F1-score*.

$$\begin{aligned} Accuracy &= (TP+TN)/(TP+TN+FP+FN) \\ Precision &= TP/(TP+FP) \\ Recall &= TP/(TP+FN) \\ F1 &= 2x (Precision x Recall)/(Precision+Recall) \end{aligned} \quad (3)$$

dengan

TP, *FP* = *true positive*, *false positive*

TN, *FN* = *true negative*, *false negative*

3. HASIL DAN PEMBAHASAN

Percobaan transformasi geometri *shearing* pada biometrik wajah dilakukan untuk melakukan evaluasi terhadap ketahanan sistem pengenalan wajah dalam transformasi *shearing* ini. Dilakukan percobaan menggunakan basis data wajah EYB yang diambil dari 5 responden dengan masing-masing responden memberikan 10 gambar wajah tampak depan. Percobaan dilakukan dengan metode reduksi dimensi dengan menggunakan *principal component analysis* (PCA) dan tanpa menggunakan PCA. Jenis reduksi yang digunakan adalah 95% variansi sehingga total fitur yang digunakan untuk setiap data akan berkurang.

Metode klasifikasi yang digunakan pada *machine learning* menggunakan model *tree* dan *k-nearest neighbor* yang memberikan waktu simulasi yang singkat. Hasil detail dari percobaan pertama ini dapat dilihat pada Tabel 1 dan Tabel 2. Sedangkan detail dari hasil *confusion matrix* dan ROC serta AUC (*area under the curve*) dapat dilihat pada Gambar 7 dan Gambar 8.

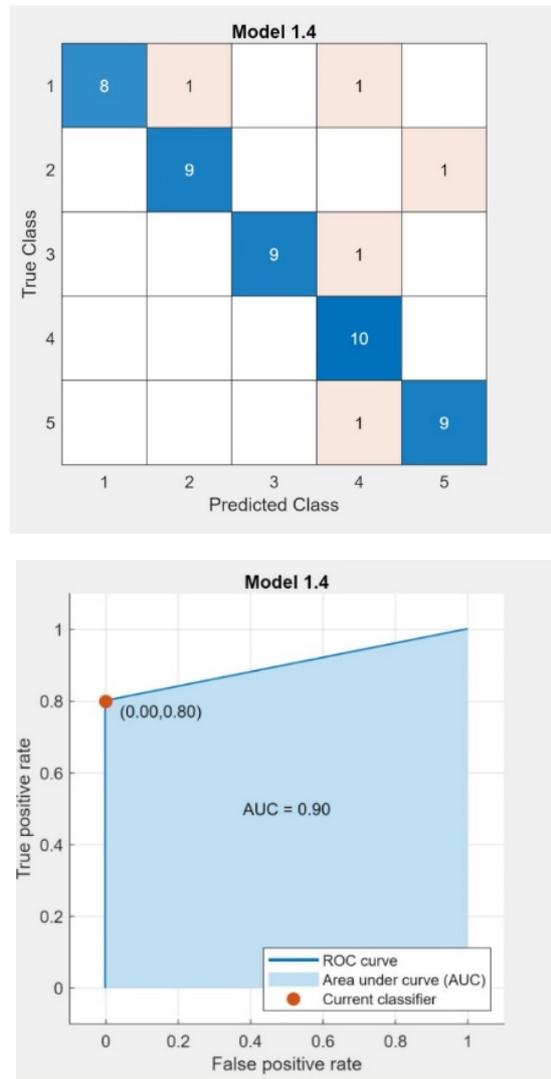
Berdasarkan Tabel 1 terlihat bahwa hasil terbaik yaitu akurasi 90% didapatkan dengan metode KNN dengan jenis *fine* KNN dan *weighted* KNN tetapi berdasarkan AUC pada Gambar 7 dan Gambar 8, hasil *weighted* KNN memberikan AUC yang lebih baik dibandingkan *fine* KNN.

Tabel 1. Hasil Akurasi Sistem Pengenalan Wajah Tanpa *Shearing*

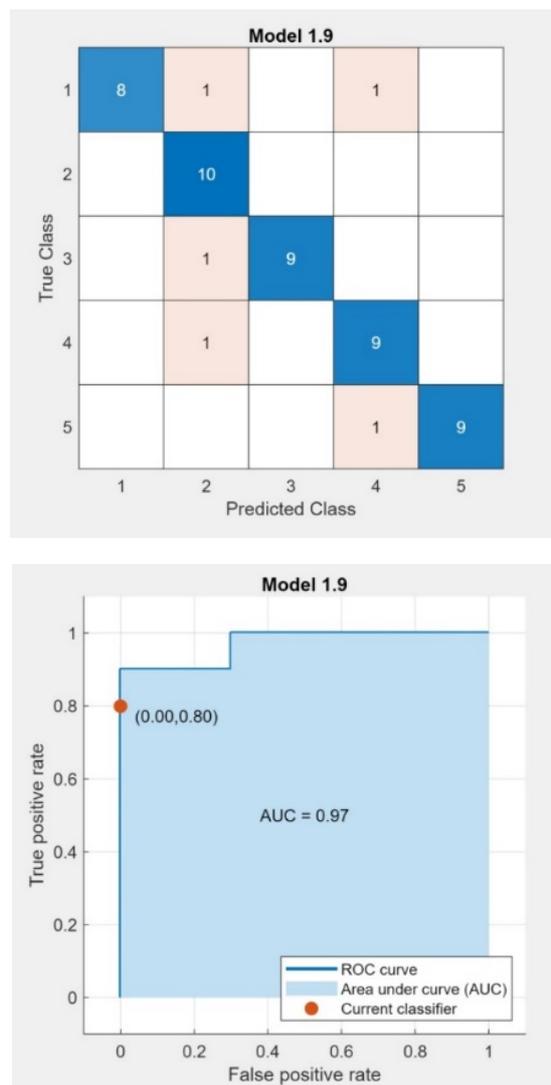
Original/tanpa transformasi <i>shearing</i>			
MODEL	Klasifikasi	PCA 95% varians	non-PCA
		33 ft	16560 ft
		<i>Accuracy</i>	<i>Accuracy</i>
<i>tree</i>	<i>fine tree</i>	62%	-
	<i>medium tree</i>	62%	-
	<i>coarse tree</i>	62%	-
KNN	<i>fine</i> KNN	90%	76%
	<i>medium</i> KNN	46%	-
	<i>coarse</i> KNN	20%	-
	<i>cosine</i> KNN	88%	-
	<i>cubic</i> KNN	38%	-
	<i>weighted</i> KNN	90%	84%

Tabel 2. Hasil Akurasi Sistem Pengenalan Wajah Dengan Transformasi *Shearing*

Dengan transformasi <i>shearing</i>		
MODEL	Klasifikasi	PCA 95% varians
		39 ft
		<i>Accuracy</i>
<i>tree</i>	<i>fine tree</i>	38%
	<i>medium tree</i>	38%
	<i>coarse tree</i>	38%
KNN	<i>fine KNN</i>	56%
	<i>medium KNN</i>	22%
	<i>coarse KNN</i>	20%
	<i>cosine KNN</i>	48%
	<i>cubic KNN</i>	26%
	<i>weighted KNN</i>	42%



Gambar 7. Confusion Matrix dan ROC/AUC untuk model klasifikasi *fine* KNN dengan PCA



Gambar 8. *Confusion Matrix* dan ROC/AUC untuk model klasifikasi *weighted KNN* dengan PCA

Percobaan transformasi geometri *shearing* pada biometrik *periocular* dilakukan untuk melakukan evaluasi terhadap ketahanan sistem pengenalan dalam transformasi *shearing* ini. Dilakukan percobaan menggunakan basis data *periocular* yang diambil dari 5 responden dengan masing-masing responden memberikan gambar 10 *periocular* tampak depan.

Percobaan dilakukan seperti pada biometrik wajah dengan metode reduksi dimensi dengan menggunakan PCA dan tanpa menggunakan PCA. Jenis reduksi yang digunakan adalah 95% variansi sehingga total fitur yang digunakan untuk setiap data akan berkurang. Metode klasifikasi yang digunakan pada *machine learning* menggunakan model *tree* dan *k-nearest neighbor* yang memberikan waktu simulasi yang singkat. Hasil detail dari percobaan ini dapat dilihat pada Tabel 3 dan Tabel 4. Berdasarkan Tabel 3 terlihat bahwa hasil terbaik sebesar akurasi 34% didapatkan dengan metode KNN dengan jenis *weighted KNN*. Sedangkan dengan menggunakan transformasi geometri *shearing*, terlihat bahwa walaupun hasil

akurasi belum memuaskan, tetapi sedikit meningkatkan akurasi untuk sistem pengenalan *periocular* yang tidak menggunakan transformasi geometri *shearing*.

Tabel 3. Hasil Akurasi Sistem Pengenalan Biometrik *Periocular* Tanpa Geometri *Shearing*

original			
MODEL	Klasifikasi	PCA 95% varians	non-PCA
		45 ft	10000ft
		<i>Accuracy</i>	<i>Accuracy</i>
<i>tree</i>	<i>fine tree</i>	22%	
	<i>medium tree</i>	22%	
	<i>coarse tree</i>	22%	
KNN	<i>fine KNN</i>	24%	
	<i>medium KNN</i>	30%	
	<i>coarse KNN</i>	20%	
	<i>cosine KNN</i>	32%	
	<i>cubic KNN</i>	24%	
	<i>weighted KNN</i>	34%	30%

Tabel 4. Hasil Akurasi Sistem Pengenalan Biometrik *Periocular* Dengan Transformasi Geometri *Shearing*

dengan transformasi <i>shearing</i>		
MODEL	Klasifikasi	PCA 95% varians
		43 ft
		<i>Accuracy</i>
<i>tree</i>	<i>fine tree</i>	24%
	<i>medium tree</i>	24%
	<i>coarse tree</i>	24%
KNN	<i>fine KNN</i>	22%
	<i>medium KNN</i>	30%
	<i>coarse KNN</i>	20%

	<i>cosine</i> KNN	32%
	<i>cubic</i> KNN	24%
	<i>weighted</i> KNN	28%

4. KESIMPULAN

Penelitian ini telah berhasil membangun sistem pengenalan biometrik menggunakan data wajah dan data *periocular* dengan memperhatikan efek transformasi *shearing* pada data yang digunakan. Hasil penelitian memperlihatkan bahwa tanpa menggunakan metode ekstraksi fitur apapun di dalam sistem pengenalan, dengan hanya data input yang dilakukan transformasi *shearing*, maka hasil performansi sistem pengenalan tidak meningkatkan nilai akurasi baik untuk data wajah dan juga data *periocular*.

Saran untuk penelitian yang akan datang adalah dengan menghitung secara presisi berapa derajat transformasi *shearing* yang dilakukan baik secara vertikal maupun horizontal untuk mengetahui efeknya pada hasil performansi sistem pengenalan. Selain itu, transformasi *shearing* ini dapat dikombinasikan dengan metode ekstraksi fitur pada sistem pengenalan dan juga beberapa tahap pra-proses.

REFERENSI

- [1] Kumari, P. and K. R. Seeja, "Periocular biometrics: A survey," J. King Saud Univ. - Comput. Inf. Sci., vol. 34, no. 4, pp. 1086–1097, Apr. 2022, doi: 10.1016/J.JKSUCI.2019.06.003.
- [2] Kumar, M. A. Zaveri, S. Bakshi, and P. K. Sa, "Who is behind the Mask: Periocular Biometrics when Face Recognition Fails," ICPC2T 2022 - 2nd Int. Conf. Power, Control Comput. Technol. Proc., 2022, doi: 10.1109/ICPC2T53885.2022.9777027.
- [3] Monteiro, J., Esteves, R., Santos, G., Fiadeiro, P., Lobo, J., & Cardoso, J. (2015). A Comparative Analysis of Two Approaches to Periocular Recognition in Mobile Scenarios. , 268-280. https://doi.org/10.1007/978-3-319-27863-6_25.
- [4] Padole CN, Proenca H. Periocular recognition: Analysis of performance degradation factors. In2012 5th IAPR international conference on biometrics (ICB) 2012 Mar 29 (pp. 439-445). IEEE.
- [5] Nakamura, T., Yoshiura, H., & Ichino, M. (2021). Periocular Recognition Based on Features from Thermal and Visible-Light Images. 2021 IEEE 10th Global Conference on Consumer Electronics (GCCE), 980-981. <https://doi.org/10.1109/GCCE53005.2021.9621934>.
- [6] Jung YG, Park J, Tiong LC, Teoh AB. Periocular recognition in the wild with learned label smoothing regularization. InTwelfth International Conference on Digital Image Processing (ICDIP 2020) 2020 Jun 12 (Vol. 11519, pp. 227-234). SPIE.
- [7] Kumar, K., Lala, A., Vyas, R., & Sharma, M. (2020). Periocular recognition via effective textural descriptor. 2020 IEEE 7th Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON), 1-6. <https://doi.org/10.1109/UPCON50219.2020.9376575>.
- [8] R. Lionnie, C. Apriono, R. Chai and D. Gunawan, "Curvature Best Basis: A Novel Criterion to Dynamically Select a Single Best Basis as the Extracted Feature for Periocular Recognition," in IEEE Access, vol. 10, pp. 113523-113542, 2022, doi: 10.1109/ACCESS.2022.3217243.
- [9] Georghiadis, P. N. Belhumeur and D. J. Kriegman, "From few to many: illumination cone models for face recognition under variable lighting and pose," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 23, no. 6, pp. 643-660, June 2001, doi: 10.1109/34.927464.
- [10] Lee, K. C., Ho, J., & Kriegman, D. J. (2005). Acquiring linear subspaces for face recognition

- under variable lighting. *IEEE Transactions on pattern analysis and machine intelligence*, 27(5), 684-698.
- [11] Bansal M, Goyal A, Choudhary A. A comparative analysis of K-nearest neighbor, genetic, support vector machine, decision tree, and long short term memory algorithms in machine learning. *Decision Analytics Journal*. 2022 Jun 1;3:100071.
- [12] Maulidah, N. Prediksi Peningkatan Jumlah Nasabah Deposito Berjangka Menggunakan Algoritma KNN, Decision Tree, Random Forest Dan Xgboost. *Incomtech*. Vol. 13, No. 2, hal 90-95, 2023.