

DIRECTION OF VEIN MAPPING IN FORENSIC IDENTIFICATION: A COMPREHENSIVE REVIEW

Neha BADHWAR , Khadija Murtala MUKADDAS, Vhagyashree NEOGI, Ameesha SWAPNA, Bill Fallah FOMBA

Department of Forensic Science, School of Bioengineering and Biosciences, Lovely Professional University, Phagwara, Punjab, India

Abstract

Vein mapping can be used to identify possible suspects using matching learning algorithms. Since vasculature deep in the skin cannot be visualized by naked eyes, the features extracted usually by converting to near infrared images which gives best track recovery with little noise. Two decades ago the premise for the use of vein patterns for identification emerged in the forensic field. Researchers are proposing innovative approaches and methods utilized to improve the recognition, quality, classification, and extraction of viable vein patterns from images. Deep learning algorithms such as convolution neural network (CNN), K-nearest network, autoencoders are being used to extract venous features with ease especially when analyzing image forensic evidence. This paper provides an overview of recently proposed finger vein, dorsal hand vein, wrist vein and hybrid systems and highlights their performance and real-life application.

Keywords

Vein mapping; Algorithms; Feature extraction; Identification; Deep learning; Infrared.

Received 9 May 2024; accepted 13 August 2024

Introduction

In the realm of identity verification, traditional methods such as keys, cards, and passwords have long held sway, but recent advancements in biometrics have opened a promising alternative. Biometrics harnesses the power of automated recognition, based on an individual's unique physiological and behavioural characteristics. This shift offers not only enhanced convenience but also an unparalleled level of security. Unlike their conventional counterparts, biometric identifiers are immune to the perils of forgetfulness, loss, or theft [1]. Beyond their role in authentication, these biometric markers often serve as critical leads in investigations, making them of paramount importance in the global landscape of security concerns [2].

Broadly, biometric systems serve two key applications: verification and identification. Verification focuses on accepting or rejecting an individual's identity and can be done as a one-to-one matching problem by comparing the captured biometric features with previously stored patterns (Figure 1). In contrast, identification involves searching for a person's identity by comparing the acquired biometric feature with all patterns in a database, i.e. a one-to-many matching problem [1].

Over the years, several biometric techniques have emerged, each relying on different characteristics: fingerprints, palm prints, hand, finger, palm, and foot veins, iris patterns, gait analysis, palates, voice characteristics, facial expressions, heartbeat patterns, signatures, body language, and facial contours etc. These

techniques can be broadly classified into two groups: extrinsic biometric features (such as palm prints, irises, fingerprints, and faces) and intrinsic biometric features (like palm veins, hand veins, and finger veins) [4].

Extrinsic features tend to be more conspicuous but more susceptible to environmental variations. Among the intrinsic features, vein patterns exhibit remarkable strength and permanence. As a biometric modality, vein pattern recognition boasts several advantages; high recognition accuracy, highly individualistic, minor inter-observer difference (low subjectivity), resilience against forgery, minimal susceptibility to external conditions, non-contact or weak contact measurement conditions, and minimal vulnerability to surface conditions such as scars, oil, or sweat [5, 6]. Furthermore, it tackles concerns regarding digital evidence involving obscured or concealed faces, in cases involving child pornography or acts of terrorism where conventional facial recognition systems are rendered ineffective [7]. Consequently, it has garnered significant attention within the research community in recent years.

As an advanced biometric technique, vein mapping has become increasingly important as evidence in biometrics and forensics. Unlike other biometric

features, vein patterns exhibit remarkable stability over a lifetime particularly on the hands fingers and wrists, even in cases where attempts were made to disguise or alter them [8]. Furthermore, the non-invasive nature of vein mapping makes it crucial in cases such as child abuse or child pornography, where consent or cooperation may be unlikely [9]. The quick development of vein mapping technology has been facilitated by a recent study on its development and use in the forensic field, highlighting its potential as a reliable method of personal forensic identification [10]. However, vein localization presents a challenge in individuals with certain physiological characteristics, such as darker skin tones, deeply embedded veins, or skin irregularities like scars, tattoos, or hair, even when using NIR (near infrared imaging). Furthermore, in specific demographic groups like the elderly, infants, obese, dehydrated patients, or intravenous drug users, the task of vein localization becomes arduous [11].

General recognition techniques for vein mapping identification are: acquiring the images or enrollment process as shown in Figure 2, region extraction, pre-processing, feature extraction, comparison and verification.

Infrared imaging technology is essential to effectively visualise these vein patterns [8] as well as

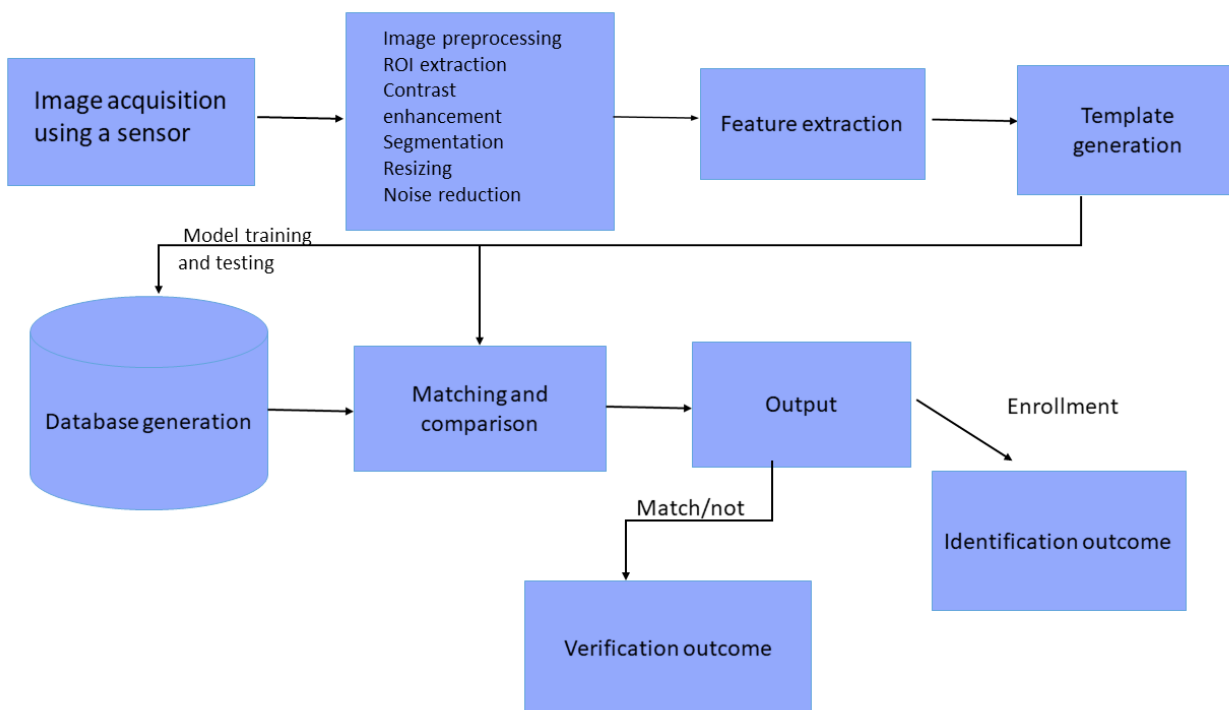


Figure 1. Generalized block representation of a biometric system describing steps necessary to acquire an outcome. Image preprocessing and feature extraction are important stages where the ROI (region of interest) is defined and can be achieved via numerous methods such as convolutional neural network (CNN), texture or shape feature extraction [3].

coloured images which can be converted to grayscale, and feature extraction algorithms can be applied.

Near IR have shown a significant leverage over far IR in recording vein images. FIR imaging functions sensing heat given off by the human body [12]. Due to the relatively higher temperature of veins compared to the surrounding tissues, vein patterns become distinct in FIR images, contrasting with undesirable skin surface characteristics resulted by visible light. However, the quality of FIR images is contingent upon external factors, resulting in instability [1].

In contrast, NIR imaging operates in an active mode requires the use of external light sources. It is rooted in biomedicine and takes advantage of the differential absorption and reflection properties of deoxy- and oxyhemoglobin, the primary components of blood. As a result, NIR images reveal clear vein patterns due to these optical properties as shown in Figure 3 [12].

NIR imaging can capture images of smaller veins closer to the skin’s surface, improving the accuracy of person identification. Recent research has focused on achieving reliable recognition performance using extensive databases of dorsal and forearm hand vein images while relying on less abundant vein features from higher-quality images [1].

Further research is being conducted to minimize NIR illumination to acquire good contrast for every skin type with less power and space used for the illumination system, taking into consideration skin characteristics and variation [11] to improve vein visualization from colour images [14].

However, several factors can impact the accuracy of the ROI detection in hand vein images, resulting in performance degradation in biometric systems. These challenges also limit their application in forensic investigations [15].

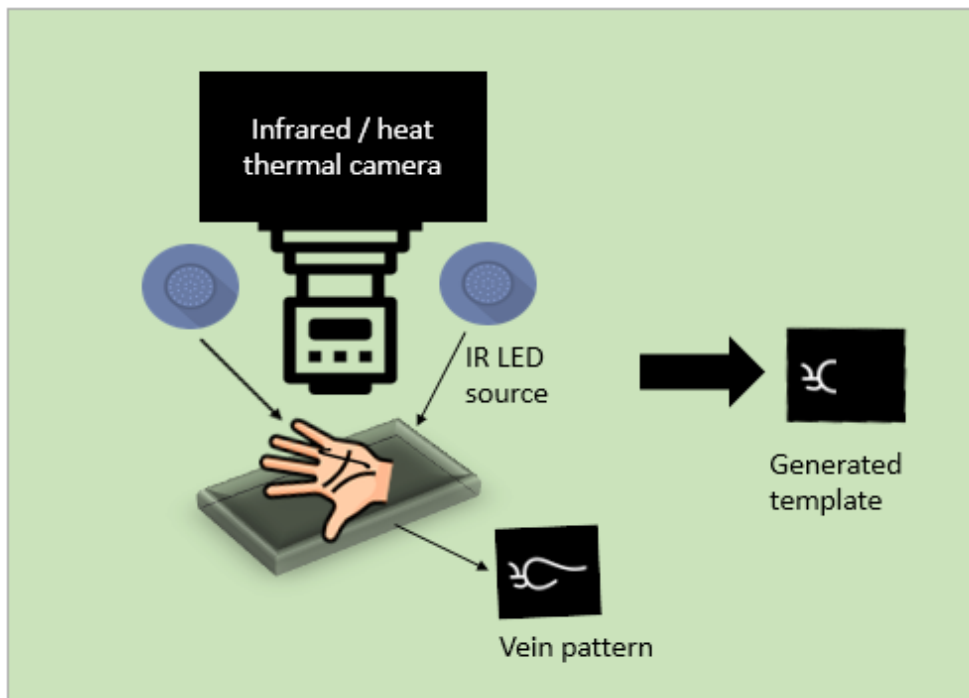


Figure 2. Schematic diagram of image enrollment.




Figure 3a. Colored image of a leg and its corresponding near infra-red; 3b. Features of pigment, heme, and depths of skin map respectively [13].

Vein pattern in forensic identification

Vein mapping has become a forensic inquisition over the last decade as image evidence has shown new potential for identifying criminals beyond their facial features [7]. In 2015 a study on genetically identical vein patterns included the forearm and thigh data taken from 324 participants in 2 sessions [16]. NIR images were used to avoid errors when using a visualization algorithm [13]. The genetically identical images were acquired by flipping the left limb images horizontally and put together with their equivalent right limb images. The virtual twin forearm data set was divided into: with and without straps (around the left wrist). The images were preprocessed via CLAHE and Gabor filters while the ROI was marked manually and then a threshold was assigned to remove noise. The ROI was skeletonized and binarized. A 3 step vein-matching scheme was employed, described by Zhang et al. [17], and the similarities were analyzed using point sets. Genuine, imposter, and virtual twin dissimilarity values were generated for the lower and upper limbs. Focusing on the virtual twin's thigh and forearms means, they showed more similarity than the fake counterpart. The division of the left forearm images with or without straps affected only the dimension of the ROI region, i.e. the data set without the straps showed better results than the data set with the wrist straps. Furthermore, the authors established the similarity was not influenced by factors such as BMI, number of reference points, size of vein, and size of the region of interest [16].

Described method is complex and demands time and resources to operate and implement the algorithm; it undoubtedly gave rise to clear visualization of the underlying vein patterns and has the possibility of spanning into larger data sets.

Dorsal hand vein

A simple, cost-effective grid system was used on macroscopic veins obtained from coloured pictures, without the need for multiple stages of preprocessing and complex mathematical models. Considering venous crossings and branching points, it included the use of 3 horizontal and vertical lines to divide the hand into 4 sectors (A, B, C, D), giving rise to 11 variables for each hand. The line placements of the first three were at the styloid process of the wrist, in-between the 2nd and 3rd, and at the dorsal aspect of the third left metacarpal, respectively. The fourth and sixth lines were placed at the 2nd and 5th metacarpal, with the fifth

line in-between. A statistical SPSS/PASW (Statistical Package for Social Sciences/Predictive Analytics Software) system was used to generate overlapping probabilities and predictions from the participants' left and right hands. Accuracy in identifying a person was seen as possible using the first 5 variables; the venous crossing points of lines 1, 2, 4, 5, and 6. Reducing the number of variables showed overlapping between participants [18]. The simulation of 1000–100,000 participants was generated 10 times and Hartung et al. found that random overlap between participants is less likely within 1 : 1000.

Similarly, a SVM (support vector machine) and KNN (K-nearest neighbor) approached on dorsal hand images from the database SUAS (Sakarya University of Applied Sciences) were developed using the SURF (speeded up robust features) approach for data standardization while applying a similar technique to Hartung et al. but on NIR images; hence required additional steps to process the images [19]. Multiple grids in rounds were used to calculate the number of squares occupied by the venous region and to input the fractal dimension at different angles. Likewise, overlapping was seen between the 8th and 6th subjects just as observed by Hartung et al. [18], therefore Cimen et al. [19] suggested morphological operatives application to mitigate the issue. To validate their approach, it was cross-checked using Bosphorous Database. SVM acquired a near 100% performance with LKF (linear kernel function) and LPF (low pass filter) while KNN ranged from 85–88%, taking 3 different K constants [19].

Pititheeraphab et al. set up a contactless identification system based on hand geometry and local vein pattern identification. The system utilized geometric points to map out the external borders of the hand, i.e., web of the hand and fingertips. In conjunction, the local vein pattern was identified using the minutiae-based method given vein bifurcations and vein termination points. Intensity profiles were generated to map the position of vein pixels and veins inflection was calculated to determine the width [8]. Minutiae points, were acquired after thinning of the extracted results, and pattern matching was assigned to locate the type of vein pattern [4, 8]. The points were triangulated from the standard to the questioned, and all sets of triangles were evaluated using an algorithm (Figure 4b).

The orientation of each triangle was standardized and arranged in ascending order and search for the matching triangles. The other method of comparison was the affine method [8, 20], in which the lengths and angles were not preserved and a window of 5%

error rate was allowed; stricter matching between the two sets (questioned and reference) and used a run length method to check for congruity. The triangles were matched to the template after aligning reducing the error rate down to 0.122% as to not being aligned 7.52%, as shown below in Figure 4c. Furthermore, the paper constituted barcodes to the generated pattern image and matching could be done based on the barcodes.

An automated dorsal vein identification tool (AD-VIT) proposed by Hussain et al. [21] utilized the grid

scheme by Hartung et al. described above. The choice of ResNet-50 was due to its flexibility and comparison based on similarity was carried out via cross-entropy. Cross entropy, described by Hussain et al. measures the difference between two probability distributions concerning a variable. The 3 datasets were tested for accuracy and false rates, with data sets from ResNet-50 showing better results (0.896 accuracy, 0.1 false positive) than the grid method (0.83 accuracy, 0.15 false positive) and the combined two methods (0.95 accuracy, 0.04 false positive) showing better




Figure 4a. The imposter and genuine curve.

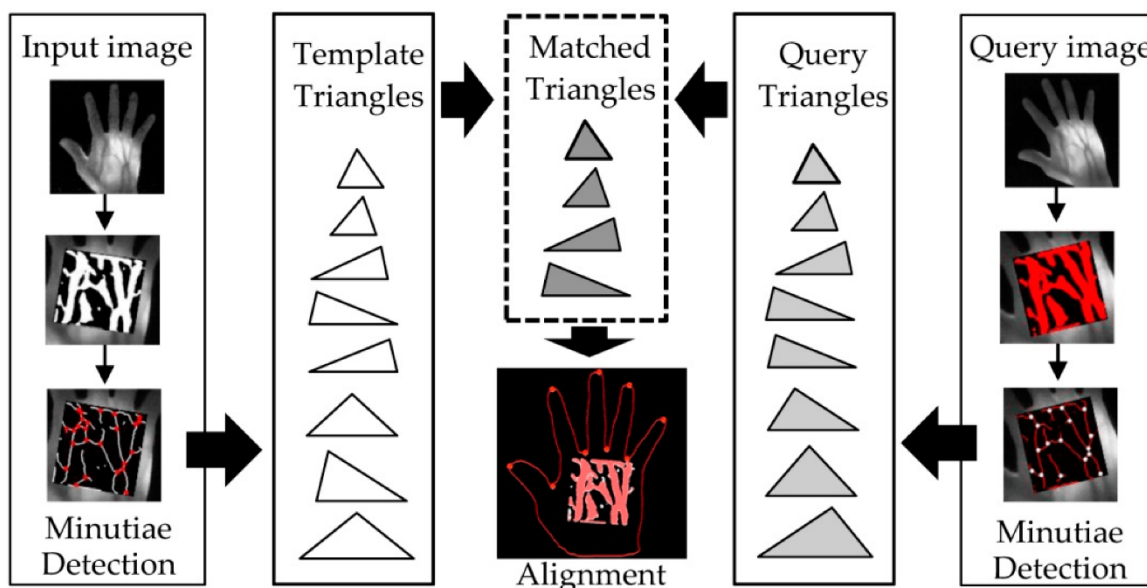


Figure 4b. The extraction-matching scheme.

results than ResNet-50. Additionally, the practicality of the method through real-life scenario was tested, i.e. training data set was not included in the testing run. Similar results were achieved with 100% of the dataset in the training phase. Although the results were promising, there are some limitations to the system, due to reliance on macroscopic vein visibility, medical and physical conditions can impact the amount of data retrieved from a suspect or participant. The selected dataset was not representative as it was generated by 30 participants only [18].

Then, live vein detection by exploiting the pulse heavily eliminated the chances of imposters or bypassing the system. The system worked on the periodic pulsation of the heart beating to successfully discriminate or verify identity. A rotation correction method was applied to mitigate problems with false identification or rejection. A comparison was drawn with a prosthetic finger which was unable to show any peaks, a 99.33% success rate was achieved using SVM. Moreover, random forest, back propagation, and KNN generated a successful recognition of 97.78%, 98.44%, and 78.22%, respectively [22].

Finger vein

A novel PHOG-LPQ (pyramid histogram of oriented gradient – local phase quantization) recognition

framework for finger veins having resistance to distortion and noise. LPQ (local phase quantization) is sensitive to uneven lighting and low-resolution images. Therefore, features extracted by both recombined at the feature level. Different pyramid layers and window sizes were applied to analyze the performance, giving rise to slightly different results; it achieved EERs (equal error rates) of 1.92% and 1.00% in FV-USM (Finger Vein – Universiti Sains Malaysia) and MNCBNU_6000, respectively. This showed the robustness and high recognition accuracy in finger veins [23]. Anila et al. highlighted a method to extract venous features from coloured images using (red-green-blue) RGB-NIR mapping, an automatic matching algorithm, and a vein visualization algorithm. Later an adjustment scheme was introduced; NN (neural network) input layer weight to add clarity to the output skeletonized vein pattern. However, the data set was highly limited on the data and accuracy for a higher number of data sets was not ensured [24].

An interclass data augmentation technique was proposed by Ou et al. [25] via merging with the conventional intra-class techniques to increase the multifariousness of the set. The originality of the dataset was maintained by vertically flipping the frames but also provided an acceptable difference in the two sets. Furthermore, they designed a cosine SoftMax + triplet (fusion loss) loss to increase the differentiability between the inter-class and intra-class cosine similarity,

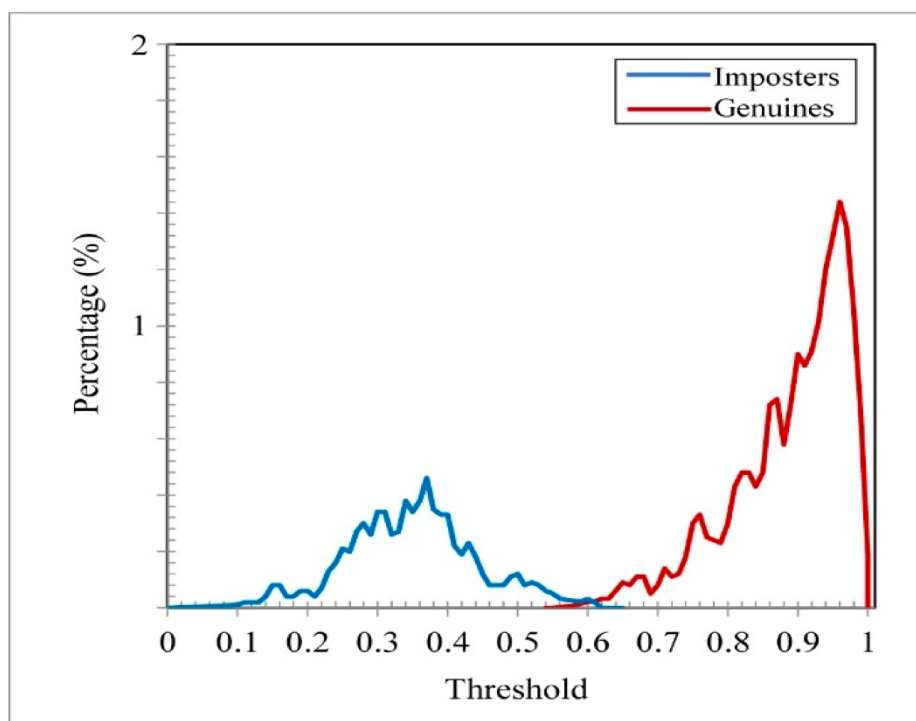


Figure 4c. False matched and non-match rate [8].

and analysis was carried out using a real-time finger vein recognition system. The real-time finger vein recognition system considered geometric changes that may occur, but could be subjected to false rejection error in case of extreme deformation of vein pattern. Then, the scheme was tested against FVUSM, HKPU (Hong Kong Polytechnic University), MNCBNU (Multimodal Chonbuk National University), and the in-house database ensuring the testing dataset was not within the training set. This method performed considerably better than other approaches through deep venous features and is simpler to perform [25].

A proposal for a new finger vein recognition system using machine learning and utilizing the freely accessible dataset from THU-FVFDT2 (Tsinghua University Finger Vein and Finger Dorsal Texture Database), SDUMLA-HMT (Shandong University Homologous Multimodal Traits), and FV-USM was done by Shakil et al. [26]. All 3 have different subject datasets with different ROI as shown in Table 1. Shakil et al. utilized a multidimensional filter to extract the ROI and enhanced the local details of the vein patterns, the authors

added that a good extraction of the segment simplifies the subsequent steps. Using the principal component analysis, Shakil et al. extracted fractal features that were constant in dimensions, used a support vector machine to classify and added a method for matching larger patch sizes. Shakil et al. analyzed the recognition rates and time taken for each step to process the 3 datasets. The accuracy correlates directly with an increase in training images. The idea was not as complex as Zhang et al. [16] and introduced an insights into a learning system. Prospects were also highlighted to further enhance the recognition rate [26].

Palm vein, sclera, and wrist vein

Matkowski et al. explored the possibility of using the wrists to offer clues for identification as they are less likely to be hidden by perpetrators. The wrist identification algorithm consisted of 5 steps: wrist segmentation, ROI extraction, feature extraction, wrist matching, and meta-recognition. It introduced

Table 1
Detailed information on some vein image databases

Database name	No. of images	Dataset type	No. of subjects	Other details about the database	References
FV-USM	5904	Finger vein	123	Images acquired from 2 sessions; both hands (index and middle) each finger provided 6 images	[27]
HKPU	6264	Finger vein	156	Images acquired from 2 sessions; index and middle finger were used and a total of 24 images were provided by each subject in 1 session.	[28]
SDUMLA-HMT	3816, 1060	Finger vein, iris respectively	106	Database contains multiple biometric data; both hands (index, middle and ring) each finger provided 6 images. Each subject provided 10 images of the iris (left and right)	[29]
Bosphorus	1200	Dorsal hand vein	100	Each participant provided 12 left hand image, taken in different conditions to determine variability	[30]
VERA	440, 2200	Finger vein and palm vein respectively	110	Images captured in two trails; two images per index finger. Each image provides specifications, e.g. gender, the trail (1/2) and side (left or right) Palm image captured in 2 session; 5 images per palm	[31, 32]
THU-FVFDT	NA	Finger vein and finger dorsal texture	220	2 different sessions; 4 finger vein and texture captured simultaneously in each session. Additionally the database contains variants which are all publically available.	[33]
DRIVE (Digital Retinal Images for Vessel Extraction)	40* randomly selected	Retinal vessels	400	40 images were divided into two sets (training and test)	[34]
PLUSVein-FV3	7200	Finger vein	60	Both hands (index, middle and ring) from dorsal and palmer side which were divided into 3 subsets	[35]

an automated wrist matcher for forensic application algorithm, simple linear iterative clustering was used to generate super pixels (segment ROI into patches) shown in (Figure 5b). Considering factors such as position of wrists to counter detection of wrist wrinkles and boundaries were taken. The paper claimed to be the earliest on wrist identification from coloured images. The experimental results showed that the suggested WMM (wrist meta-matching) algorithm was able to match (Figure 5a) and outperform other advanced and modern palm print and palm vein identification methods. Matkowski et al. method showed a high level of performance and was successfully able to identify and match the wrist to the corresponding probe images [7].

A CNN-based palm-vein recognition system with a texture feature extraction tool binarized statistical image features (BSIF), taken from 5 sub-regions; making the ROI and then fused using score-level fusion method [36]. The second half of the system was a CNN, based on the method of Kannala et al. [37]. The images were enhanced using histogram equalization and each sub-region score was linked using the KNN classifier to make the first decision, the second decision was taken by the CNN approach and applied to the whole palm. The texture feature extraction quantified binary codes for each image known as the local descriptor of the image. Additionally, the values of the pixel code in histogram gave the texture properties within the sub-regions [37]. The decision levels were fused to provide the final decision by weighted OR rules within a threshold of 0.9 [36]. The method was tested against several databases with accuracy levels of 99.83%, 100%, 99%, 100%, and 100% of the CASIA, FYO, PUT, Tongji, and VERA databases respectively. It also achieved an accuracy level of 100% while tested against other proposed methods and well-known architecture models.

Eye vein patterns are utilized for ocular biometrics [20], specifically the sclera mapping was considered in these articles [20, 38, 39, 40]. Embedded in the sclera are veins arbitrarily oriented and sandwiched in between the sclera layers [38, 41]. The Y formations of the vein pattern were found to be consistent; resisting deformation due to eye movement. Low pass filters were implemented to improve the pattern acquisition and productivity [41]. Vitek et al. sectioned the study into 7 different parts with each stage annotating a function of their proposed method. Five segmentation models were used, but RefineNet-50, U-NET, SegNet, and RefineNet-101 were chosen for their robustness [20]. They established age and direction of movement as contributing factors to the recognition success using 5 different recognition models: SIFT (scale-invariant feature transform), CNN, ORB (oriented FAST and rotated BRIEF), SURF (speeded up robust features), and dense-SIFT (dSIFT), with CNN maintaining the highest level of accuracy. SIFT, k-mean value of 35, and SVM classifiers were used to achieve segmentation accuracy of 98.35% and 99.51% of sclera and iris respectively [40]. First, a fast iris segmentation scheme was applied to accurately map the iris before applying a low saturation to the sclera. The enhancement of the veins was achieved through 3 steps: CLAHE, Gabor filters, and Top-Hat transform. The desired features were matched up against a dictionary formulated from class features. UBIRISv1 database was used to check the execution of the method. However, false positives increased when the classifier operated on one-to-one while the accuracy was affected when running on one-to-many, this can be avoided by using a large dataset.

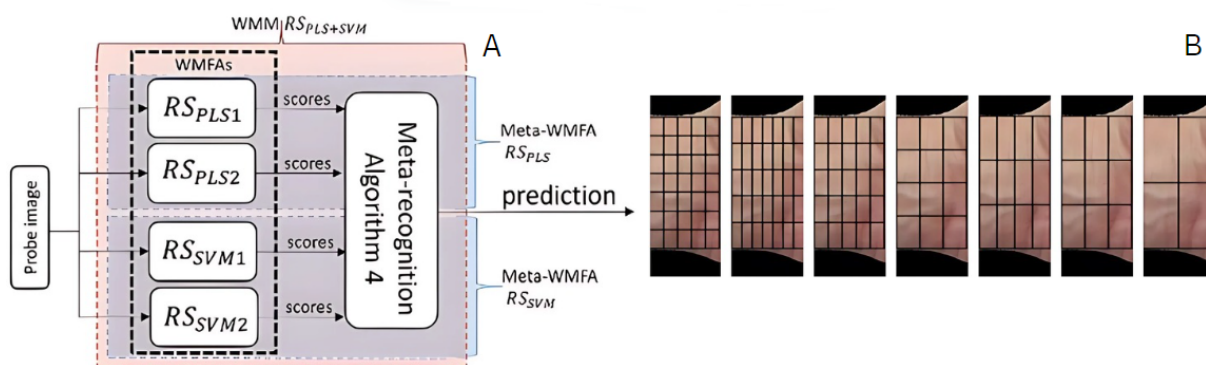


Figure 5a. The WMFA algorithm workflow. Figure 5b. The grid system ROI segmentation [7].

Hybrid vein systems

Researchers for a decade focused on the possibility of singling out a person from their vein patterns, but Kuzu et al. [42], and Zabala-Blanco et al. [43], and a few others recently exploited the possibility of gender differentiation from acquired vein patterns. Due to the biological difference between the male and female venous diameter, appearance under IR due to hemoglobin levels, etc., gave rise to the possibility of differentiation. Zabala-Blanco et al. and Kuzu et al. both outlined the soft biometric traits; skin colour, age, and gender [43]. Moreover, Kuzu et al. [42] used 3 databases VERA, UTFVP, and R3VEIN, which was proposed and detailed by the author in 2020 [44]. Two testing strategies; unbalanced and balanced scenario due to the unequal distribution of gender in the databases were employed [44]. This problem was also indicated by Zabala-Blanco et al. using the VERA and PolyU (Hong Kong Polytechnic University) datasets and proposed a two-scheme SoftVein-weighted Extreme learning machine (W-ELM) model to tackle the issue and by considering two factors for palm veins; age and gender. The method skipped feature extraction, introduced a golden ratio to the bulk class, but used a modified CNN approach for image processing. The results were compared against earlier approaches. Furthermore, the approach performed better in age and gender identification than other biometric authentication features [43]. The study achieved high accuracy for gender (98.91%) and age (97.05%), with the second scheme W-ELM showing the highest accuracy, 93.54% and 93.37% F1 scores were achieved for the imbalanced and balanced scenarios respectively [42, 43]. The latter results were achieved using a modified Densenet-161, which proved to be a better classifier than the others in the study (Resnext-101 and VGG19). These results are presented for the VERA database only, as a similar trend occurred between all 3 databases. The balanced scenario showed little variability in the accuracy of recognition in the male than female subjects in all three cases, whereas the unbalanced scenario showed higher performance in male due to the data proportion. Furthermore, gender-determining features were considered when drawing out a frame to increase proficiency and additionally proposed the possibility of gender-aware biometric systems [44].

Discussion

It is notable that the probability of obtaining a match is very high while using very robust, fast

algorithms. Machine learning algorithms are the core of these findings, showing flexibility and automation in extracting and enhancing the quality of vein pattern, which is required to capture and analyze images from crime scene. Despite their apparent abilities, they can be limited in correctly matching crime scene images to the reference, considering body parts can contort into various positions. The same issue was targeted by Pititheeraphab et al. [8] via implementing position variation, but they are very limited as were done in a controlled setting.

Additionally, the choice of a region of interest and points of matching; the less variables observed, the higher the chances of overlapping between entries will be seen, as stated by Hartung et al. [18]. Although the minutiae points can be generally individualistic, a threshold should be set to ascertain identification. One of the leading problems would be lack of similar ROI region to compare against the questioned (very small region); this could prove problematic as the data yield could have less individualistic characteristics. The same applied to the usage of geometric outline of the hand – the geometric shape of the hand can easily change with medical conditions and growth, which can prove detrimental when presenting as evidence. Interestingly, the use of pulsating vein is ingenious, but as of now, the application of such through frames or images cannot be implemented.

Extracted vein can both be used as an initial screening method during an investigation or as a supporting evidence, because the chances of acquiring the same pattern profile is low as seen from the reason shared above. Furthermore, method implementation has the possibility to become more automated and easier with emerging advancements in artificial intelligence technology.

We also found that the hybrid systems performed better than standalone systems, but their major setback would be damage caused to one of the features; it would be incapable of establishing an identity due to integration.

Conclusion

Biometric recognition, particularly vein pattern recognition, offers a compelling alternative to identity verification. With its high accuracy, resilience against forgery, and stability over an individual's lifetime, vein mapping technology holds great promise for enhancing security and forensic investigations. However, the permanence of vein patterns over a person's lifetime remains uncertain, and further research and

development are needed to maximize the potential of vein pattern recognition. Despite challenges related to image quality, advancements in infrared imaging, extensive database utilization, and novel algorithms have contributed to the rapid growth of this technology. The development of various vein recognition algorithms and techniques has demonstrated promising results, although some limitations such as the impact of medical and physical conditions on data retrieval, real-life integration, and the representativeness of the data sets should be considered (the need for large dataset). Further research and development are needed to address these limitations and maximize the potential of vein pattern recognition for admissibility in the courtroom. These technologies not only enhance the accuracy of vein pattern identification but also have significant applications in biometrics, medical diagnostics, and forensic analysis.

Prospects

Establishing a positive identity is the outcome of any analysis but the correct identification of said features cannot be emphasized enough. Most crimes captured on camera are acquired from CCTV footage which are notorious for grainy images. Therefore, algorithms need to be faster, and more automated to recognize and map out the regions as well as be able to combat extremely bad-quality images. These will need to be prolific and be able to put out predictions of discontinued vein tracts with high accuracy. As further research and development continue, these techniques have a high chance of playing a crucial role in advancing security, medical diagnostics, and wide acceptability in forensic investigations through vein pattern recognition.

List of abbreviations

ROI: region of interest, NIR: near-infrared, k-nearest neighbor: KNN, convolutional neural networks: CNN, RGB: red-green-blue, FIR: far infrared, SVM: support vector machine, CLAHE: contrast-limited adaptive histogram equalization.

Authors' contributions

All authors contributed to the drafting, designing, and structure of the manuscript. Concept development, final editing, reviewing, and revision was done by Neha Badhwar and Khadija Murtala Mukaddas.

Introduction was written by Bill Fallah Fomba, Dorsal hand vein and finger vein was written by Vhagyashree Neogi and Ameesha S. wrote discussion and conclusion. Other sections were written by Khadija Murtala Mukaddas. All authors have read and approved the final manuscript.

References

1. Wang Y, Zhang K, Shark LK. Personal identification based on multiple keypoint sets of dorsal hand vein images. *IET Bio*. 2014;3(4):234-45.
2. Dargan S, Kumar M. A comprehensive survey on the biometric recognition systems based on physiological and behavioral modalities. *Expert Syst Appl*. 2020 Apr 1;143:113114.
3. Li X, Li C, Rahaman MM, Sun H, Li X, Wu J, et al. A comprehensive review of computer-aided whole-slide image analysis: from datasets to feature extraction, segmentation, classification and detection approaches. *Artif Intell Rev*. 2022 Aug 1;55(6):4809-78.
4. Shaheed K, Liu H, Yang G, Qureshi I, Gou J, Yin Y. A systematic review of finger vein recognition techniques. *Information*. 2018 Aug 24;9(9):213.
5. Galeandro AI, Quistelli G, Scicchitano P, Gesualdo M, Zito A, Caputo P, et al. Doppler ultrasound venous mapping of the lower limbs. *Vasc Health Risk Manag*. 2012;8(1):59-64.
6. Abd Rahman AB, Juhim F, Chee FP, Bade A, Kadir F. Near infrared illumination optimization for vein detection: hardware and software approaches. *Appl Sci*. 2022;12(21):11173.
7. Matkowski WM, Chan FKS, Kong AWK. A study on wrist identification for forensic investigation. *Image Vis Comput*. 2019 Aug 1;88:96-112.
8. Pititheeraphab Y, Thongpance N, Aoyama H, Pintavirroj C. Vein pattern verification and identification based on local geometric invariants constructed from minutia points and augmented with barcoded local feature. *Appl Sci*. 2020 May 1;10(9):3192.
9. Aiken RS. Vein pattern analysis – a comparison of two vein imaging modalities (Doctoral dissertation). University of Dundee; 2014.
10. Kang W, Liu H, Luo W, Deng F. Study of a Full-view 3D finger vein verification technique. *IEEE Trans Inf Forensics Secur*. 2020;15:1175-89.
11. Shahzad A, Saad M, Walter N, Malik A, Meriaudeau F. A review on subcutaneous veins localization using imaging techniques. *Curr Med Imaging Rev*. 2014;10(2):125-33.
12. Wang L, Leedham G, Cho SY. Infrared imaging of hand vein pattern for biometric purposes. *IET Computer Vision*. 2007;1(3):113-122.

13. Tang C, Kong AWK, Craft N. Uncovering vein patterns from color skin images for forensic analysis. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Colorado Springs: IEEE; 2011. p. 665-72.
14. Sharma N, Hefeeda M. Hyperspectral reconstruction from RGB images for vein visualization. In: MMSys 2020 – Proceedings of the 2020 Multimedia Systems Conference. Association for Computing Machinery, Inc; 2020. p. 77-87.
15. Damak W, Trabelsi RB, Damak MA, Sellami D. Dynamic ROI extraction method for hand vein images. IET Computer Vision. 2018;12(5):586-95.
16. Zhang H, Tang C, Li X, Kong AWK. A study of similarity between genetically identical body vein patterns. In: IEEE Workshop on Computational Intelligence in Biometrics and Identity Management, CIBIM. Orlando, FL; 2015. p. 151-9.
17. Zhang H, Tang C, Kong AWK, Craft N. Matching vein patterns from color images for forensic investigation. In: 2012 IEEE 5th International Conference on Biometrics: Theory, Applications and Systems (BTAS). Arlington, VA: IEEE; 2012. p. 77-84.
18. Hartung B, Rauschnig D, Schwender H, Ritz-Timme S. A simple approach to use hand vein patterns as a tool for identification. Forensic Sci Int. 2020 Feb 1;307:110115.
19. Cimen ME, Boyraz OF, Yildiz MZ, Boz AF. A new dorsal hand vein authentication system based on fractal dimension box counting method. Optik (Stuttg). 2021 Jan 1;226:165438.
20. Vitek M, Rot P, Štruc V, Peer P. A comprehensive investigation into sclera biometrics: a novel dataset and performance study. Neural Comput Appl. 2020 Dec 1;32(24):17941-55.
21. Hussain W, Rasool N, Yaseen M. ADVIT: Using the potentials of deep representations incorporated with grid-based features of dorsum vein patterns for human identification. Forensic Sci Int. 2020 Aug 1;313:110345.
22. Chen X, Huang M, Fu Y. Simultaneous acquisition of near infrared image of hand vein and pulse for liveness dorsal hand vein identification. Infrared Phys Technol. 2021 Jun 1;115:103688.
23. Ma H, Hu N, Fang C. The biometric recognition system based on near-infrared finger vein image. Infrared Phys Technol. 2021 Aug 1;116:103734.
24. Anila S, Mary A, Chacko MO. Identifying pedophiles by visualizing vein patterns from color skin images. International Journal of Computer Science and Information Technologies. 2017;8(1):45-7.
25. Ou WF, Po LM, Zhou C, Rehman YAU, Xian PF, Zhang YJ. Fusion loss and inter-class data augmentation for deep finger vein feature learning. Expert Syst Appl. 2021 Jun 1;171:114584.
26. Shakil S, Arora D, Zaidi T. An optimal method for identification of finger vein using supervised learning. Meas: Sens. 2023 Feb 1;25:100583.
27. Mohd Asaari MS, Suandi SA, Rosdi BA. Fusion of band limited phase only correlation and width centroid contour distance for finger based biometrics. Expert Syst Appl. 2014;41(7):3367-82.
28. Kumar A, Zhou Y. Human identification using finger images. IEEE Trans Image Process. 2012 Apr;21(4):2228-44.
29. Yin Y, Liu L, Sun X. SDUMLA-HMT: a multimodal biometric database. Conference: Biometric Recognition – 6th Chinese Conference, CCBP 2011, Beijing, China, December 3-4, 2011. Proceedings. Lect Notes Comput Sci. 2011;260-8.
30. Yüksel A, Akarun L, Sankur B. Biometric identification through hand vein patterns. In: 2010 International Workshop on Emerging Techniques and Challenges for Hand-Based Biometrics (ETCHB). Istanbul, Turkey: IEEE; 2010. p. 1-6.
31. Tome P, Marcel S. On the vulnerability of palm vein recognition to spoofing attacks. In: 2015 International Conference on Biometrics (ICB). Phuket, Thailand: IEEE; 2015. p. 319-25.
32. Tome P, Raghavendra R, Busch C, Tirunagari S, Poh N, Shekar BH, et al. The 1st Competition on counter measures to finger vein spoofing attacks. In: Proceedings of 2015 International Conference on Biometrics (ICB). Phuket, Thailand : IEEE; 2015. p. 513–8.
33. Yang W, Yu X, Liao Q. Personal authentication using finger vein pattern and finger-dorsa texture fusion. In: MM'09 – Proceedings of the 17th ACM International Conference on Multimedia. Association for Computing Machinery; 2009. p. 905-8.
34. Staal J, Abramoff MD, Niemeijer M, Viergever MA, van Ginneken B. Ridge-based vessel segmentation in color images of the retina. IEEE Trans Med Imaging. 2004;23(4):501-9. Available from: <https://drive.grand-challenge.org/>
35. Kauba C, Prommegger B, Uhl A. Focussing the beam – A new laser illumination based data set providing insights to finger-vein recognition. In: 2018 IEEE 9th International Conference on Biometrics Theory, Applications and Systems (BTAS). Redondo Beach, CA: IEEE; 2018. p. 1-9.
36. Babalola FO, Bitirim Y, Toygar Ö. Palm vein recognition through fusion of texture-based and CNN-based methods. Signal Image Video P. 2021 Apr 1;15(3):459-66.
37. Kannala J, Rahtu E. BSIF: Binarized statistical image features. In: Proceedings – International Conference on Pattern Recognition (ICPR2012). Tsukuba, Japan: IEEE; 2012. p. 1363-6.
38. Alkassar SHM. Advancing the technology of sclera recognition (Doctoral dissertation). Newcastle upon Tyne: Newcastle University; 2018.
39. Uhl A, Busch C, Marcel S, Veldhuis R, editors. Handbook of vascular biometrics. Cham: Springer Nature; 2020. p. 599.

40. He SY, Fan C-P. SIFT features and SVM learning based sclera recognition method with efficient sclera segmentation for identity identification. In: 2019 IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS). Hsinchu, Taiwan: IEEE; 2019. p. 297-8.
41. A. Suganya and, M. Sivitha. A new biometric using sclera vein recognition for human identification. In: 2014 IEEE International Conference on Computational Intelligence and Computing Research. Coimbatore, India: IEEE; 2014. p. 1-4.
42. Kuzu RS, Maiorana E, Campisi P. Gender-specific characteristics for hand-vein biometric recognition: analysis and exploitation. *IEEE Access*. 2023 Jan 26;11:11700-11710.
43. Zabala-Blanco D, Hernández-García R, Barrientos RJ. SoftVein-WELM: a weighted extreme learning machine model for soft biometrics on palm vein images. *Electronics*. 2023 Sep 1;12(17):3608.
44. Kuzu RS, Piciuccio E, Maiorana E, Campisi P. On-the-fly finger-vein-based biometric recognition using deep neural networks. *IEEE Trans Inf Forensics Secur*. 2020;15:2641-54.

ORCID

Neha Badhwar  0000-0003-4375-8113

Corresponding author

Assistant Prof. Neha Badhwar
Lovely Professional University
Phagwara, Punjab, India
e-mail: neha.28873@lpu.co.in

MAPOWANIE ŻYŁ W BADANIACH KRYMINALISTYCZNYCH – PRZEGLĄD LITERATURY

Wprowadzenie

Dzięki postępom w biometrii w dziedzinie potwierdzania tożsamości osób, zdominowanej dotąd przez metody tradycyjne, takie jak klucze, karty czy hasła, pojawiła się obiecująca alternatywa. Biometria wykorzystuje potencjał zautomatyzowanego rozpoznawania na podstawie indywidualnych cech fizjologicznych i behawioralnych. Postępy dotyczą nie tylko większej wygody pomiaru, ale także zwiększenia bezpieczeństwa. W odróżnieniu od swoich tradycyjnych odpowiedników identyfikatory biometryczne są niewrażliwe na ryzyko związane z roztargnieniem, utratą i kradzieżą [1]. Oprócz uwierzytelniania są też często stosowane w dochodzeniach kryminalistycznych, co stanowi o ich doniosłym znaczeniu na światowej scenie zabezpieczeń [2].

Ogólnie mówiąc, systemy biometryczne mają dwa główne zastosowania: uwierzytelnianie i identyfikację. Celem uwierzytelniania jest przyjęcie bądź odrzucenie tożsamości danej osoby, co polega na porównaniu mierzonych cech biometrycznych z zapisanym wzorcem, tj. na rozwiązaniu problemu dopasowania jeden do jednego (Ryc. 1). Z kolei identyfikacja polega na wyszukaniu tożsamości osoby poprzez porównanie mierzonych cech biometrycznych ze wszystkimi wzorcami w bazie danych, tj. na rozwiązaniu problemu dopasowania jeden do wielu [1].

Na przestrzeni lat opracowano wiele technik biometrycznych wykorzystujących różne cechy: ślady linii papilarnych, ślady dłoni, żyły ręki, dłoni, palców i stóp, wzory tęczówki, analizę chodu, charakterystykę podniebienia i głosu, mimikę twarzy, wzory rytmu serca, podpis, mowę ciała, zarys twarzy i in. Techniki te można ogólnie podzielić na dwie grupy w zależności od mierzonych parametrów: zewnętrzne cechy biometryczne (np. ślady dłoni, tęczówka, ślady linii papilarnych czy twarz) oraz wewnętrzne cechy biometryczne (np. żyły ręki, dłoni i palców) [4].

Cechy zewnętrzne są zazwyczaj lepiej widoczne, ale też bardziej narażone na zmienność środowiskową. Natomiast spośród cech wewnętrznych układ żył wykazuje się wyjątkową siłą i trwałością. Rozpoznawanie układu żył do celów biometrycznych ma kilka zalet: dużą dokładność pomiaru, indywidualność, niewielkie różnice w odczycie pomiędzy osobami dokonującymi pomiaru (mała subiektywność), odporność na fałszerstwo oraz minimalną wrażliwość na warunki zewnętrzne i powierzchniowe, takie jak blizny, łój czy pot [5, 6]. Co więcej, podejście to rozwiązuje problem dowodów cyfrowych zawierających niewyraźne lub zakryte twarze w sprawach związanych

z pornografią dziecięcą i terroryzmem, w przypadku których zawodzą tradycyjne systemy rozpoznawania twarzy [7]. Zalety te zdecydowały o rosnącej w ostatnich latach popularności mapowania żył w kręgach naukowych i jego znaczeniu jako zaawansowanej technice służącej uzyskiwaniu dowodów biometrycznych i sądowych. Układ żył, w odróżnieniu od innych cech biometrycznych, wykazuje znaczną trwałość przez całe życie, zwłaszcza w rękach, palcach i nadgarstkach, nawet w przypadku osób, które próbowały go zamaskować lub zmienić [8]. Co więcej, nieinwazyjność tej metody jest nieoceniona w przypadkach znęcania się nad dzieckiem czy pornografii dziecięcej, w których rzadko udaje się uzyskać zgodę czy współpracę [9]. Szybki rozwój technologii mapowania żył ułatwiły niedawne badania nad jej zastosowaniem w kryminalistyce; uwidoczniły one potencjał tej techniki jako wiarygodnego sposobu identyfikacji osób [10]. Umiejscawianie żył stanowi jednak wyzwanie w przypadku osób o niektórych cechach fizjologicznych, takich jak ciemniejszy kolor skóry, głęboko położone żyły czy nieregularności skórne, np. blizny, tatuaże albo włosy – i to nawet z wykorzystaniem obrazowania w bliskiej podczerwieni (*near infrared radiation*, NIR). Co więcej, umiejscawianie żył okazuje się trudne u niektórych grup demograficznych, takich jak osoby starsze, otyłe lub odwodnione, niemowlęta czy osoby zażywające leki dożylnie [11].

Ogólne techniki identyfikacji stosowane w mapowaniu żył to: pozyskiwanie obrazu lub rekrutacja (Ryc. 2), wyodrębnianie obszaru, przetwarzanie wstępne, wyodrębnianie cech, porównanie i weryfikacja.

Obrazowanie w podczerwieni jest tu kluczową techniką, pozwalającą skutecznie wizualizować układ żył [8] i tworzyć obrazy, które można przetworzyć z kolorowych na skalę szarości, a następnie zastosować algorytmy do ekstrakcji cech.

Okazuje się, że bliska podczerwień znacznie skuteczniej rejestruje obraz żył od dalekiej (*far infrared radiation*, FIR). Obrazowanie w FIR polega na wykrywaniu ciepła wydzielanego przez ludzkie ciało [12]. Względnie wyższa temperatura żył w porównaniu do otaczających je tkanek powoduje, że układ żył na obrazach FIR jest wyraźny i kontrastujący z niepożądanymi cechami powierzchni skóry, widocznymi w świetle widzialnym. Wadą zdjęć wykonanych w FIR jest natomiast to, że ich jakość zależy od czynników zewnętrznych, co prowadzi do niestabilności [1].

W odróżnieniu od FIR, aktywne obrazowanie w NIR wymaga stosowania zewnętrznych źródeł światła. Technika ta wywodzi się z biomedycyny i wykorzystuje

różnice w absorpcji dyferencyjnej i odbiciu dezoksy- i oksyhemoglobiny – głównych składników krwi. Te właściwości optyczne sprawiają, że na zdjęciach NIR wyraźnie widać układ żył, jak pokazano na rycinie 3 [12].

Co więcej, obrazowanie w NIR pozwala rejestrować obrazy mniejszych żył znajdujących się bliżej powierzchni skóry, co poprawia dokładność identyfikacji osób. Ostatnie badania skupiały się na opracowaniu metody wiarygodnego rozpoznawania na podstawie obszer-nych baz danych zawierających obrazy żył wierzchu ręki i przedramienia przy użyciu rzadziej spotykanych cech żylnych widocznych na obrazach o wysokiej rozdziel-ności [1].

Są również prowadzone badania zmierzające do minimalizacji oświetlenia NIR, co pozwoliłoby uzyskać dobry kontrast dla każdego typu skóry, w tym także dla różnych cech charakterystycznych i zmienności osobniczej [11], oraz lepszą wizualizację na podstawie obrazów kolorowych [14], przy jednoczesnym mniejszym zapo-trzebowaniu na zasilanie i przestrzeń ze strony systemu oświetlenia.

Jest jednak kilka czynników, które mogą wpływać negatywnie na dokładność wykrywania obszarów zainte-resowania (ROI) w obrazach żył ręki, tym samym pogar-szając skuteczność systemów biometrycznych. Problemy te ograniczają też zastosowanie biometrii w dochodze-niach sądowych [15].

Układ żył w badaniach kryminalistycznych

W ciągu ostatnich dziesięciu lat mapowanie żył stało się przedmiotem zainteresowania kryminalistów, kie-dy otrzymywane tą metodą obrazy okazały się nowym, potencjalnym sposobem identyfikacji przestępców nie-ograniczającym się do rysów twarzy [7]. W przeprowa-dzonym w 2015 r. badaniu na temat genetycznej jedna-kowych układów żył wykorzystano dane dotyczące prze-dramienia i uda pobrane od 324 uczestników w dwóch sesjach [16]. Obrazy wykonano w NIR, żeby uniknąć błędów związanych z algorytmem wizualizacyjnym [13]. Genetycznie jednakowe zdjęcia otrzymano, przerzucając w poziomie obrazy lewej kończyny i nakładając je na ob-razy odpowiadającej jej prawej kończyny. Następnie taki wirtualny, bliźniaczy zestaw danych o przedramieniu po-dzielono na grupy z paskiem i bez paska (na lewym nad-garstku). Obrazy przetwarzano wstępnie filtrami CLA-HE i Gabor. Obszar zainteresowania zaznaczano ręcznie, po czym wprowadzano próg w celu usunięcia szumu. Obszar zainteresowania szkieletoowano i binaryzowano. Zastosowano trzyetapową procedurę dopasowywania żył, opisaną w pracy Zhanga i in. [17], a podobieństwa analizowano za pomocą zestawów punktów. Wygenero-wano wartości różnic pomiędzy prawdziwymi, fałszy-wymi i wirtualnymi bliźniakami dla kończyny dolnej i

górnjej. Średnie dla uda i przedramienia wirtualnego bliź-niaka wykazywały większe podobieństwo niż średnie fałszywego bliźniaka. Podział zdjęć lewego i prawego przedramienia na grupy z paskiem na nadgarstku i bez niego wpłynął tylko na wymiar obszaru zainteresowa-nia, tj. zestaw danych bez paska dawał lepsze wyniki niż zestaw z paskiem. Ponadto autorzy ustalili, że na podo-bieństwo nie wpływały czynniki takie jak BMI, liczba punktów odniesienia, wielkość żyły czy wielkość obsza-ru zainteresowania [16].

Opisana metoda jest złożona. Jej stosowanie, a tak-że wprowadzanie algorytmu, wymaga czasu i środków. Z drugiej strony metoda bez wątplenia jest pionierska w wyraźnej wizualizacji układu żył, a jej zastosowanie można rozszerzyć na większe zbiory danych.

Żyła grzbietowa ręki

Do żył makroskopowych uzyskanych z kolorowych zdjęć zastosowano prostą i ekonomiczną siatkę, niewy-magającą wieloetapowego przetwarzania wstępnego ani skomplikowanych modeli matematycznych. Ze wzglę-du na punkty krzyżowania i rozgałęziania się żył siat-kę tworzą trzy linie poziome i pionowe, dzielące rękę na cztery strefy (A, B, C, D), co daje 11 zmiennych na rękę. Pierwsze trzy linie umieszczono odpowiednio na wyrostku rylcowatym nadgarstka, pomiędzy 2 a 3 kością śródrezcza oraz na grzbietowej stronie 3 kości śródrezcza. Czwartą i szóstą linię umieszczono na 2 i 5 kości śródrezcza, a piątą linię – pomiędzy nimi. Do wygenerowania nakładających się prawdopodobieństw oraz predykcji na podstawie lewych i prawych rąk uczestników użyto pakietu SPSS/PASW (*Statistical Package for Social Scien-ces/Predictive Analytics Software*). Trafną identyfikację osoby uznawano za możliwą przy zastosowaniu pierw-szych pięciu zmiennych, tj. skrzyżowań żył na 1, 2, 4, 5 i 6 linii. Po zmniejszeniu liczby zmiennych zaobser-wowano nakładanie się wyników pomiędzy uczestnika-mi [18]. Symulację 1000–100 000 uczestników przepro-wadzono dziesięciokrotnie. Hartung i in. stwierdzili, że przypadkowe nakładanie się wyników uczestników jest mniej prawdopodobne w zakresie 1 : 1000.

Podobnie maszyna wektorów nośnych (*support vec-tor machine*, SVM) i K-najbliższy sąsiad (*K-nearest ne-ighbour*, KNN) zastosowane do obrazów grzbietowych dłoni z bazy Uniwersytetu Nauk Stosowanych w Sakaryi zostały opracowane za pomocą metody przyspieszonych solidnych cech (*speeded up robust features*, SURF) do standaryzacji danych, z zastosowaniem podobnej tech-niki do tej, którą posługiwali się Hartung i jego współ-pracownicy, ale w odniesieniu do zdjęć w NIR. Z tego względu do przetworzenia obrazów były potrzebne do-datkowe kroki [19]: zastosowano wiele siatek etapowo w celu obliczenia liczby kwadratów, które pokrywał

obszar żylny, i wprowadzenia wymiarów fraktalnych pod różnymi kątami. Ponieważ zaobserwowano też nakładanie się wyników uczestników nr 8 i 6, podobnie jak w badaniu Hartunga i in. [18], Cimen i in. [19] zaproponowali stosowanie operatorów morfologicznych w celu złagodzenia tego problemu. Walidację podejścia przeprowadzono, porównując wyniki z bazą danych Bosphorous. SVF osiągnęła niemal 100% skuteczności w połączeniu z liniową funkcją jądra (*linear kernel function*, LKF) i filtrem dolnoprzepustowym (*low pass filter*, LPF), podczas gdy KNN wahał się w granicach 85–88% i przyjmował 3 różne stałe K [19].

Pititheeraphab i in. przygotowali system identyfikacji oparty na geometrii dłoni i miejscowym układzie żył. System ten na podstawie punktów geometrycznych mapuje zewnętrzne krawędzie dłoni, tj. fałdy skóry pomiędzy palcami i czubki palców. Miejscowy układ żył zidentyfikowano metodą minucji, biorąc pod uwagę rozwidlenia żył i punkty zakończenia żył. Wygenerowano profile intensywności w celu zmapowania położenia pikseli żył oraz obliczono przebiegi żył w celu określenia szerokości [8]. Punkty minucji otrzymano po zredukowaniu wyekstrahowanych wyników. Ustalono położenie danego typu układu żył metodą dopasowywania wzorów [4, 8]. Przeprowadzono triangulację tych punktów od wzorcowych do badanych, a wszystkie zestawy trójkątów oceniano algorytmem (Ryc. 4b).

Orientację poszczególnych trójkątów standaryzowano i układano w kolejności rosnącej. Następnie wyszukiwano pasujące trójkąty. Innym sposobem porównywania była metoda afiniczna [8, 20], w której nie zachowywano długości i kątów oraz dopuszczano częstotliwość błędów na poziomie 5%. Zgodność sprawdzano na podstawie ściślejszego dopasowania pomiędzy dwoma zestawami (badanym i odniesienia) i metody długości przebiegu. Trójkąty dopasowano do wzorca po wyrównaniu, zmniejszając częstotliwość błędów do 0,122% w porównaniu do poziomu 7,52%, osiągniętego przy braku wyrównania (Ryc. 4c). Artykuł zawierał ponadto kody kreskowe odpowiadające wygenerowanemu obrazowi wzorca, które pozwalały na przeprowadzenie dopasowania.

Zautomatyzowane narzędzie do identyfikacji żył grzbietowych (*automated dorsal vein identification tool*, ADVIT), zaproponowane przez Hussaina i in. [21], wykorzystuje opisaną wyżej siatkę opracowaną przez Hartunga i in. Wybór ResNet-50 był podyktowany jej elastycznością. Porównanie na podstawie podobieństwa przeprowadzono na zasadzie entropii krzyżowej. Entropia krzyżowa, opisaną w pracy Hussaina i in., mierzy się różnicę pomiędzy dwoma rozkładami prawdopodobieństwa dotyczącymi danej zmiennej. Oceniono dokładność i częstość wyników fałszywie pozytywnych trzech zestawów danych. Zbiory danych z ResNet-50 okazały się skuteczniejsze (dokładność 0,896, wyniki fałszywie pozytywne 0,1) niż metoda siatki (dokładność 0,83,

wyniki fałszywie pozytywne 0,15), a połączenie obu metod (dokładność 0,95, wyniki fałszywie pozytywne 0,04) – skuteczniejsze od ResNet-50. Dodatkowo sprawdzono użyteczność metody w rzeczywistym scenariuszu, tzn. w przebiegu testowym nie uwzględniono zestawu danych treningowych. Otrzymano podobne wyniki dla 100% zestawów danych w fazie treningowej. Mimo że wyniki te były obiecujące, system miał pewne ograniczenia związane z potrzebą dobrej widoczności makroskopowej żył oraz możliwego wpływu stanu zdrowia i uwarunkowań fizycznych na ilość danych uzyskiwanych od danego uczestnika lub podejznanego. Wybrany zestaw danych nie był reprezentatywny, ponieważ wygenerowano go z udziałem tylko 30 uczestników [18].

Wykrywanie żył w czasie rzeczywistym na podstawie tętna znacznie zmniejsza ryzyko podszycia się pod inną osobę albo obejścia systemu. System skutecznie odróżnia osoby i ustala ich tożsamość na podstawie okresowych pulsacji wywołanych uderzeniami serca. Zastosowano metodę korekcji rotacji w celu zmniejszenia problemów związanych z nieprawidłową identyfikacją i odrzuceniem. Przeprowadzono porównanie z protezą palca, która nie wykazywała szczytów – prawidłowe wyniki przy użyciu SVM uzyskano w 99,33% przypadków. Ponadto las losowy, propagacja wsteczna i KNN wykazały skutecznie rozpoznawanie na poziomie odpowiednio 97,78%, 98,44% i 78,22% [22].

Żył palców

Innowacyjnym systemem rozpoznawania żył palców, odpornym na zniekształcenia i szumy, jest histogram piramidowy zorientowanego gradientu – kwantyzacja fazy lokalnej (*pyramid histogram of oriented gradient – local phase quantization*, PHOG-LPQ). Ponieważ kwantyzacja fazy lokalnej (LPQ) jest wrażliwa na niejednolite oświetlenie i obrazy o niskiej rozdzielczości, cechy wyodrębnione przez obie metody są rekombinowane na poziomie cech. Skuteczność oceniano za pomocą różnych warstw piramidy i rozmiarów okna, które dały nieco inne wyniki. Osiągnięto błędy zrównoważone (*equal error rates*, EER) na poziomie 1,92% oraz 1,00% odpowiednio dla FV-USM (*Finger Vein – Universiti Sains Malaysia*) i MNCBNU_6000. Testy wskazały zatem na rzetelność i dobrą dokładność rozpoznawania żył palców [23]. Anila i in. zwrócili uwagę na metodę wyodrębniania cech żylnych z kolorowych obrazów przy użyciu czerwono-zielono-niebieskiego mapowania w NIR (RGB-NIR), tj. algorytmu służącego do automatycznego dopasowywania, oraz algorytmu wizualizacji żył. Później wprowadzono procedurę dostosowawczą: za pomocą wejściowej wagi warstwy w sieci neuronowej (*neural network*, NN) polepszoano wyrazistość wyjściowego szkieletowanego układu żył. Z powodu jednak niewielkiej liczby

zestawów danych zestaw wykorzystany w badaniach zawierał znacznie ograniczoną ilość danych i wykazywał słabą dokładność [24].

Ou i in. [25] zaproponowali technikę międzyklasowego wzmocnienia danych, polegającą na zwiększaniu wielopostaciowości danego zestawu przez łączenie z tradycyjnymi technikami wewnątrzklasowymi. Oryginalność zestawu danych zachowano, przerzucając klatki w pionie, co pozwoliło też uzyskać zadowalającą różnicę pomiędzy dwoma zestawami danych. Autorzy opracowali również stratę cosinusową straty SoftMax + straty trypletu (strata fuzji), aby zwiększyć rozróżnialność podobieństwa cosinusowego międzyklasowego i wewnątrzklasowego. Analizę przeprowadzono przy użyciu systemu rozpoznawania żył palców w czasie rzeczywistym, który brał pod uwagę możliwe zmiany geometryczne, ale wiązał się z ryzykiem błędu nieprawidłowego odrzucenia w przypadkach skrajnej deformacji układu żył. Procedurę sprawdzono na podstawie baz danych FVUSM, HKPU (*Hong Kong Polytechnic University*), MMCBNU (*Multimodal Chonbuk National University*) oraz własnej bazy danych, zapewniającej, że zestaw danych testowych nie był częścią zestawu treningowego. Procedura ta okazała się znacznie skuteczniejsza niż pozostałe podejścia w odniesieniu do głębokich cech żylnych i prostsza do przeprowadzenia [25].

Shakil i in. [26] zaproponowali nowy system rozpoznawania żył palców wykorzystujący uczenie maszynowe i swobodnie dostępny zbiór danych z THU-FVFD2 (*Tsinghua University Finger Vein and Finger Dorsal Texture Database*), SDUMLA-HMT (*Shandong University Homologous Multimodal Traits*) oraz FV-USM. Wszystkie trzy bazy danych zawierały zestawy otrzymane od różnych uczestników z różnymi obszarami zainteresowania, co pokazuje tabela 1. Autorzy za pomocą wielowymiarowego filtru wyodrębnili obszar zainteresowania i wzmocnili miejscowe szczegóły układu żył, stwierdzając, że udana ekstrakcja segmentu upraszcza dalsze kroki analizy. Shakil i in. użyli analizy składowych głównych do wyodrębnienia cech fraktalnych, które były wymiarowo stałe, a klasyfikację przeprowadzili za pomocą SVM. Dodali również metodę dopasowywania większych pól. Shakil i in. zanalizowali częstość rozpoznawania i czas, jaki na poszczególnych krokach zajęło przetworzenie wyżej wymienionych trzech zestawów danych. Dokładność była bezpośrednio skorelowana ze wzrostem liczby obrazów treningowych. Podejście to było mniej skomplikowane od metody zaproponowanej przez Zhanga i in. [16], dało również wgląd w system uczenia się. Autorzy podkreślili, że przyszłe badania mogą doprowadzić do polepszenia częstości rozpoznawania [26].

Żyły dłoni, twardówki i nadgarstka

Matkowski i in. badali możliwości identyfikacyjne na podstawie cech nadgarstka, ponieważ ukrycie ich przez sprawców jest mało prawdopodobne. Na użyty przez autorów algorytm identyfikacyjny składało się pięć etapów: segmentacja nadgarstka, wyodrębnienie obszaru zainteresowania, wyodrębnienie cech, dopasowanie nadgarstków oraz metarozpoznawanie. Wprowadzono zautomatyzowany algorytm dopasowywania nadgarstków do celów kryminalistycznych. Superpiksele wygenerowano prostym liniowym klastrowaniem iteracyjnym (segmentowanie obszaru zainteresowania na pola), co pokazuje rycina 5b. Uwzględniono czynniki takie jak pozycja nadgarstków, aby przeciwdziałać wykrywaniu zmarszczek i granic nadgarstków. Według autorów była to pierwsza praca zajmująca się identyfikacją nadgarstków na podstawie kolorowych obrazów. Wyniki doświadczalne wskazały, że zaproponowany algorytm metadopasowywania nadgarstków (*wrist meta-matching*, WMM) był równie (Rycina 5a), a nawet bardziej skuteczny od innych zaawansowanych i nowoczesnych metod identyfikacji śladów i żył dłoni. Metoda Matkowskiego i in. sprawdziła się bardzo dobrze – pozwoliła zidentyfikować i dopasować nadgarstki do odpowiadających im obrazów z sondy [7].

Systemem rozpoznawania żył dłoni opartym na konwolucyjnej sieci neuronowej (*convolutional neural network*, CNN) z narzędziem do ekstrakcji cech tekstury analizowano binaryzowane statystyczne cechy obrazu (*binarized statistical image features*, BSIF), pobrane z pięciu podregionów. Na ich podstawie wyznaczono obszar zainteresowania, a następnie połączono metodą fuzji na poziomie wyniku [36]. Na drugą połowę systemu składała się CNN, opracowana zgodnie z metodą Kannali i in. [37]. Obrazy wzmocniano metodą wyrównania histogramu, a w celu podjęcia pierwszej decyzji wyniki odpowiadające poszczególnym podregionom zostały powiązane za pomocą klasyfikatora KNN. Druga decyzja została podjęta za pomocą CNN i zastosowana do całej dłoni. Ekstrakcja cech tekstury skwantyfikowała kody binarne poszczególnych obrazów – stanowiły one tzw. miejscowy deskryptor obrazu. Dodatkowo wartości kodu pikseli w histogramie pozwoliły ustalić właściwości tekstury w podregionach [37]. Poziomy decyzyjne połączono w celu podjęcia decyzji końcowej na podstawie ważonych zasad OR do wartości granicznej 0,9 [36]. Metodę sprawdzono w odniesieniu do kilku baz danych, osiągając dokładność na poziomie 99,83%, 100%, 99%, 100% i 100% odpowiednio dla bazy CASIA, FYO, PUT, Tongji i VERA. Co więcej, metoda ta osiągnęła dokładność na poziomie 100% podczas testów porównawczych z innymi proponowanymi metodami i znanymi modelami architektonicznymi.

W biometrii ocznej wykorzystuje się układ żył oka [20]. Szczególnym zainteresowaniem wśród autorów cieszy się mapowanie twardówki [20, 38, 39, 40]. Wewnątrz twardówki, pomiędzy jej warstwami, znajdują się żyły ukierunkowane w nieuporządkowany sposób [38, 41]. Stwierdzono, że formacje żyłne w kształcie litery Y są trwałe i odporne na odkształcenia spowodowane ruchem gałek ocznych. Zastosowano filtry dolnoprzepustowe w celu poprawienia wydajności i pozyskiwania układów [41]. Vitek i in. podzielili swoje badania na siedem różnych etapów. Każdy z nich dotyczył innej funkcji proponowanej metody. Zastosowano pięć modeli segmentacji, przy czym RefineNet-50, U-NET, SegNet i RefineNet-101 wybrano ze względu na ich rzetelność [20]. Zaobserwowano, że wiek i kierunek ruchu były czynnikami wpływającymi na skuteczność rozpoznawania osiąganą pięcioma różnymi modelami rozpoznawania: skalo-niezmienniczym przekształceniem cech (*scale-invariant feature transform*, SIFT), CNN, zorientowanym FAST i obróconym BRIEF (*oriented FAST and rotated BRIEF*, ORB), przyspieszonymi rzetelnymi cechami (*speeded up robust features*, SURF) oraz gęstym SIFT (*dense-SIFT*, dSIFT), przy czym CNN utrzymywało najlepszą dokładność. Za pomocą klasyfikatorów SIFT, k-średniej 35 i SVM osiągnięto dokładność segmentacji na poziomie 98,35% i 99,51% odpowiednio twardówki i tęczówki [40]. Najpierw zmapowano dokładnie tęczówkę za pomocą szybkiej procedury segmentacji, po czym lekko nasycono obraz twardówki. Żyły wzmocniono w trzech etapach: CLAHE, filtry GABOR i transformacja Top-Hat. Cechy docelowe porównano ze słownikiem sporządzonym na podstawie cech klasowych. Do sprawdzenia działania metody użyto bazy danych UBIRISv1. Liczba wyników fałszywie pozytywnych wzrastała, gdy klasyfikator działał w trybie jeden-do-jednego, natomiast na dokładność wpływał tryb jeden-do-wielu. Problemu tego można uniknąć, stosując duży zestaw danych.

Hybrydowe systemy analizy żył

Badacze już od dziesięciu lat skupiają się na możliwościach identyfikacji osób na podstawie układu żył. Kuzu i in. [42], Zabala-Blanco i in. [43] oraz inni autorzy sprawdzali natomiast użyteczność układu żył do rozróżniania płci. Jest to możliwe dzięki biologicznym różnicom w średnicy żył mężczyzn i kobiet, ich wyglądzie w podczerwieni zależnym od poziomu hemoglobiny i innym parametrom. Zabala-Blanco i in. oraz Kuzu i in. opisali miękkie cechy biometryczne, tj. kolor skóry, wiek i płeć [43]. Kuzu i in. [42] wykorzystali trzy bazy danych – VERA, UTFVP i R3VEIN, co zaproponowano i omówiono szczegółowo w pracy z 2020 r. [44]. Z powodu nierównych proporcji płci w bazach danych zastosowano dwie strategie testowe: zrównoważoną

i niezrównoważoną [44]. Problem ten zasygnalizowali również Zabala-Blanco i in., którzy na podstawie zbiorów danych VERA i PolyU (*Hong Kong Polytechnic University*) zaproponowali dwuschematowy model *SoftVein-weighted extreme learning machine* (W-ELM) mający na celu zaradzenie temu problemowi. Brali przy tym pod uwagę dwa czynniki dla żył dłoni: wiek i płeć. Zaproponowana metoda pomija etap wyodrębniania cech i wprowadza złoty podział do klasy masowej, ale obrazy przetwarza za pomocą zmodyfikowanego podejścia CNN. Otrzymane wyniki porównano z tymi z wcześniejszych podejść. Okazało się, że metoda ta skuteczniej identyfikowała wiek i płeć niż inne biometryczne techniki uwiaryzelniania [43]. Uzyskano dobrą dokładność dla płci (98,91%) i wieku (97,05%) – najlepszą za pomocą drugiego schematu W-ELM; wyniki F1 na poziomie 93,54% i 93,37% uzyskano odpowiednio dla strategii niezrównoważonej i zrównoważonej [42, 43]. Te ostatnie wyniki osiągnięto przy użyciu zmodyfikowanego modelu Densenet-161, który okazał się lepszym klasyfikatorem od pozostałych sprawdzanych w badaniu (Resnext-101 i VGG19). Przedstawiono wyniki odpowiadające wyłącznie bazie VERA, ponieważ zbliżone tendencje zaobserwowano dla wszystkich trzech baz danych. Strategia zrównoważona wykazała się niewielką zmiennością w dokładności rozpoznawania pomiędzy mężczyznami a kobietami w przypadku wszystkich trzech baz danych, natomiast strategia niezrównoważona sprawdziła się lepiej wśród mężczyzn ze względu na proporcję danych. Podczas tworzenia klatek brano również pod uwagę cechy determinujące płeć, aby zwiększyć wydajność. Dodatkowo zasugerowano możliwość opracowania systemów biometrycznych rozróżniających płeć [44].

Dyskusja

Stosując rzetelne, szybkie algorytmy, można osiągnąć dopasowanie z potencjalnie bardzo dużym prawdopodobieństwem. Podstawą postępów w tej dziedzinie są algorytmy uczenia maszynowego, które pozwalają w automatyczny i elastyczny sposób wyodrębnić układ żył i poprawić jakość jego obrazu, co jest krokiem niezbędnym do pozyskania i analizy obrazów z miejsca przestępstwa. Pomimo jednak swojego potencjału skuteczność, z jaką algorytmy takie dopasowują obrazy z miejsca przestępstwa do wzorca, może się obniżać ze względu na zmiany ułożenia ciała. Problemem tym zajęli się Pititheeraphab i in. [8], wprowadzając zróżnicowanie w pozycjach, ale ze względu na kontrolowane warunki zakres ich badań był bardzo ograniczony.

Liczy się także wybór obszaru zainteresowania i punktów dopasowania: Hartung i in. [18] dochodzą do wniosku, że im mniej obserwowanych zmiennych, tym większe prawdopodobieństwo nakładania się próbek.

Mimo że punkty minucji są z reguły indywidualne, powinno się wprowadzić próg, według którego stwierdzałoby się identyfikację. Jednym z głównych problemów jest brak podobnego obszaru zainteresowania, z którym można by porównać (bardzo mały) region badany, co może prowadzić do obniżania się indywidualności obserwowanych cech. To samo dotyczy analiz wykorzystujących zarys geometryczny ręki, ponieważ łatwo może on się zmieniać na skutek chorób i w trakcie rośnięcia, utrudniając stosowanie takich danych jako dowodu. Co ciekawe, o ile analiza pulsujących żył jest pomysłem błyskotliwym, obecnie jej zastosowanie na podstawie obrazów czy klitek jest niemożliwe.

Wyodrębnione żyły mogą posłużyć za dowód pomocniczy bądź do wstępnego przesiewu w śledztwie, ponieważ prawdopodobieństwo uzyskania identycznego układu żył jest bardzo niewielkie z powodów wyjaśnionych wcześniej w pracy. Wdrażanie metod może stać się jednak łatwiejsze i przebiegać w sposób bardziej zautomatyzowany dzięki ciągłym postępom w technologii sztucznej inteligencji.

Autorzy niniejszej pracy stwierdzili również, że systemy hybrydowe były skuteczniejsze niż systemy niezależne, ale ich główną wadą może być pogorszenie jednej z funkcji – integracja uniemożliwiłaby ustalenie tożsamości.

Wnioski

Rozpoznawanie biometryczne, w szczególności rozpoznawanie układu żył, stanowi obiecujący, alternatywny sposób weryfikacji tożsamości. Technologia mapowania żył dzięki dobrej dokładności, odporności na fałszerstwa i niezmienności przez całe życie danej osoby daje wielką możliwość poprawy bezpieczeństwa i zapewnienia wsparcia dla dochodzeń kryminalistycznych. Nie jest jednak pewne, czy układ żył pozostaje taki sam przez całe życie człowieka, a żeby w pełni wykorzystać tę technikę, potrzebne są dalsze badania i jej rozwój. Z drugiej strony pomimo problemów związanych z jakością obrazu rozwój obrazowania w podczerwieni, szerokie zastosowanie baz danych oraz innowacyjne algorytmy przyczyniły się do szybkiego wzrostu tej technologii. Rozwój różnych algorytmów i technik rozpoznawania żył przyniósł obiecujące rezultaty, choć wciąż należy mieć świadomość pewnych ograniczeń, takich jak wpływ stanu zdrowia i warunków fizycznych na pobór danych, integracja w czasie rzeczywistym czy reprezentatywność danych (zapotrzebowania na duże zbiory danych). Przyszłe badania i rozwój powinny skupić się na eliminacji tych ograniczeń i maksymalizacji możliwości, jakie daje ta technologia, tak aby dowody uzyskane dzięki jej stosowaniu były dopuszczalne w sądzie. Omówione tu technologie nie tylko poprawiają dokładność identyfikacji

wzoru żył, ale także mają istotne zastosowania w biometrii, diagnostyce medycznej i analizie kryminalistycznej.

Dalsze perspektywy

Ustalenie pozytywnej tożsamości jest wynikiem każdej analizy, ale nie da się przecenić znaczenia prawidłowej identyfikacji wspomnianych wyżej cech. Większość przestępstw uchwyconych na nagraniach wideo pochodzi z kamer monitoringu, które najczęściej dostarczają ziarnistego obrazu. Dlatego algorytmy powinny być szybsze i bardziej zautomatyzowane, aby dać możliwość rozpoznania i zmapowania obszarów zainteresowania, a także by przeciwdziałać uzyskiwaniu obrazów o bardzo złej jakości. Oczekuje się, że będą one wydajne i zdolne przewidywać nieciągłe wzory żył z dużą dokładnością. W miarę dalszych badań i rozwoju rozpoznawanie wzorów żył ma duże szanse na odegranie kluczowej roli w zwiększaniu bezpieczeństwa, diagnostyce medycznej i w dochodzeniach kryminalistycznych.

Wykaz skrótów

ROI: obszar zainteresowania (*region of interest*), NIR: bliska podczerwień (*near-infrared*), KNN: k-najbliższy sąsiad (*k-nearest neighbour*), CNN: konwolucyjna sieć neuronowa (*convolutional neural network*), RGB: czerwony-zielony-niebieski (*red-green-blue*), FIR: daleka podczerwień (*far infrared*), SVM: maszyna wektorów nośnych (*support vector machine*), CLAHE: adaptacyjna korekcja histogramu z ograniczeniem kontrastu (*contrast-limited adaptive histogram equalisation*).

Udział autorów

Wszyscy autorzy mieli wkład w opracowanie, projektowanie i strukturę manuskryptu. Neha Badhwar i Khadija Murtala Mukaddas – opracowanie konceptu, redakcja końcowa i korekta. Bill Fallah Fomba – wstęp. Vhagyashree Neogi – rozdział o żyłach ręki i palców. Ameesha S. – dyskusja i wnioski. Khadija Murtala Mukaddas – pozostałe rozdziały. Wszyscy autorzy przeczytali i zaakceptowali ostateczną wersję manuskryptu.