

MICHAŁ BUKOWSKI¹
ORCID: 0000-0002-7336-453X

ALGORYTMY ROZPOZNAWANIA TWARZY — PRZEGLĄD

Wprowadzenie

Klasyfikacja, inaczej system typologii lub typologia antropologiczna, mająca na celu opisanie zróżnicowania systematycznego wewnątrz gatunku *homo sapiens*, istnieje od wielu lat. Już w 1940 r. William Sheldon opracował somatotypy, czyli typy budowy ciała człowieka. Zaproponował on system klasyfikacji, w którym wszystkie możliwe typy ciała zostały scharakteryzowane na podstawie stopnia, w jakim do siebie pasowały i zakwalifikował je do tych trzech somatotypów². Typ ektomorficzny, mezomorficzny i endomorficzny. Inne taksonomie zostały opracowane dla kształtu ciała³, rąk⁴,

¹ Mł. insp. Michał Bukowski — od 1997 r. funkcjonariusz Policji, od 2020 r. naczelnik Wydziału Techniki Operacyjnej Komendy Wojewódzkiej Policji w Gdańsku, wcześniej naczelnik Wydziału Wsparcia Operacyjnego Biura Spraw Wewnętrznych Policji oraz zastępca naczelnika Wydziału Techniki Specjalnej i Realizacji, później Wydziału Techniki Operacyjnej Biura Kryminalnego Komendy Głównej Policji. Absolwent Wydziału Elektroniki Wojskowej Akademii Technicznej, Wydziału Matematyczno-Przyrodniczego Uniwersytetu Kardynała Stefana Wyszyńskiego w Warszawie. Wykładowca w Instytucie Informatyki Wydziału Matematyczno-Przyrodniczego Uniwersytetu Kardynała Stefana Wyszyńskiego w Warszawie.

Kontakt z autorem za pośrednictwem redakcji.

² W. Sheldon, *Atlas of Men: A Guide for Somatotyping the Adult Image of All Ages*, New York 1970.

³ S. Alemany i in., *Anthropometric survey of the Spanish female population aimed at the apparel industry*, <https://www.3dbodyscanning.org/cap/papers/2010/10307_11alemany.pdf>, 21 stycznia 2021 r.; G. Vinué, I. Epifanio, S. Alemany, *Archetypoids: A new approach to define representative archetypal data*, "Computational Statistics and Data Analysis" 2015, Vol. 87, Iss. C.

⁴ S.C. Jee, M.H. Yun, *An anthropometric survey of Korean hand and hand shape types*, "International Journal of Industrial Ergonomics" 2016, Vol. 53.

stóp⁵ lub głowy⁶. Taksonomie pozwalają używać wspólnej terminologii do definiowania konfiguracji części ciała. Zapewniają jednocześnie ustandaryzowany sposób ich opisu. Szeroko stosuje się je w wielu dziedzinach naukowych: humanistycznych (archeologia), inżynieryjno-technicznych (automatyka, informatyka techniczna, inżynieria biomedyczna⁷, we wszystkich dyscyplinach dziedziny nauk medycznych i nauk o zdrowiu⁸ oraz całej dziedzinie nauk ścisłych i przyrodniczych. Ogólnie rzecz biorąc, tego typu systemy typologii są przeznaczone do jakościowej kategoryzacji, opierając się na globalnym wyglądzie części ciała, chociaż w niektórych przypadkach opracowano analizę ilościową wybranych cech w celu uzyskania klasyfikacji.

Ludzie szczególnie rozwinęli swoją zdolność percepcyjną do przetwarzania twarzy i wydobywania informacji z jej rysów⁹. Ludzki mózg ma wyspecjalizowaną „sieć neuronową”, która służy do przetwarzania informacji pochodzących z obrazów twarzy innych ludzi¹⁰. Pozwala ona człowiekowi identyfikować innych ludzi, ich płeć, wiek i rasę, a nawet oceniać emocje. Wykorzystując zdolność behawioralną człowieka, co do postrzegania twarzy i jej cech, dokonuje się atrybucji takich jak osobowość, inteligencja lub wiarygodność danej osoby na podstawie wyglądu jej twarzy¹¹. Od stuleci artyści, badacze i naukowcy próbowali opracować procedury mierzenia i jednocześnie klasyfikowania ludzkich twarzy. Antropometryczna analiza twarzy jest wykorzystywana w różnych dziedzinach nauki, sztuki oraz informatyki. Wykorzystuje się ją w trakcie zabiegów

⁵ N.S. Kim, W.H. Do, *Classification of Elderly Women's Foot Type*, "Journal of the Korean Society of Clothing and Textiles" 2014, Vol. 38.

⁶ P. Sarakon, T. Charoenpong, S. Charoensiriwath, *Face shape classification from 3D human data by using SVM*, <https://www.researchgate.net/publication/282382114_Face_shape_classification_from_3D_human_data_by_using_SVM>, 22 stycznia 2021 r.

⁷ T.A. Preston, M. Singh, *Redintegrated Somatotyping*, "Ergonomics" 1972, Vol. 15; Y.-L. Lin, K.-L. Lee, *Investigation of anthropometry basis grouping technique for subject classification*, "Ergonomics" 1999, Vol. 42.

⁸ S. Ritz-Timme i in., *A new atlas for the evaluation of facial features: Advantages, limits, and applicability*, "International Journal of Legal Medicine" 2011, Vol. 125; M. Massidda i in., *Somatotype of elite Italian gymnasts*, "Coll Antropol" 2013, Vol. 37; G.G. Malousaris i in., *Somatotype, size and body composition of competitive female volleyball players*, "Journal of Science and Medicine in Sport" 2008, Vol. 11; M. Koleva, A. Nacheva, M. Boev, *Somatotype and disease prevalence in adults*, "Reviews on Environmental Health" 2002, Vol. 17, Iss. 1.

⁹ A.R. Damasio, *Prosopagnosia*, "Trends Neurosciences" 1985, Vol. 8; V. Bruce, A. Young, *Understanding face recognition*, "British Journal of Psychology" 1986, Vol. 77, No. 3.

¹⁰ N. Kanwisher, J. McDermott, M.M. Chun, *The Fusiform Face Area: A module in human extrastriate cortex specialized for the perception of faces*, "Journal of Neuroscience" 1997, Vol. 17, Iss. 11.

¹¹ V. Bruce, A. Young, *Face perception*, New York 2012.

chirurgicznych, działań związanych z kryminalistyką, tworzeniu sztuki, rozpoznawaniu twarzy¹², emocji¹³ oraz oceny cech twarzy człowieka¹⁴.

W ostatnich latach nowe technologie informatyczne otworzyły drogę do automatycznej oceny cech twarzy oraz gestów mimicznych. Opracowane metody obliczeniowe, dzięki którym dokonuje się analizy informacji o twarzy, są coraz dokładniej dostosowane do jej klasyfikacji na podstawie kryteriów antropometrycznych lub emocjonalnych¹⁵.

Mówiąc o rysach twarzy, wykorzystano taksonomie w ergonomii, antropologii sądowej, zapobieganiu przestępczości, interakcji człowiek — maszyna lub działaniach *online*. E-commerce, e-learning, gry, randki czy sieci społecznościowe to dziedziny codziennego życia, w których są wykorzystywane różne klasyfikacje cech twarzy. W takich działaniach powszechne jest używanie cyfrowych reprezentacji ludzi, awatarów (wcieleni), które symbolizują naszą obecność lub działają jako wirtualny rozmówca¹⁶. Kilka taksonomii rysów twarzy można odnaleźć w literaturze. Na przykład atlas Petera Vanezisa¹⁷ klasyfikuje 23 cechy twarzy, formularz identyfikacji ofiary katastrof (*Disaster Victim Identification — DVI*) Interpolu 6, natomiast baza danych DVM (*Data Volume Management*)¹⁸ — 45 cech twarzy. Abraham Tamir podzielił różne kształty ludzkiego nosa na 14 grup¹⁹. Podziału dokonał na podstawie 1793 zdjęć nosa. Podobne podejście zastosowano do klasyfikacji ludzkich podbródków²⁰. W tych pracach przeanalizowano i sklasyfikowano duży zbiór fotografii na podstawie podobieństwa cech podbródków.

¹² S.G. Kong i in., *Recent advances in visual and infrared face recognition — A review*, "Computer Vision and Image Understanding" 2005, Vol. 97.

¹³ G. Tavares, A. Mourão, J. Magalhães, *Crowdsourcing facial expressions for affective-interaction*, "Computer Vision and Image Understanding" 2016, Vol. 147.

¹⁴ G. Buckingham i in., *Visual adaptation to masculine and feminine faces influences generalized preferences and perceptions of trustworthiness*, "Evolution and Human Behavior" 2006, Vol. 27, Iss. 5; M. Boberg, P. Piippo, E. Ollila, *Designing Avatars* [w:] *Proceedings of the 3rd International Conference on Digital Interactive Media in Entertainment and Arts, 10–12 September 2008, Athens Greece 2008*; M.M. Rojas i in., *Automatic prediction of facial trait judgments: Appearance vs. structural models*, "PLoS One" 2011, Vol. 6, Iss. 8; A. Laurentini, A. Bottino, *Computer analysis of face beauty: A survey*, "Computer Vision and Image Understanding", 2014, Vol. 125.

¹⁵ S.Z. Li, A.K. Jain, *Handbook of Face Recognition*, New York 2005.

¹⁶ G. Vinué, I. Epifanio, S. Alemany, *Archetypoids...*, wyd. cyt.

¹⁷ P. Vanezis i in., *Morphological classification of facial features in adult Caucasian males based on an assessment of photographs of 50 subjects*, "The Journal of Forensic Sciences" 1996, Vol. 41.

¹⁸ S. Asmann i in. *Anthropological atlas of male facial features*, Frankfurt 2007; S. Ohlogge i in., *Anthropological atlas of female facial features*, Frankfurt 2009.

¹⁹ A. Tamir, *Numerical Survey of the Different Shapes of the Human Nose*, "Journal of Craniofacial Surgery" 2011, Vol. 22, Iss. 3.

²⁰ A. Tamir, *Numerical Survey of the Different Shapes of Human Chin*, "Journal of Craniofacial Surgery" 2013, Vol. 24, Iss. 5.

Zautomatyzowane rozpoznawanie twarzy człowieka jest bardzo złożonym problemem komputerowym o dużym znaczeniu praktycznym. Opiera się na licznych aplikacjach napisanych specjalnie w tym celu. Aplikacje uwzględniają w sposób szczególny zautomatyzowany bezpieczny dostęp, automatyczny nadzór, analizę sądową, szybkie pobieranie informacji z baz danych, np. w departamentach policji, automatyczną identyfikację pacjentów w szpitalach, sprawdzanie oszustw lub tożsamości oraz interakcje człowiek — komputer.

W ostatnich latach skierowano znaczną uwagę badawczą na opracowanie niezawodnych systemów automatycznego rozpoznawania powierzchni, które wykorzystują dwuwymiarowe obrazy²¹. Trójwymiarowa technologia rozpoznawania twarzy pojawia się w chwili obecnej ze względu na dostępność ulepszonych urządzeń do trójwymiarowego obrazowania oraz nowoczesnych szybkich algorytmów przetwarzania. Trójwymiarowe obrazy twarzy pozyskuje się za pomocą urządzeń do trójwymiarowej akwizycji, zbliżonych działaniem do systemu percepcji wzrokowej człowieka. W przypadku automatycznego rozpoznawania twarzy oraz dopasowywania obrazu do wzorca, trójwymiarowe obrazy mają pewne zalety w stosunku do obrazów dwuwymiarowych. Orientację twarzy możemy skorygować za pomocą obrotu bryły sztywnej w przestrzeni 3D. Obrazy 3D dostarczają również informacji o strukturze twarzy, przykładowo krzywiznie powierzchni czy odległościach geodezyjnych. Takich informacji nie uzyskamy z pojedynczego obrazu 2D. Algorytm rozpoznawania oparty na 3D reprezentacji twarzy okazał się odporny, podczas akwizycji obrazu, na zmiany warunków oświetlenia²².

Istniejące algorytmy trójwymiarowego rozpoznawania twarzy można podzielić na dwie duże klasy: algorytmy wykorzystujące techniki holistyczne oraz oparte na cechach lokalnych²³. Techniki rozpoznawania twarzy wykorzystujące algorytmy holistyczne korzystają z informacji z całej twarzy lub z dużych jej regionów. Możliwe jest podejście, w którym fragmenty powierzchni twarzy są uszeregowane i dopiero wtedy są porównywane. Druga klasa algorytmów wykorzystuje właściwości strukturalne lokalnych cech fizycznych.

Wiele badań wykazało ogromny potencjał algorytmów rozpoznawania twarzy wykorzystujących lokalne cechy twarzy. W teście rozpoznawania twarzy (*Face Recognition Vendor Test*; FRVT) przeprowadzonym w 2002 r.²⁴, analizowano dwa algorytmy rozpoznawania twarzy oparte na lokalnych cechach fizycznych twarzy. Pierwszy oparty na lokalnej analizie jej cech²⁵ i drugi oparty na elastycznym

²¹ W. Zhao i in., *Face recognition: a literature survey*, "ACM Computing Surveys" 2003, Vol. 35, Iss. 4.

²² E.P. Kukula i in., *Effects of illumination changes on the performance of geometric facevision/spl reg/3d frs*. [w:] *38th Annual 2004 International Carnahan Conference on Security Technology, Albuquerque*, 11–14 October 2004 NM, USA 2004.

²³ S. Gupta, M.K. Markey, A.C. Bovik, *Advances and challenges in 3D and 2D+3D human face recognition* [w:] E.A. Zoeller (eds), *Pattern recognition research horizons*, New York 2007.

²⁴ P.J. Phillips i in., *Face recognition vendor test 2002 evaluation report*, Gaithersburg 2003.

²⁵ P.S. Penev, J.J. Atick, *Local feature analysis: a general statistical theory for ob-*

dopasowaniu pęku grafów twarzy (*Elastic Bunch Graph Matching*; dalej jako: EBG_M)²⁶. W EBG_M twarz reprezentowana jest jako „elastyczny graf”, składający się z falkowych współczynników transformaty Gabora w określonych punktach odniesienia fragmentach twarzy i euklidesowych odstępów między tymi punktami. Michael Hüsken i inni²⁷ w 2005 r. opracowali algorytm rozpoznawania twarzy 2D + 3D zwany „hierarchicznym dopasowaniem grafów”. Łączy on wyniki dwóch algorytmów 2D EBG_M i 3D EBG_M. Ich algorytm był również jednym z najlepiej ocenianych w ramach *Face Recognition Grand Challenge* (pol. wielkie wyzwanie w rozpoznawaniu twarzy; FRGC) zorganizowanym właśnie w 2005 r.²⁸ w celu oceny działania nowoczesnych algorytmów rozpoznawania twarzy 3D z uwzględnieniem kryterium minimalizacji czasu działania.

Algorytmy rozpoznawania twarzy na obrazie 2D

Rozpoznanie twarzy od dawna przyciągało uwagę wielu naukowców. Każdy z nich zaproponował inną technikę rozpoznania twarzy na obrazie 2D. Techniki te można podzielić na trzy podstawowe kategorie. Pierwsza kategoria to podejście globalne (holistyczne). Wykorzystano w niej całą twarz (jej powierzchnię) jako dane wejściowe dla proponowanego systemu rozpoznawania. Dane te następnie rzutowane są na podprzestrzeń o małym wymiarze.

Druga kategoria obejmuje metody lokalne. Nie uwzględnia całej twarzy, ale tylko niektóre charakterystyczne jej cechy lub obszary, klasyfikowane następnie zgodnie z zdefiniowanymi wcześniej statystykami.

Podejście hybrydowe (hybryda dwóch wyżej wymienionych metod) i metody oparte na modelach statystycznych stanowią trzecią kategorię. Obejmuje ona podejścia hybrydowe, które wykorzystują jednocześnie cechy globalne i lokalne. Kumuluje w sobie pozytywne cechy dwóch powyższych metod. Wykorzystuje także podejście oparte na modelach statystycznych. Modele te formalizują zależności między zmiennymi losowymi za pomocą równań matematycznych. Równania te opisują, w jaki sposób jedna lub więcej zmiennych losowych jest związana z jedną lub większą ich liczbą. Model jest uważany za statystyczny, gdy zmienne nie są deterministyczne, ale stochastycznie powiązane.

Globalne liniowe techniki rozpoznawania twarzy

Liniowe techniki rozpoznawania twarzy wykorzystują liniowe rzutowanie danych wejściowych interesującego obrazu z przestrzeni o dużej wymiarowości do przestrzeni o stosunkowo małej wymiarowości. Takie rzutowanie ma dwie

ject representation, “Network: Computation in Neural Systems” 1996, Vol. 7, No. 3.

²⁶ L. Wiskott i in., *Face recognition by elastic bunch graph matching*, “IEEE Transactions on Pattern Analysis and Machine Intelligence” 1997, Vol. 19, Iss. 7.

²⁷ M. Hüsken i in., *Strategies and benefits of fusion of 2d and 3d face recognition*, “Computer Vision and Pattern Recognition” 2005, Vol. 1

²⁸ P.J. Phillips i in., *Overview of the face recognition grand challenge* [w:] IEEE Computer Society, *Conference on Computer Vision and Pattern Recognition 20–26 June 2005*, San Diego, California 2005.

wady. Pierwsza to brak możliwości zachowania wypukłych zmian na twarzy, druga to słabe odwzorowanie odległości euklidesowych pomiędzy punktami charakterystycznymi. Zatem wskaźnik wykrywania i rozpoznawania twarzy przy wykorzystaniu metod liniowych jest niski. Poniżej od myślników wymienione zostały najbardziej popularne liniowe techniki rozpoznawania twarzy: — Eigenface²⁹ — technika ta odnosi się do opartego na wygładzie podejścia do rozpoznawania twarzy, które ma na celu uchwycenie zmienności w kolekcji obrazów twarzy i wykorzystanie tych informacji do kodowania i porównywania obrazów poszczególnych twarzy w sposób holistyczny (w przeciwieństwie do metod częściowych lub opartych na elementach). W szczególności — wektory własne są głównymi składnikami rozkładu powierzchni, lub równoważnie — macierzy kowariancji z zestawu obrazów twarzy, gdzie obraz z N pikselami jest uważany za punkt (lub wektor) w przestrzeni N -wymiarowej. Zatem twarz każdego człowieka może zostać zrekonstruowana z odpowiedniej liniowej kombinacji „eigenów” i może wynosić np. 7% twarzy A, 3,4% twarzy B itd., podczas gdy twarz kogoś innego będzie miała inną kombinację właściwości własnych. Aby skonstruować macierz kowariancji, każdy obraz twarzy jest przekształcany w wektor. Każdy element wektora odpowiada intensywności pikseli. Takie przekształcenie niszczy geometryczną, 2D, strukturę obrazu.

Rysunek 1

Wizualizacja obszarów własnych




Źródło: M. Deshpande, *Face Recognition with Eigenfaces*, <<https://pythonmachinelearning.pro/face-recognition-with-eigenfaces/>>, 8 grudnia 2020 r.

²⁹ A. Turk, A.P. Pentland, *Face recognition using eigenfaces* [w:] *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 3–6 June 1991, Maui, HI, USA 1991.

— 2D PCA (analiza składowych głównych — *Principal Component Analysis*; dalej jako: PCA³⁰; dwuwymiarowy PCA) — technika opiera się na macierzach obrazu 2D, a nie na wektorach 1D, więc macierz obrazu nie musi być przekształcana w wektor przed ekstrakcją cech. W tym systemie macierz kowariancji konstruowana jest bezpośrednio przy użyciu oryginalnych macierzy obrazu, a jej wektory własne są pochodnymi obrazu.

Rysunek 2
Zrekonstruowane obrazy na podstawie 2D PCA (górne) i PCA (dolne), gdzie d oznacza liczbę wektorów własnych



Źródło: Y. Jian, i in., *Two-dimensional PCA: A new approach to appearance-based face representation and recognition*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2004, Vol. 26, Iss. 1

— Niezależna analiza składników (dalej jako: ICA — *Independent Component Analysis*)³¹ — aby zdefiniować zasadę działania tego algorytmu, należy użyć statystycznego modelu „zmiennych ukrytych”. Załóżmy, że obserwujemy n liniowo zmieszanych elementów x_1, \dots, x_n utworzonych z n niezależnych komponentów. Mamy

$$x_j = a_{j1}s_1 + a_{j2}s_2 + \dots + a_{jn}s_n \text{ dla każdego } j \quad (1).$$

Korzystając z notacji macierzowej, możemy powyższe równanie zapisać jako

$$x = As \quad (2).$$

³⁰ Y. Jian i in., *Two-dimensional PCA: A new approach to appearance-based face representation and recognition*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2004, Vol. 26, Iss. 1.

³¹ A. Hyvärinen, E. Oja, *Independent Component Analysis: Algorithms and Applications*, "Neural Networks" 2000, Vol. 13, Iss. 4–5.

Punktem wyjścia dla ICA jest założenie, że składniki są statystycznie niezależne.

ICA jest bardzo blisko związana z metodą nazywaną ślepym separowaniem źródła (BSS — *Blind Source Separation*) lub separacją sygnałów ślepych. „Źródło” oznacza tutaj oryginalny sygnał, tj. jakiś niezależny element. ICA jest jedną z metod, być może najszerzej stosowaną, do przeprowadzania separacji źródeł.

- Wielowymiarowe skalowanie (*Multidimensional Scaling*; dalej jako: MDS)³² — jest to kolejna dobrze znana technika liniowego zmniejszania wymiarów. Zamiast zachowywać wariancję danych podczas projekcji, technika stara się zachować wszystkie odległości między każdą parą przykładów $\text{dist}(x_i, x_j)$, poszukując liniowej transformacji. Problem minimalizacji można rozwiązać poprzez dekompozycję do wartości własnych przy wykorzystaniu euklidesowej odległości między danymi, które wykorzystujemy. Wyniki z tego algorytmu są zbliżone do wyników uzyskanych z algorytmu PCA, jednak uzyskujemy je poprzez wykonanie obrotu, a później rzutowania ich na obszar płaski.
- Nieujemna faktoryzacja macierzy (*Non-negative Matrix Factorization*; dalej jako: NMF)³³ — jest to metoda, która — podobnie do algorytmu PCA — widzi twarz osoby jako liniową kombinację wektorową bez użycia pojęcia klasy. Różnica pomiędzy tymi algorytmami polega na tym, że przy wykorzystaniu algorytmu NMF nie ma możliwości, aby wektory będące podstawą kombinacji cech były ujemne.
- Liniowa analiza dyskryminacyjna (*Linear Discriminant Analysis*; dalej jako: LDA)³⁴ funkcjonuje na zasadzie budowania podprzestrzeni dyskryminacyjnej, która umożliwi odróżnienie twarzy różnych ludzi. Zwana jest także liniową dyskryminacją Fishera. Obraz twarzy, który zazwyczaj składa się z dużej liczby pikseli jest redukowany do niewielkiego zbioru liniowych kombinacji cech dla danej twarzy. Następnie z tych liniowych kombinacji za pomocą klasyfikatora Fishera tworzony jest jej obraz, określane mianem twarzy Fishera (*Fisher face*).

Jeśli chodzi o liniowe techniki PCA, LDA i ICA analizy podprzestrzeni, prowadzono prace mające na celu poprawę ich wydajności. Na przykład praca wykonana m.in. przez Goncalo Tavaresa poprawiła PCA pod kątem odporności na zmiany pozy/orientacji³⁵. Podprzestrzeń probabilistyczna została wprowadzona, aby zapewnić bardziej znaczące podobieństwo miary w ramach probabilistycznych. Poza tym m.in. Gavin Buckingham przedstawił kombinację D-LDA (bezpośrednia LDA) i F-LDA (ułamkowa LDA),

³² Chapter 435, *Multidimensional Scaling*, <https://www.ncss.com/wp-content/themes/ncss/pdf/Procedures/NCSS/Multidimensional_Scaling.pdf>, 19 stycznia 2021 r.

³³ D.D. Lee, H.S. Seung, *Learning the parts of objects by non-negative matrix factorization*, “Nature” 1999, Vol. 401.

³⁴ P.N. Belhumeur, J.P. Hespanha, D.J. Kriegman, *Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection*, “IEEE Transactions on Pattern Analysis and Machine Intelligence” 1997, Vol. 19, Iss. 7.

³⁵ G. Tavares, A. Mourão, J. Magalhães, *Crowdsourcing...*, wyd. cyt.

wariant LDA, w którym funkcje ważne są używane w celu uniknięcia błędnej klasyfikacji spowodowanej przez zbyt bliskie kategorie³⁶. W związku z tym zaproponowane zostało podejście oparte na wieloliniowym rozkładzie tensora zestawu obrazów w celu zmniejszenia wpływu kilku czynników związanych z samym systemem rozpoznawania twarzy, takich jak oświetlenie i orientacja³⁷.

— Falki Gabora³⁸ — aby poprawić rozpoznawanie twarzy, wektory transformacji o wysokiej intensywności są wyodrębniane z transformaty falkowej Gabora przednich obrazów twarzy przy połączeniu z modelem wykrywania ICA³⁹. Charakterystyka falki Gabora została uznana za jedną z najlepszych reprezentacji umożliwiającej rozpoznawanie twarzy.

Chociaż opisane wyżej metody liniowe unikają niestabilności, wcześniej opracowanych metod identyfikacji, metod geometrycznych, nie są one jednak wystarczająco precyzyjne. Słabo opisują subtelności związane z różnicami geometrycznymi obecnymi w przestrzeni obrazu oryginalnego. W głównej mierze wynika to z ograniczeń w możliwościach zarządzania nieliniowością parametrów w trakcie rozpoznawania twarzy. Zatem odkształcenia nieliniowe mogą zostać wygładzone, a wklęsłości mogą być wypełniane, co może spowodować niekorzystne konsekwencje odnośnie rozpoznawania twarzy.

Kolejne globalne liniowe techniki wykorzystywane do rozpoznawania twarzy to:

— Uregulowana analiza dyskryminacyjna (*Regularized Discriminant Analysis*; dalej jako: RDA)⁴⁰. W technice tej macierze kowariancji warunkowej klasy są zastępowane przez oszacowanie regularne. Po wstępnej analizie metodą, którą przedstawił Jerome H. Friedman⁴¹, najpierw obliczamy połączoną (wewnątrz klasy) macierz kowariancji próbki. Następnie za pomocą parametru regularyzacji konwertujemy macierz kowariancji klasy na kombinację liniową. Taka procedura ustawia dwuwymiarową siatkę punktów na dwóch płaszczyznach. Ocenia potwierdzone krzyżowo szacowanie ryzyka błędnej klasyfikacji w każdym przepisanym punkcie na siatce dwóch płaszczyzn, a następnie wybiera punkt o najmniejszym szacowanym ryzyku jako odpowiednie wartości parametrów regularyzacji.

— RLDA (*Regression; LDA*)⁴² — technika ta jest tożsama z LDA, czyli obie działają na podstawie takich samych podstawowych modeli liniowych.

³⁶ G. Buckingham i in., *Visual...*, wyd. cyt.

³⁷ M. Boberg, P. Piippo, E. Ollila, *Designing...*, wyd. cyt.

³⁸ A. Kar i in., *High performance human face recognition using Gabor based pseudo hidden Markov model*, "International Journal of Applied Evolutionary Computation" 2013, Vol. 4, Iss. 1.

³⁹ A. Hyvärinen, E. Oja, *Independent...*, wyd. cyt.

⁴⁰ J.H. Friedman, *Regularized discriminant analysis*, "Journal of the American Statistical Association" 1989, Vol. 84, No. 405.

⁴¹ Tamże.

⁴² T. Hastie, A. Buja, R. Tibshirani, *Penalized discriminant analysis*, "Annals of Statistics" 1995, Vol. 23, No. 1.

Różnica polega na tym, że RLDA optymalizuje prawdopodobieństwo warunkowe, natomiast LDA prawdopodobieństwo pełne.

- NLDA (*Null-space*; LDA)⁴³ — to naturalne rozszerzenie konwencjonalnego LDA. Nazywane tak w przypadku, kiedy wewnątrz klasy znajduje się macierz osobliwa (*singular matrix*). Gdy wewnątrz klasy macierz jest pojedyncza, może znaleźć w niej podprzestrzeń stanowiącą międzyklasową macierz rozproszenia. Uzyskujemy w ten sposób liniowe kryterium dyskryminacji Fishera.
- *Dual-space* LDA⁴⁴ — zostało opracowane w celu wyeliminowania problemów związanych z zastosowaniem LDA dla małej liczby próbek danych, tak aby w pełni wykorzystać dyskryminujące informacje w przestrzeni twarzy. Na podstawie probabilistycznego modelu wizualnego szacuje się widmo wartości własnych w wewnątrzklasowej przestrzeni zerowej macierzy rozrzutu, a analizę dyskryminacyjną stosuje się zarówno w podprzestrzeni głównej, jak i wewnątrzklasowej podprzestrzeni zerowej macierzy rozproszenia. Oba zestawy cech dyskryminujących są ostatecznie łączone w celu rozpoznania osoby.
- *Boosting* LDA⁴⁵ — zapewnia wysoką precyzję klasyfikacji danych. Algorytm ten zamiast pojedynczych cech do klasyfikowania używa rozpoznanych grup wzorców, które opisywane są jako funkcje. Dodatkowo wykorzystuje dwuetapową iterację ważoną, która polega na zintegrowaniu słabych klasyfikatorów z silnymi klasyfikatorami. Wzajemne informacje powstałe pomiędzy klasyfikatorami wykorzystywane są jako wskaźniki alokacji ich wag. Algorytm ten jest szybszy niż algorytmy oparte na wektorach wsparcia czy sieciach neuronowych.
- *Block* LDA⁴⁶ — algorytm ten wykorzystuje podzielenie obrazu twarzy na kilka nienakładających się podobrazów o tym samym rozmiarze. Dzięki temu zwiększa się liczba próbek, natomiast wymiar próbki się zmniejsza. Ponadto, aby zmniejszyć wpływ zmienności oświetlenia, wszystkie wykorzystywane obrazy twarzy są przekształcane w obrazy gradientowe. Uzyskany obraz gradientowy jest dzielony na N^2 mniejszych obrazów.

⁴³ W. Liu i in., *Null space approach of fisher discriminant analysis for face recognition* [w:] D. Maltoni, A.K. Jain (eds), *Biometric Authentication, Proceedings of the ECCV 2004 International Workshop on Biometric Authentication, Prague, Czech Republic, 15 May 2004*, Berlin–Heidelberg 2004.

⁴⁴ X. Wang, X. Tang, *Dual-space linear discriminant analysis for face recognition* [w:] *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*, Washington, DC, USA, 27 June–2 July 2004.

⁴⁵ J.W. Lu, K.N. Plataniotis, A.N. Venetsanopoulos, *Boosting linear discriminant analysis for face recognition*, <https://www.researchgate.net/profile/Konstantinos-Plataniotis/publication/224744759_Boosting_linear_discriminant_analysis_for_face_recognition/links/0f31753a4351c1151c000000/Boosting-linear-discriminant-analysis-for-face-recognition.pdf>, 22 stycznia 2021 r.

⁴⁶ V.D.M. Nhat, S. Lee, *Block LDA for face recognition* [w:] J. Cabestany, A. Prieto, F. Sandoval (eds), *Computational Intelligence and Bioinspired Systems. Proceedings of the 8th International Work-Conference on Artificial Neural Networks, Barcelona, Spain, 8–10 June 2005*, Barcelona 2005.

Następnie podobrazy są rzutowane na wektory przy wykorzystaniu klasycznego algorytmu LDA. Na koniec stosuje się pomiar euklidesowy w celu ustalenia wyniku rozpoznania.

- Ulepszony dyskryminator liniowy Fisher (*Enhanced Fisher Linear Discriminant*; FLD)⁴⁷ — algorytm ten obejmuje równoczesną diagonalizację dwóch wewnętrznych klas macierzy oraz jednej klasy, która powstaje pomiędzy macierzami. Najpierw czyszczona jest wewnątrzmacierzowa macierz rozpraszająca, a następnie stosowane jest PCA pomiędzy klasami macierzy rozproszenia przy wykorzystaniu danych przetworzonych. Celem etapu czyszczenia jest normalizacja macierzy rozproszenia wewnątrz klasy dla jej wzmocnienia. Druga operacja na macierzach maksymalizuje rozproszenie między klasami, tak aby jak najbardziej rozdzielić różne klasy.
- Wspólne wektory deskryminacyjne (*Discriminative Common Vectors*; DCV)⁴⁸ — ten algorytm zamiast używać własnej macierzy rozproszenia dla danej klasy, używa macierzy rozproszenia wszystkich dostępnych klas. Uzyskuje się w ten sposób wspólne wektory. Nowy zestaw wektorów, zwany dyskryminującymi wektorami wspólnymi, jest wykorzystany do klasyfikacji.
- Dwuliniowa analiza dyskryminacyjna (*Bilinear Discriminant Analysis*; BDA)⁴⁹ lub termo-liniowa analiza dyskryminacyjna — polega na znalezieniu zestawu wag oraz progów, tak aby funkcja dyskryminacyjna maksymalizowała kryterium dyskryminacji, np. w dwóch klasach wektor danych. Metody określania wag i wartości progowej obejmują regresję metodą najmniejszych kwadratów, regresję logistyczną, dyskryminator liniowy Fishera i perceptron jednowarstwowy. Prostota tego algorytmu czyni go dobrym kandydatem do klasyfikacji w sytuacjach, w których dane dotyczące szkolenia są bardzo ograniczone. Ponadto pozwala na identyfikację klas/elementów zależnych od posiadanych danych.

Globalne nieliniowe techniki rozpoznawania twarzy

W przypadku kiedy wejściowe struktury danych są liniowe, podejścia liniowe, opisane powyżej, zapewniają ich wierną reprezentację. Jednak, gdy dane są nieliniowe, możliwym rozwiązaniem jest użycie funkcji jądra (*kernel functions*), która umożliwi niejawne porównywanie danych w przestrzeni wysoko wymiarowej, w której problem nieliniowy staje się liniowy.

⁴⁷ D. Zhou, X. Yang, *Face recognition using enhanced fisher linear discriminant model with Facial combined feature* [w:] C. Zhang, H.W. Guesgen, W.K. Yeap (eds), *PRICAI 2004: Trends in Artificial Intelligence, Proceedings of the 8th Pacific Rim International*, Berlin-Heidelberg 2004.

⁴⁸ M. Visani, C. Garcia, J.M. Jolion, *Normalized radial basis function networks and bilinear discriminant analysis for face recognition*, <https://www.researchgate.net/publication/4215341_Normalized_Radial_Basis_Function_Networks_and_Bilinear_Discriminant_Analysis_for_Face_Recognition>, 22 stycznia 2021 r.

⁴⁹ H. Cevikalp i in., *Discriminative common vectors for face recognition*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2005, Vol. 27, Iss. 1.

Daje to możliwość zastosowania technik liniowych, w przypadku kiedy wewnętrzna struktura danych pozostaje nieliniowa.

Proces rozpoznania/klasyfikacji w tym przypadku polega na opisanu danych nieliniowych za pomocą produktu liniowego przy wykorzystaniu funkcji kernel. Właśnie w takim kontekście zaproponowano kilka, wymienionych poniżej, podejść dla metod nieliniowych:

- Analiza składowych głównych z wykorzystaniem funkcji jądra, (*Kernel Principal Component Analysis*; dalej jako: KPCA)⁵⁰ — jest niczym innym jak zamianieniem klasycznej technologii liniowej PCA z wykorzystaniem funkcji kernel do opisu danych nieliniowych. Różnica polega na tym, że w KPCA oblicza się główne wektory własne z wykorzystaniem funkcji kernel, a nie bezpośrednio macierzy kowariancji. Tak zmienione PCA może być postrzegane jako realizacja PCA na przestrzeni wysokowymiarowej przez powiązaną z nią funkcją kernel. KPCA pozwala więc na budowę odwzorowań nieliniowych. Ponieważ technika KPCA opiera się na funkcjach kernel, jej skuteczność w dużej mierze zależy od wyboru modelu tej funkcji. Zazwyczaj używane są funkcje wielomianowe lub funkcja Gaussa⁵¹. Metoda KPCA została z dużym powodzeniem wykorzystana do rozwiązania takich problemów jak rozpoznawanie osób, mowy lub wykrywanie nowych elementów danych zestawów. Jej główną słabością jest rozmiar macierzy jądra, który stanowi kwadrat liczby próbek zbioru treningowego, zatem może szybko osiągać duże wartości (duży rozmiar).
- Maszyna wektorów podpierających (*Support Vector Machine*; dalej jako: SVM)⁵² — jest to technika uczenia się skutecznie wykorzystywana do rozpoznawania wzorca np. twarzy, z wysoką wydajnością bez konieczności dodawania większej liczby informacji o obiekcie. Kilka lat wcześniej opisał tą technikę Vladimir Naumovich Vapnik⁵³, a rozbudował ją Guodong Guo⁵⁴, który wykorzystał SVM, opierając się na strategii rozpoznawania za pomocą drzewa binarnego ze szczególnym uwzględnieniem i rozwiązaniem problemów związanych z rozpoznawaniem twarzy.
- Analiza komponentów niezależnych od jądra (*Kernel Independent Component Analysis*; KICA)⁵⁵ — jest to wydajny algorytm służący do niezależnej analizy komponentów, który szacuje komponenty źródłowe przy

⁵⁰ T. Maurer i in., *Performance of Geometric Active IDTM 3D Face Recognition Engine on the FRGC Data* [w:] *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 21–23 September 2005 San Diego, CA, USA 2005*.

⁵¹ H. Hoffmann, *Kernel PCA for novelty detection*, "Pattern Recognit" 2007, Vol. 40, Iss. 3.

⁵² J. Shawe-Taylor, N. Cristianini, *Kernel Methods for Pattern Analysis*, New York 2004.

⁵³ V.N. Vapnik, *The Nature of Statistical Learning Theory*, New York 1995.

⁵⁴ G. Guo, S.Z. Li, K. Chan, *Face recognition by support vector machines* [w:] *Proceedings Fourth IEEE International Conference on Automatic Face and Gesture Recognition, 28–30 March 2000, Grenoble, France 2000*.

⁵⁵ F. Bach, M.I. Jordan, *Kernel independent component analysis*, "Journal of Machine Learning Research" 2002, Vol. 3.

wykorzystaniu uogólnionej funkcji wariancji opartej na przestrzeni Hilberta. Jądro tego algorytmu opiera się na korelacji między dwiema zmiennymi losowymi reprezentowanymi w przestrzeni Hilberta powiązanyymi z daną mapą obiektów. Badania przeprowadzone przez Francisa Bacha i Michaela I. Jordana⁵⁶ oraz badania przeprowadzone m.in. przez Tommaso Martiriggiano⁵⁷ wykazały, że jest on bardziej skutecznym algorytmem niż Fast ICA czy PCA.

- Isomap⁵⁸ — metoda która wykazała dobre wyniki w znajdowaniu niskowymiarowych niejednorodności z licznych próbek w wielowymiarowej przestrzeni wejściowej. Podczas gdy konwencjonalne metody podprzestrzenne obliczają wartości w celu przedstawienia odległości między próbkami oraz stosują analizę głównych składowych lub podobnie do indukowania różnorodności liniowych, metoda izomapy szacuje odległość geodezyjną między próbkami, a następnie wykorzystuje wielowymiarowe skalowanie do wywołania różnorodności niskowymiarowej.
- Maksymalne rozwijanie wariancji (*Maximum Variance Unfolding*; dalej jako: MVU)⁵⁹ — metoda ta w przeciwieństwie do metody Isomap, uczy się danych z wyznaczonych podobieństw, zachowując zarówno lokalne odległości, jak i kąty między parami wszystkich sąsiadów każdego punktu w danym zestawie danych. Ponieważ metoda zachowuje lokalną maksymalną wariancję w przetwarzaniu redukcji wymiarowości, nazywa się ją rozwijaniem poziomu maksymalnej wariancji. Podobnie jak skalowanie MDS, MVU można zastosować do przypadków, w których mamy podane np. tylko lokalne podobieństwa obiektów w określonym zestawie danych. W takich przypadkach MVU próbuje znaleźć dane w stosunku do danych wejściowych. Technicznie rzecz biorąc, MVU przyjmuje programowanie częściowo skończone⁶⁰ (SDP) w celu rozwiązania założeń problemowych.

⁵⁶ Tamże.

⁵⁷ T. Martiriggiano i in., *Face Recognition by Kernel Independent Component Analysis*, "IEEE Transactions on Neural Networks" 2002, Vol. 13, Iss. 6.

⁵⁸ K.Q. Weinberger, L.K. Saul, *Unsupervised learning of image manifolds by semidefinite programming*, <https://repository.upenn.edu/cgi/viewcontent.cgi?article=1000&context=cis_papers>, 22 stycznia 2021 r.

⁵⁹ Yang M.H., *Face recognition using extended isomap* [w:] *Proceedings of the IEEE International Conference on Image Processing, Rochester, USA, 22–25 September 2002, New York 2002*.

⁶⁰ Programowanie częściowo skończone to stosunkowo nowa dziedzina optymalizacji, która cieszy się coraz większym zainteresowaniem. Wiele praktycznych problemów związanych z badaniami operacyjnymi i optymalizacją można modelować lub aproksymować jako częściowo skończone problemy programistyczne. W teorii automatycznej kontroli SDP są używane w kontekście liniowych nierówności macierzy. Wszystkie programy liniowe można wyrazić jako SDP, a poprzez hierarchie SDP można przybliżyć rozwiązania problemów optymalizacji wielomianów. Do optymalizacji wykorzystano programowanie częściowo skończone złożonych systemów. W ostatnich latach niektóre kwantowe problemy ze złożonością zapytań zostały sformułowane w kategoriach programów częściowo skończonych.

- Lokalne liniowe osadzenie (*Local Linear Embedding*; dalej jako: LLE)⁶¹ — w porównaniu do metody Isomap ma ona szybszą optymalizację po zaimplementowaniu dzięki wykorzystaniu algorytmów macierzowych. Metoda ta zaczyna od znalezienia zbioru najbliższych sąsiadów każdego punktu. Następnie oblicza zestaw wag dla każdego punktu, który najlepiej opisuje ten punkt jako liniową kombinację jego sąsiadów. Wreszcie — wykorzystuje technikę optymalizacji opartą na wektorze własnym w celu znalezienia niskowymiarowego osadzania punktów, tak że każdy punkt jest nadal opisywany za pomocą tej samej liniowej kombinacji swoich sąsiadów. Metoda ta słabo jednak radzi sobie z niejednorodnymi gęstościami próbek, ponieważ nie ma ustalonej jednostki, która zapobiegałaby przesuwaniu środków ciężkości bryły, a wynika to z tego, że różne obszary różnią się gęstością próbek.
- Projekcja z zachowaniem jej lokalizacji (*Locality Preserving Projection*; dalej jako: LPP)⁶² to metoda, która stosuje liniowe mapy rzutowe. Powstają one w wyniku rozwiązania problemu wariacji danych źródłowych, który optymalizuje strukturę zbioru najbliższych sąsiadów. Metoda ta to alternatywa dla PCA, jednak rzutuje ona dane wzdłuż kierunków maksymalnej ich wariacji. Lokalność danych uzyskujemy poprzez znalezienie optymalnych liniowych przybliżeń funkcji własnych operatora Laplace’a Beltramięgo. W rezultacie LPP ma wiele właściwości charakterystycznych dla technik nieliniowych, takich jak *Laplacian Eigenmaps* lub LLE, jednak jest w pełni liniowe i — co ważniejsze — jest definiowane w otaczającej dane przestrzeni, a nie tylko w punktach danych treningowych. LPP może być przeprowadzane w oryginalnej przestrzeni danych lub w odtwarzanej przestrzeni jądra Hilberta, do której mapowane są punkty danych.
- Lokalne osadzenie liniowe (*Local Tangent Space Analysis*; LTSA)⁶³ — metoda ta modeluje dane z przestrzeni n wymiarowej na przestrzeń m wymiarową, przy czym $m < n$ w ten sposób, że znajduje zbiór k najbliższych sąsiadów każdego punktu, następnie wydobywa informacje lokalne w ten sposób, że oblicza d wektorów własnych, z których następnie powstaje macierz korelacji danych. Kolejny krok to budowa macierzy wyrównania B z początkiem danych od $B=0$. W tym momencie zbiór sąsiedztwa danej reprezentowany jest jako zbiór indeksów dla k najbliższych sąsiadów i transponowany jest do nowej macierzy danych. Następnie obliczane są najmniejsze wektory własne i przyporządkowuje się im globalne współrzędne danych odpowiadające własnej najmniejszej wartości własnej.

⁶¹ D.A. Socolinsky, A. Selinger, *Thermal face recognition in an operational scenario*, "Conference Proceedings" 2004, Vol. 2.

⁶² X. He i in., *Learning a locality preserving subspace for visual recognition*, "Conference Proceedings" 2003, Vol. 1.

⁶³ Q. Wang, J. Li, *Combining local and global information for nonlinear dimensionality reduction*, "Neurocomputing" 2009, Vol. 72, Iss. 10–12.

- Podejścia neuronowe⁶⁴ — rozwój sieci neuronowych umożliwił zmianę wydajności algorytmów. Wykorzystanie sieci neuronowych daje lepsze efekty niż metryka liniowa z uwagi na fakt, że tworzą one bardziej skomplikowane powierzchnie decyzyjne. Sieci mogą być uczone ekstrakcji cech głównych zadanego obrazu w różnych wariantach. Perceptron wielowarstwowy (*multilayer perceptron*; dalej jako: MLP) uczony algorytmem propagacji wstecznej daje na wyjściu środkowej warstwy dokładnie m pierwszych wartości cech głównych, które można by otrzymać z rozwiązania macierzowego, pod warunkiem, że neurony są liniowe. W przeciwnym przypadku otrzymane wartości nie są dokładnie wartościami cech głównych, ale lepiej opisują wektor cech wejściowych. Sieć neuronową w tym wariantcie możemy uczyć na dwa sposoby. Można stworzyć jedną sieć i uczyć ją przykładami twarzy z wszystkich dostępnych klas lub wygenerować odrębną sieć dla każdej z klas i testować twarze w poszczególnych sieciach. Ekstrakcję cech można realizować także przy pomocy sieci uczonych w sposób nienadzorowany, np. metodą Hebba. W przypadku natomiast kiedy mamy tylko po jednym przykładzie z każdej klasy, typowa dla danej klasy twarz może być otrzymana jako atraktor przy użyciu rekurencyjnych sieci neuronowych, np. sieci Hopfielda. Na podstawie powyższego można powiedzieć, że MLP umożliwia detekcję twarzy, sieć Hebba ekstrakcję jej cech, a sieć Hopfielda umożliwia stworzenie typowej twarzy jako atraktora. Jeżeli będziemy rozpatrywać twarz, która nie jest dokładnie frontalna, wykorzystujemy sieci rekurencyjne do znalezienia reprezentacji twarzy najbardziej niezależnej od jej obrotu.
- Sieci Kohonen’a⁶⁵ — to jeden z podstawowych typów sieci samoorganizujących się. Ta właściwość daje możliwość adaptacji do wcześniej nieznanymi danych wejściowych, o których bardzo niewiele wiadomo. Sieci Kohonen’a stanowią synonim całej grupy sieci, w których uczenie odbywa się metodą samoorganizującą typu konkurencyjnego. Polega ona na podawaniu na wejścia sieci sygnałów, a następnie wybraniu w drodze konkurencji zwycięskiego neuronu, który najlepiej odpowiada wektorowi wejściowemu. Właśnie taka sytuacja odpowiada rozpoznawaniu twarzy. Mając jeden słabo rozpoznawalny obiekt, możemy spowodować, że sieć spróbuje go odnaleźć w kolejnych obrazach.
- Splotowe sieci neuronowe⁶⁶ — typowa splotowa sieć neuronowa składa się z kombinacji trzech podstawowych typów warstw: warstwy splo-

⁶⁴ B. Raducanu, F. Dornaika, *Dynamic facial expression recognition using laplacian eigenmaps-based manifold learning*, <http://www.cvc.uab.es/~bogdan/Publications/raducanu_ICRA2010.pdf>, 22 stycznia 2021 r.

⁶⁵ S. Lawrence i in., *Face recognition: A convolutional neural-network approach*, “IEEE Transactions on Neural Network” 1997, Vol. 8, Iss. 1.

⁶⁶ S. Duffner, C. Garcia, *Face recognition using non-linear image reconstruction*, <https://www.researchgate.net/publication/4308236_Face_recognition_using_non-linear_image_reconstruction>, 22 stycznia 2021 r.; T. Zhang i in., *Generalized discriminant analysis: A matrix exponential approach*, “IEEE Transactions on Pattern Analysis and Machine Intelligence” 2010, Vol. 40, Iss. 1.

towej, warstwy aktywacji oraz warstwy redukującej rozmiar. Dodatkową warstwę stanowią klasyczne warstwy neuronowe, nazywane warstwami pełnego połączenia. Obraz wejściowy przepuszczany jest przez warstwę spłotową, która wykonuje na nim operacje spłotu dyskretnego. Na jej wyjściu otrzymujemy mapę cech. W obszarze analizy operacja spłotu wykorzystywana jest do filtracji. Kolejny etap przetwarzania to nieliniowa funkcja aktywacji, która przetwarza każdy piksel obrazu. Wyjście ostatniej warstwy spłotowej trafia na klasyczną sieć neuronową. Cechą odróżniającą głębokie sieci neuronowe od klasycznych systemów klasyfikacji obrazów jest możliwość automatycznej ekstrakcji cech bez udziału badacza.

Wszystkie powyższe metody projekcji przestrzeni obrazów na podstawie przestrzeni cech są nieliniowe. Dzięki temu możliwe jest — do pewnego oczywiście stopnia — zmniejszenie wymiaru problemu rozpoznawania. Jednakże, chociaż techniki te często poprawiają szybkość rozpoznawania, są zbyt elastyczne, aby były odporne na nowe typy danych, w przeciwieństwie do opisanych powyżej metod liniowych.

Lokalne metody rozpoznawania twarzy

W metodach lokalnych wyodrębniamy określone cechy geometryczne, takie jak szerokość głowy, odległość między oczami czy kącikami ust, a następnie dane te są zapamiętywane jako wektor cech, dzięki któremu możemy rozpoznać — zidentyfikować daną osobę.

Metody te możemy podzielić na dwie klasy. Pierwsza klasa skupia się na sposobie działania detektorów punktów charakterystycznych twarzy, natomiast druga zajmuje się bardziej rozbudowanymi reprezentacjami informacji przenoszonymi przez te punkty, a nie tylko ich cechami geometrycznymi.

Popularną metodą jest tutaj architektura połączeń dynamicznych (*Dynamic Link Architecture*; dalej jako: DLA). Takie rozwiązanie zaproponował m.in. Daniel Saez Trigueros⁶⁷. W tej metodzie twarz jest reprezentowana za pomocą wykresu jej węzłów. Węzły zawierają współczynniki falkowe Gabora⁶⁸ wyodrębnione dla obszarów wokół zestawu predefiniowanych punktów orientacyjnych twarzy. Podczas próby identyfikacji twarzy wykresy węzłów są porównywane i mierzone są podobieństwa między ich węzłami graficznymi. Na tej podstawie podejmuje się decyzję o rozpoznaniu osoby. Kolejna to metoda wykorzystująca elastyczne dopasowanie grafów wiązek EBGM, w którym współczynniki falkowe Gabora zastąpiono histogramem gradientów kierunkowych (*Histogram*

⁶⁷ D.S. Trigueros, L. Meng, M. Hartnett, *Face recognition: From traditional to deep learning methods*, <https://www.researchgate.net/profile/Daniel_Saez_Trigueros2/publication/328685305_Face_Recognition_From_Traditional_to_Deep_Learning_Methods/links/5d19cd21a6fdcc2462b4a85f/Face-Recognition-From-Traditional-to-Deep-Learning-Methods.pdf>, 22 stycznia 2021 r.

⁶⁸ T.S. Lee, *Image representation using 2D Gabor wavelets*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 1996, Vol. 18, Iss. 10.

of *Oriented Gradients*; deskryptory HOG)⁶⁹. Algorytm ten ma lepszą wydajność w stosunku do DLA z uwagi na właściwości deskryptorów histogramowych obrazu. Są one bardziej odporne na zmiany oświetlenia, rotacji lub małe przemieszczenia. Powodują także większą rozróżnialność grafów twarzy w porównaniu z grafami otrzymywanymi czy metodą DLA czy EBGM z wykorzystaniem współczynników falkowych Gabora.

Wektor funkcji geometrycznych⁷⁰ to metoda wykorzystująca obraz wzorca do bardzo dokładnego wykrywania pozycji interesującego nas źródła w badanym obrazie. Metoda ta wyznacza dla każdego punktu źródła współczynniki korelacji między obrazem badanym a obrazem wzorca, a następnie poszukuje wartości maksymalnych.

Inną metodą jest model statystyczny twarzy⁷¹ — wykorzystuje on wiele detektorów o specyficznych cechach dla każdej części twarzy, takich jak oczy, nos, usta, podbródek itp. Zakłada się, że można zbudować modele statystyczne kształtów twarzy. Jednak pomimo wielu prac badawczych nie ma wystarczająco wiarygodnych i dokładnych punktów charakterystycznych, które przy zastosowaniu tej metody dadzą możliwość identyfikacji.

Reasumując, istnieje wiele algorytmów rozpoznawania twarzy, dużo więcej niż zostało do tej pory przedstawione w niniejszym opracowaniu. W artykule skupiono się na najnowszych rozwiązaniach — metodach opartych na wyodrębnianiu cech. Można je skutecznie wykorzystać do rozpoznawania twarzy, gdy dostępne jest np. tylko jedno zdjęcie referencyjne. Jednak wydajność tych algorytmów zależy od wielu pojedynczych i skutecznych algorytmów lokalizowania punktów charakterystycznych twarzy. W praktyce dokładne zadanie detekcji charakterystycznego punktu nie jest łatwe i nie zostało całkowicie rozwiązane, szczególnie w przypadkach, gdy cechy charakterystyczne twarzy np. kształt lub wygląd obrazu twarzy mogą się znacznie różnić.

Powyższe algorytmy opierające się na wyglądzie twarzy bazują na zdefiniowanych lokalnych regionach. Po ich zdefiniowaniu wybieramy najlepszy sposób reprezentowania informacji o zawartości każdego regionu. Ma to kluczowe znaczenie dla wydajności systemu rozpoznawania, który chcemy zastosować. Powszechnie używane cechy to: współczynniki Gabora⁷², falki Hara⁷³, transformaty Fouriera, deskryptory jak przykładowo transformacja elementu niezmiennego (*Scale-Invariant Feature Transform*; dalej jako: SIFT)⁷⁴,

⁶⁹ D. Monzo, *HOG-EBGM vs. Gabor-EBGM* [w:] *15th IEEE International Conference on Image Processing, ICIP 2008*, Malta 2008.

⁷⁰ M. Seyed i in., *Geometric feature descriptor and dissimilarity-based registration of remotely sensed imagery*, <<https://doi.org/10.1371/journal.pone.0200676>>, 19 lipca 2018 r.

⁷¹ Z. Yang Z. i in., *Single Image 3D Face Reconstruction Based on Statistical Model*, "Journal of Physics: Conference Series" 2018, Vol. 1087, Iss. 5.

⁷² R. Brunelli, T. Poggio, *Face recognition: Features versus templates*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 1993, Vol. 15, No. 10.

⁷³ P. Viola, M.J. Jones, *Robust real-time face detection*, "International Journal of Computer Vision" 2004, Vol. 57, No. 2.

⁷⁴ D.G. Lowe, *Distinctive image features from scale-invariant keypoints*, "International Journal of Computer Vision" 2004, Vol. 60.

charakterystyki oparte na metodzie lokalnego wzoru binarnego (*Local Binary Pattern*; dalej jako: LBP)⁷⁵, kwantyzacja fazy lokalnej (LPQ)⁷⁶, deskryptor prądu Webera (WLD)⁷⁷ i binaryzowane funkcje obrazu statystycznego (BSIF)⁷⁸.

W porównaniu z podejściem globalnym metody lokalne mają pewne zalety. Po pierwsze, mogą dostarczyć dodatkowych informacji wygenerowanych na podstawie lokalnych regionów. Po drugie dla każdego rodzaju charakterystyki lokalnej możemy wybrać najbardziej odpowiedni dla jej opisu wektor cech. Pomimo jednak tych zalet w podejściu lokalnym wymagana jest integracja danych lokalnych do bardziej ogólnych informacji o strukturze. Ogólnie rzecz biorąc, istnieją dwa sposoby osiągnięcia tego celu. Pierwszym sposobem jest zintegrowanie globalnych informacji o algorytmach przy użyciu struktur danych takich jak graf, w którym każdy węzeł reprezentuje lokalną cechę, podczas gdy krawędź między dwoma węzłami reprezentuje relację przestrzenną między nimi. Rozpoznawanie twarzy jest zatem problemem dopasowania dwóch grafów. Drugi sposób polega jednak na wykorzystaniu technik fuzji punktowej: oddzielne klasyfikatory są używane w każdej lokalnej charakterystyce do obliczania podobieństwa. Następnie uzyskane podobieństwa są łączone, aby zapewnić globalny wynik końcowej decyzji, np. zespoły klasyfikatorów (*Ensemble Classifier*) w tym lasy losowe (*Random Forest*) lub klasyfikatory drzewowe XGBoost i podobne.

Metody hybrydowe

Ta kategoria obejmuje podejścia hybrydowe, które wykorzystują jednocześnie cechy globalne, jak i lokalne, aby najlepiej wykorzystać zalety tych metod. Obejmuje również techniki oparte na modelach statystycznych. Ta ostatnia technika formalizuje relacje między zmiennymi w postaci równań matematycznych, które opisują, w jaki sposób jedna lub więcej zmiennych losowych jest powiązanych z jedną lub większą liczbą zmiennych losowych. Ten model jest uważany za statystyczny, gdy zmienne nie są deterministyczne, ale stochastycznie powiązane. Do metod hybrydowych należą: — Ukryte modele Markowa (*Hidden Markov Model*; dalej jako: HMM)⁷⁹ — zaczęły być używane w 1975 r. w różnych dziedzinach, zwłaszcza w rozpoznawaniu głosu. W pełni wykorzystywane były od 1980 r. w rozpo-

⁷⁵ T. Ahonen, A. Hadid, M. Pietikainen, *Face recognition with local binary patterns*. In *Computer Vision — ECCV 2004*, Berlin–Heidelberg 2004.

⁷⁶ V. Ojansivu, J. Heikkilä, *Blur insensitive texture classification using local phase quantization* [w:] A. Elmoataz i in. (eds), *Image and Signal Processing. 3rd International Conference, ICISP 2008, Cherbourg-Octeville, France, July 1–3, 2008. Proceedings*, Berlin–Heidelberg 2008.

⁷⁷ J. Chen i in., *WLD: A robust local image descriptor*, “IEEE Transactions on Pattern Analysis and Machine Intelligence” 2010, Vol. 32, Iss. 9.

⁷⁸ J. Kannala, E. Rahtu, *BSIF: Binarized statistical image features* [w:] *Proceedings of the 21st International Conference on Pattern Recognition ICPR, 11–15 November 2012, Tsukuba Science City, Japan 2012*.

⁷⁹ M. Lal i in., *Study of Face Recognition Techniques: A Survey*, “International Journal of Advanced Computer Science and Applications” 2018, Vol. 9, Iss. 6.

- znawaniu mowy. Następnie zastosowano je do rozpoznawania tekstu rękopisu, przetwarzania obrazu, muzyki i bioinformatyki (sekwencjonowanie DNA itp.), a także w kardiologii (segmentacja sygnału EKG). Ukryte modele Markowa, zwane również źródłami Markowa lub probabilistycznymi funkcjami Markowa są potężnymi narzędziami statystycznymi do modelowania sygnałów stochastycznych. Modele te okazały się skuteczne od czasu ich wynalezienia przez Leonarda E. Bauma i jego kolegów. Mogą być zdefiniowane przez model statystyczny łańcucha Markowa. Model ten złożony jest ze „stanów” i „przejęć”. W przypadku obrazów twarzy znaczące obszary twarzy (włosy, czoło, brwi, oczy, nos, usta i podbródek) są umieszczane w naturalnej kolejności od góry do dołu, nawet jeśli obraz jest wykonywany przy małych obrotach. Dla każdego z tych regionów występuje stan od lewej do prawej.
- Transformacja falkowa Gabora oparta na pseudoukrytym modelu Markowa (*Poisson Hidden Markov Model*; dalej jako: GWT-PHMM)⁸⁰ to podejście, które łączy zdolność wielorozdzielczości transformacji falkowej Gabora (dalej jako: GWT) z lokalnymi interakcjami występującymi w strukturze twarzy wyrażonymi przez pseudoukryte modele Markowa (*Poisson Hidden Markov Model*; dalej jako: HMM). W odróżnieniu od tradycyjnej metody zygzakowego skanowania do ekstrakcji cech, metoda ciągłej analizy powinna być przeprowadzana od lewej górnej strony do prawej, a następnie od góry do dołu i od prawej do lewej itd., aż do prawego dolnego rogu obrazu. Ponadto w przeciwieństwie do tradycyjnego HMM, PHMM nie wymaga warunkowej niezależności stanów dla widocznej sekwencji obserwacji. Wynik ten został osiągnięty dzięki koncepcji lokalnych struktur wprowadzonych przez PHMM wykorzystywanych do wydobywania pasm twarzy i automatycznego wybierania najbardziej informacyjnych cech obrazu twarzy. Ponownie użycie najbardziej informacyjnych pikseli zamiast całego obrazu sprawia, że proponowana metoda rozpoznawania twarzy jest stosunkowo szybka.
 - Systemy rozpoznawania wykorzystujące PCA oraz dyskretną transformację kosinusową (*Discrete Cosine Transform*; dalej jako: DCT) w podejściu HMM⁸¹ — kiedy nie używamy DCT, PCA stosuje się do zmniejszenia wymiaru, najpierw szczegóły twarzy organizujemy w bloki, a następnie nakładamy na te bloki DCT. Kolejny krok to korzystamy z PCA, ponownie nie wykorzystując odwrotnej transformacji DCT, co tym samym przyspiesza działanie takiego rozwiązania.
 - HMM-LBP⁸² — to podejście hybrydowe, które pozwala na klasyfikację obrazu twarzy 2D za pomocą narzędzia LBP. Składa się ono z czterech etapów. Pierwszy rozkłada obraz twarzy na bloki. Kolejny wyodrębnia cechy obrazu za pomocą LBP. Następny oblicza wysokość prawdopodo-

⁸⁰ D.D. Lee, H.S. Seung, *Learning...*, wyd. cyt.

⁸¹ S. Jameel, *Face recognition system using PCA and DCT in HMM*, “International Journal of Advanced Research in Computer and Communication Engineering” 2015, Vol. 4, Iss. 1.

⁸² M. Chihaoui i in., *Face recognition using HMM-LBP* [w:] A. Abraham i in. (eds), *Hybrid Intelligent Systems*, Cham 2015.

bieństwa, z jakim w danym bloku znajduje się twarz. Ostatni wybiera blok o maksymalnym prawdopodobieństwie.

- Podejście hybrydowe oparte na charakterystycznych wartościach SVD (*Singular Value Decomposition*, pol. rozkład według wartości osobliwych; dalej jako: SVD) dla rozkładu falkowego⁸³ — to skuteczny system rozpoznawania twarzy wykorzystujący wartości własne transformaty falkowej jako wektory cech i sieć neuronową z radialną funkcją bazową (RBF) jako klasyfikator. Za pomocą transformaty falkowej 2D obraz twarzy dekomponowany jest na dwa poziomy, następnie obliczana jest średnia współczynników falkowych w celu znalezienia charakterystycznych centrów.
- Dyskryminacyjny model zmiennej utajonej procesu Gaussa (*Discriminative Gaussian Process Latent Variable Model*; dalej jako: DGPLVM)⁸⁴ — jest rozszerzeniem GPLVM (*Gaussian Process Latent Variable Model*), w którym proces transformaty gaussowskiej jest mapowany z niskowymiarowej przestrzeni utajnionej do wielowymiarowego zestawu danych, gdzie lokalizacja punktów w przestrzeni utajnionej jest określana przez maksymalizację prawdopodobieństwa procesu Gaussa w odniesieniu do macierzy, w której wiersze reprezentują odpowiednie pozycje utajnionej przestrzeni X. Model ten umieszcza dyskryminator nad ukrytymi w macierzy pozycjami, stosując metodę przydzielania pozycji tak, aby pozycje różnych klas były od siebie maksymalnie oddalone, a tych samych maksymalnie blisko.
- Analiza dyskryminacyjna różnych rozkładów Gaussa według Riemanna (*Discriminant analysis on riemannian manifold of Gaussian distributions*; dalej jako: DARG)⁸⁵ — koncepcją tej metody jest uchwycenie rozkładów podstawowych, założonych danych w każdym zestawie obrazów w celu ułatwienia klasyfikacji i zwiększenia jej niezawodności. W tym celu reprezentuje się zestaw obrazów jako mieszaninę m modeli Gaussa (*Gaussian Mixture M-models*; dalej jako: GMM) zawierającą wcześniej określoną liczbę składników Gaussa z określonym prawdopodobieństwem. Biorąc pod uwagę informacje geometryczne, komponenty Gaussa leżą na określonych rozmaitościach Riemanna. Aby poprawnie zakodować taki kolektor Riemanna, DARG wykorzystuje kilka odległości między składnikami Gaussa i wyznacza serię udokumentowanych pozytywnych probabilistycznych rdzeni. W tym ostatnim opracowywana jest ważona analiza różnicowa rdzeni w celu traktowania GMM jako próbek, a ich wyznaczone prawdopodobieństwa jako ich wagi.

⁸³ V.H. Hashemi, A.A. Gharahbagh, *A novel hybrid method for face recognition based on 2d wavelet and singular value decomposition*, "American Journal of Networks and Communications" 2015, Vol. 4, Iss. 4.

⁸⁴ R. Urtasun, T. Darrell, *Discriminative Gaussian process latent variable model for classification* [w:] Z. Ghahramani (ed.), *Proceedings of the 24th international conference on Machine learning, Corvallis, OR, USA, 2007*, New York 2007.

⁸⁵ W. Wang i in., *Discriminant analysis on riemannian manifold of Gaussian distributions for face recognition with image sets*, "Conference Proceedings" 2015, Vol. 1.

- Lokalne deskryptory afiniczne i podobieństwo probabilistyczne⁸⁶ — algorytm ten łączy transformację afiniczną oraz skaloniezmiennicze deskryptory cech (SIFT) zgodnie z podobieństwem probabilistycznym ich wystąpienia. Affine SIFT jest rozszerzeniem metody SIFT. Wykrywa lokalne niezmiennicze deskryptory, generuje szereg różnych widoków przy wykorzystaniu transformacji afinicznej. W tym kontekście umożliwia zobrazowanie różnic między obrazem twarzy oraz obrazem wzorca. Jednak ludzka twarz nie jest płaska, ponieważ zawiera ważną dla rozpoznawania twarzy głębię 3D, której algorytm ten nie uwzględnia. Podejście to nie jest skuteczne także w przypadku dużych zmian pozycji/orientacji danej twarzy. Ponadto łączy się z podobieństwem probabilistycznym, które uzyskujemy między obrazem twarzy a wzorcem na podstawie sumy rozkładu różnic kwadratowych w procesie uczenia się online.
- Algorytm hybrydowy wykorzystujący falki PCA i transformatę Gabora⁸⁷ — to podejście, które wykorzystuje algorytm rozpoznawania twarzy podzielony na dwa etapy rozpoznawania. Oparty jest on o cechy globalne i lokalne. W pierwszym etapie rozpoznawania tzw. zgrubnego algorytm stosuje analizę głównych składników (PCA) w celu wstępnej identyfikacji obrazu testowego. Etap rozpoznawania twarzy kończy się na tym etapie, jeśli otrzymany wynik poziomu ufności okaże się wiarygodny. W przeciwnym razie algorytm wykorzystuje otrzymany wynik do filtrowania obrazów, „najlepszych kandydatów”, o wysokim stopniu podobieństwa i przesyła je do następnego etapu rozpoznawania, w którym stosowane są filtry Gabora.
- Ręczna segmentacja za pomocą filtru Gabora oraz sieci neuronowej⁸⁸ jest kolejną techniką ekstrakcji cech twarzy, która zapewnia wysoką precyzję rozpoznawania. W tym podejściu rysy topograficzne twarzy są wydobywane podczas ręcznej segmentacji obszarów twarzy, czyli wyznaczania położenia oczu, nosa i ust. Następnie realizowana jest transformata Gabora i dookreślane jest maksimum tych regionów, tak aby obliczyć lokalną ich reprezentację. W fazie uczenia się podejście to wykorzystuje metodę najbliższego sąsiada. Metoda ta jest wykorzystywana do obliczenia odległości między trzema wektorami cech tych regionów oraz odpowiadającymi im wektorami porównawczymi.
- HMM-SVM-SVD⁸⁹ — to kombinacja dwóch klasyfikatorów: SVM i HMM. Pierwszy z nich jest używany z cechami PCA, podczas gdy drugi jest

⁸⁶ Y. Gao, H.J. Lee, *Viewpoint unconstrained face recognition based on affine local descriptors and probabilistic similarity*, "Journal of Information Processing Systems" 2015, Vol. 11, Iss. 4.

⁸⁷ H. Cho i in., *An efficient hybrid face recognition algorithm using PCA and GABOR wavelets*, "International Journal of Advanced Robotic Systems" 2014, Vol. 11, Iss. 1.

⁸⁸ A. Qasim, P. Prashan, V. Peter, *A hybrid feature extraction technique for face recognition*, "International Proceedings of Computer Science and Information Technology" 2014, Vol. 1.

⁸⁹ S. Nebti, B. Fadila, *Combining classifiers for enhanced face recognition*, "Advances in Information Science and Computer Engineering" 2015, Vol. 82.

jednowymiarowym modelem w siedmiu stanach, w których cechy oparte są na SVD. Dzięki temu podejściu wykorzystujemy reguły wyżej wymienionej kombinacji do łączenia wyników.

- Scalanie lokalnych i globalnych cech opartych na transformacji Gabora oraz PCA⁹⁰ — to połączenie dwóch rodzajów cech. Lokalnych cech wyodrębnionych przez transformację Gabora i globalnych cech wyodrębnionych przez „przekształcenie konturu”. Etap rozpoznawania jest w końcu dokonywany przez klasyfikator oparty na PCA.
- SIFT-2D-PCA⁹¹ — to algorytm łączący metodę SIFT z 2D-PCA. Ponieważ SIFT służy do wydobywania charakterystycznych cech, które są niezmiennie względem skalowania, orientacji i oświetlenia, jest to korzystne połączenie dla rozpoznania twarzy, nawet jeśli globalne jej funkcje nie będą dostępne; 2D-PCA służy do wydobywania cech globalnych, a także do zmniejszania rozmiaru obrazu.
- Wielowarstwowy perceptron-PCA-LBP⁹² — to algorytm wykorzystujący metodę rozpoznawania twarzy stosowaną, kiedy badany podmiot podlega zmianom polegającym na zmianie oświetlenia, pozycji głowy czy mimiki. Dokonuje on globalnej i lokalnej ekstrakcji cech odpowiednio przy użyciu PCA i LBP. Tak więc te globalne i lokalne cechy są wprowadzane do sieci o nazwie MLP, która realizuje klasyfikację.
- Lokalny wzór kierunkowy (*Local Directional Pattern*; dalej jako: LDP)⁹³ — wykorzystuje model kierunku lokalnego. W tym podejściu cechę LDP dla każdej pozycji piksela uzyskuje się poprzez obliczenie wartości odpowiedzi obrazu w ośmiu różnych kierunkach. Następnie obraz LDP jest wykorzystywany jako dane wejściowe do ekstrakcji i reprezentacji cech przez 2D-PCA. Jednak do rozpoznawania twarzy wykorzystywany jest klasyfikator najbliższego sąsiada. Chociaż ta metoda ma dobrą dokładność rozpoznawania w różnych warunkach oświetleniowych, działa tylko z płaskimi obrazami pozyskanymi w frontalnej orientacji twarzy.
- Transformacja falkowa i kierunkowa LBP⁹⁴ — zaczyna się to od obróbki wstępnej obrazu za pomocą transformaty falkowej w celu uzyskania szeregu różnych rozdzielczości podobrazów i dekompozycji falkowej w celu uzyskania różnych składników skali. Następnie obliczany jest histogram LBP (*directional weighted*, pol. kierunkowo wa-

⁹⁰ J. Zhang, *Comparison of wavelet, Gabor and curvelet transform for face recognition*, „Optica Applicata” 2011, Vol. 41, No. 1.

⁹¹ M. Singha, D. Deb, S. Roy, *Hybrid feature extraction method for partial face recognition*, „International Journal of Emerging Technology and Advanced Engineering” 2014, Vol. 4.

⁹² M. Sompura, V. Gupta, *An efficient face recognition with ANN using hybrid feature extraction methods*, „International Journal of Computer Applications” 2015, Vol. 117, No. 17.

⁹³ D.J. Kim, S.H. Lee, M.Q. Shon, *Face recognition via local directional pattern*, „International Journal of Security and its Applications” 2013, Vol. 7, Iss. 2.

⁹⁴ F. Wu, *Face recognition based on wavelet transform and regional directional weighted local binary pattern*, „Journal of Multimedia” 2014, Vol. 9, No. 8.

żona; DW-LBP) dla różnych ważonych podregionów obrazu twarzy. Test chi kwadrat służy do dopasowania sekwencji histogramu. Ta metoda zmniejsza złożoność obliczeniową i poprawia współczynnik rozpoznawania, ale jest wrażliwa na zamianę orientacji twarzy.

Algorytmy rozpoznawania twarzy na obrazie 3D

Rozpoznawanie twarzy 2D przez lata modyfikacji i rozwój metod numerycznych osiągnęło wysoki poziom dojrzałości oraz wysoki wskaźnik precyzji. Po latach badań stan techniki rozpoznawania twarzy stale się poprawia i zapewnia coraz dokładniejsze wyniki. Jest to jeden z najbardziej aktywnych obszarów badań w dziedzinie komputerowego przetwarzania obrazów. Jednak w ciągu ostatnich kilku lat, na skutek rozwoju technologicznego pojawiły się nowe, bardzo obiecujące, kierunki badań. Pomimo wysokiego wskaźnika skuteczności osiągniętego w rozpoznawaniu twarzy w obrazach płaskich, zauważalne pozostają problemy z uzyskaniem niewrażliwości na zmiany oświetlenia, orientacji twarzy względem osi kamery, parametry akwizycji. Panaceum okazało się rozpoznawanie twarzy w reprezentacji 3D, która zawiera informacje o kształcie powierzchni twarzy. Kilka z najnowszych technik wykorzystujących dane 3D zostało opisane w literaturze⁹⁵.

Jednak, analizując zagadnienie, ostatnie badania wskazują, że połączenie multimodalnego rozpoznawania twarzy 2D i 3D jest dużo dokładniejsze i bardziej niezawodne niż rozpoznawanie jednomodalne⁹⁶. Badania w tym zakresie można odnaleźć w literaturze⁹⁷. Są one

⁹⁵ D. Huang i in., *3D face analysis: Advances and perspectives* [w:] Z. Sun i in. (eds), *Biometric Recognition: 9th Chinese Conference on Biometric Recognition, CCBR 2014, Shenyang, China, November 7–9, 2014, Proceedings*, New York 2014; H. Drira i in., *3D face recognition under expressions, occlusions, and pose variations*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2013, Vol. 35; D. Huang i in., *3-D face recognition using eLBP-based facial description and local feature hybrid matching*, "IEEE Transactions on Information Forensics and Security" 2012, Vol. 7; S. Said i in., *Fast and efficient 3D face recognition using wavelet networks* [w:] *16th IEEE International Conference on Image Processing (ICIP), 7–10 November 2009, Cairo, Egypt 2009*; M.A. Borgi, M. El'Arbi, C.B. Amar, *Wavelet network and geometric features fusion using belief functions for 3D face recognition* [w:] R. Wilson i in. (eds), *Computer Analysis of Images and Patterns. Proceedings of the 15th International Conference, CAIP 2013, York, UK, 27–29 August 2013*, Berlin–Heidelberg 2013; W.B. Soltana i in., *Multi library wavelet neural networks for 3D face recognition using 3D facial shape representation*, <<https://zenodo.org/record/41296#YA6mM3ZKh9M>>, 25 stycznia 2021 r.

⁹⁶ K.W. Bowyer, K. Chang, P. Flynn, *A survey of approaches and challenges in 3D and multimodal 3D+2D face recognition*, "Computer Vision and Image Understanding" 2006, Vol. 101, Iss. 3.

⁹⁷ N.S. Lakshmiprabha, J. Bhattacharya, S. Majumder, *Face recognition using multimodal biometric features* [w:] *Proceedings of the IEEE International Con-*

poświęcone uwypukleniem zalet łączenia reprezentacji twarzy w postaci 2D i 3D. W kolejnych pracach do technik 3D dołączono techniki głębokiego uczenia się⁹⁸. Głębokie sieci neuronowe (*Deep Neural Networks*; DNN) są, jak się wydaje, najlepszymi technikami realizacji szeroko pojętych zadań w zakresie klasyfikacji obrazów, rozpoznawaniu mowy czy rozpoznawaniu twarzy. W szczególności splotowe sieci neuronowe (*Convolutional Neural Network*; CNN) osiągnęły obiecujące wyniki w rozpoznawaniu twarzy. Opracowano także nowe podejście do rozpoznawania twarzy, czyli obrazowanie w podczerwieni. Ma ono na celu przezwycięzenie ograniczeń rozpoznawania twarzy, takich jak zmiany oświetlenia, a także przebrania twarzy, które mogą znacznie zmniejszyć dokładność rozpoznawania⁹⁹. Obrazy w podczerwieni są modalnością, która zwróciła szczególną uwagę ze względu na niezmiennosc wyniku klasyfikacji względem zmian oświetlenia¹⁰⁰. Rzeczywiście, dane uzyskane za pomocą kamer na podczerwień mają wiele zalet w porównaniu ze zwykłymi kamerami, które działają w widmie widzialnym. Na przykład obrazy twarzy w podczerwieni można uzyskać w każdych warunkach oświetleniowych, nawet w całkowicie ciemnym otoczeniu. Taka technika podczerwieni pozwala osiągnąć wyższy stopień odporności na zmiany wyrazu twarzy¹⁰¹.

Istnieją prace, w których połączono kilka wymienionych powyżej technik. Przykładowo autorzy pracy *Multimodal biometrics based on near-infrared face*¹⁰² połączyli multimodalne rozpoznawanie twarzy, zaś m.in. Jiquan Ngiam¹⁰³ zastosował zarówno multimodalne rozpoznawanie twarzy, jak i głębokie uczenie się.

ference on Image Information Processing (ICIIP), 3–5 November 2011 Shimla, India 2011; S. Radhey, S.Y. Narain, *Identifying individuals using multimodal face recognition techniques*, "Procedia Computer Science" 2015, Vol. 48.

⁹⁸ S. Balaban, *Deep learning and face recognition: The state of the art*, "Proceeding SPIE" 2015, Vol. 9457.

⁹⁹ S.Z. Li i in., *Illumination invariant face recognition using near-infrared images*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2007, Vol. 29; D. Huang, Y. Wang, Y. Wang, *A robust method for near infrared face recognition based on extended local binary pattern*, <<http://rendicahya.lecture.ub.ac.id/files/2018/03/A-Robust-Method-for-Near-Infrared-Face-Recognition-Based-on-Extended-Local-Binary-Pattern.pdf>>, 22 stycznia 2021 r.

¹⁰⁰ G. Friedrich, Y. Yeshurun, *Seeing people in the dark: Face recognition in infrared images* [w:] H.H. Bülthoff i in. (eds), *Biologically Motivated Computer Vision*, Berlin 2003.

¹⁰¹ L.A. Jeni, H. Hashimoto, T. Kubota, *Robust facial expression recognition using near infrared cameras*, "Journal of Advanced Computational Intelligence and Intelligent Informatics" 2012, No. 16.

¹⁰² R. Wang i in., *Multimodal biometrics based on near-infrared face* [w:] K.N. Plataniotis, N.V. Boulgouris, E. Micheli-Tzanakou (eds), *Biometrics: Theory, Methods, and Applications*, New Jersey 2009.

¹⁰³ J. Ngiam i in., *Multimodal deep learning* [w:] *Proceedings of the 28th International Conference on Machine Learning, ICML 2011, 28 June–2 July 2011, Bellevue, WA, USA 2011*.

Omówienie modeli 3D twarzy

Z punktu widzenia wyglądu istotną cechą powierzchni 3D jest jej kształt. Powszechnym sposobem jej przedstawienia jest siatka powierzchniowa 3D wierszy i ich współrzędne 3D. Biorąc pod uwagę zestaw wierzchołków, możemy skojarzyć z każdym wierzchołkiem nie tylko jego informacje geometryczne (współrzędne 3D), ale także jego wartości RGB¹⁰⁴. Podczas pracy z twarzami konieczne jest zarejestrowanie ich we wspólnej siatce wierzchołków, w której każdy wierzchołek ma określoną tożsamość. Można to osiągnąć poprzez proces rejestracji¹⁰⁵, który mapuje kanoniczny szablon siatki na obraz twarzy 3D.

Ludzka twarz jest przedmiotem odkształcalnym. Jej kształt zmienia się dynamicznie wraz z płcią, wiekiem i pochodzeniem etnicznym. Zasadniczo podstawy modelu kształtu mogą uchwycić te zmiany kształtu. Jednak skonstruowanie takiego modelu wymagałoby ogromnego zestawu szkoleniowego obrazów twarzy 3D zawierających wszystkie interesujące kształty. Załóżmy, że mamy dużą liczbę próbek uczących dla konkretnej grupy osób zidentyfikowanych według ich wieku lub płci. Bardziej wydajnym rozwiązaniem jest przeniesienie wewnętrznych odmian jednej konkretnej grupy twarzy do drugiej. W tym celu najsensowniejszy wydaje się model twarzy Morphable 3D z mieszanką Gaussa (GM-3DMM)¹⁰⁶.

Metody lokalne

Jedną z metod lokalnych jest użycie krzywizn Gaussa do znalezienia pięciu punktów orientacyjnych w modelu 3D¹⁰⁷. Jej pomysłodawcy założyli, że właściwy punkt orientacyjny może być obciążony maksymalnym błędem ± 4 mm. Natomiast użycie krzywizny Gaussa i czystej krzywizny w połączeniu z mapami głębokości, aby wyodrębnić obszary oczu i nosa zaproponował Gaile G. Gordon¹⁰⁸. Dopasowanie obszarów oczu i nosa do siebie pozwoliło na osiągnięcie precyzji rozpoznania na poziomie 97% dla zbioru danych 24 obrazów. Zastosowanie zarówno mediany, jak i krzywizny Gaussa do wyboru 35 rysów twarzy opisujących okolice nosa i oczu opisane zostało w *Face Recognition using 3D Surface-Extracted*

¹⁰⁴ Jeden z modeli przestrzeni barw, opisywanej współrzędnymi RGB. Jego nazwa powstała ze złożenia pierwszych liter angielskich nazw barw: Red (czerwony), Green (zielony), Blue (niebieski).

¹⁰⁵ J.T. Rodriguez, *3D Face Modelling for 2D+3D Face Recognition*, Surrey University, Guildford, UK, 2007, praca doktorska.

¹⁰⁶ P. Koppen i in., *Gaussian mixture 3D morphable face model*, "Pattern Recognition" 2018, Vol. 74.

¹⁰⁷ C.A.M. Suikerbuik i in., *Automatic feature detection in 3D human body scans*, <https://www.researchgate.net/publication/46659540_Automatic_Feature_Detection_in_3D_Human_Body_Scans>, 25 stycznia 2021 r.

¹⁰⁸ G.G. Gordon, *Face Recognition Based on Depth Maps and Surface Curvature*, "Geometric Methods in Computer Vision" 1991, Vol. 1570.

*Descriptors*¹⁰⁹. Najlepszy wskaźnik rozpoznania tą metodą został osiągnięty na neutralnych (bez ekspresji) twarzach ze współczynnikiem rozpoznania wynoszącym 78%.

Zastosowanie momentów Gaussa-Hermit'a jako lokalnych deskryptorów w połączeniu z globalną siatką zaproponowali autorzy artykułu *Automatic 3D Face recognition combining global geometric features with local shape variation information*¹¹⁰. W swoich próbach pomysłodawcy metody osiągnęli wskaźnik rozpoznania na poziomie 96,1% dla 30 obiektów badanych. Przy 120 obiektach wskaźnik spadł do 72,4%. Taka różnica wynika z rodzaju zastosowanej bazy danych. Dla 30 obiektów była to baza danych stworzona ręcznie (*Manual DataBase*; MDB), przy 120 obiektach była to baza danych stworzona automatycznie (*Automatic DataBase*; ADM). Dane w MDB mają lepszą jakość niż te w ADB.

Inną metodą lokalną jest wykorzystanie konkretnych cech punktów — ich sygnatur w celu szczegółowego opisanie punktów w 3D¹¹¹. Tutaj przy pomocy sygnatur punktowych opisane zostało czoło, nos i oczy. Metoda ta dla sześciu obiektów osiągnęła wskaźnik rozpoznania 100%. Testy przeprowadzone na 50 obiektach zestawiono z wynikami z podejścia falkowego Gabora. Określono poziom rozpoznania zaproponowanej metody na 85%, natomiast podejścia falkowego Gabora na poziomie 87%. Po połączeniu punktów orientacyjnych 2D i 3D obie metody osiągnęły wskaźnik rozpoznawania na poziomie 89%.

Użycie krzywizny Gaussa do zdefiniowania cech kwadratowych łąt zaproponowano w publikacji *Three-Dimensional Surface Curvature Estimation using Quadric Surface Patches*¹¹². Jej autorzy twierdzą, że ich metoda może być stosowana do rozpoznawania wszelkiego rodzaju modeli 3D, nie tylko twarzy. Innym lokalnym deskryptorem kształtu, który okazał się dobrze działać na ludzkich ciałach, był deskryptor kształtu Paquet¹¹³.

¹⁰⁹ A.B. Moreno i in., *Face Recognition using 3D Surface-Extracted Descriptors*, "Irish Machine Vision and Image Processing Conference Proceedings" 2003, Vol. 2.

¹¹⁰ C. Xu i in., *Automatic 3D Face recognition combining global geometric features with local shape variation information* [w:] *Proceedings of the IEEE International Conference on Automatic Face and Gesture Recognition, 19 May 2004, Seoul, South Korea 2004*.

¹¹¹ Zob. C.S. Chua, R. Jarvis, *Point Signatures: A New Representation for 3D Object Recognition*, "International Journal on Computer Vision" 1997, Vol. 25; C.S. Chua, F. Han, Y.K. Ho, *3D human face recognition using point signature* [w:] *Proceedings Fourth IEEE International Conference on Automatic Face and Gesture Recognition, 28–30 March 2000, Grenoble, France 2000*.

¹¹² I. Douros, B.F. Buxton, *Three-Dimensional Surface Curvature Estimation using Quadric Surface Patches*, <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.98.7059&rep=rep1&type=pdf>>, 25 stycznia 2021 r.

¹¹³ K.M. Robinette, *An Alternative 3D descriptor for database mining* [w:] *SAE International, Proceedings of the Digital Human Modelling Conference, Pittsburgh 2004*.

Metody globalne

Jedną globalną metodę krzywizny zaprezentowano w artykule *3D head model classification by evolutionary optimization of the extended Gaussian image representation*¹¹⁴. Powierzchnię modelu twarzy przedstawiono w publikacji za pomocą rozszerzonego obrazu Gaussa (*extended Gaussian image*; EGI), który umożliwia redukcję problemów rozpoznawania twarzy w modelu 3D do problemu podobnego do porównywania histogramów dla modelu twarzy 2D. Jako klasyfikator zastosowano klasyfikator funkcji masowego prawdopodobieństwa wielokrotnego (*Multiple Conditional Probability Mass Function Classifier*; MCPMFC). Klasyfikator ten, testowany na zbiorze danych pięciu obiektów, osiągnął współczynnik rozpoznawania 80,08%. Klasyfikator minimalnej odległości (*Minimum Distance Classifier*; MDC) osiągnął współczynnik rozpoznawania 67,40%. Jednak dalsze testy wykazały, że dla obu metod odsetek rozpoznania spada o 10%, gdy zwiększymy zestaw danych już do 21 osób.

Propozycję użycia kombinacji modelu 3D i tekstury twarzy zaproponowali Theodoros Papatheodorou oraz Daniel Rueckert¹¹⁵ wraz z miarami podobieństwa dla dwóch modeli 3D bez tekstury i w połączeniu z teksturą. Wyniki wykazały wzrost liczby poprawnie sklasyfikowanych zdjęć czółowych w przypadku uwzględnienia tekstury.

Propozycję wykorzystania profili modeli 3D do rozpoznawania twarzy zaproponowali Charles Beumier, Marc Acheroy¹¹⁶. Pierwsza próba rozpoznawania twarzy opierała się na trzech profilach jednej twarzy i wykazywała poziom błędu 9%. W drugiej próbie dołączenie informacji o wartości szarości do procesu dopasowywania¹¹⁷, spowodowało obniżenie błędu do 2,5%. Yijun Wu, Gang Pan, Zhaohui Wu zaproponowali¹¹⁸ technikę rozpoznawania twarzy 3D poprzez wyodrębnienie wielu profili poziomych (warstw) modelu 3D i pasowaniu profili do siebie. Osiągnęli oni poziom błędu od 1% do 5,5% dla danych z 30 obiektami.

¹¹⁴ H.S. Wong, K.K.T. Cheung, H.S. Ip Horace, *3D head model classification by evolutionary optimization of the extended Gaussian image representation*, "Pattern Recognition" 2004, Vol. 37.

¹¹⁵ T. Papatheodorou, D. Rueckert, *Evaluation of automatic 4D Face recognition using surface and texture registration* [w:] *Proceedings of the IEEE International Conference in Automatic Face and Gesture Recognition, 19 May 2004, Seoul, South Korea 2004*.

¹¹⁶ C. Beumier, M. Acheroy, *Automatic 3D face authentication*, "Image and Vision Computing" 2000, Vol. 18, No. 4.

¹¹⁷ C. Beumier, M. Acheroy, *Face verification from 3D and grey level clues*, "Pattern Recognition Letters" 2001, Vol. 22.

¹¹⁸ Y. Wu, G. Pan, Z. Wu, *Face Authentication Based on Multiple Profiles Extracted from range data* [w:] J. Kittler, S.M. Nixon (eds), *Proceedings of the Audio- and Video-Based Biometric Person Authentication*, Guildford 2003.

Podsumowanie

W artykule przedstawiono najnowsze, opracowane w różnych ośrodkach badawczych, metody identyfikacji osób. Analizę przeprowadzono pod kątem rzetelnego przedstawienia wyżej wymienionych metod w celu możliwości późniejszego odniesienia się do nich i ich porównania z algorytmem opracowanym w ramach własnych prac i badań. Z analizy przedmiotowej literatury wynika, że brak opracowania naukowego, które wskazywałoby na zmianę parametrów biometrycznych ludzkiej twarzy z powodu nieskoordynowanych ruchów głową w trzech osiach Eulera. Kolejnym etapem pracy będzie analiza takich zmian i próba wyznaczenia parametrów umożliwiających transformację zmienionych cech do cech bazowych. Następnym etapem to dokładne porównanie szybkości i dokładności funkcjonowania istniejących na rynku algorytmów z algorytmem opracowanym w ramach prac własnych.

Bibliografia

Literatura

- Asmann S. i in., *Anthropological atlas of male facial features*, Frankfurt 2007.
- Bach F., Jordan M., *Kernel independent component analysis*, "Journal of Machine Learning Research" 2002, Vol. 3.
- Balaban S., *Deep learning and face recognition: The state of the art*, "Proceeding SPIE" 2015, Vol. 9457.
- Belhumeur P.N., Hespanha J.P., Kriegman D.J., *Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 1997, Vol. 19, Iss. 7.
- Beumier C., Acheroy M., *Automatic 3D face authentication*, "Image and Vision Computing" 2000, Vol. 18, No. 4.
- Beumier C., Acheroy M., *Face verification from 3D and grey level clues*, "Pattern Recognition Letters" 2001, Vol. 22.
- Borgi M.A., El'Arbi M., Amar C.B., *Wavelet network and geometric features fusion using belief functions for 3D face recognition* [w:] Wilson R. i in. (eds), *Computer Analysis of Images and Patterns. Proceedings of the 15th International Conference, CAIP 2013, York, UK, 27–29 August 2013*, Berlin–Heidelberg 2013.
- Bowyer K.W., Chang K., Flynn P., *A survey of approaches and challenges in 3D and multimodal 3D+2D face recognition*, "Computer Vision and Image Understanding" 2006, Vol. 101, Iss. 3.
- Bruce V., Young A., *Face perception*, New York 2012.
- Bruce V., Young A., *Understanding face recognition*, "British Journal of Psychology" 1986, Vol. 77, No. 3.

- Brunelli R., Poggio T., *Face recognition: Features versus templates*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 1993, Vol. 15, No. 10.
- Buckingham G. i in., *Visual adaptation to masculine and feminine faces influences generalized preferences and perceptions of trustworthiness*, "Evolution and Human Behavior" 2006, Vol. 27, Iss. 5.
- Cevikalp H. i in., *Discriminative common vectors for face recognition*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2005, Vol. 27, Iss. 1.
- Chen J. i in., *WLD: A robust local image descriptor*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2010, Vol. 32, Iss. 9.
- Chihaoui M. i in., *Face recognition using HMM-LBP* [w:] Abraham A. i in. (eds), *Hybrid Intelligent Systems*, Cham 2015.
- Cho H. i in., *An efficient hybrid face recognition algorithm using PCA and GABOR wavelets*, "International Journal of Advanced Robotic Systems" 2014, Vol. 11, Iss. 1.
- Chua C.S., Jarvis R., *Point Signatures: A New Representation for 3D Object Recognition*, "International Journal on Computer Vision" 1997, Vol. 25.
- Damasio A.R., *Prosopagnosia*, "Trends Neurosciente" 1985, Vol. 8.
- Drira H. i in., *3D face recognition under expressions, occlusions, and pose variations*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2013, Vol. 35.
- Friedman J.H., *Regularized discriminant analysis*, "Journal of the American Statistical Association" 1989, Vol. 84, No. 405.
- Friedrich G., Yeshurun Y., *Seeing people in the dark: Face recognition in infrared images* [w:] Bülthoff H.H. i in. (eds), *Biologically Motivated Computer Vision*, Berlin 2003.
- Gao Y., Lee H.J., *Viewpoint unconstrained face recognition based on affine local descriptors and probabilistic similarity*, "Journal of Information Processing Systems" 2015, Vol. 11, Iss. 4.
- Gordon G.G., *Face Recognition Based on Depth Maps and Surface Curvature*, "Geometric Methods in Computer Vision" 1991, Vol. 1570.
- Gupta S., Markey M.K., Bovik A.C., *Advances and challenges in 3D and 2D+3D human face recognition* [w:] Zoeller E.A. (eds), *Pattern recognition research horizons*, New York 2007.
- Hashemi V.H., Gharahbagh A.A., *A novel hybrid method for face recognition based on 2d wavelet and singular value decomposition*, "American Journal of Networks and Communications" 2015, Vol. 4, Iss. 4.
- Hastie T., Buja A., Tibshirani R., *Penalized discriminant analysis*, "Annals of Statistics" 1995, Vol. 23, No. 1.
- He X. i in., *Learning a locality preserving subspace for visual recognition*, "Conference Proceedings" 2003, Vol. 1.
- Hoffmann H., *Kernel PCA for novelty detection*, "Pattern Recognit" 2007, Vol. 40, Iss. 3.
- Huang D. i in., *3-D face recognition using eLBP-based facial description and local feature hybrid matching*, "IEEE Transactions on Information Forensics and Security", Vol. 7.

- Huang, D. i in., *3D face analysis: Advances and perspectives* [w:] Sun Z. i in. (eds), *Biometric Recognition: 9th Chinese Conference on Biometric Recognition, CCBR 2014, Shenyang, China, November 7–9, 2014, Proceedings*, New York 2014.
- Hüsken M. i in., *Strategies and benefits of fusion of 2d and 3d face recognition*, "Computer Vision and Pattern Recognition" 2005, Vol. 1.
- Hyvärinen A., Oja E., *Independent Component Analysis: Algorithms and Applications*, "Neural Networks" 2000, Vol. 13, Iss. 4–5.
- Jameel S., *Face recognition system using PCA and DCT in HMM*, "International Journal of Advanced Research in Computer and Communication Engineering" 2015, Vol. 4, Iss. 1.
- Jee S.C., Yun M.H., *An anthropometric survey of Korean hand and hand shape types*, "International Journal of Industrial Ergonomics" 2016, Vol. 53.
- Jeni L.A., Hashimoto H., Kubota T., *Robust facial expression recognition using near infrared cameras*, "Journal of Advanced Computational Intelligence and Intelligent Informatics" 2012, No. 16.
- Jian Y. i in., *Two-dimensional PCA: A new approach to appearance-based face representation and recognition*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2004, Vol. 26, Iss. 1.
- Kanwisher N., McDermott J., Chun M.M., *The Fusiform Face Area: A module in human extrastriate cortex specialized for the perception of faces*, "Journal of Neuroscience" 1997, Vol. 17, Iss. 11.
- Kar A. i in., *High performance human face recognition using Gabor based pseudo hidden Markov model*, "International Journal of Applied Evolutionary Computation" 2013, Vol. 4, Iss. 1.
- Kim D.J., Lee S.H., Shon M.Q., *Face recognition via local directional pattern*, "International Journal of Security and its Applications" 2013, Vol. 7, Iss. 2.
- Kim N.-S., Do W.-H., *Classification of Elderly Women's Foot Type*, "Journal of the Korean Society of Clothing and Textiles" 2014, Vol. 38.
- Koleva M., Nacheva A., Boev M., *Somatotype and disease prevalence in adults*, "Reviews on Environmental Health" 2002, Vol. 17, Iss. 1.
- Kong S.G. i in., *Recent advances in visual and infrared face recognition — A review*, "Computer Vision and Image Understanding" 2005, Vol. 97.
- Koppen P. i in., *Gaussian mixture 3D morphable face model*, "Pattern Recognition" 2018, Vol. 74.
- Lal M. i in., *Study of Face Recognition Techniques: A Survey*, "International Journal of Advanced Computer Science and Applications" 2018, Vol. 9, Iss. 6.
- Laurentini A., Bottino A., *Computer analysis of face beauty: A survey*, "Computer Vision and Image Understanding" 2014, Vol. 125.
- Lawrence S. i in., *Face recognition: A convolutional neural-network approach*, "IEEE Transactions on Neural Network" 1997, Vol. 8, Iss. 1.
- Lee D.D., Seung H.S., *Learning the parts of objects by non-negative matrix factorization*, "Nature" 1999, Vol. 401.
- Lee T.S., *Image representation using 2D Gabor wavelets*, "IEEE Transactions

- on Pattern Analysis and Machine Intelligence” 1996, Vol. 18, Iss. 10.
- Li S.Z. i in., *Illumination invariant face recognition using near-infrared images*, “IEEE Transactions on Pattern Analysis and Machine Intelligence” 2007, Vol. 29.
- Li S.Z., Jain A.K., *Handbook of Face Recognition*, New York 2005.
- Lin Y.-L., Lee K.-L., *Investigation of anthropometry basis grouping technique for subject classification*, “Ergonomics” 1999, Vol. 42.
- Liu W., *Null space approach of fisher discriminant analysis for face recognition* [w:] Maltoni D., Jain A.K. (eds), *Biometric Authentication, Proceedings of the ECCV 2004 International Workshop on Biometric Authentication, Prague, Czech Republic, 15 May 2004*, Berlin–Heidelberg 2004.
- Lowe D.G., *Distinctive image features from scale-invariant keypoints*, “International Journal of Computer Vision” 2004, Vol. 60.
- Malousaris G.G. i in., *Somatotype, size and body composition of competitive female volleyball players*, “Journal of Science and Medicine in Sport” 2008, Vol. 11.
- Martiriggiano T. i in., *Face Recognition by Kernel Independent Component Analysis*, “IEEE Transactions on Neural Networks” 2002, Vol. 13, Iss. 6.
- Massidda M. i in., *Somatotype of elite Italian gymnasts*, “Coll Antropol” 2013, Vol. 37.
- Moreno A.B. i in., *Face Recognition using 3D Surface-Extracted Descriptors*, “Irish Machine Vision and Image Processing Conference Proceedings” 2003, Vol. 2.
- Nebti S., Fadila B., *Combining classifiers for enhanced face recognition*, “Advances in Information Science and Computer Engineering” 2015, Vol. 82.
- Nhat V.D.M., Lee S., *Block LDA for face recognition* [w:] Cabestany J., Prieto A., Sandoval F. (eds), *Computational Intelligence and Bioinspired Systems. Proceedings of the 8th International Work-Conference on Artificial Neural Networks, Barcelona, Spain, 8–10 June 2005*, Barcelona 2005.
- Ohlrogge S. i in., *Anthropological atlas of female facial features*, Frankfurt 2009.
- Ojansivu V., Heikkilä J., *Blur insensitive texture classification using local phase quantization* [w:] Elmoataz A. i in. (eds), *Image and Signal Processing. 3rd International Conference, ICISP 2008. Cherbourg-Octeville, France, July 1–3, 2008. Proceedings*, Berlin–Heidelberg 2008.
- Penev P.S., Atick J.J., *Local feature analysis: a general statistical theory for object representation*, “Network: Computation in Neural Systems” 1996, Vol. 7, No. 3.
- Phillips P.J. i in., *Face recognition vendor test 2002 evaluation report*, Gaithersburg 2003.
- Preston T.A., Singh M., *Redintegrated Somatotyping*, “Ergonomics” 1972, Vol. 15.
- Qasim A., Prashan P., Peter V., *A hybrid feature extraction technique for face recognition*, “International Proceedings of Computer Science and Information Technology” 2014, Vol. 1.

- Radhey S., Narain S.Y., *Identifying individuals using multimodal face recognition techniques*, "Procedia Computer Science" 2015, Vol. 48.
- Ritz-Timme S. i in., *A new atlas for the evaluation of facial features: Advantages, limits, and applicability*, "International Journal of Legal Medicine" 2011, Vol. 125.
- Rojas M.M., *Automatic prediction of facial trait judgments: Appearance vs. structural models*, "PLoS One" 2011, Vol. 6, Iss. 8.
- Shawe-Taylor J., Cristianini N., *Kernel Methods for Pattern Analysis*, New York 2004.
- Sheldon W., *Atlas of Men: A Guide for Somatotyping the Adult Image of All Ages*, New York 1970.
- Singha M., Deb D., Roy, S., *Hybrid feature extraction method for partial face recognition*, "International Journal of Emerging Technology and Advanced Engineering" 2014, Vol. 4.
- Socolinsky D.A., Selinger A., *Thermal face recognition in an operational scenario*, "Conference Proceedings" 2004, Vol. 2.
- Sompura M., Gupta V., *An efficient face recognition with ANN using hybrid feature extraction methods*, "International Journal of Computer Applications" 2015, Vol. 117, No. 17.
- Tamir A., *Numerical Survey of the Different Shapes of Human Chin*, "Journal of Craniofacial Surgery" 2013, Vol. 24, Iss. 5.
- Tamir A., *Numerical Survey of the Different Shapes of the Human Nose*, "Journal of Craniofacial Surgery" 2011, Vol. 22, Iss. 3.
- Tavares G., Mourão A., Magalhães J., *Crowdsourcing facial expressions for affective-interaction*, "Computer Vision and Image Understanding" 2016, Vol. 147.
- Urtasun R., Darrell T., *Discriminative Gaussian process latent variable model for classification* [w:] Ghahramani Z. (ed.), *Proceedings of the 24th international conference on Machine learning, Corvallis, OR, USA, 2007*, New York 2007.
- Vanezis P. i in., *Morphological classification of facial features in adult Caucasian males based on an assessment of photographs of 50 subjects*, "The Journal of Forensic Sciences" 1996, Vol. 41.
- Vapnik V.N., *The Nature of Statistical Learning Theory*, New York 1995.
- Vinué G., Epifanio I., Alemany S., *Archetypoids, A new approach to define representative archetypal data*, "Computational Statistics and Data Analysis" 2015, Vol. 87.
- Viola P., Jones M.J., *Robust real-time face detection*, "International Journal of Computer Vision" 2004, Vol. 57, No. 2.
- Wang Q., Li J., *Combining local and global information for nonlinear dimensionality reduction*, "Neurocomputing" 2009, Vol. 72, Iss. 10–12.
- Wang R. i in., *Multimodal biometrics based on near-infrared face* [w:] Plataniotis K.N., Boulgouris N.V., Micheli-Tzanakou E. (eds), *Biometrics: Theory, Methods, and Applications*, New Jersey 2009.
- Wang W. i in., *Discriminant analysis on riemannian manifold of Gaussian distributions for face recognition with image sets*, "Conference Proceedings" 2015, Vol. 1.

- Wiskott L. i in., *Face recognition by elastic bunch graph matching*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 1997, Vol. 19, Iss. 7.
- Wong H.S., Cheung K.K.T., Horace Ip H.H.S., *3D head model classification by evolutionary optimization of the extended Gaussian image representation*, "Pattern Recognition" 2004, Vol. 37.
- Wu F., *Face recognition based on wavelet transform and regional directional weighted local binary pattern*, "Journal of Multimedia" 2014, Vol. 9, No. 8.
- Wu Y., Pan G., Wu Z., *Face Authentication Based on Multiple Profiles Extracted from range data* [w:] Kittler J., Nixon S.M. (eds), *Proceedings of the Audio- and Video-Based Biometric Person Authentication*, Guildford 2003.
- Yang Z. i in., *Single Image 3D Face Reconstruction Based on Statistical Model*, "Journal of Physics: Conference Series" 2018, Vol. 1087, Iss. 5.
- Zhang J. i in., *Comparison of wavelet, Gabor and curvelet transform for face recognition*, "Optica Applicata" 2011, Vol. 41, No. 1.
- Zhang T. i in., *Generalized discriminant analysis: A matrix exponential approach*, "IEEE Transactions on Pattern Analysis and Machine Intelligence" 2010, Vol. 40, Iss. 1.
- Zhao W. i in., *Face recognition: a literature survey*, "ACM Computing Surveys" 2003, Vol. 35, Iss. 4.
- Zhou D., Yang X., *Face recognition using enhanced fisher linear discriminant model with Facial combined feature* [w:] Zhang C., Guesgen H.W., Yeap W.K. (eds), *PRICAI 2004: Trends in Artificial Intelligence, Proceedings of the 8th Pacific Rim International*, Berlin-Heidelberg 2004.

Inne

- Ahonen T., Hadid A., Pietikainen M., *Face recognition with local binary patterns*, <https://www.researchgate.net/publication/221304831_Face_Recognition_with_Local_Binary_Patterns>, 25 stycznia 2021 r.
- Alemaný S. i in., *Anthropometric survey of the Spanish female population aimed at the apparel industry*, <https://www.3dbodyscanning.org/cap/papers/2010/10307_11alemany.pdf>, 21 stycznia 2021 r.
- Boberg M., Piippo P., Ollila E., *Designing Avatars* [w:] *Proceedings of the 3rd International Conference on Digital Interactive Media in Entertainment and Arts, 10–12 September 2008, Athens Greece 2008*.
- Chapter 435, *Multidimensional Scaling*, <https://www.ncss.com/wp-content/themes/ncss/pdf/Procedures/NCSS/Multidimensional_Scaling.pdf>, 19 stycznia 2021 r.
- Chua C.S., Han F., Ho Y.K., *3D human face recognition using point signature* [w:] *Proceedings Fourth IEEE International Conference on Automatic Face and Gesture Recognition, 28–30 March 2000, Grenoble, France 2000*.
- Deshpande M., *Face Recognition with Eigenfaces*, <<https://pythonmachinelearning.pro/face-recognition-with-eigenfaces/>>, 29 grudnia 2020 r.

- Douros I., Buxton B.F., *Three-Dimensional Surface Curvature Estimation using Quadric Surface Patches*, <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.98.7059&rep=rep1&type=pdf>>, 25 stycznia 2021 r.
- Duffner S., Garcia C., *Face recognition using non-linear image reconstruction*, <https://www.researchgate.net/publication/4308236_Face_recognition_using_non-linear_image_reconstruction>, 22 stycznia 2021 r.
- Guo G., Li S.Z., Chan K., *Face recognition by support vector machines* [w:] *Proceedings Fourth IEEE International Conference on Automatic Face and Gesture Recognition, 28–30 March 2000, Grenoble, France 2000*.
- Huang D., Wang Y., Wang Y., *A robust method for near infrared face recognition based on extended local binary pattern*, <<http://rendicahya.lecture.ub.ac.id/files/2018/03/A-Robust-Method-for-Near-Infrared-Face-Recognition-Based-on-Extended-Local-Binary-Pattern.pdf>>, 22 stycznia 2021 r.
- Kannala J., Rahtu E., *BSIF: Binarized statistical image features* [w:] *Proceedings of the 21st International Conference on Pattern Recognition ICPR, 11–15 November 2012, Tsukuba Science City, Japan 2012*.
- Kukula E.P. i in., *Effects of illumination changes on the performance of geometrix facevision/spl reg/3d frs*. [w:] *38th Annual 2004 International Carnahan Conference on Security Technology, Albuquerque, 11–14 October 2004 NM, USA 2004*.
- Lakshmi Prabha N.S., Bhattacharya J., Majumder, S., *Face recognition using multimodal biometric features* [w:] *Proceedings of the IEEE International Conference on Image Information Processing (ICIIP), 3–5 November 2011 Shimla, India 2011*.
- Lu J.W., Plataniotis K.N., Venetsanopoulos A.N., *Boosting linear discriminant analysis for face recognition*, <https://www.researchgate.net/profile/Konstantinos_Plataniotis/publication/2247444759_Boosting_linear_discriminant_analysis_for_face_recognition/links/0f31753a4351c1151c000000/Boosting-linear-discriminant-analysis-for-face-recognition.pdf>, 22 stycznia 2021 r.
- Maurer T. i in., *Performance of Geometrix Active IDTM 3D Face Recognition Engine on the FRGC Data* [w:] *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 21–23 September 2005 San Diego, CA, USA 2005*.
- Monzo D i in., *HOG-EBGM vs. Gabor-EBGM* [w:] *15th IEEE International Conference on Image Processing, ICIP 2008, Malta 2008*.
- Ngiam J. i in., *Multimodal deep learning* [w:] *Proceedings of the 28th International Conference on Machine Learning, ICML 2011, 28 June–2 July 2011, Bellevue, WA, USA 2011*.
- Papatheodorou T., Rueckert D., *Evaluation of automatic 4D Face recognition using surface and texture registration* [w:] *Proceedings of the IEEE International Conference in Automatic Face and Gesture Recognition, 19 May 2004, Seoul, South Korea 2004*.
- Phillips P.J. i in., *Overview of the face recognition grand challenge* [w:]

- IEEE Computer Society, *Conference on Computer Vision and Pattern Recognition 20–26 June 2005, San Diego, California 2005*.
- Raducanu B., Dornaika F., *Dynamic facial expression recognition using laplacian eigenmaps-based manifold learning*, <http://www.cvc.uab.es/~bogdan/Publications/raducanu_ICRA2010.pdf>, 22 stycznia 2021 r.
- Robinette K.M., *An Alternative 3D descriptor for database mining* [w:] SAE International, *Proceedings of the Digital Human Modelling Conference, Pittsburgh 2004*.
- Rodriguez J.T., *3D Face Modelling for 2D+3D Face Recognition*, Surrey University, Guildford, UK, 2007, praca doktorska.
- Said S. i in., *Fast and efficient 3D face recognition using wavelet networks* [w:] *16th IEEE International Conference on Image Processing (ICIP), 7–10 November 2009, Cairo, Egypt 2009*.
- Sarakon P., Charoenpong T., Charoensiriwath S., *Face shape classification from 3D human data by using SVM*, <https://www.researchgate.net/publication/282382114_Face_shape_classification_from_3D_human_data_by_using_SVM>, 22 stycznia 2021 r.
- Seyed M. i in., *Geometric feature descriptor and dissimilarity-based registration of remotely sensed imagery*, <<https://doi.org/10.1371/journal.pone.0200676>>, 19 lipca 2018 r.
- Soltana W.B. i in., *Multi library wavelet neural networks for 3D face recognition using 3D facial shape representation*, <<https://zenodo.org/record/41296#.YA6mM3ZKh9M>>, 25 stycznia 2021 r.
- Suikerbuik C.A.M. i in., *Automatic feature detection in 3D human body scans*, <https://www.researchgate.net/publication/46659540_Automatic_Feature_Detection_in_3D_Human_Body_Scans>, 25 stycznia 2021 r.
- Trigueros D.S., Meng L., Hartnett M., *Face recognition: From traditional to deep learning methods*, <https://www.researchgate.net/profile/Daniel_Saez_Trigueros2/publication/328685305_Face_Recognition_From_Traditional_to_Deep_Learning_Methods/links/5d19cd21a6fdcc2462b4a85f/Face-Recognition-From-Traditional-to-Deep-Learning-Methods.pdf>, 22 stycznia 2021 r.
- Turk A., Pentland A.P., *Face recognition using eigenfaces* [w:] *IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 3–6 June 1991, Maui, HI, USA 1991*.
- Visani M., Garcia C., Jolion J.M., *Normalized radial basis function networks and bilinear discriminant analysis for face recognition*, <https://www.researchgate.net/publication/4215341_Normalized_Radial_Basis_Function_Networks_and_Bilinear_Discriminant_Analysis_for_Face_Recognition>, 22 stycznia 2021 r.
- Wang X., Tang X., *Dual-space linear discriminant analysis for face recognition* [w:] *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition, Washington, DC, USA, 27 June–2 July 2004*.
- Weinberger K.Q., Saul L.K., *Unsupervised learning of image manifolds by*

semidefinite programming, <https://repository.upenn.edu/cgi/viewcontent.cgi?article=1000&context=cis_papers>, 22 stycznia 2021 r.

Xu C. i in., *Automatic 3D Face recognition combining global geometric features with local shape variation information* [w:] *Proceedings of the IEEE International Conference on Automatic Face and Gesture Recognition, 19 May 2004, Seoul, South Korea 2004*.

Yang M.H., *Face recognition using extended isomap* [w:] *Proceedings of the IEEE International Conference on Image Processing, Rochester, USA, 22–25 September 2002, New York 2002*.

DOI: 10.5604/01.3001.0014.8469

<http://dx.doi.org/10.5604/01.3001.0014.8469>

Słowa kluczowe: rozpoznawanie twarzy, biometria, przetwarzanie obrazu, rozpoznawanie wzorców, sieć neuronowa

Streszczenie: Informatyczne technologie XX i XXI w. otworzyły drogę do automatycznej oceny antropometrycznych cech twarzy, gestów mimicznych oraz innych charakterystycznych zachowań. Rozpoznawanie człowieka to bardzo złożony problem techniczny o ogromnym znaczeniu praktycznym. W tym celu wykorzystywane są dedykowane aplikacje. W artykule przedstawiono algorytmy rozpoznawania twarzy na obrazach 2D w przestrzeniach trójwymiarowych oraz metody wykorzystujące sieci neuronowe. Przedstawiono liniowe i nieliniowe, lokalne i globalne oraz hybrydowe metody rozpoznawania twarzy. W opracowaniu uwzględniono mocne i słabe strony powyższych algorytmów oraz, o ile istniała taka możliwość, dokonano analizy ich wydajności. Przegląd metod powstał w związku z zamysłem opracowania własnego, szybkiego algorytmu wykrywania i rozpoznawania twarzy.