

## Rozpoznawanie płci z obrazu twarzy

**Streszczenie.** W artykule opisano autorski algorytm rozpoznawania płci na podstawie analizy obrazu twarzy osoby. Kolejne etapy działania algorytmu to obróbka wstępna obrazu, detekcja twarzy w obrazie, ekstrakcja i selekcja cech oraz klasyfikacja. W ramach eksperymentów określono wpływ wybranych parametrów opracowanego algorytmu na efektywność klasyfikacji oraz zaproponowano rozwiązania mające na celu poprawę jego skuteczności.

**Abstract.** The article describes the gender recognition algorithm based on facial image analysis. The subsequent stages of the algorithm are: image preprocessing, face detection, feature extraction/selection and classification. In the framework of experiments, the influence of selected algorithm parameters on the efficiency of classification was determined and proposals how to improve effectiveness of classification was described. (**Recognition of gender from a facial image**).

**Słowa kluczowe:** przetwarzanie obrazu, rozpoznawanie płci, ekstrakcja cech, klasyfikacja..

**Keywords:** image analysis, gender recognition, feature extraction, classification.

doi:10.12915/pe.2014.08.50

### Wstęp

Rozpoznawanie płci jest jedną z najbardziej podstawowych i najprostszych zdolności ludzkiej percepcji i odgrywa ogromną rolę w komunikacji społecznej. Płeć jest stosunkowo inwariantnym aspektem twarzy. W naturze, zwykle potrafimy rozpoznawać płeć na podstawie twarzy, zarówno osób nam znanych jak i nieznanymi. Bez względu na kolor skóry, fryzurę czy zarost, ludzie są w stanie określić płeć drugiej osoby ze skutecznością rzędu 96% [1]. Jednak osiągnięcie podobnego poziomu skuteczności w przypadku systemu HMI (Human-Machine Interaction), stanowi problem.

Aplikacje zawierające algorytmy rozpoznawania płci, znajdują szerokie zastosowanie przy pozyskiwaniu informacji demograficznych czy wspomaganiu marketingu. Przy projektowaniu algorytmów rozpoznawania płci z obrazu twarzy rozwiązywany jest problem przynależności obrazu do jednej z dwóch klas: kobieta, mężczyzna. Przyjmuje się, że zarejestrowane obrazy twarzy mogą być zarówno kolorowe jak i czarno-białe. Rozdzielczość obrazu oraz rasa i wiek osób nie powinny mieć wpływu na poprawność klasyfikacji.

Obrazy poddane analizie mogą zawierać wiele twarzy. Pierwszym etapem w procesie rozpoznawania płci jest detekcja twarzy w obrazie. Do realizacji tego zadania w projekcie wykorzystany został algorytm *Viola-Jones*, który bazuje na analizie cech tzw. obrazu integralnego, z wykorzystaniem falek Haara [2]. Proces klasyfikacji zrealizowano z użyciem algorytmu *AdaBoost* (kaskada klasyfikatorów) [3].

Rozwiązanie zadania rozpoznawania płci na podstawie analizy obrazu twarzy, należy rozpocząć od określenia, które części twarzy umożliwiają poprawną klasyfikację. Możliwe do wykorzystania dane dzieli się na trzy grupy:

- powierzchniowe lub lokalne, naturalne cechy twarzy jak kolor skóry, ewentualny zarost, układ brwi;
- odległościowe relacje pomiędzy cechami naturalnymi;
- różnice w trójwymiarowej strukturze twarzy.

### Algorytmy rozpoznawania płci

Opracowanie skutecznego algorytmu automatycznego rozpoznawania płci, wymaga użycia odpowiedniej bazy uczącej, zawierającej obrazy twarzy kobiet i mężczyzn. Wykorzystaną w projekcie bazą, która spełnia stosowne wymagania jest baza *FEI Face Database* [4]. Zawiera ona po 14 zdjęć każdej z 200 osób (100 kobiet i 100 mężczyzn), co daje w sumie 2800 obrazów. Wszystkie obrazy są

kolorowe i mają jasne, jednolite tło. Przykład sekwencji zdjęć z bazy FEI Face Database zamieszczono na rys. 1.



Rys. 1. Przykład sekwencji zdjęć jednej osoby z bazy FEI Face Database.

Proponowane do wykorzystania metody statystyczne wymagają dużego podobieństwa obrazów testowych do obrazów referencyjnych [5]. Dla osiągnięcia tego celu wykorzystany został proces przetwarzania wstępnego, mający na celu normalizację obrazów. Zawiera on trzy etapy takie jak:

- I. Zmiana palety barw na odcienie szarości,
- II. Przeskalowanie,
- III. Wyrównanie histogramu.

Proces rozpoznawania płci przeprowadzono z użyciem dwu niezależnych metod, wykorzystując analizę składowych głównych (PCA) oraz „fisherowską” odmianę liniowej analizy dyskryminacyjnej (FLD).

### Ekstrakcja cech - analiza składowych głównych

Analiza składowych głównych zaliczana jest do nienadzorowanych metod ekstrakcji cech, ponieważ nie uwzględnia się w niej przynależności do konkretnej klasy. W analizie składowych głównych tworzone są wektory cech jako tzw. „twarze własne” (*Eigenfaces*).

Pierwszym krokiem jest znalezienie średniej wartości dla wszystkich próbek (obrazów) [9] zbioru:  $X_j = \{x_1, x_2, \dots, x_N\}$ :

$$(1) \quad \mu = \frac{1}{N} \sum_{j=1}^N x_j$$

gdzie  $N$  to całkowita liczba obserwacji.

Wektory cech definiowane są przez liniową transformację:

$$(2) \quad y_j = W^T x_j, \quad j = 1, 2, \dots, N$$

Dalej poszukuje się tzw. macierzy rozrzutu:

$$(3) \quad S_T = \sum_{j=1}^N (x_j - \mu)(x_j - \mu)^T$$


Projekcja optymalna  $W_{opt}$  jest wybierana w taki sposób, aby maksymalizować wyznacznik macierzy rozrzutu:

$$(4) \quad W_{opt} = \arg \max_{[W]} |W^T S_T W| = [w_1, w_2 \dots w_m]$$

gdzie  $\{w_i | i = 1, 2, \dots, m\}$  stanowi zbiór  $n$ -wymiarowych wektorów własnych macierzy  $S_T$  zawierających  $m$  największych wartości własnych.

Po dokonaniu ekstrakcji cech metodą PCA, do danych wejściowych, oprócz wektorów własnych (twarzy własnych), należą również macierz przekształcenia oraz obraz średni.

Z otrzymanych wektorów własnych ("twarzy własnych") możliwe jest na powrót, odtworzenie obrazu oryginalnego. Proces ten, nazywany rekonstrukcją, zrealizowany z zachowaniem tylko tych „twarzy własnych”, które mają największe wartości własne, wiąże się z utratą informacji. Na rys. 2 przedstawiono przykładowy obraz twarzy zrekonstruowany przy wykorzystaniu różnej liczby „twarzy własnych”.



Rys. 2 Wpływ liczby „twarzy własnych” na rekonstrukcję obrazu

Baza treningowa zawiera pewną liczbę obrazów podzielonych na klasy. W procesie rozpoznawania sprawdzana jest przynależność analizowanego obrazu, o zredukowanej liczbie cech, do danej klasy poprzez obliczenie miary podobieństwa między tym obrazem a wzorcami znajdującymi się w bazie. Analizowany obraz jest przydzielony do klasy, dla której miara podobieństwa jest największa.

#### Ekstrakcja cech - liniowa analiza dyskryminacyjna

Metodą, w której dokonuje się redukcji przestrzeni cech z uwzględnieniem istnienia klas, jest liniowa analiza dyskryminacyjna (*Linear Discriminant Analysis - LDA*). Fisher sformułował zadanie analizy dyskryminacyjnej jako: „Znajdź kierunek  $a \in \mathbb{X}$ , który najlepiej rozdziela klasy w próbie uczącej. Konstruując miarę odległości między klasami uwzględnij zmienność wewnątrzgrupową” [7,8].

Metoda LDA wymaga zagregowania informacji o klasach, do których będą klasyfikowane nowe obserwacje, przy użyciu wskaźników położenia i rozproszenia w próbie uczącej [9].

Pierwszym krokiem jest znalezienie średniej wartości dla wszystkich próbek (obrazów) zbioru uczącego  $X_j = \{x_1, x_2, \dots, x_N\}$

$$(5) \quad \mu = \frac{1}{N} \sum_{j=1}^N x_j$$

gdzie  $N$  to całkowita liczba obserwacji.

Następnie znajdowana jest średnia wewnątrzgrupowa dla każdej z  $C$  klas  $X_i = \{x_1, x_2, \dots, x_K\}$ :

$$(6) \quad \mu_i = \frac{1}{K} \sum_{x_k \in X_i} x_k$$

Fundamentem metody jest znalezienie macierzy rozrzutu wewnątrzklasowego  $S_B$  oraz macierzy rozrzutu międzyklasowego  $S_W$ :

$$(7) \quad S_B = \sum_{i=1}^C N_i (\mu_i - \mu)(\mu_i - \mu)^T$$

$$(8) \quad S_W = \sum_{i=1}^C \sum_{x_k \in X_i} (x_k - \mu_i)(x_k - \mu_i)^T$$

Wymagane jest użycie takiej projekcji  $W$ , która maksymalizuje kryterium separowalności klas. W pracy [9]

zaproponowano rozwiązanie powyższego problemu poprzez rzutowanie próbek na przestrzeń o zredukowanym wymiarze. Redukcja wymiaru odbywa się przy wykorzystaniu analizy składowych głównych (PCA). Ostatecznie macierz transformacji obliczana jest z zależności:

$$(9) \quad W_{opt} = \arg \max_{[W]} \frac{|W^T S_B W|}{|W^T S_W W|} = [w_1, w_2 \dots w_m]$$

gdzie  $\{w_i | i = 1, 2, \dots, m\}$  to zbiór wektorów własnych macierzy  $S_B$  i  $S_W$  odpowiadających  $m$  największym wartościom własnym.

Okazuje się, że otrzymuje się  $C-1$  niezerowych wartości własnych, więc górna granica  $m$  to właśnie  $C-1$ , gdzie  $C$  to liczba klas [10]. Wynikową macierz transformacji tworzą tak zwane twarze „fisherowskie”, będące odpowiednikiem twarzy „własnych” metody PCA. Zgodnie z powyższymi zależnościami ich liczba wynosi  $C-1$ , co w przypadku dwuklasowego problemu rozpoznawania płci daje jedną twarz „fisherowską” (rys. 3). Przedstawiony algorytm nosi nazwę *Fisher's Linear Discriminant Analysis (FLD)*.



Rys. 3. "Twarz fisherowska" zbioru uczącego

#### Klasyfikacja

W procesie klasyfikacji, wektory cech analizowanych obrazów, są porównywane z wektorami cech obiektów bazy uczącej i na tej podstawie przypisywane do jednej z dwu klas: kobieta lub mężczyzna. Realizacja tego etapu wykonana została z użyciem trzech różnych metod: klasyfikatora  $k$  najbliższych sąsiadów ( $k$ -NN) oraz klasyfikatorów dyskryminacyjnych LDA i QDA.

Klasyfikator  $k$ -NN wskazuje, do której klasy należy dany obiekt poprzez sprawdzenie podobieństwa względem  $k$  najbliższych sąsiadów. Pierwszym krokiem jest znalezienie najbliższych sąsiadów danego obiektu, a następnie dokonanie porównań [11].

Klasyfikacja „próbek” bazująca na analizie dyskryminacyjnej polega na znalezieniu tzw. *powierzchni separujących*. Najczęściej takimi powierzchniami są hiperpłaszczyzny w przestrzeni  $N$ -wymiarowej, gdzie  $N$  to liczba wykorzystanych cech. Parametry owych hiperpłaszczyzny oblicza się poprzez analizę sekwencji treningowych. Przynależność do klas określa się sprawdzając położenie analizowanego obiektu względem powierzchni separującej. W metodzie LDA przestrzeń podzielona jest funkcją liniową, a w metodzie QDA funkcją kwadratową.

Ocena jakości pracy algorytmów polegała na analizie wpływu wybranych parametrów na skuteczność procesu rozpoznawania płci. Skuteczność rozumiana była jako stosunek liczby poprawnych rozpoznań płci do liczby wszystkich twarzy, wyrażony w procentach. Zbiór testowy stanowiła baza twarzy *Stanford Medical Student Database* [12].

#### Wyniki eksperymentów

Przebadany został wpływ liczby użytych „twarzy własnych”, dla różnych metod klasyfikacji. W tabelach 1 i 2 przedstawiono procentową skuteczności obydwu algorytmów (PCA, FLD) przy klasyfikacji, z wykorzystaniem

klasyfikatorów k-NN (dla  $k=5$ , który okazał się najlepszy), oraz LDA i QDA. Najlepsze wyniki zostały wyróżnione.

Tabela 1. Skuteczność metody PCA dla klasyfikatorów LDA i QDA

Liczba składowych	5-NN	LDA	QDA
1	73,2	81,5	82,7
2	<b>86,7</b>	<b>89,7</b>	<b>90,0</b>
3	85,2	87,2	87,0
4	83,7	89,0	71,2
5	89,0	84,7	68,5
10	85,5	81,0	61,2

Przyjęte metody klasyfikacji okazały się bardzo wrażliwe na liczbę składowych PCA. Przy większej ich liczbie skuteczność algorytmu w odczuwalny sposób spada, zwłaszcza dla klasyfikatora QDA. Dla liczby składowych wynoszącej 2 i metodzie QDA algorytm osiąga bardzo wysoką skuteczność wynoszącą 90%.

Tabela 2. Skuteczność metody FLD dla różnej liczby składowych

Liczba składowych	5-NN	LDA	QDA
1	73,2	81,5	82,7
2	<b>85,7</b>	<b>89,7</b>	<b>89,5</b>
3	79,7	87,2	85,7
4	84,2	89,0	88,7
5	83,2	84,7	83,2
10	76,2	81,0	81,2

Wyniki zawarte w tabeli 2. są bardzo zbliżone do wyników modelu PCA, wykazują takie same tendencje. Ponownie najlepszy wynik osiągnięty został dla 2 składowych. Skuteczność metody LDA w tym przypadku jest minimalnie wyższa niż QDA.

Istotą metody FLD, jest znalezienie takiego kierunku, który umożliwi najlepszą separację klas (jedna „twarz fisherowska”). Jednak nic nie stoi na przeszkodzie, by brać pod uwagę większą liczbę takich kierunków czyli „twarzy fisherowskich”.

Tabela 3. Skuteczność metody FLD dla różnej liczby „twarzy fisherowskich”

Liczba „twarzy fisherowskich”	LDA	QDA
1	81,5	82,7
2	89,7	<b>90,2</b>
3	87,2	87,0
4	89,0	71,2
5	84,7	68,5
10	81,0	61,2

Analiza wpływu ich liczby została przeprowadzona dla modelu klasyfikacji wykorzystującego klasyfikatory dyskryminacyjne, gdyż wykazywały one lepszą skuteczność dla metody FLD. Jedynym ograniczeniem przy wyborze liczby „twarzy fisherowskich” jest liczba składowych, dla którym przeprowadzony został etap PCA. Liczba „twarzy fisherowskich” musi być mniejsza lub równa liczbie składowych głównych. Autorzy zdecydowali się na przeprowadzenie badań, przy liczbie „twarzy fisherowskich” równej liczbie składowych PCA. Wyniki zawarto w tabeli 3.

Zwiększenie liczby „twarzy fisherowskich” do dwóch, dla klasyfikatora QDA poprawia skuteczność, aż do 90,2%, co jest najlepszym uzyskanym wynikiem. Dalsze dokładanie kierunków rzutowania pogarsza skuteczność algorytmu.

## Podsumowanie

Seria przeprowadzonych badań wskazuje na wysoką skuteczność metod PCA i FLDA w procesie ekstrakcji cech dla problemu rozpoznawania twarzy. Najlepszym modelem okazał się model z metodą FLD dla dwóch „twarzy fisherowskich” i klasyfikatorem QDA. Warto podkreślić, że znaczna redukcja przestrzeni cech w korzystny sposób wpływa na czas wykonywania obliczeń. Pojedynczy przypadek rozpoznawania płci zajmuje mniej niż 1s.

Najlepszy model działania algorytmu, który został wyłoniony na drodze eksperymentów, osiągnął skuteczność wynoszącą aż 90,2%. Jest to wynik pozwalający konkurować ze znanymi rozwiązaniami opublikowanymi w literaturze (88,9% [13], 99,07% [14], 98,8% [15]). Wysoka skuteczność i szybkość działania uzasadniają celowość wykorzystania systemu w zastosowaniach komercyjnych.

## LITERATURA

- [1] Burton A.M., Bruce V., Dench N., What's the difference between men and women? *Perception*, (1993).
- [2] Viola P., Jones M., Rapid object detection using a boosted cascade of simple features, *Computer Vision and Pattern Recognition*, (2001).
- [3] Freund Y., Schapire R. E., A decision-theoretic generalization of on-line learning and an application to boosting, *Proceedings of the Second European Conference on Computational Learning Theory*, London, Springer-Verlag, (1995).
- [4] <http://fei.edu.br/~cet/facedatabase.html>
- [5] Beumier C., Acheroy M., Automatic Face Recognition, *Proceedings symposium IMAGING*. Eindhoven, The Netherlands, pp.77-89, (2000).
- [6] Kukharev G., Kuźminski A., Techniki Biometryczne Część 1 Metody Rozpoznawania Twarzy. Politechnika Szczecińska Wydział Informatyki, (2003).
- [7] Fisher R. A., The Use of Multiple Measurements in Taxonomic Problems, *Annals of Eugenics* 7 (2): 179–188, (1936).
- [8] Koronacki J., Cwik J., Statystyczne systemy uczące się, Wydawnictwa Naukowo-Techniczne, Warszawa, (2005).
- [9] Belhumeur P., Hespanha J., Kriegman D., Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, *IEEE Transactions on pattern analysis and machine intelligence*, (1997).
- [10] Duda R., Hart P., Pattern Classification and Scene Analysis, New York: Wiley, (1973).
- [11] Web A. R., Statistical Pattern Recognition, John Wiley & Sons LTD, (2002).
- [12] [http://scien.stanford.edu/pages/labsite/2001/ee368/projects2001/dropbox/project16/med\\_students.tar.gz](http://scien.stanford.edu/pages/labsite/2001/ee368/projects2001/dropbox/project16/med_students.tar.gz)
- [13] Guo J., Lin C., Nguyen H., Face Gender Recognition Using Improved Appearance-Based Average Face Difference and Support Vector Machine, *International Conference on System Science and Engineering*, (2010).
- [14] Alexandre L.A., Gender recognition: A multiscale decision fusion approach, *Pattern Recognition Letters*, 31, pp. 1422-1427, (2010).
- [15] Zang J., Lu B. L., A support vector machine classifier with automatic confidence and its application to gender classification, *Neurocomputing* vol. 74, pp.1926-35, (2011).

**Autorzy:** prof. dr hab. inż. Remigiusz J. Rak, E-mail: [rakrem@iem.pw.edu.pl](mailto:rakrem@iem.pw.edu.pl); dr inż. Andrzej Majkowski, E-mail: [amajk@iem.pw.edu.pl](mailto:amajk@iem.pw.edu.pl); dr inż. Marcin Kołodziej, E-mail: [kolodzim@iem.pw.edu.pl](mailto:kolodzim@iem.pw.edu.pl); inż. Michał Nasternak, E-mail: [mn@gmail.com](mailto:mn@gmail.com), Instytut Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych, Politechnika Warszawska, ul. Koszykowa 75, 00-661 Warszawa