

Marek BŁASZCZYK

Instytut Informatyki Politechniki Śląskiej

ul. Pstrowskiego 16, 44-100 Gliwice

Metody rozpoznawania twarzy – przegląd

Streszczenie. Rozpoznawanie twarzy można rozpartywać w kategoriach klasyfikacji twarzy widzianej „en face” lub jako klasyfikacja krzywej profilu twarzy. Opublikowane dotychczas metody są adaptacjami metod heurystycznych i statystycznych nie uwzględniających specyfiki twarzy. W niniejszym opracowaniu skupiono się na skrótowym przedstawieniu opublikowanych metod klasyfikacji profilu twarzy (metody Harmona, Wu Huang) i twarzy widzianej „en face” (Nakamura) oraz najnowszych badań sugerujących użycie osiągnięć psychologii eksperymentalnej i modelowania już istniejącego systemu „naturalnego” rozpoznawania twarzy (Tigerghien, Bruyer) za pomocą technik wykorzystywanych w systemach sztucznej inteligencji.

METHODES DE RECONNAISSANCE DES VISAGES - UNE REVUE

Résumé. La reconnaissance des visages peut être faite à partir d'une image prise en face ou bien à partir de la ligne du contour pris en profil. Les méthodes publiées jusqu'au présent sont des adaptations de méthodes heuristiques et statistiques qui ne prennent pas en compte les propriétés spécifiques du problème. Dans l'article nous sommes concentrés sur un résumé des méthodes publiées pour la reconnaissance du profil (méthode de Harmon, de Wu Huang) et du visage vus en face (méthode de Nakamura), aussi bien que de la recherche récente qui suggère que les découvertes de la psychologie expérimentale soient appliquées pour modéliser le système existant "naturel" de reconnaissance des visages (Tigerghien, Bruyer) avec des techniques de l'intelligence artificielle.

FACE RECOGNITION METHODS - A SURVEY

Summary. Automatic human face recognition can be based on a front view of the face or on the curve of its profile. The methods published so far are adaptations of heuristic and statistical methods which do not take into account specific characteristics of the problem. The present article concentrates on summarizing the methods published so far for face profile recognition (Harmon, Wu Huang) and face front view recognition (Nakamura), as well as the latest research which suggests that the findings of experimental psychology be used to model the existing "natural" face recognition (Tigerghien, Bruyer) by artificial intelligence techniques.


1. Wstęp

Badania nad metodami rozpoznawania twarzy w informatyce zostały zapoczątkowane w latach siedemdziesiątych. Pierwsze opublikowane prace dotyczyły rozpoznawania profilu twarzy (metody Harmona [6], [8], [7] oraz metoda Wu-Huanga [16]). Nieco później rozpoczęto badania nad rozpoznawaniem twarzy widzianej „en face” (metoda kompresji Sirowitcha [10] czy metoda Nakamury [13]). Ostatnie lata przyniosły w tej dziedzinie zasadniczy zwrot po opublikowaniu pierwszych modeli rozpoznawania twarzy bazujących na wynikach doświadczeń przeprowadzonych w laboratoriach psychologii eksperymentalnej (Tiberghien [15], Bruyer [1]). W części (2.) przedstawiono pokrótce metody rozpoznawania twarzy poprzez klasyfikację profili. Część następną (3.) przedstawia rozpoznawanie twarzy widzianej „en face” ze szczególnym uwzględnieniem metody Nakamury. Wszystko kończy krótki przegląd modeli psychologicznych (część 4.), opis metody klasyfikacji ust (część 5.) i podsumowanie.

2. Rozpoznawanie profilu twarzy

Prace z lat 1977-90 (Harmona i Hunta [6], Harmona, Kuo (1978) [8], Harmona i Khana [7] oraz Wu i Huanga [16]) są poświęcone rozpoznawaniu profilu twarzy. Metody przedstawione w tych opracowaniach bazują na traktowaniu profilu twarzy jako krzywej charakterystycznej, której kształt i poszczególne punkty wyróżnione stanowią wektor cech charakterystycznych dla każdej twarzy. Rozpoznawanie odbywa się poprzez klasyfikację metodami statystycznymi lub heurystycznymi.

2.1. Metoda Harmona



Nr	Nazwa punktu
1	nos
2	broda
3	czoło
4	początek nosa
5	koniec nosa
6	szyja
7	warga górna
8	usta
9	warga dolna

Rys. 1. Metoda Harmona: punkty charakterystyczne
 Fig. 1. Harmon's method: characteristic points

Pierwsze podejście (1977)

Podstawy metody Harmona przedstawia atykuł [6]. Metoda Harmona jest oparta na punktach charakterystycznych profilu twarzy przedstawionych na rysunku (Rys.1) wybranych na podstawie badań antropologa F.Galtona [4].

TABLICA 1.

Definicje składowych wektora cech (Harmon 1)

Nr	NAZWA	OPIS
1	Wysokość nosa (PROT)	Odległość pomiędzy p.1 (nos) a linią poprowadzoną pomiędzy 2 i 3 (broda i czoło)
2	Powierzchnia (AREA)	Powierzchnia pomiędzy linią 2-3 i krzywą profilu
3	Kąt (ANG1)	Kąt trójkąta charakterystycznego twarzy pomiędzy liniami 2-3 i 3-1
4	Krzywizna górna (WIGU)	Srednia krzywizna górnej części profilu pomiędzy punktami 3 i 1
5	Krzywizna dolna (WIGD)	Srednia krzywizna dolnej części profilu pomiędzy punktami 1 i 2
6	Dystans (R12)	Odległość pomiędzy punktami 1 i 2
7	Dystans (R14)	Odległość pomiędzy punktami 1 i 4
8	Dystans (R15)	Odległość pomiędzy punktami 1 i 5
9	Dystans (R16)	Odległość pomiędzy punktami 1 i 6
10	Dystans (R18)	Odległość pomiędzy punktami 1 i 8
11	Dystans (R79)	Odległość pomiędzy punktami 7 i 9

Uczenie systemu: Na podstawie dziewięciu punktów charakterystycznych Harmon konstruuje wektor cech o 11 składowych. Klasyfikacja profili odbywa się na podstawie porównywania odległości znormalizowanych.

$$D^2(X, Y) = \sum_{i=1}^N \frac{(x_i - y_i)^2}{\sigma_i^2}, \quad (1)$$

gdzie x_i i y_i są i -tymi składowymi wektorów cech X i Y , a σ_i^2 jest wariancją cechy i , N jest liczbą danych profili.

Rozpoznawanie: Klasyfikacja profilu polega na wyodrębnieniu wektora charakterystycznego „nieznanego” profilu, a następnie wyborze minimalnej odległości pomiędzy wektorami bazowymi i danym wektorem w sensie dystansu znormalizowanego [wzór (1)]. W artykule [6] przytoczone są dane o rozkładach statystycznych cech wraz z dowodami o słuszności doboru składowych wektora cech. Pomimo tak szczegółowych analiz metoda jest mało skuteczna i doczekała się wkrótce krytyki oraz nowych wersji.

Drugie podejście (1978)

Poprawki wprowadzone w drugim algorytmie [8] metody Harmona usuwają niektóre błędy poprzedniej. Po raz pierwszy autorzy definiują kompletną procedurę klasyfikacji

profi. W porównaniu z metodą poprzednią można wyróżnić następujące modyfikacje:

- zwiększenie ilości wstępnych fotografii, na podstawie których tworzony jest zbiór opisu statystycznego,
- wprowadzenie zbioru opisu statystycznego z wariancją i momentami opisującymi statystyczne własności profili i poszczególnych cech,
- propozycja algorytmów klasyfikacji:
 - przez porównywanie odległości,
 - z wykorzystaniem zbioru opisu statystycznego,
 - metodą mieszaną,
- poprawa algorytmu znajdowania kątów i krzywizn w porównaniu z metodą poprzednią,
- wysokość nosa liczona jako wysokość trójkąta charakterystycznego (1-2-3).

Opis metod klasyfikacji

Klasyfikacja odbywa się nadal na podstawie tego samego wektora cech o 11 składowych.

• Przez porównywanie dystansów

Porównuje się profil klasyfikowany z każdym profilem bazowym, a następnie wybieramy ten, dla którego odległość zdefiniowana równaniem (2) jest najmniejsza.

$$D(P, R) = \sqrt{\sum_{i=1}^n \left[\frac{p_i - r_i}{\sigma_i} \right]^2}, \quad (2)$$

gdzie p_i jest cechą wektora opisującego profil r_i w zbiorze opisu statystycznego, σ_i^2 wariancją cechy w zbiorze N profili bazowych, a n jest liczbą składowych wektora cech (u Harmona $n = 11$). Harmon pokazuje trzy różne sposoby liczenia odchylenia standardowego podając skuteczność klasyfikacji dla każdej z metod (Tablica(2)).

Pierwszy:

$$\sigma_i = \sqrt{\frac{1}{N \times M} \sum_{j=1}^N \sum_{k=1}^M (r_{ijk} - \mu_i)^2}, \quad (3)$$

gdzie μ jest średnią daną wzorem:

$$\mu_i = \frac{1}{N} \sum_{j=1}^N \left(\frac{1}{M} \sum_{k=1}^M r_{ijk} \right), \quad (4)$$

dla

k - indeks fotografii (tu: $k = (1, \dots, M = 3)$ dla każdej osoby)

i - indeks cechy (tu: $i = (1, \dots, n = 11)$ cech)

j – indeks profilu (tu: $j = (1, \dots, N = 121)$ osób w eksperymencie).

Drugi:

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (r_{ij} - \mu_i)^2}, \quad (5)$$

ze średnią liczoną po fotografiach dla j -tej osoby i l -tej cechy:

$$r_{ij} = \frac{1}{M} \sum_{k=1}^M r_{ijk}. \quad (6)$$

Trzeci:

$$\sigma_i = \sqrt{\frac{1}{N} \sum_{j=1}^N \left(\frac{1}{M} \sum_{k=1}^M (r_{ijk} - r_{ij})^2 \right)}. \quad (7)$$

TABLICA 2.

Procent błędnych klasyfikacji dla różnych metod liczenia odchylenia standardowego

METODA	RÓWNANIE NR	PROCENT BŁĘDÓW
I	3	60%
II	5	20%
III	7	16%

• Przez podział zbioru opisu statystycznego

Druga metoda klasyfikacji polega na użyciu zbioru statystycznego opisu cech. Harmon wprowadza pojęcie *okna* dla każdej cechy zdefiniowanego następująco:

$$w_{ij} = \max_{k=1,2,3} \frac{|r_{ij} - r_{ijk}|}{\frac{r_{ij} - r_{ijk}}{2}}. \quad (8)$$

gdzie w_{ij} jest i -tą cechą profilu j -tej osoby i klasyfikacja (podział na grupy) odbywa się z użyciem następującej formuły:

$$\frac{|r_{ij} - r_{ijk}|}{\frac{r_{ij} - r_{ijk}}{2}} \leq w_i \quad i = 1, \dots, n = 11. \quad (9)$$

Następnie w artykule [8] (s. 305–307) przedstawione są rezultaty klasyfikacji opierając się na metodzie mieszanej, to znaczy stosując jednocześnie metodę porównywania dystansów i podziału zbioru opisu statystycznego, która pozwala na osiągnięcie skuteczności 85%–100%.

Sukcesem tej metody [8] (s. 311) jest pozbycie się dużych współczynników korelacji pomiędzy cechami.

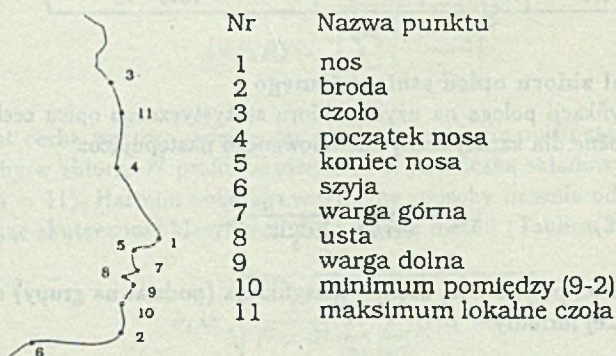
TABLICA 3.

Definicje składowych wektora cech (Harmon 3)

Nr	CECHA	UWAGA
1	Kąt 1-2-3 ϕ	stara cecha nr 3
2	Kąt 1-3-4 ψ	
3	Kąt 4-1-5 α	
4	Powierzchnia 2-3	stara cecha nr 2
5	Powierzchnia 10-6	
6	Dystans 1-2	stara cecha nr 6 (R12)
7	Dystans 1-4	stara cecha nr 7 (R14)
8	Dystans 1-5	stara cecha nr 8 (R15)
9	Dystans 1-6	stara cecha nr 9 (R16)
10	Dystans 1-8	stara cecha nr 10 (R18)
11	Dystans 3-4	
12	Dystans 4-2	
13	Dystans 5-10	
14	Dystans 7-9	stara cecha nr 11 (R79)
15	Współczynnik R12 R14	
16	Krzywizna górna	stara cecha nr 4
17	Krzywizna dolna	stara cecha nr 5

Trzecie podejście

W roku 1981 Harmon proponuje kolejną modyfikację metody rozpoznawania profilu. W porównaniu do poprzednich propozycji autor wprowadza dwa nowe punkty charakterystyczne 10 i 11 (Rys. 2) i zwiększa liczbę cech do 17 (Tablica (3)).

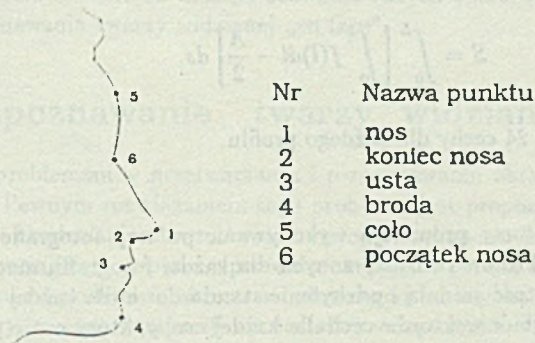


Rys. 2. Trzecia metoda Harmona: Punkty charakterystyczne
Fig. 2. Third Harmon's method: characteristic points

Autor przeprowadzając taką samą analizę statystyczną jak poprzednio [7] (s. 100-110) wykazuje, że skuteczność metody wzrasta aż do 96 % dla zbioru 112 osób biorących udział w eksperymencie.

2.2. Metoda Wu i Huanga

Ostatnią opublikowaną metodą rozpoznawania profilu twarzy jest algorytm Wu i Huanga [16] (1990). Jest to udoskonalona metoda Harmona stosująca 6 punktów charakterystycznych i 24-elementowy wektor cech (Rys.3).



Rys. 3. Metoda Wu & Huanga: punkty charakterystyczne
Fig. 3. Wu & Hang's method: characteristic points

Opis metody

Krzywa profilu jest aproksymowana krzywą β -sklejaną [11], co praktycznie umożliwiło znormalizowanie długości krzywej profilu. Profil dzielony jest na 5 segmentów wyznaczonych przez 6 punktów charakterystycznych. Segmenty są aproksymowane β -splineami rzędu trzeciego. Dla każdego segmentu autorzy proponują przyjąć po 5 cech:

1. Odległość w sensie euklidesowym pomiędzy dwoma punktami charakterystycznymi $P_i(x_i, y_i)$ i $P_j(x_j, y_j)$

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (10)$$

2. Kąty pomiędzy sąsiednimi segmentami krzywej profilu

$$\Theta = \arccos \frac{(x_i - x_j)(x_j - x_k) + (y_i - y_j)(y_j - y_k)}{d_{ij} \times d_{jk}} \quad (11)$$

liczonymi pomiędzy trzema punktami charakterystycznymi $P_i(x_i, y_i)$, $P_j(x_j, y_j)$ i $P_k(x_k, y_k)$

3. Długość krzywej liczoną jako liczbę punktów segmentu aproksymowanego L

4. Krzywiznę segmentu

$$A = \int_0^L f(l) dl \quad (12)$$

gdzie $f(l)$ jest funkcją krzywej zdefiniowanej β -splineem rzędu trzeciego [11]

$$f(i) = \frac{4}{[(x_{i+1} - x_{i-1})^2 + (y_{i+1} - y_{i-1})^2]^{\frac{3}{2}}}$$

$$\begin{aligned} & \times [(x_{i+1} - x_{i-1})(y_{i-1} - 2y_i + y_{i+1}) \\ & - (y_{i+1} - y_{i-1})(x_{i-1} - 2x_i + x_{i+1})] \end{aligned} \quad (13)$$

gdzie (x_i, y_i) jest i -tym punktem krzywej.

5. Miara symetrii każdej krzywej

$$S = \int_0^L \left[\int_0^s f(t) dt - \frac{A}{2} \right] ds. \quad (14)$$

W ten sposób otrzymano 24 cechy dla każdego profilu.

Rozpoznawanie

Uczenie systemu: Autorzy proponują wykonywanie po trzy fotografie dla każdego profilu. Na podstawie wektorów cech tworzonych dla każdej fotografii, metodami statystycznymi określa się wartość średnią i odchylenie standardowe dla każdej cechy. Na tej podstawie tworzony jest zbiór wektorów cech dla każdej osoby, który może podlegać modyfikacjom w trakcie przybywania nowych profili [16].

Rozpoznawanie: Dla profilu „nieznanego” są wyznaczane 24 cechy stanowiące wektor charakterystyczny, dla którego liczone są odległości według następującego wzoru:

$$d = \sum_{i=1}^{24} \frac{|X_i - \mu_i|}{\sigma_i}, \quad (15)$$

gdzie X_i są wartościami wektora cech, μ_i i σ_i są odpowiednio: średnią i odchyleniem standardowym i -tej cechy

Metoda rozpoznawania oparta jest na heurystycznym rozpatrywaniu każdego profilu wejściowego i porównywaniu z danymi zgromadzonymi w fazie uczenia systemu. Odrzucenie cechy odbywa się w przypadku, gdy i -ta cecha nie należy do przedziału ufności $\mu_i \pm 20\sigma_i$ wyznaczonego empirycznie.

2.3. Podsumowanie metod rozpoznawania profilu twarzy

TABLICA 4.

Porównanie metod rozpoznawania profilu twarzy

METODA	SKUTECZNOŚĆ	WSTĘPNE PRZETWARZANIE PROFILU	LICZBA PUNKTÓW CHARAKTERYSTYCZNYCH	LICZBA CECH	ALGORYTM KLASYFIKACJI
Harmon 2	85%	—	9	11	statystyczny
Harmon 3	96%	—	11	17	statystyczny
Wu&Huang	100%	δ -spline	6	24	heurystyczny

Tablica (4) przedstawia porównanie skuteczności przedstawionych metod rozpoznawania profilu twarzy w zależności od liczby punktów charakterystycznych, liczby cech i algorytmu klasyfikacji. Należy zauważyć, że wszystkie przedstawione powyżej metody

opierają się na badaniach Harmona i są kolejnymi modyfikacjami jego metod, które poprawiały skuteczność rozpoznawania. Eksperymenty przedstawione w publikacjach obejmowały typy profili najczęściej spotykanych (twarze bez nadmiernych zniekształceń, bez zarostu itp.) oraz niewielką liczbę osób, co dodatkowo podważa wszelkie uogólnienia statystyczne. Mimo to należy odnotować istnienie skutecznej metody rozpoznawania profilu twarzy w przeciwieństwie do niezbyt zaawansowanych badań (opublikowanych) w dziedzinie rozpoznawania twarzy widzianej „en face”.

3. Rozpoznawanie twarzy widzianej „en face”

Wielkim problemem w przetwarzaniu i rozpoznawaniu obrazów są rozmiary danych wejściowych. Pewnym rozwiązaniem tego problemu jest propozycja Sirovitcha Kirby'go [10] kompresji i kodowania obrazu twarzy metodą Karhunen-Löve [3]. Skuteczność kompresji 100:1 osiągnięto poprzez wprowadzenie pojęcia obrazu własnego i metody rekonstrukcji obrazu na podstawie obrazu uśrednionego i tablicy wartości własnych. Niestety, jak do tej pory, metoda kompresji nie została zaadoptowana do systemu rozpoznawania twarzy.

3.1. Metoda Nakamury

Innym kompletnym rozwiązaniem jest propozycja O. Nakamury [13] oparta na klasyfikacji obszarów o jednakowych poziomach szarości w obrazie twarzy. Sposób ten charakteryzuje się prostotą i, według autora, skutecznością 100%.

Opis metody

Przetwarzanie wstępne

1. Wyodrębnienie konturu twarzy z zastosowaniem operatora Sobela S_0 zdefiniowanego:

$$S_0 = |X_4 + 2X_3 + X_2 - X_6 - 2X_7 - X_8| + |X_4 + 2X_5 + X_6 - X_2 - 2X_1 - X_8|, \quad (16)$$

gdzie X_i są wartościami poziomów szarości w otoczeniu punktu X_0 (Rys.4).

X_4	X_3	X_2
X_5	X_0	X_1
X_6	X_7	X_8

Rys. 4. Okno w operatorze Sobela

Fig. 4. Sobel's window

Kontur jest zdefiniowany jako:

$$X' = \begin{cases} 1, & \text{dla } X \geq T_h, \\ 0, & \text{dla } X < T_h, \end{cases}$$

gdzie T_k jest wartością progu wyznaczonego empirycznie, a X'

$$X' = S_0 - \sum_{i=1}^8 \frac{S_i}{8}, \quad (17)$$

gdzie S_i jest wartością operatora Sobela w otoczeniu punktu X_i .

2. Eliminacja nieciągłości konturu – metoda wymaga, aby cały kontur był krzywą zamkniętą.

3. Wycięcie obszaru twarzy. Zastąpienie wartością 0 każdego piksela znajdującego się poza obszarem twarzy, na zewnątrz konturu.

4. Wygładzenie konturu i normalizacja obszaru twarzy. Jeśli piksel należy do twarzy, to zwracana jest wartość 1, jeśli nie 0. Algorytm przedstawia się następująco:

Jeśli $X(i)$ jest pikselem bieżącym i $X(j)$, ($j = 1, \dots, 8$) są wartościami z jego otoczenia (Rys. 4), wtedy:

1. Jeśli $X(i)$ jest 0 i warunek (18) jest prawdziwy, wtedy wartość $X(i)$ zmienia się z 0 na wartość średnią w sąsiedztwie punktu X_i .

$$\sum_{j=k}^{k+1} X(j) = 5; k = 1, 3, 5, 7 \quad (18)$$

2. Jeśli $X(i)$ jest równe 1 i warunek (19) jest spełniony, wtedy wartość $X(i)$ jest zastępowana przez 0.

$$1 \leq \sum_{j=k}^{k+2} X(j) \leq 3 \quad \wedge \quad \sum_{j=k+3}^{k+7} X(j) = 0; k = 1, \dots, 8. \quad (19)$$

Bliższe szczegóły dotyczące implementacji zamieszczone są w artykule [13] (s. 266).

Wyodrębnianie linii otaczających obszary o jednakowym stopniu szarości

Przedstawiana metoda bazuje na możliwości reprezentacji trzeciego wymiaru w sposób symboliczny, jak w kartografii, liniami otaczającymi obszary o jednakowej wysokości. Nakamura zakłada, że przy jednolitym kolorze twarzy linie otaczające obszary o jednakowym stopniu szarości będą przedstawiać topologię twarzy, na podstawie której odbywa się jej klasyfikacja.

Algorytm ekstrakcji linii opiera się na podziale histogramu obrazu na osiem przedziałów o różnych szerokościach zależnych od natury obrazu. Następnie linia prowadzona jest wokół obszarów o stopniach szarości należących do danych przedziałów. Linie tak uzyskane tworzą bazę do kodowania danej twarzy.

Klasyfikacja

Autor jest przekonany, że linie otaczające obszary o jednakowych stopniach szarości charakteryzują jednoznacznie twarz. Nie istnieje zbiór tych samych linii dla dwu różnych osób. Na tej przesłance klasyfikuje się obrazy twarzy licząc odpowiedni współczynnik klasyfikacji [13] (s. 266–271). Zaletą tej metody jest jej duża skuteczność, opis twarzy może być łatwo porównywany metodami klasycznymi, cechy są w miarę stabilne zależne jedynie od pozycji, w jakiej twarz jest prezentowana.

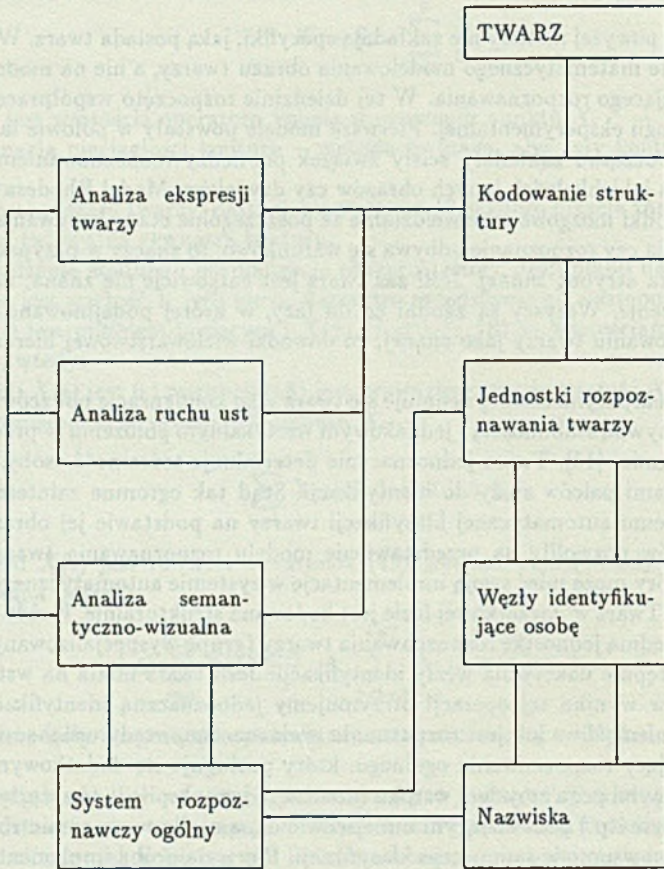
4. Rozpoznawanie twarzy a sztuczna inteligencja

Przedstawione powyżej metody nie zakładają specyfiki, jaką posiada twarz. Wszystkie oparte są na próbie matematycznego modelowania obrazu twarzy, a nie na modelowaniu systemu już istniejącego rozpoznawania. W tej dziedzinie rozpoczęto współpracę z laboratoriami psychologii eksperymentalnej. Pierwsze modele powstały w połowie lat osiemdziesiątych i od początku zakładały ścisły związek pomiędzy rozpoznawaniem twarzy a rozpoznawaniem jakichkolwiek innych obrazów czy dźwięków. Model Rhodessa [14] lokalizuje nawet ośrodki mózgowie odpowiedzialne za poszczególne etapy kodowania obrazu twarzy. Klasyfikacja czy rozpoznanie odbywa się warunkowo, to znaczy w przypadku, gdy dana twarz posiada atrybut *znanej*. Jeśli zaś twarz jest całkowicie nieznana, następuje automatyczne uczenie. Wszyscy są zgodni co do fazy, w której podejmowana jest decyzja o zakwalifikowaniu twarzy jako znanej, co dowodzi wielowarstwowej hierarchizacji kodowania.

W psychologii eksperymentalnej definiuje się twarz jako konfigurację bodźców charakteryzującą się relatywną stabilnością i jednakowym wertykalnym położeniem w przestrzeni, o strukturalnej formie [15]. Twarz jednoznacznie determinuje tożsamość osoby, dlatego na równi z odciskami palców służy do identyfikacji. Stąd tak ogromne zainteresowanie w stworzeniu systemu automatycznej klasyfikacji twarzy na podstawie jej obrazu. Wyniki eksperymentów pozwoliły na przedstawienie modelu rozpoznawania twarzy przez człowieka [15], który może mieć swoją implementację w systemie automatycznego rozpoznawania (Rys.5). Twarz w początkowej fazie jest kodowana strukturalnie. Każdy element uaktywnia odpowiednią jednostkę rozpoznawania twarzy (grupę wyspecjalizowanych neuronów), która następnie uaktywnia węzły identyfikacji. Jeśli twarz miała na wstępie atrybut *znanej*, to w wyniku tej operacji otrzymujemy jednoznaczną identyfikację, jeśli natomiast jest to niemożliwe lub jest rozpoznanie wieloznaczne, wtedy uruchamiany jest system wspomagający rozpoznawania ogólnego, który posługuje się dodatkowymi informacjami uzyskiwanymi poza zmysłem wzroku (analiza mowy, ekspresja twarzy, wrażenia, dane o płci, zawodzie itp.) pozwalającym umiejscowić daną osobę w otoczeniu rozpoznającego i tym samym wspomóc sam proces klasyfikacji. Pierwszą próbą implementacji jest system, stworzony w laboratorium Profesora Tiberghiena w Grenoble, który symuluje zachowanie się naturalnego systemu za pomocą sieci neuronowych. Tam też opracowano przetwarzanie i wstępne kodowanie struktury syntaktycznej i geometrycznej twarzy. Na tej podstawie dokonuje się klasyfikacji za pomocą sieci neuronowych. Niestety, jest to jeszcze metoda bardzo kosztowna obliczeniowo i rezultaty mają jak dotychczas charakter eksperymentalno-teoretyczny.

5. Rozpoznawanie elementów twarzy – usta

Zgodnie z sugestią przedstawioną w pracy [15] naturalnym sposobem rozpoznawania twarzy jest rozpoznawanie i kodowanie poszczególnych elementów jej struktury. Jednym z takich elementów są usta.



Rys. 5. Model Tiberghiena

Fig. 5. Tiberghien's model

5.1. Klasyfikacja ust

Usta stanowią relatywnie stabilny element twarzy. Ich kształt, charakterystyczny dla poszczególnych twarzy, może być jedną z cech klasyfikujących całą twarz. Podejście do tego problemu jest całkowicie tradycyjne – polega na wyodrębnieniu ust jako elementu o charakterystycznym kształcie, zakodowaniu i określeniu skutecznego algorytmu ich klasyfikacji.

Wyodrębnienie ust

W badaniach zastosowano obraz twarzy 512×512 punktów w 16 poziomach szarości. Wyodrębnienie ust polegało na sekwencyjnym stosowaniu filtracji poprawiającej jakość obrazu i znajdowaniu konturu ust za pomocą operatorów Frei i Chena [2].

Kodowanie

Kontur następnie został zakodowany za pomocą kodu łańcuchowego ośmioelementowego Freemana [5]. Łańcuch w ten sposób otrzymany był traktowany jako wektor cech charakterystycznych i stanowił część bazy wiedzy.

Klasyfikacja

Po utworzeniu bazy wiedzy z zapamiętanymi wektorami cech wszystkich ust klasyfikacja polegała na sukcesywnym liczeniu dystansu pomiędzy wektorem cech ust „do rozpoznania” i wszystkimi wektorami bazy. Dystans określano na podstawie algorytmu Wagnera-Fischera [12]. Usta klasyfikowano na podstawie minimalnego dystansu.

5.2. Eksperyment

W eksperymencie uczestniczyło 5 osób. Każdej osobie wykonywano dwie fotografie w różnym czasie. Fotografie pierwszej serii służyły do stworzenia bazy wiedzy, a fotografie serii drugiej jako dane, na podstawie których badano skuteczność algorytmu klasyfikacji. Wyniki eksperymentu przedstawia tablica 5.

TABLICA 5.

Wyniki klasyfikacji (Odległości)

	1	2	3	4	5
1	169	368	264	204	210
2	370	141	370	343	340
3	294	448	277	246	328
4	337	314	320	180	206
5	264	292	307	192	190

Na osi poziomej są umieszczone numery fotografii pierwszej serii, na pionowej drugiej. Tablica przedstawia odległości w sensie Wagnera-Fischera. Jak można zauważyć w 4 przypadkach na pięć, algorytm działa poprawnie (minimalna odległość na głównej przekątnej), w jednym natomiast przypadku, na skutek podobieństwa, rezultat jest błędny. Eliminuje to metodę jako jedyny klasyfikator twarzy, ale nie jako klasyfikator samych ust będących jednym z elementów twarzy.

6. Podsumowanie

Jak nie trudno zauważyć, że rozpoznawanie twarzy nie doczekało się dotychczas pełnego systemu pracującego niezawodnie. Prace w tej dziedzinie można podzielić na dwa nurty, tradycyjny i nowoczesny oparty na ścisłej współpracy interdyscyplinarnej, oczywiście bez rozstrzygnięcia o wyższości jednego nad drugim. Wielkie nadzieje budzi aktualnie podejście nietradycyjne, łączące ze sobą doświadczenia psychologii poznawczej i sztucznej inteligencji, poprzez bardziej globalne spojrzenie na naturę problemu. Prawdopodobnie tu należy szukać drogi do automatycznego rozpoznawania twarzy.

LITERATURA

- [1] BRUYER R. *Les Mécanismes de la Reconnaissance des Visages*. Press Universitaires de Grenoble Grenoble (1987).
- [2] FREI W. CHEN C.C. Fast boundary detection: a generalization and a new algorithm. *IEEE Trans. Pattern Analysis and Machine Intelligence* 6 (1), s. 58-68, (1977).
- [3] FUKUNAGA K. *Introduction to Statistical Pattern Recognition* New York Academic, 1972.
- [4] GALTON F. Personal identification and description *Nature*, 21 June, s. 173-177; 28 June, s. 201-202, (1888).
- [5] GONZALEZ R.C. WINTZ P. *Digital Image Processing*. Addison-Wesley (1987).
- [6] HARMON L.D. HUNT W.F. Automatic recognition of human face profiles *Computer Graphics and Image Processing*, Vol.6, s. 136-156, (1977).
- [7] HARMON L.D. KHAN M.K. LASCH R. RAMIG P.F. Machine identification of human faces *Pattern Recognition*, Vol. 13, nr 2, s. 97-110, (1981).
- [8] HARMON L.D. KUO S.C. RAUDKIVI U. Identification of human face profiles by computer *Pattern Recognition*, Vol.10, s. 301-312, (1978).
- [9] KIRBY M. SIROVITCH L. Low-dimensional procedure for the characterization of human faces, *J. Opt. Soc. Am. A*, Vol. 4, nr 3 March (1987).
- [10] KIRBY M. SIROVITCH L. Application of the Karhunen-Löve procedure for the characterization of human faces *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 12, nr 1, s. 103-108, (1990).
- [11] MEDIONI G. YASUMOTO Y. Corner detection and curve representation using cubic B-splines. *Computer Vision Image Processing* 1987, 37, s. 267-278. (1987).
- [12] MICLET L. *Méthodes structurelles pour la reconnaissance des formes*. EYROLLES Paris (1984).

- [13] NAKAMURA O. MATHUR S. MINAMI T. Identification of human faces based on isodensity Maps, *Pattern Recognition*, Vol. 24, s. 263-272, (1991).
- [14] RHODES G. Lateralized processes in face recognition. *British Journal of Psychology*, 1985, 76, s. 249-271.
- [15] TIBERGHEN G. Perception et mémoire des visages *Intellectica*, n° 5, s. 89-111, (1988).
- [16] WU CH.J. HUANG J.S. Human face profile recognition by computer *Pattern Recognition*, Vol. 23, s. 255-259, (1990).

Recenzent: Doc. dr hab. inż. Adam Mrózek

Wpłynęło do Redakcji dnia 31.08.92

Abstract

The face recognition methods have been developed since the seventies. The first approach based upon the face profile treated as the characteristic curve.

Harmon [1977] considered nine distinctive points lying on the profile curve and built the vector of eleven characteristic features derived from the relations between those points. Afterwards, he calculated the normalized distances between the vector components. The results of this method turned out to be insufficient in application. So, Harmon put forward its modifications: in 1978 and in 1981. Eventually, he got 96% adequate answers for profile samples of 112 people.

Harmon's statistical algorithms were improved in 1990 by Wu and Huang who also introduced some heuristic additions. They took only six characteristic points of the profile but the constructed characteristic vector consisted of 24 elements. The profile curve was prepared for the processing by β -spline approximation. Efficiency of this method is 100 per cent.

The front-view face recognition methods are not so advanced as those previously described. Nakamura [1991] extracted from the face the regions of the same grey level. The boundary curves of these regions form contour lines on the face map. He claims 100% efficiency of his method.

The latest methods of face recognition contain some factors taken from experimental psychology allowing one to reconstruct elements of natural process of face recognition. They are also a field for applying the artificial intelligence methods.

As a practical example the separation, coding and classification of pictures of human mouths were presented.