

Ernest CZOGAŁA, Jerzy IHNATOWICZ
Józef JAGIELSKI, Jan WALICHIEWICZ

ZASTOSOWANIE ESTYMATORA WSPÓŁCZYNNIKA KORELACJI DO KONSTRUKCJI ALGORYTMU KLASYFIKACJI OBRAZÓW O NIEREGULARNYCH KONTURACH

Streszczenie. Praca zawiera rozważania dotyczące możliwości zastosowania estymatora współczynnika korelacji dla celów rozpoznawania i klasyfikacji obrazów o nieregularnych konturach, opisanych przy pomocy łańcuchowych funkcji autokorelacji.

Przedstawiono algorytm klasyfikacji, w którym wykorzystano omawianą metodę rozpoznawania obrazów oraz omówiono uzyskane wyniki.

Wprowadzenie

W dotychczasowych pracach nad rozpoznawaniem obrazów przy pomocy maszyny cyfrowej, zarówno z nauczycielem jak i bez nauczyciela przedstawiano algorytmy opierające się w zasadzie na różnych rodzajach norm reprezentujących odległości w przestrzeni cech tych obrazów [1]. W przypadku zadania klasyfikacji prezentowanego w niniejszej pracy, zwanego też uczeniem bez nauczyciela, maszynie cyfrowej kolejno przedstawia się obrazy, nie podając żadnej informacji do jakiej klasy obrazy te należą. Maszyna powinna obiekty te sklasyfikować na podstawie ich "podobieństwa", dzieląc cały zbiór obiektów na podzbiory obiektów "podobnych". Rozwiązanie tego zadania wymaga uprzedniej formalizacji intuicyjnego pojęcia podobieństwa. Pojęcie to stosuje człowiek w rozmaitych aspektach i dlatego możliwe są rozmaite jego formalizacje [1].

W niniejszej pracy zaproponowano stopień podobieństwa obrazów, wykorzystując tzw. łańcuchową funkcję autokorelacji wyznaczaną na podstawie znajomości przebiegu linii konturowej obrazu. Prezentowaną metodą pozwala prawidłowo klasyfikować zbiory obrazów o nieregularnych konturach przez określanie podzbiorów obiektów podobnych.

W metodzie tej przyjmuje się stopień podobieństwa obrazów jako funkcję realizacji współczynnika korelacji liniowej między łańcuchowymi funkcjami autokorelacji będącymi dogodnymi niezmiennikami konturów, trudnych do scharakteryzowania w inny sposób. Prezentowane rozważania wykorzystano do praktycznej realizacji algorytmu zastosowanego do klasyfikacji rzeczywistych obrazów o nieregularnych konturach.

1. Sformułowanie problemu

Rozpatrzmy zadanie klasyfikacji zbioru obrazów o nieregularnych konturach zapisanych w postaci odpowiednich łańcuchów wg powszechnie stosowanego schematu kodowego Freemana [4, 3].

Przyjmujemy całkowitą dowolność położenia, kątów obrotu konturów względem przyjętego układu współrzędnych, losowy wybór punktów uznanych za początki konturów oraz dowolne kierunki kodowania. Obrazy te należy sklasyfikować poprzez połączenie ich np. w pary a następnie w grupy.


Dla konturu A (rys. 1) zapisanego w postaci:

$$A = a_1 a_2 \dots a_n = \prod_{i=1}^n a_i \quad (1)$$

gdzie:

C - oznacza symbol uszeregowania ogniw łańcucha a_i , najbardziej użyteczną dla celów klasyfikacji jest łańcuchowa funkcja autokorelacji zaproponowana przez Freemana [4]. Funkcja ta zapisana wzorem:

$$K_{aa}(j) = \frac{1}{n} \sum_{i=1}^n \cos(a_i - a_{i+j}) \frac{\pi}{4} \quad (2)$$



Rys. 1. Przykład opisu konturu przy pomocy schematu kodowego Freemana

spełnie podane powyżej postulaty; jest zatem dobrym niezmiennikiem charakteryzującym kontur. Dostarcza ona przeciętnej (uśrednionej) miary uszeregowania par ogniw łańcucha, stanowiąc zarazem podstawową informację statystyczną o konturze. Interesujące własności tej funkcji omówiono w pracy [5]. Obliczone w powyższy sposób łańcuchowe funkcje autokorelacji stanowią podstawę do określenia stopnia podobieństwa obrazów.

W niniejszych rozważaniach stopień podobieństwa wyznacza się przez porównywanie między sobą łańcuchowych funkcji autokorelacji wszystkich możliwych par tworzonych w zbiorze obiektów. Należy ponadto uwzględnić pewne problemy związane z porównywaniem łańcuchowych funkcji autokorelacji odpowiadających obrazom o różnych długościach linii konturowych. Problemy te można sprowadzić do stosowania różnego rodzaju ekstrapolacji.

Stopień podobieństwa między dwoma konturami oznaczonymi odpowiednio i oraz j zapiszemy wzorem:

$$P_{ij} = 1 - \frac{e_{ij}}{(e_{ij})_{\max}} \quad (3)$$

gdzie:

e_{ij} - stanowi miarę odchylenia między łańcuchowymi funkcjami autokorelacji odpowiadających tym

konturom. Znajomość wartości stopni podobieństwa pozwala na podejmowanie decyzji przy wyborze odpowiednich par. Za miarę odchylenia przyjęto wartości estymatora współczynnika korelacji liniowej [2]

$$Q_{ij} = \frac{\text{Cov}(X_i, Y_j)}{S_{X_i} S_{Y_j}} \quad (4)$$

dla pary zmiennych losowych X_i, Y_j reprezentujących łańcuchowe funkcje autokorelacji i-tego i j-tego konturu. Realizację tego estymatora można zapisać w postaci

$$r_{ij} = \hat{Q}_{ij} = \frac{s_{X_i Y_j}}{s_{X_i} s_{Y_j}} = \frac{\sum_{k=1}^N (x_{ik} - \bar{x}_i)(y_{jk} - \bar{y}_j)}{\left[\sum_{k=1}^N (x_{ik} - \bar{x}_i)^2 \sum_{k=1}^N (y_{jk} - \bar{y}_j)^2 \right]^{1/2}} \quad (5)$$

przy czym zakłada się, że zmienne losowe X_i, Y_j są próbkowane w wyniku czego uzyskuje się N par wartości.

Dokładność estymatora r_{ij} można ocenić, posługując się następującą funkcją argumentu r_{ij} [2]:

$$w = \frac{1}{2} \ln \frac{1 + r_{ij}}{1 - r_{ij}} \quad (6)$$

Zmienna losowa W , której realizację określa powyższy wzór, posiada rozkład normalny, przy czym wartość średnia i wariancja wyrażają się wzorami:

$$m_W = \frac{1}{2} \ln \frac{1 + r_{ij}}{1 - r_{ij}} \quad (7)$$

$$G_W^2 = \frac{1}{N-3} \quad (8)$$

W celu wyznaczenia przedziału ufności dla współczynnika korelacji Q_{ij} można stosować następujący wzór [5] dla dużej próby

$$P \left\{ r_{ij} - z \frac{1-r_{ij}^2}{\sqrt{N}} < Q_{ij} < r_{ij} + z \frac{1-r_{ij}^2}{\sqrt{N}} \right\} = 1 - \alpha \quad (9)$$

Z uwagi na zmienność estymatora współczynnika korelacji wskazane jest sprawdzenie, czy niezerowa wartość współczynnika korelacji z próby faktycznie odzwierciedla istnienie korelacji statystycznej między interesującymi nas konturami. Można tego dokonać weryfikując hipotezę $H_0: Q_{ij} = 0$. Odrzucając tę hipotezę można przyjąć korelację pomiędzy X_i i Y_j za istotną.

Z normalności rozkładu zmiennej W przy $Q_{ij} = 0$ wynika, że:

$$m_W = 0 \quad (10)$$

$$G_W^2 = \frac{1}{N-3}$$

Przedział akceptacji hipotezy o zerowym współczynniku korelacji jest następujący:

$$-z_{\frac{\alpha}{2}} \frac{\sqrt{N-3}}{2} \ln \frac{1+r_{1j}}{1-r_{1j}} < z_{\frac{\alpha}{2}} \quad (11)$$

gdzie:

$z_{\frac{\alpha}{2}}$ - jest wartością standaryzowanej zmiennej losowej o rozkładzie normalnym przy założonym poziomie istotności α .

Prezentowanego powyżej estymatora współczynnika korelacji można użyć jako miary podobieństwa dwóch funkcji.

Przyjmując przekształcenie liniowe dla estymatora współczynnika korelacji można uzyskać prosto stopień podobieństwa w postaci

$$P_{1j} = 1 - \frac{(r_{1j})_{\max} - r_{1j}}{(r_{1j})_{\max} - (r_{1j})_{\min}} \quad (12)$$

Powyższe rozważania stanowią podstawę konstrukcji algorytmu klasyfikacji obrazów o nieregularnych konturach, którego opis podano poniżej.



Algorytm klasyfikacji obrazów o nieregularnych konturach

Omawianą powyżej łańcuchową funkcję autokorelacji zastosowano do klasyfikacji grupy N obrazów o dużej nieregularności i stopniu złożoności konturów.

Dla każdego konturu, opisanego łańcuchem kodowym Freemana, można wyznaczyć łańcuchową funkcję autokorelacji, zawierającą podstawową informację statystyczną o danym konturze.

Zagadnienie rozpoznawania obrazów można więc sprowadzić do problemu łączenia ich w pary, uwzględniając podobieństwo kształtów dobieranych konturów. Zamiast rozważać podobieństwo kształtów konturów znacznie łatwiej jest rozważać podobieństwa łańcuchowych funkcji autokorelacji, odpowiadających poszczególnym konturom.

Wystarczy zatem wyznaczyć łańcuchowe funkcje autokorelacji dla każdego z klasyfikowanych konturów, a następnie dobrać w pary najbardziej podobne do siebie funkcje, ze względu na przyjęte kryteria podobieństwa. Łatwo zauważyć, że ze względu na możliwą rozpiętość wielkości N obrazów przyjętych do klasyfikacji, powstaje problem porównywania między sobą łańcuchowych funkcji autokorelacji odpowiadających łańcuchom kodowym o różnej liczbie ogniw. Można wykazać, że przy porównywaniu między sobą takich funkcji, najkorzystniej jest dokonać ekstrapolacji "krótszej" funkcji, tak by porównywane funkcje autokorelacji były określone dla tych samych wartości j (por. wzór (2)). W pracy zbadano konsekwencje zastosowania dwóch rodzajów takich ekstrapolacji - pierwszy polegał na przyjęciu, że krótsza funkcja jest równa zeru dla $b < j \leq a$ (por. rys. 2), przy drugim natomiast wykorzystano fakt, że łańcuchowa funkcja autokorelacji może przybierać wartości z przedziału $(+1, -1)$, zatem krótszą funkcję można ekstrapo-



Rys. 2. Przykłady różnego sposobu ekstrapolacji łańcuchowej funkcji autokorelacji

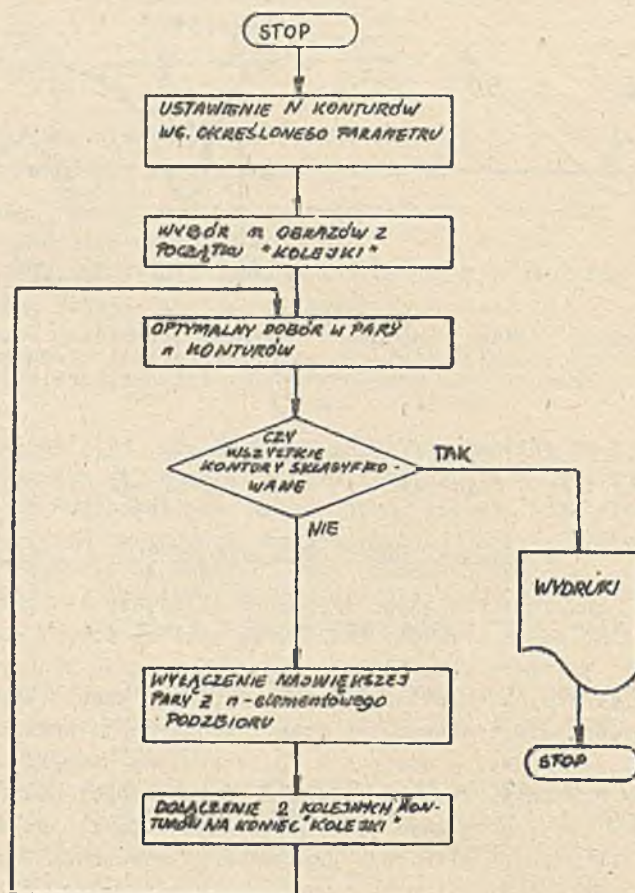
Rys. 3. Przykłady różnego sposobu ekstrapolacji łańcuchowej funkcji autokorelacji

ować tak, by w przedziale $b < j \leq a$, funkcja F_2 różniła się najbardziej od funkcji F_1 , co ilustruje rys. 3. Stanowi to oszacowanie z góry. Za miarę podobieństwa porównywanych między sobą łańcuchowych funkcji autokorelacji przyjęto wartości estymatora współczynnika korelacji liniowej, które unormowano zgodnie ze wzorem (12), otrzymując wartości stopni podobieństwa p_{ij} charakteryzujących podobieństwo między i -tym i j -tym obrazem. W ten sposób można otrzymać kwadratową macierz stopni podobieństw o N kolumnach i N wierszach, której elementy stanowią zredukowaną informację o klasyfikowanych obiektach. Celem dokonania klasyfikacji (tzn. doboru w pary stanowiące poszczególne klasy) konturów należałoby przebadać wszystkie możliwe wybory, a następnie za ostateczny przyjąć ten, który charakteryzowałby się największą wartością średnich stopni podobieństw obrazów dobranych w pary, przy czym wybór średniego stopnia podobieństwa do oceny danej klasyfikacji eliminuje przypadek jednoczesnego wyboru par o skrajnych wartościach stopni podobieństw. Łatwo zauważyć, że ten sposób postępowania jest możliwy jedynie w przypadku bardzo niewielkiej liczby obrazów, w przeciwnym bowiem razie gwałtownie narastający czas obliczeń dyskwalifikuje praktyczną przydatność takiego algorytmu. Z tych też względów zastosowano inny, suboptymalny algorytm klasyfikacji, wykorzystujący pewną dodatkową informację o klasyfikowanych obrazach. Uwzględniono mianowicie fakt, że w prawidłowo sklasyfikowanym zbiorze obrazów można przyjmować odpowiednie uszeregowanie klas. Doprowadziło to do zbudowania algorytmu, którego uproszczony schemat przedstawia rys. 4.

Uzyskane wyniki będą omówione w kolejnej części pracy.

Wyniki obliczeń

Stosując powyżej opisany algorytm dokonano dwu serii obliczeń numerycznych dotyczących klasyfikacji grup obrazów o nieregularnych konturach. W każdej z serii badano inny rodzaj ekstrapolacji łańcuchowych funkcji autokorelacji.



Rys. 4. Schemat blokowy omawianego algorytmu klasyfikacji obrazów

W obu przypadkach uzyskano dobre wyniki klasyfikacji, przy czym należy podkreślić, że stosując ekstrapolację przedstawioną na rys. 2 uzyskano jeszcze większą zgodność z klasyfikacją wzorcową. Wyniki klasyfikacji, dokonanej w oparciu o wartości estymatora współczynnika korelacji poddano następnie weryfikacji, badając czy uzyskane wartości współczynnika korelacji są statystycznie istotne. Przyjmując $\alpha = 0,05$ zbadano hipotezę o zerowym współczynniku korelacji (por. wzór (11)). Po dokonaniu obliczeń okazało się, że w każdej z dobranych przez komputer par wartości estymatorów współczynników korelacji są statystycznie istotne. Kolejne obliczenia dotyczyły wyznaczenia przedziału ufności dla współczynnika korelacji zgodnie ze wzorem (9), przy czym podobnie jak poprzednio przyjęto, że $\alpha = 0,05$ i przeprowadzono obliczenia dla każdej z ustalonych przez komputer par.

Uwagi i wnioski końcowe

Obliczenia ilustrujące zastosowanie estymatora współczynnika korelacji do komputerowej klasyfikacji obrazów o nieregularnych konturach wykazały, że prezentowana metoda daje dobre wyniki i nadaje się do klasyfikacji obrazów, trudnych do rozpoznawania przy użyciu innych metod. Porównując oba rodzaje ekstrapolacji można stwierdzić, że większą zgodność uzyskuje się stosując ekstrapolację zilustrowaną na rys. 2, taką też proponujemy stosować podczas dalszych badań.

Weryfikacja hipotez dotyczących uzyskanych wyników wykazała, że wybrane przez komputer pary obrazów charakteryzują się wartościami współczynników korelacji istotnymi statystycznie. Wartości estymatorów współczynników korelacji mierzy się ponadto w wąskich przedziałach (odchyłki rzędu kilku% przy poziomie istotności 0.05).

Uwzględniając ponadto, że czas obliczeń w przypadku klasyfikacji kilkudziesięciu obiektów jest rzędu 10-14 minut, można stwierdzić, że opisywaną metodę ocenia się jako metodę charakteryzującą się dużą efektywnością i dogodną do sterowania w praktyce.

LITERATURA

- [1] AJZERMAN M.A., BRAWERMAN E.M., ROZONOER L.I.: Rozpoznawanie obrazów - metoda funkcji potencjalnych. WNT, Warszawa 1978.
- [2] BENDAT J.S., PIERSOL A.G.: Metody analizy i pomiaru sygnałów losowych PWN, Warszawa 1976.
- [3] CZOGAŁA E., DREWNIAK J., IHNATOWICZ J., JAGIELSKI.: Zastosowanie łańcuchowych funkcji korelacji do komputerowej analizy obrazów o nieregularnych konturach. Zesz. Nauk. Pol. Śl. s. Automatyka (w druku).
- [4] FREEMAN H.: Computer Processing of Line-Drawing Images. Computing Surveys Vol. 6 No. 1 March 1974.
- [5] GREN J.: Statystyka matematyczna - modele i zadania. PWN, Warszawa 1978.

ПРИМЕНЕНИЕ ОЦЕНКИ КОЭФФИЦИЕНТА КОРРЕЛЯЦИИ
ДЛЯ КОНСТРУИРОВАНИЯ АЛГОРИТМА КЛАССИФИКАЦИИ ОБРАЗОВ
С НЕРЕГУЛЯРНЫМИ КОНТУРАМИ

Резюме

В работе обсуждена возможность классификации образов с нерегулярными контурами на основе алгоритма, использующего значения коэффициента линейной корреляции между цепными функциями, характеризующими эти контуры. Приведен пример такого алгоритма а также обсуждены полученные результаты для различных его модификаций.

APPLICATION OF THE CORRELATION COEFFICIENT ESTIMATOR IN DESIGNING THE ALGORITHM OF THE CLASSIFICATION OF PICTURES WITH IRREGULAR CONTOURS

S u m m a r y

In the paper the discussion of the possibilities of using a correlation estimator in recognition and classification of pictures with irregular contours described by the chain autocorrelation function is presented.

The classification algorithm making the most of the presented method of picture recognition has been shown, and the results have been discussed.