

AKADEMIA TECHNICZNO-ROLNICZA
IM. JANA I JĘDRZEJA ŚNIADECKICH
W BYDGOSZCZY

Rozprawy
nr 26

RYSZARD S. CHORAŚ

Redukcja redundancji
w cyfrowych systemach przetwarzania
obrazów

4.92/.93

Choraś, Ryszard S.
Redukcja redundancji w cy

88.

BYDGOSZCZ – 1988

004.92/93

AKADEMIA TECHNICZNO-ROLNICZA
IM. JANA I JĘDRZEJA ŚNIADECKICH
W BYDGOSZCZY

R o z p r a w y
nr 26

RYSZARD S. CHORAŚ

Redukcja redundancji
w cyfrowych systemach przetwarzania
obrazów

Biblioteka Główna ATR w Bydgoszczy



000000080301

BYDGOSZCZ – 1988

PRZEWODNICZĄCY KOMITETU REDAKCYJNEGO

doc. dr hab. Juliusz Skonieczny

OPINIODAWCY

prof. dr hab. inż. Tadeusz Batorycki

prof. dr hab. inż. Antoni Woźniak

REDAKTOR NAUKOWY

prof. dr hab. inż. Lech J. Weiss

OPRACOWANIE REDAKCYJNE I TECHNICZNE

mgr Halina Koziółkiewicz, Zbigniew Gackowski



Wydano za zgodą Rektora
Akademii Techniczno-Rolniczej
w Bydgoszczy

ISSN-0209-0597

**WYDAWNICTWO UCZELNIANE AKADEMII TECHNICZNO-ROLNICZEJ
W BYDGOSZCZY**

Wyd. I. Nakład 100+50 egz. Ark. wyd. 6,5, ark. druk. 6,25. Papier kl. III, 70 g.

Oddano do druku w maju 1988 r. Druk ukończono w czerwcu 1988 r.

Cena 170 zł

Prasowe Zakłady Graficzne RSW „Prasa-Książka-Ruch” w Bydgoszczy, ul. Dworcowa 13

Zamówienie nr 1710/88. TR E-8

88 D 60/69

SPIS TREŚCI

str.

Wykaz skrótów, oznaczeń i symboli używanych w pracy	5
1. Wstęp	11
2. Redukcja redundancji	17
2.1. Wiadomości ogólne	17
2.2. Klasyfikacja metod redukcji redundancji	20
2.3. Redukcja redundancji obrazów	26
3. Redukcja redundancji obrazu cyfrowego-metoda dekompozycji obra - zu	33
3.1. Histogram obrazu	33
3.2. Filtracja medianowa /FM/ obrazu	34
3.3. Wydzielanie zmian jasności	37
3.4. Segmentacja obrazu	41
3.5. Wybór punktów określających położenie "okien" obrazu	44
3.6. Uwagi końcowe dotyczące redukcji redundancji metodą dekompo- zycji	46
4. Kryteria jakości odtwarzanego obrazu	51
4.1. Kryteria subiektywne	53
4.2. Kryteria obiektywne	56
4.3. Ocena jakości obrazu w przypadku redukcji redundancji meto- dą dekompozycji	58
5. Redukcja redundancji parametrów opisujących obiekty obrazu	63
6. Opis obiektów obrazu.....	67
6.1. Parametry opisujące obiekty obrazu	67
6.2. Analiza parametrów obiektów	74
7. Podsumowanie	81
Dodatek A. Macierzowa reprezentacja obrazu cyfrowego	84
Dodatek B. Inwariantny układ współrzędnych	87
Literatura	90
Streszczenia	95

WYKAZ SKRÓTÓW, OZNACZEŃ I SYMBOLI UŻYWANYCH W PRACY

1. Skróty

wrr	współczynnik redukcji redundancji
RR	redukcja redundancji
FM	filtracja medianowa
/mppo/	możliwy punkt położenia „okien”-obrazu
ppo	punkt położenia „okien”-obrazu
Oo	„okno”-obrazu
zp1	z prawdopodobieństwem 1
OIP	odcinek linii prostej

2. Oznaczenia

R o z d z i a ł 2

$X_i(t), \underline{X}(t)$	- sygnał wejściowy, wektor wejściowy
R^M	- M wymiarowa przestrzeń stanów
$Y_i(t), \underline{Y}(t)$	- sygnał wyjściowy, wektor wyjściowy
$Z_i(t)$	- sygnał na wyjściu kodera źródła
$\Phi_1(\underline{X}(t))$	- wektor parametrów
$\hat{X}_i(t), \hat{Y}_i(t), \hat{Z}_i(t)$	- sygnały odtworzone
\underline{U}	- wektor wskaźników jakości
\underline{A}	- wektor określający algorytmy przetwarzania informacji
\underline{S}	- wektor określający strukturę systemu
\underline{B}	- wektor określający bazę systemu
\mathcal{L}	- wektor określający zależność wskaźników \underline{U} od $\underline{A}, \underline{S}, \underline{B}, \underline{X}(t)$
$I(\underline{U})$	- wskaźnik efektywności systemu
$y(t)$	- wielomian
y_t	- wartość próbki danych w czasie t
\hat{y}_t	- predykowana wartość próbki danych w czasie t
Δ	- różnica pomiędzy wartościami próbek danych
a_i, a_k	- współczynniki
$R_y\{\}$	- autokorelacyjna funkcja sygnału
S	- liczba okresów próbkowania
$\hat{X}(kT)$	- odtworzona wartość próbki danych
Φ_1	- wektor własny
e^2	- błąd średniokwadratowy
λ_k	- wartości własne
R	- statystyczna redundancja źródła informacji

H	- entropia
p_i	- częstotliwość występowania i-tego stanu
h	- liczba poziomów kwantowania
R o z d z i a ł 3	
σ_k	- sygnał /bodziec/ wzrokowy
h	- histogram obrazu
h_1	- histogram gradientu
$h(k)$	- liczba elementów obrazu o jaskrawości k
$h_1(k)$	- suma wartości gradientu dla wszystkich elementów obrazu o jaskrawości k
Z	- zbiór liczb całkowitych nieujemnych
F	- obraz cyfrowy
$d_{r,c}$	- wartość gradientu jaskrawości elementu o współrzędnych /r,c/
$I(k)$	- zbiór elementów o jaskrawościach k
$M(F)$	- funkcja zawartości informacyjnej obrazu
t, t_1	- wartości progowe funkcji jaskrawości obrazu
$f_{i,j}, f_{r,c}$	- elementy obrazu cyfrowego
\underline{Y}	- obraz po FM
$y_{i,j}$	- element obrazu po FM
A_1	- okno FM
R	- raster
L_A	- prosta
P	- prawdopodobieństwo
$f'_{i,j}$	- zaszumiony element obrazu
L	- wymiar A_1
$\{n_{i,j}\}$	- szum
D	- obraz uzyskany w wyniku operacji wydzielenia zmian jaskrawości
$d_{i,j}$	- element obrazu D
$y(k)$	- element obrazu Y ponumerowany zgodnie z rys.3.1
$wk_{i,j}$	- wskaźnik punktu konturowego
$d(k)$	- element obrazu D ponumerowany zgodnie z rys.3.1
$q_{i,j}$	- element obrazu konturowego
Q	- obraz konturowy
$b_{i,j}$	- element obrazu binarnego
B	- obraz binarny
$\Theta((i,j), (n,k)); \Theta_4((i,j), (n,k)); \Theta_8((i,j), (n,k))$	- metryka
$V(i,j); V_4(i,j); V_8(i,j)$	- otoczenie /sąsiedztwo/ elementu (i,j); 4-elementowe i 8-elementowe otoczenie elementu o współrzędnych (i,j)

C	- kontur
$V(E)$	- otoczenie obszaru E
P_{izol}	- punkt izolowany obrazu konturowego
$LL_{\theta}(i,j); LL_u(i,j)$	- liczba punktów w otoczeniu $V_{\theta}(i,j)$; $V_u(i,j)$ o wartości $q_{h,k}=1$
S_u	- podzbiór R
$F_{S_u}; F'_{S_u}$	- średnie wartości jaskrawości obszaru S_u
t_{S_u}	- wartość progowa dla obszaru S_u
$\sigma_{S_u}, \sigma'_{S_u}$	- standardowe odchylenie dla obszaru S_u
t_o	- stała wartość progowa
ΔF_{S_u}	- błąd
T	- ilość grup
$P_1(1); P_2(1); P_z(k); P_x(k)$	- punkty środkowe grup 1,2,z i x
J_z	- kryterium jakości
W_z	- liczba punktów wchodzących w skład grupy $S_z(k)$
Z	- zbiór liczb rzeczywistych
C	- wymiar "okna"-obrazu

R o z d z i a ł 4

X, Y	- sygnały
U, V	- jaskrawości na ekranie monitora
S_F	- wskaźnik subiektywnej oceny jakości obrazu
$f_{i,j}$	- element obrazu cyfrowego
Q, K, P, L, LL	- obiektywne kryteria oceny jakości obrazu
$G_{i,j}$	- wartość laplasjanu w punkcie(i,j)
A	- max. wartość jaskrawości obrazu
$e_a^{(1)}$	- średni bezwzględny błąd i-tej linii
e_a	- średni bezwzględny błąd obrazu
$e_r^{(1)}$	- pierwiastek z błędu średniokwadratowego i-tej linii
e_r	- średni błąd dla obrazu
h_b	- histogram błędów
$\mathcal{E}_{i,j}$	- wartość bezwzględna różnicy pomiędzy jaskrawościami obrazu oryginalnego i odtworzonego w punkcie(i,j)
$e_{SNR_k}^{NOR}$	- błąd znormalizowany
$SNR_k^{(1)}, SNR_k^{(ob)}$	- uzupełniające kryteria jakości obrazu

R o z d z i a ł 5

X, Y	- zmienne losowe
$F(\cdot, \cdot), F(\cdot)$	- funkcje rozkładu prawdopodobieństwa /łączna i brzegowa/

Prob []

$g()$

d, d'

r

$T_{X,Y}$

- prawdopodobieństwo
- rzeczywista, niemalejąca funkcja
- reguły decyzyjne
- prawdopodobieństwo błędnej decyzji
- test nadmiarowości

R o z d z i a ł 6

A

δ_{ir}

Ob

O

$z_{i,j}$

b, a

e

I_o, J_o

m_{pq}

$Z_{pq}(i,j)$

C'_{pq}, C'_{pq}

S'_{pq}, S'_{pq}

θ

ϱ, φ

a_1, a_o

d_L

$M(q)$

C

$W(q)$

P_q, P_{qm}

- ogólna liczba punktów obiektu
- maksymalna liczba charakteryzująca r-tą serię elementów niezerowych i-tej linii
- obwód obiektu
- obiekt
- liczba elementów nie należących do obiektu w $V_{Li}(i,j)$
- odpowiednio długości maksymalnej i minimalnej cięciwy obiektu
- współczynnik, zależny od konturu obiektu
- współrzędne środka ciężkości obiektu
- ogólny moment rzędu p,q
- funkcja (i,j)
- momenty kosinusowe rzędu pq
- momenty sinusowe rzędu pq
- kąt
- współrzędne biegunowe
- współczynniki prostej aproksymującej
- odległość pomiędzy punktem a OLP
- funkcja określająca zgodność parametru obiektu z parametrem modelu
- współczynnik prawidłowości identyfikacji obiektu
- waga określająca stopień ważności q-tego parametru
- odpowiednio q-te parametry obiektu i modelu

D o d a t e k A

R

F

G

\underline{f}

[I]

[φ]

[A_j]

[y_j]

- raster
- obraz cyfrowy
- zbiór wartości jaskrawości
- wektor kolumna
- macierz jednostkowa
- macierz zerowa
- macierz wymiaru $m \cdot n \cdot m$
- wektor kolumna mający wszystkie elementy równe zero oprócz elementu j-tego równego 1

D o d a t e k B

m_1, m_j - współczynniki zmiany skali

3. Używane symbole matematyczne

{ }	- nawiasy definicyjne zbioru
()	- nawiasy definicyjne ustalonych elementów występujących w zadanym porządku
[]	- nawiasy definicyjne wektora i/lub macierzy
x	- iloczyn kartezjański zbiorów
\geq	- ... większe, równe od ...
\leq	- ... mniejsze, równe od ...
$=$	- ... równe ...
\neq	- ... różne ...
\sum	- suma elementów liczbowych
$ \cdot $	- wartość bezwzględna
$[]^t$	- operacja transponowania wektora i/lub macierzy
# A	- moc zbioru
\rightarrow	- symbol odwzorowania /łączy zbiór będący dziedziną ze zbiorem będącym przeciwdziedziną/
\wedge	- ... dla każdego ...
\vee, \exists	- ... istnieje .. takie, że
$\max()$	- wartość maksymalna
$\min()$	- wartość minimalna
\in	- należy do /jest elementem/
\cap	- przecięcie zbiorów
\cup	- suma zbiorów
$[]$	- najbliższa wartość całkowita mniejsza od argumentu tego operatora

2

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1

1


1

1

1. WSTĘP

Cyfrowe przetwarzanie obrazów charakteryzuje się intensywnym rozwojem różnych metod i zastosowań, co ma bezpośredni związek ze zwiększeniem wielkości pamięci, szybkości obliczeń i efektywności maszyn cyfrowych i technologii przetwarzania sygnałów. Przetwarzanie obrazów odgrywa istotną rolę w nauce, przemyśle, biomedycynie, zastosowaniach wojskowych i wlotach kosmicznych. Jest ono stosowane przy cyfrowej transmisji obrazów satelitarnych i wizjotelefonii, uzyskiwaniu obrazów o wysokiej rozdzielczości oraz jakości za pomocą mikroskopów elektronowych, automatycznej klasyfikacji i teledetekcji, formowaniu i poprawianiu jakości obrazów biomedycznych, przy automatycznym wykreślaniu map na podstawie zdjęć lotniczych, wykrywaniu wad i uszkodzeń części maszynowych itp. Przedstawiona lista zastosowań jest oczywiście niepełna i daje tylko pewne wyobrażenie o możliwościach wykorzystania cyfrowego przetwarzania obrazów.

Problematyka cyfrowego przetwarzania obrazów obejmuje cztery grupy zagadnień: rozpoznawanie i identyfikację obrazu, kodowanie obrazu, analizę i opis obrazu, restaurację obrazu^{*}. Zagadnienia te powiązane są ze sobą poprzez metody służące do rozwiązywania pewnych występujących w tych zagadnieniach problemów, bądź też poprzez wspólne problemy występujące w każdym z tych zagadnień. Jednym z takich problemów jest problem redukcji redundancji obrazu cyfrowego^{**} /rys.1.1/.



Rys.1.1. Zagadnienia cyfrowego przetwarzania obrazów i usytuowanie problemu redukcji redundancji obrazu

Redukcja redundancji informacji obrazu umożliwia znaczne skrócenie czasu przetwarzania /większa szybkość przetwarzania/ obrazów, upraszcza

* Oczywiście możliwe jest wyodrębnienie większej liczby zagadnień. Zaproponowany tutaj podział przedstawiono w pracy [78,79].

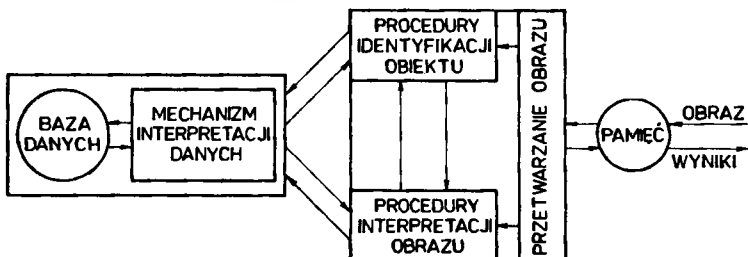
** Definicję obrazu cyfrowego przedstawiono w Dodatku A.

rozwiązania układowe systemów przetwarzania obrazów przy jednoczesnym zwiększeniu niezawodności i obniżeniu kosztów ich realizacji. W przypadku transmisji obrazów uzyskuje się przy takiej samej szybkości transmisji skrócenie czasu transmisji. W przypadkach, w których na podstawie wyników przetwarzania obrazów realizowane są decyzje odnośnie identyfikacji obiektów znajdujących się w obrazie, np. w systemach wizyjnych robotów, uzyskuje się znaczne skrócenie czasu oczekiwania na wypracowanie decyzji o rodzaju obiektów itp.

Aby umiejscowić tematykę niniejszej pracy w dotychczasowym dorobku związanym z cyfrowym przetwarzaniem obrazów przyjrzyjmy się pozycjom zamieszczonym w wykazie literatury, a w szczególności pozycjom [84,85] zawierającym liczący odpowiednio 1063 i 1436 pozycji przegląd opublikowanych opracowań związanych z cyfrowym przetwarzaniem obrazu. Można stwierdzić, że:

- brak jest syntetycznych opracowań poświęconych redukcji redundancji obrazu,
- można zaobserwować stale zwiększającą się liczbę publikacji dotyczących problematyki tzw. komputerowej wizji, co związane jest z możliwościami wykorzystania systemów komputerowej wizji w licznych zastosowaniach przemysłowych, wojskowych, naukowych itp.,
- pojawiające się nieliczne publikacje dotyczące redukcji redundancji obrazu nie uwzględniają redukcji redundancji obrazu w systemach komputerowej wizji,
- badania dotyczące nowych, oryginalnych metod redukcji redundancji obrazu opracowanych m.in. dla systemów komputerowej wizji nie zostały dotychczas przedstawione w formie monograficznej.

Pojawiający się w ostatnich latach w literaturze termin "komputerowa wizja" obejmuje cały szereg problemów związanych z przetwarzaniem obrazów w różnych zastosowaniach, od oceny obrazów satelitarnych poprzez zastosowania dla celów medycznych i systemów wizyjnych robotów. System komputerowej wizji /rys.1.2/ zawiera m.in. bloki realizujące automatyczną iden-



Rys.1.2. Schemat blokowy komputerowej wizji

tyfikację obiektów obrazu i analizę złożonych sytuacji przedstawionych w postaci obrazów i ich interpretację.

Najbardziej spektakularnymi przykładami wykorzystania interpretacji obrazu i identyfikacji obiektów w obrazie są systemy wizyjne robotów i

systemy przetwarzania zdjęć satelitarnych. System wizyjny robota musi umożliwiać uzyskanie odpowiedzi na pytanie, czy w obrazie /scenie/znajduje się obiekt, w którym miejscu i w jakim otoczeniu. Przetwarzanie obrazów w systemie wizyjnym robota musi być realizowane w czasie rzeczywistym, ponieważ na podstawie wyników tego przetwarzania robot wykonuje kolejne operacje /czas rzeczywisty przy współczesnym rytmie operacji przemysłowych to ułamki sekund/. Istnieje więc bezpośredni związek pomiędzy wymiarem obrazu, liczbą operacji przetwarzania, ilością obiektów w obrazie przetwarzanym, a czasem potrzebnym do uzyskania wyników przetwarzania obrazu. Ponadto elementem systemu wizyjnego robota nie może być, ze względu na koszty, komputer o b. dużej szybkości i b. dużej mocy obliczeniowej. W takiej sytuacji koniecznością w systemach wizyjnych robotów jest redukcja redundancji obrazu. Określenie otoczenia jest bardzo ważne ze względu na konieczność obliczenia trajektorii ruchu manipulatora do obiektu. O ile obiekt został znaleziony, przetwarzane jest tylko odpowiednie „okno” - obrazu w celu obliczenia parametrów obiektu i zidentyfikowania go.

W przypadku przesyłania obrazów satelitarnych, nadajnik satelity Landsat może przekazywać dane z szybkością 46 megabitów na sekundę. Są to olbrzymie ilości - opracowanie 5-godzinnej transmisji danych zajmuje doświadczonemu fachowcowi cały rok. Jak stwierdził Milton Halem - szef przetwarzania danych w ośrodku NASA w Greenbelt - „satelita Landsat pracujący 24 godziny na dobę dostarcza 6000 obrazów, podczas gdy opracowujący je komputer Vax 11780 może w tym czasie opracować ich zaledwie 10”.

Wykorzystywane więc muszą być różnego rodzaju metody redukcji redundancji, w tym metody umożliwiające interpretację obrazów i identyfikację obiektów w obrazie.

Treść pracy jest odzwierciedleniem wniosku, że najważniejszym problemem w zakresie redukcji redundancji obrazu jest redukcja redundancji obrazów cyfrowych w procesach interpretacji obrazu i identyfikacji jego obiektów, w szczególności obrazów, w których informacja użyteczna i niezbędna z punktu widzenia użytkownika systemu przetwarzania obrazów skoncentrowana jest na niewielkim obszarze ich powierzchni*. Na obszarze tym przedstawione są obiekty interesujące użytkownika systemu m.in. ze względu na wykorzystanie informacji o nich na dalszych etapach procesu przetwarzania informacji, bądź też dlatego, że informacja o nich umożliwia zrozumienie całej sceny, którą przedstawia obraz. Położenie obiektów nie jest znane, ich rozmiar jest niewielki w porównaniu z rozmiarem obrazu.


Człowiek oglądający obraz nie tylko zapamiętuje odbieraną informację o obrazie, ale wykorzystując odpowiednie obszary mózgu dokonuje jego interpretacji. Interpretacja dokonywana jest nie tylko na odbieranym sygnale obrazu, ale też na wcześniej znanych wiadomościach o tym co obraz powinien sobą przedstawiać. Wiadomości te uzyskuje się z wczesniej odbie-

* W dalszej części pracy obrazy takie nazywane będą N-obrazami. N-obrazami są m.in. obrazy sytuacji technologicznych, obrazy przedstawiające obiekty o niewielkim wymiarze w porównaniu z wymiarem obrazu, obrazy medyczne itp.

ranych i przechowywanych w pamięci informacji o obrazie. Interpretacja możliwa jest tylko przez porównanie z informacją już znajdującą się w pamięci. Porównanie nie powinno być połączone z pełnym przeglądem informacji znajdującej się w pamięci, gdyż powodowałoby to wydłużenie procesu interpretacji. Unikalność procedury interpretacji-tzw. procedury analizy przez syntezę - polega na tym, że możliwe jest analizowanie tylko tego fragmentu obrazu, który jest niezbędny do jednoznacznej interpretacji obrazu. Potwierdzeniem prawdziwości modelu analizy przez syntezę są eksperymentalne fakty uzyskane w procesie interpretacji danych przez człowieka. Człowiek przyjmuje do analizy tylko tyle danych ile jest niezbędnych do potwierdzenia hipotez odnośnie obrazu i uzupełnia brakującą informację o obrazie danymi ze swojej wewnętrznej pamięci, w której zawarty jest model obrazu. Proces interpretacji można przedstawić jako proces, w którym wykorzystywane są: /i/ pamięć o niezbyt dużej pojemności, w której zapamiętywana jest informacja o obrazie i wynikach przetwarzania, /ii/ pamięć o bardzo dużej pojemności - pamięć człowieka, /iv/ mechanizm interpretacji. Mechanizm interpretacji danych umożliwia:

- ocenę nowej informacji,
- jej zapamiętywanie w formie pewnych pojęć i ich związków,
- realizację poszukiwania w bazie danych potrzebnej informacji dla odpowiedzi na pytanie co przedstawia obraz,
- analizę wybranej informacji,
- zmianę struktury informacji w bazie danych zgodnie z nową informacją,
- ustalenie nowych związków pomiędzy pewnymi pojęciami o obrazie.

W procesie interpretacji w przypadku robota wyposażonego w system wizyjny, tj. komputerową wizję /przypomnijmy, że podstawowymi operacjami takiego systemu są:



wykorzystywana jest w charakterze pamięci o dużej pojemności pamięć komputera, jednak mechanizm interpretacji pozostaje bez zmian i umożliwia realizację identycznych operacji.

Sformułujemy następujące wnioski:

1. Dla prawidłowej i jednoznacznej interpretacji obrazu konieczna i wystarczająca jest tylko informacja zawarta w pewnym fragmencie obrazu. Możliwa jest redukcja redundancji obrazu polegająca m.in. na wydzieleniu fragmentów obrazu zawierających informacje istotne z punktu widzenia interpretacji obrazu, tj. fragmentów zawierających obiekty obrazu,

2. W zależności od konkretnego zastosowania zakres pojęcia: interpretacja obrazu będzie się zmieniała, jednak mechanizm interpretacji pozostanie bez zmian.

Wychodząc z takich założeń w pracy przedstawiono problematykę redukcji redundancji ze szczególnym uwzględnieniem redukcji redundancji obrazów cyfrowych /w szczególności N-obrazów/ w procesach interpretacji obrazu i identyfikacji jego obiektów.

Pracę można podzielić na trzy duże działy:

Dział pierwszy odpowiadający rozdziałowi 2 poświęcony jest ogólnemu opisowi redukcji redundancji, klasyfikacji metod redukcji redundancji oraz przedstawieniu problematyki redukcji redundancji obrazów.

Dział drugi odpowiada rozdziałom 3 i 4. Dział ten zawiera teoretyczne podstawy nowej, oryginalnej metody redukcji redundancji obrazu cyfrowego. Przedstawienie istotnych treści tego rozdziału w postaci definicji i twierdzeń pozwala na ich łatwe wykorzystanie przy omawianiu innych operacji przetwarzania obrazu.

Informacje te mają na celu - po pierwsze - zapoznać czytelnika z operacjami realizowanymi w procesie redukcji redundancji obrazu, po drugie - dostarczyć tym spośród czytelników, którzy chcieliby sami opracować metody redukcji redundancji obrazu lub inne metody przetwarzania obrazu, wiadomości o operacjach i algorytmach koniecznych do tego celu.

Przedstawiono w charakterze przykładu obrazu uzyskane przy zastosowaniu omawianej metody oraz uwagi odnośnie jej realizacji. Informacje o kryteriach oceny jakości obrazu zawarte w rozdziale 4 pozwalają ocenić przetwarzane obrazy. Jednocześnie starano się wprowadzić nowe kryteria oceny jakości obrazów, które zdaniem autora pozwalają na bardziej adekwatną do jego treści ocenę jakości obrazu.

Dział trzeci obejmuje rozdziały 5 i 6, poświęcony jest redukcji redundancji parametrów obiektu i opisowi obiektów obrazu. Informacje zawarte w rozdziale 5 nie były dotychczas publikowane w literaturze poświęconej problematyce redukcji redundancji obrazu. A przecież, jeżeli obrazy /obiekty obrazów/ są opisywane za pomocą parametrów, to występuje problem nadmiarowości tych parametrów. Rozważania rozdz. 6, zapewne dla wielu czytelników niewiele mające wspólnego z redukcją redundancji są istotne z punktu widzenia wyboru parametrów opisujących obiekty. Nie ma zdefiniowanych metod wyboru parametrów. Mamy więc do czynienia z sytuacją "zły wybór parametrów - duża redundancja parametrów - zła identyfikacja obiektów". Przedstawione parametry opisu obiektów są pewną propozycją autora /opartą na doświadczeniach wieloletnich badań związanych z przetwarzaniem obrazów/ umożliwiającą zbudowanie specjalistycznych narzędzi służących do identyfikacji i opisu obiektów. Doświadczenie wskazuje bowiem, że często brak wiadomości odnośnie niezbędnych parametrów opisu obiektów i definicji tych parametrów, stoi na przeszkodzie praktycznej realizacji tych narzędzi.

Poszczególne działy są w dużym stopniu wzajemnie niezależne. Rozdziały 3 i 4 i 5,6 mogą być czytane osobno i w dowolnej kolejności, jednak lepiej je poprzedzić lekturą rozdziału 2. Uzupełnieniem pracy są Dodatki oraz obficie cytowana literatura zebrana w porządku alfabetycznym.

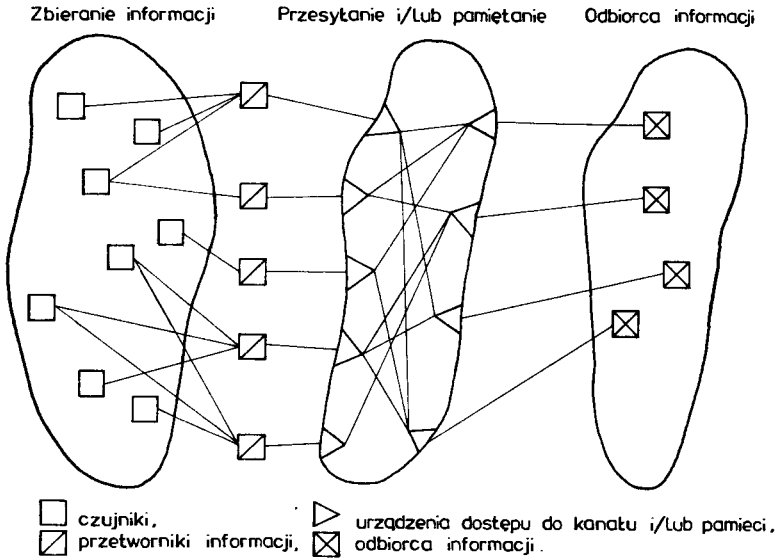
2. REDUKCJA REDUNDANCJI

2.1. Wiadomości ogólne

Tendencją ostatnich lat jest stale zwiększająca się złożoność urządzeń technicznych i procesów technologicznych, ich przestrzenna lokalizacja, konieczność podniesienia jakości sterowania różnorodnymi obiektami przy jednoczesnym wymaganiu dostępności całkowitej informacji o ich stanach. Ważną rolę odgrywają środki zbierania i rejestracji informacji, systemy jej transmisji, systemy przetwarzania i zapamiętywania informacji. Systemy realizujące tego typu działania charakteryzują się występowaniem różnych form przedstawienia i przekształcenia sygnałów, rodzajów transmisji, sposobów przetwarzania danych. Pojawia się problem redukcji danych, którego rozwiązanie pozwala zmniejszyć wymagania odnośnie np. pojemności pamięci, przepustowości linii transmisji, czasu przetwarzania informacji, bez uszczerbku dla realizacji podstawowych funkcji systemu.

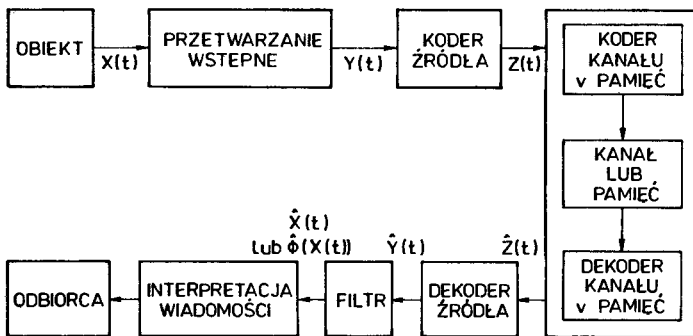
Redukcja danych może być realizowana na kilku poziomach. Na najwyższym określa się objętość danych w całości, np. liczbę i dokładność mierzonych parametrów w układach sterowania. Na niższym w kolejności poziomie wyklucza się tę informację, która zawiera niepotrzebne lub zdublowane dane. Na następnym poziomie redukuje się statystyczną i psychofizyczną redundancję, natomiast na najniższym, tzw. fizycznym poziomie - określa się rodzaj kodów, sygnałów i sposoby fizycznej realizacji przetwarzania informacji. Różne metody przetwarzania informacji i jej ekonomicznego przedstawienia są trudno formalizowane i noszą heurystyczny charakter. Matematyczna formalizacja możliwa jest w przypadku przetwarzania danych, opierającego się o metody i środki redukcji strukturalnej, statystycznej i psychofizycznej redundancji, uwarunkowane deterministycznymi lub statystycznymi związkami między ich oddzielnymi elementami lub też wynikającymi ze specyfiki odbierania informacji przez człowieka. Najbardziej rozpowszechniona forma redundancji to statystyczna i psychofizyczna redundancja informacji, przy czym zmniejszenie tego typu redundancji jest trudne do przewidzenia na etapie projektowania systemu.

Proces zbierania i przetwarzania informacji można przedstawić następująco /rys.2.1/. Układy zbierające informację, np. czujniki, mikrofon, kamera itp. zwykle redukują informację wnosząc pewne zakłócenia i szumy /szum czujnika/. Na wyjściu tych układów uzyskuje się tzw. informację źródła. Po przetworzeniu do odpowiedniej postaci podlega ona rejestracji, transmisji lub przetwarzaniu. Odbiorcy informacji /np. człowiek, komputer/ mogą być rozdzieleni w czasie i/lub przestrzeni. Środki redukcji danych mogą występować w dowolnym miejscu na drodze od źródła informacji do od-



Rys.2.1. Struktura systemu zbierania i przetwarzania informacji

biorcy, jednak celowym jest zmniejszenie ilości informacji w miejscu jej powstawania lub w pobliżu źródła. Tego typu środki nazywane są koderem źródła. Na rys.2.2 przedstawiono system z redukcją danych.



Rys.2.2. System przesyłania danych z redukcją danych

W przypadku ciągłego źródła informacji, wyjściowy sygnał obiektu $\underline{X}(t) = (X_1(t), \dots, X_M(t)) \in \mathbb{R}^M$, gdzie \mathbb{R}^M - M wymiarowa przestrzeń stanów, zostaje wstępnie przetworzony do postaci $\underline{Y}(t) = (Y_1(t), \dots, Y_N(t)) \in \mathbb{R}^N$ /wstępna obróbka sygnału/. Na wyjściu kodera źródła pojawia się albo sygnał $\underline{Z}(t)$ różny od $\underline{Y}(t)$, albo przedstawienie ogólnych parametrów obiektu $\phi_o(\underline{X}(t))$, np. wektor parametrów niezbędnych w procesie rozpoznawania obrazu. Na wejście dekodera doprowadzany jest sygnał $\hat{\underline{Z}}(t)$, różniący się od $\underline{Z}(t)$ np. błędami transmisji, czasami opóźnień itp. Dekoder źródła realizuje przetwo-

rzenie sygnału do postaci $\hat{Y}(t)$, a następnie tworzona jest ocena $\hat{X}(t)$ sygnału $X(t)$ lub ocena jego parametrów $\hat{\phi}_0(X(t))$. W przypadku źródła dyskretnego rozpatrywana jest cyfrowa informacja $\hat{Y}_c(t)$ w formie sekwencji symboli określonego alfabetu, jej kodowe przedstawienie $Z_c(t)$, a następnie $\hat{Y}_c(t)$. Przetwarzanie informacji uwzględniające redukcję danych można zrealizować za pomocą operatora F_i , tj. $\hat{Y} = F_i(\underline{Y})$. Dla realizacji operatora F_i niezbędne jest dysponowanie fizycznym przedstawieniem informacji \underline{Y} i jej oceny \hat{Y} /lub odpowiednio $\hat{\phi}_0(\underline{X})$ i $\hat{\phi}_0(\underline{X})/$. Operator F_i może być przedstawiony w postaci sekwencji przekształceń.

Każdy system z redukcją danych charakteryzuje się wektorem wskaźników jakości $\underline{U} = (u_1, u_2, \dots, u_k) \in R^K$, gdzie R^K - K wymiarowa przestrzeń jakości systemu, określona zbiorem wszystkich możliwych wartości wektora \underline{U} . Realizacja konkretnego wariantu redukcji danych związana jest z wyborem wektorów określających:

- algorytmy przetwarzania informacji - \underline{A} ,
- strukturę systemu - \underline{S} , realizującą algorytmy określone przez \underline{A} ,
- bazę systemu - \underline{B} , tj. zespół aparaturowych i programowych środków, które są wykorzystywane do realizacji systemu.

W charakterze współrzędnych wektorów \underline{A} , \underline{S} , \underline{B} występują nieformalizowane zmienne i wskaźniki liczbowe, np. $\underline{A} = (a_1, a_2, a_3, \dots)$, gdzie a_1 - nazwa metody redukcji danych, a_2, a_3, \dots - parametry ilościowe charakteryzujące tę metodę. Konkretny wariant systemu zadany jest trójką $(\underline{A}, \underline{S}, \underline{B})$ i charakteryzowany wskaźnikiem jakości $\underline{U} = \varphi(\underline{A}, \underline{S}, \underline{B}, \underline{X}(t))$, gdzie $\varphi(\dots)$ - wektor określający zależność wskaźników \underline{U} od określających ich czynników \underline{A} , $\underline{S}, \underline{B}, \underline{X}(t)$. Zbiór wszystkich możliwych wartości wektorów $\underline{A}, \underline{S}, \underline{B}$ będzie określał realizowaną przestrzeń systemu o wymiarze równym sumie wymiarów wektorów $\underline{A}, \underline{S}, \underline{B}$.

Projektując system redukcji danych możemy wybrać dwie drogi postępowania:

- pierwsza, polegająca na wyborze przy określonej informacji wejściowej $\underline{X}(t)$ takich wektorów $\underline{A}, \underline{S}$ i \underline{B} , które zabezpieczają wypełnienie ograniczeń na wskaźnik jakości \underline{U}

$$\{(\underline{A}, \underline{S}, \underline{B}) : \underline{U} = \varphi(\underline{A}, \underline{S}, \underline{B}, \underline{X}(t)) \in D^K\} \quad (2.1)$$

- druga, polegająca na wyborze przy określonej informacji wejściowej $\underline{X}(t)$ takich wektorów $\underline{A}, \underline{S}$ i \underline{B} , które zabezpieczają ekstremalną wartość wskaźnika efektywności systemu $I(\underline{U})$

$$\text{extr } I(\underline{U}), \{(\underline{A}, \underline{S}, \underline{B}) : \underline{U} = \varphi(\underline{A}, \underline{S}, \underline{B}, \underline{X}(t)) \in D^K\} \quad (2.2)$$

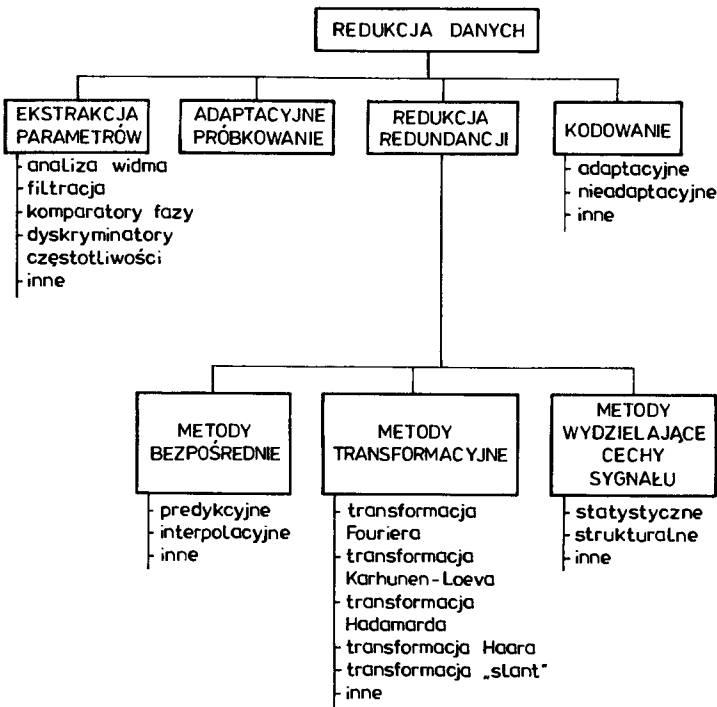
$(\underline{A}, \underline{S}, \underline{B})$

W pierwszym przypadku rozwiązanie zadania projektowania systemu redukcji danych określone jest zbiorem możliwych wariantów systemu lub obszarem dopuszczalnych wariantów zbudowania systemu. W drugim przypadku rozwiązanie zadania określa się optymalnym wariantem systemu $(\underline{A}, \underline{S}, \underline{B})_{\text{opt}}$ za-

pewniającym ekstremalną wartość wskaźnika efektywności. Jeżeli zbiór możliwych wariantów systemu jest zbiorem pustym, to należy wprowadzić dodatkowe algorytmy, struktury lub rozszerzyć bazę. Jeżeli zbiór ten nie jest zbiorem pustym, to możliwe jest znalezienie optymalnego wariantu systemu.

2.2. Klasyfikacja metod redukcji redundancji

Redukcja danych obejmuje metody redukcji pasma koniecznego do transmisji danej ilości informacji w danym czasie lub redukcji czasu koniecznego do transmisji danej ilości informacji w danym paśmie. Metody redukcji danych można podzielić na cztery główne kategorie: ekstrakcja parametrów, adaptacyjne próbkowanie, redukcja redundancji i kodowanie. Rys. 2.3



Rys.2.3. Klasyfikacja metod redukcji danych

przedstawia klasyfikację metod redukcji danych, przy czym dwie lub więcej metod należących do różnych kategorii można połączyć dla zrealizowania efektywniejszej redukcji. Krótko omówimy poszczególne kategorie metod redukcji danych.

Ekstrakcja parametrów jest metodą pozwalającą zredukować pasmo wymagane do transmisji danych poprzez nieodwracalną transformację umożliwiającą opis informacji. Transformacja jest nieodwracalna, ponieważ realizu-

je opis sygnału wejściowego w taki sposób, że odtworzenie oryginalnego sygnału jest niemożliwe. Ekstrakcja parametrów jest najstarszą i szeroko stosowaną metodą redukcji danych. Analizatory widma, komparatory fazy, dyskryminatory częstotliwości itp. są typowymi przykładami urządzeń pozwalających na ekstrakcję parametrów sygnału praktycznie wykorzystywanych dla celów redukcji danych.

Adaptacyjne próbkowanie jest metodą redukcji danych szeroko opisaną w literaturze [3,10,22,50,63,70,78,82]. Szczegółowo problematykę próbkowania obrazu omówił autor w monografii [22].

Kodowanie polega na transformacji danej wiadomości w odpowiadającą jej sekwencję słów kodowych. Również w tym przypadku, bibliografia dotycząca tej problematyki jest na tyle obszerna [8,10,11,15,18, 47], że autor czuje się zwolniony z obowiązku jej omówienia.

Redukcja redundancji jest metodą eliminującą próbki danych, które mogą być określone poprzez analizę poprzednich i/lub następnych próbek, lub też drogą porównania z arbitralnie ustalonymi wzorcami. Podstawowa różnica pomiędzy metodą adaptacyjnego próbkowania a redukcją redundancji jest taka, że w metodzie adaptacyjnego próbkowania ilość próbek danych jest zmienna w czasie, podczas gdy w przypadku redukcji redundancji okres próbkowania jest stały, natomiast nadmiarowe próbki są eliminowane na dalszych etapach przetwarzania.

Shannon zdefiniował redundancję jako "część wiadomości, która jest niekonieczna i powtarzana w tym sensie, że jeśli zostanie usunięta to wiadomość będzie ciągle zupełna" [82].

Techniki redukcji redundancji można podzielić na:

- bezpośrednie,
- transformacyjne,
- wydzielające cechy sygnału.

Do pierwszej grupy należą metody interpolacji i predykcji sygnału, do drugiej metody liniowych i nieliniowych transformacji sygnału, do trzeciej metody związane z rozpoznawaniem sygnału.

Wielomianowa predykcja pozwala wielomian n-tego rzędu przeprowadzić przez n+1 punktów danych.

Wielomian

$$y(t) = a_0 + a_1 t + a_2 t^2 + \dots + a_n t^n \quad (2.3)$$

aprosymuje punkty danych wykorzystując równanie różnicowe

$$\hat{y}_t = y_{t-1} + \Delta y_{t-1} + \Delta^2 y_{t-1} + \dots + \Delta^n y_{t-1} \quad (2.4)$$

gdzie: \hat{y}_t - predykowana wartość danych w czasie t,
 y_{t-1} - próbka danych w czasie t-1,

$$\Delta^{n+1} y_t = \Delta^n y_t - \Delta^n y_{t-1}$$

$$\Delta y_t = y_t - y_{t-1}$$

(n+1) poprzednich wartości $y_{t-1}, y_{t-2}, \dots, y_{t-n+1}$, są znane, y_t jest predykowane. Możliwe są następujące implementacje:

P r e d y k c j a z e r o w e g o r z ę d u

Najprostsza wielomianowa predykcja to predykcja zerowego rzędu dla $n = 0$.

W tym przypadku

$$\hat{y}_t = y_{t-1} \quad (2.5)$$

i predykowana wartość jest równa wartości poprzedniej próbki danych. Granice tolerancji są jednakowe i odpowiadają ustalonej szerokości K . Realizowane jest to przez odrzucenie pewnej ilości mniej znaczących bitów w binarnym słowie danych. Jeżeli dwa słowa danych mają taką samą postać po odrzuceniu tych bitów, to dane znajdują się w tym samym przedziale tolerancji. Predykcja realizowana jest zgodnie z (2.5), nowy punkt danych leży w granicach tolerancji poprzedniego punktu. Jeżeli nowy punkt danych leży na zewnątrz granic tolerancji poprzedniego punktu, wtedy jego wartość jest przesyłana i proces powtarzany jest od początku. Możliwy jest zmodyfikowany algorytm predykcji zerowego rzędu z tzw. "pływającą" szczeliną.

P r e d y k c j a p i e r w s z e g o r z ę d u - wykorzystuje do aproksymacji punktów danych wielomian

$$\hat{y}_t = 2 y_{t-1} - y_{t-2} \quad (2.6)$$

Równanie to obrazuje linię prostą pomiędzy dwoma ostatnimi punktami danych. Początkowo przesyłane są dwa pierwsze punkty danych i wykreślana jest linia prosta przechodząca przez nie. Szczelina tolerancji szerokości $2K$ umieszczona jest wokół tej linii. Predykowana wartość nowego punktu danych jest punktem tej linii prostej. Jeżeli nowy punkt danych leży wewnątrz szczeliny tolerancji szerokości $\pm K$ umieszczonej wokół wartości predykowanej, wtedy ten punkt nie jest przesyłany. Jeżeli nowy punkt danych leży na zewnątrz szczeliny tolerancji, wtedy ten punkt jest przesyłany i nowa linia predykcji przechodząca przez obecny punkt danych, który był przesyłany i poprzedni predykowany punkt danych jest tworzona.

O p t y m a l n a l i n i o w a p r e d y k c j a - predykcja następnej próbki danych jest realizowana przez utworzenie liniowej kombinacji poprzednich próbek danych

$$\hat{y}_t = \sum_{k=1}^H a_k y_{t-k} \quad (2.7)$$

gdzie:

\hat{y}_t - predykowana wartość aktualnej próbki danych,

a_k - współczynnik liniowej predykcji,

y_{t-k} - poprzednie próbki danych.

Optymalna liniowa predykcja wykorzystuje zbiór współczynników, który minimalizuje średniokwadratowy błąd pomiędzy predykowaną i aktualną wartością danych. Optymalny zbiór współczynników jest tworzony poprzez rozwiązanie układu N równań liniowych

$$\sum_{k=1}^H a_k R_y \{(\tau - k\theta)T\} = R_y \{(\tau + S)T\}, \tau = 1, 2, \dots, N \quad (2.8)$$

gdzie:


$R_y \{(\tau - k\theta)T\}$ - autokorelacyjna funkcja sygnału dla opóźnienia $(\tau - k\theta)T$

S - liczba okresów próbkowania

Można rozpatrywać dwa warianty optymalnej liniowej predykcji. Pierwszy polegający na tym, że predykowana wartość rzeczywistej próbki danych jest tworzona na podstawie N poprzednich rzeczywistych wartości próbek. Różnica pomiędzy wartościami, predykowaną i rzeczywistą jest kodowana i przesyłana. Jeżeli odbiornik wykorzystuje takie same współczynniki predykcji wtedy możliwe jest otrzymanie wartości próbki rzeczywistej. Drugi, wykorzystuje szczylinę tolerancji wokół wartości predykcji. Początkowo, pierwsze N próbek są przesyłane. Predykowana wartość $N + 1$ próbki jest otrzymywana na podstawie rzeczywistych wartości N poprzednich próbek. Szczylina tolerancji jest umieszczona wokół obecnej predykowanej wartości $/N + 1$ wartości/. Jeżeli wartość rzeczywistej próbki leży wewnątrz szczyliny umieszczonej wokół wartości predykowanej, wtedy ta próbka nie jest przysyłana. Obecna wartość predykcji jest wykorzystywana w równaniu predykcji w celu otrzymania wartości predykcji dla następnej próbki. Jeżeli następna rzeczywista wartość próbki leży wewnątrz szczyliny tolerancji, wtedy ta próbka nie jest przesyłana i jej wartość predykowana wykorzystywana jest w równaniu predykcji. Kiedy rzeczywista wartość próbki danych leży na zewnątrz szczyliny tolerancji, wtedy próbka ta jest przesyłana i rzeczywista wartość próbki wykorzystywana jest w równaniu predykcji do predykowania następnego punktu danych. Równanie predykcji (2.7) opisuje optymalny liniowy nierekursywny filtr /tylko ostatnie wartości próbek wejściowych są wykorzystywane do otrzymania sygnału wyjściowego/, który może być otrzymany poprzez rozwiązanie równania Wienera-Hopfa dla przypadku dyskretnych danych.

Metody interpolacji różnią się od metod predykcji tym, że wszystkie wartości próbek pomiędzy ostatnio przesyłaną wartością i obecną wartością próbki podlegają interpolacji. Metody te omówiono w pracy autora [22] oraz w pracach [36, 47, 76, 78]. Na rys. 2.4 przedstawiono relację pomiędzy współczynnikami redukcji a szczyliną tolerancji K dla predykcji zerowego rzędu, interpolacji zerowego rzędu i interpolacji pierwszego rzędu.

Redukcja redundancji metodą transformacji jest szeroko omówiona w licznych pracach [30, 47, 49, 78, 82], w tym w pracach autora [17, 22]. W tym



Rys.2.4. Zależność pomiędzy współczynnikiem redukcji a szczeliną tolerancji

miejszu omówimy tylko ogólne możliwości wykorzystania transformacji Karhunen-Loeve'go w procesie redukcji redundancji. Wykorzystujemy w tym przypadku pewien optymalny zbiór ortonormalnych funkcji bazowych. Ten ortonormalny zbiór funkcji bazowych jest optymalny, ponieważ najmniejsza liczba ortonormalnych funkcji jest konieczna dla uzyskania danego błędu.

Niech sekwencja próbek danych będzie następująca

$$X(T), X(2T), \dots, X(NT)$$

Wprowadzimy zbiór funkcji taki, że

$$\hat{X}(kT) = \sum_{i=1}^M a_i \phi_i(kT) \quad (2.9)$$

gdzie:

- $\hat{X}(kT)$ - odtworzona wartość próbki danych,
- a_i - współczynniki, które są przesyłane,
- ϕ_i - wektory własne autokorelacyjnej macierzy X -ów.

Wybieramy do reprezentowania danych M wektorów własnych o największych wartościach własnych.

Współczynniki, które są przesyłane otrzymywane są następująco

$$a_i = \sum_{j=1}^N X(jT) \phi_i(jT) \quad (2.10)$$

Do otrzymania każdego współczynnika wymagane jest N mnożeń i dodawań. Jeżeli mamy M wektorów własnych, wtedy konieczne jest $M \cdot N$ operacji mnożenia i dodawania. Jeżeli wiedza o statystyce sygnału nie jest znana, wtedy musi być najpierw uzyskana macierz autokorelacji, następnie realizuje się diagonalizację macierzy w celu otrzymania wektorów i wartości własnych. Średniokwadratowy błąd wynosi

$$e^2 = \sum_{k=M+1}^N \lambda_k \quad (2.11)$$

gdzie:

λ_k - wartości własne macierzy autokorelacji.

Implementacja tej metody jest niepraktyczna. Tablica 2.1 przedstawia ocenę poszczególnych metod redukcji redundancji.

Tablica 2.1

Ocena poszczególnych metod redukcji redundancji

Algorytm	Wyniki	Implementacja Stopień skomplikowania
Predykcja zerowego rzędu	Dobre dla wszystkich typów danych	Umiarkowany
Interpolacja pierwszego rzędu-2 stopnie swobody	Dobre, głównie dla dużych szczelin	Umiarkowany
Interpolacja pierwszego rzędu-4 stopnie swobody	Dobre	Wymaga dużej ilości i zmiennej liczby obliczeń
Liniiowa predykcja	Złe	Umiarkowany /jeżeli współczynniki są stałe/
DPCM	Zerowy błąd	Kodowanie trudne
Transformacja Karhunen-Loeve	Bardzo dobre	Niepraktyczna
Transformacja Fouriera	Dobre	Niepraktyczna

W powyższym, krótkim omówieniu pominięto metody redukcji redundancji związane z rozpoznawaniem sygnału. Uwagi dotyczące tego typu metod przedstawione zostaną w rozdziale 5 i 6.

2.3. Redukcja redundancji obrazów

Obraz jest jedną z ważniejszych postaci przedstawienia informacji. Można go opisać formalnie w postaci pewnej funkcji dwóch zmiennych, natomiast w rzeczywistych, fizycznych systemach obraz zawsze występuje w formie materialnej, energetycznej, w postaci określonych sygnałów. Przesyłanie, zapamiętywanie i odtwarzanie obrazów może być realizowane przy wykorzystaniu układów analogowych i cyfrowych. Układy cyfrowe w porównaniu z układami analogowymi posiadają szereg zalet z punktu widzenia przesyłania obrazów, a także ich zapamiętywania i przetwarzania. Przy przetwarzaniu przy pomocy e.m.c obraz można przedstawić w postaci macierzy /dyskretnych zbiorów liczb/, a nie funkcji. Oczywiście przy dostatecznie dużej liczbie próbek i poziomów kwantowania obraz cyfrowy w nieznacznym stopniu różni się od obrazu oryginalnego.

Obrazy przedstawiają sobą źródło informacji z dużą redundancją. W licznych praktycznych zadaniach, przy zadanej ocenie jakości obrazu można zmniejszyć niezbędną liczbę informacji obrazu w porównaniu z obrazem wejściowym. Przy tym obniżają się wymagania odnośnie przepustowości kanału, pojemności pamięci, zmniejszają się także straty energii związane z przetwarzaniem i transmisją obrazu. Redundancja przejawia się w występowaniu funkcjonalnych lub statystycznych związków między różnymi elementami obrazu /statystyczny nadmiar/ lub też może być wywołana nieczułością odbiorcy /np. systemu wzrokowego człowieka/ na pewne nieodwracalne, wprowadzając pewne zakłócenia, przekształcenia obrazów /psychofizyczny nadmiar/. Zadanie redukcji redundancji obrazu w warunkach niedostatecznej informacji a priori o właściwościach obrazu polega na zredukowaniu lub całkowitym usunięciu statystycznego nadmiaru i/lub zastosowaniu zmniejszających ogólną liczbę danych, nieodwracalnych przekształceń, nie obniżających subiektywnej jakości obrazu, tj. redukcji psychofizycznego nadmiaru. Można stwierdzić, że istnieją dwie wzajemnie uzupełniające się drogi redukcji redundancji obrazu: pierwszy, wykorzystująca właściwości systemu wzrokowego; druga, wykorzystująca właściwości rzeczywistych obrazów.

Z teorii informacji wiadomo, że dla zadanego źródła wiadomości przy zadanym kryterium wierności jej odtworzenia można określić szybkość formowania wiadomości v . Przy czym, wejściowa wiadomość może być przesyłana z określonymi według kryterium wierności dowolnie małymi zakłóceniami, jeżeli przepustowość kanału będzie większa niż szybkość formowania wiadomości v . Praktyczna realizacja tej teorii przy opisie i kodowaniu obrazów jest utrudniona, ponieważ nie istnieje uniwersalny model obrazu i brak jest analitycznego opisu kryterium wierności odtwarzanego obrazu. Zastosowanie teorii informacji dla celów transmisji obrazów przedstawione w pracy autora [16].

Pomijając te trudności opracowano szereg metod redukcji redundancji dla opisu i kodowania obrazów. Podstawą tych metod jest wykorzystanie statystycznych właściwości obrazu i rozdzielenie kryteriów wierności na zbiór cząstkowych kryteriów.

Redundancja może być oceniana dla obrazu cyfrowego, wykorzystując pojęcie względnej statystycznej redundancji źródła informacji, tj.

$$R = \frac{H_{MAX} - H}{H_{MAX}} = 1 - \frac{\sum_{i=1}^Q p_i \log_2 p_i}{1 \cdot \log_2 h} = 1 - \frac{1}{wrr} \quad (2.12)$$

gdzie:

- H - entropia źródła obrazu,
- $Q=h^l$ - liczba możliwych stanów źródła obrazu,
- h - liczba poziomów kwantowania każdej współrzędnej,
- l - liczba współrzędnych,
- p_i - częstotliwość występowania i-tego stanu,
- wrr - współczynnik redukcji redundancji informacji źródła.

Oczywiście

$$wrr = \frac{1 \cdot \log_2 h}{\sum_{i=1}^Q p_i \log_2 p_i} \quad (2.13)$$

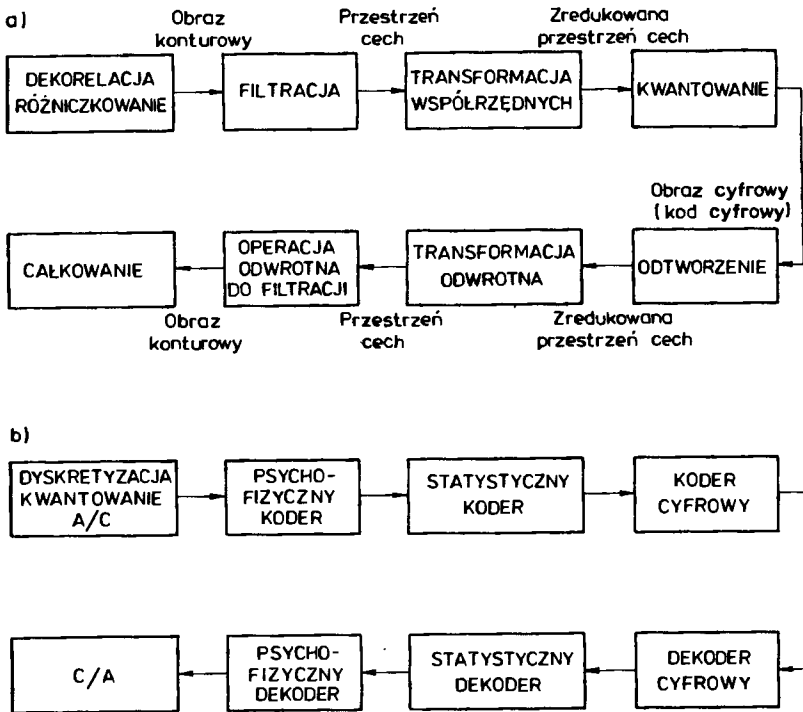
Sposób statystycznej oceny pozwala zredukować ilość informacji obrazu przy uwzględnieniu prawdopodobieństw występowania elementów obrazu. Jednak, zwykle prawdopodobieństwa występowania poszczególnych obrazów nie są znane, dlatego też w ogólnym przypadku współczynnik redukcji określa się stosunkiem dwóch wielkości, oceniających ilość informacji w obrazie, przetwarzanym dwoma różnymi sposobami, przy uwzględnieniu pewnego kryterium wierności. Wynika stąd, że przy różnych sposobach znajdowania ilości informacji można otrzymać różne postacie współczynników redukcji redundancji. Najbardziej rozpowszechniona definicja współczynnika redukcji redundancji jest następująca

$$wrr = \frac{\text{liczba bitów obrazu wejściowego}}{\text{liczba bitów obrazu przetworzonego}} \quad (2.14)$$

Niekiedy, w celu określenia wielkości redukcji redundancji podaje się tylko liczbę bitów/element obrazu przetworzonego milcząco przyjmując, że ilość bitów/element obrazu wejściowego jest z góry określona.

Układ blokowy systemu redukcji redundancji obrazu przedstawiono na rys.2.5 Na rys.2.5a pokazano schemat redukcji redundancji obrazu w przypadku przetwarzania obrazu bazującego na wydzieleniu cech obrazu, np. w procesie identyfikacji, rozpoznawania itp., natomiast rys.2.5b przedstawia schemat redukcji redundancji przy kodowaniu obrazu.


Prac dotyczących metod redukcji redundancji obrazu jest dużo, tak, że dokonanie chociażby skrótowego przeglądu tych prac wykracza poza ramy mo -



Rys.2.5. System redukcji redundancji obrazu
 a/ w przypadku przetwarzania obrazu bazującego
 na wydzieleniu cech obrazu,
 b/ w przypadku kodowania obrazu

nografii. W pracy autora [22] oraz pracach [47,50,78,82] przedstawiono podstawowe informacje o różnych metodach kodowania obrazów. Jednak, prezentowane w licznych pracach metody kodowania obrazu cyfrowego, umożliwiające redukcję redundancji obrazu znajdują zastosowanie głównie dla obrazów telewizyjnych. Pozwalają one na uzyskiwanie współczynników redukcji redundancji $wrr \leq 10^*$. Prace dotyczące zagadnienia redukcji redundancji obrazu są intensywnie rozwijane [10,11,15,18,50,54,63,71,79,82,88]. Stymulatorem jest fakt, że stosowanie dotychczas opisanych metod i ich wzajemnych kombinacji nie pozwala na osiągnięcie lepszych rezultatów aniżeli przedstawiono na rys.2.6. Przy czym osiągnięcie najniższych wartości liczby bitów na element obrazu możliwe jest tylko przy bardzo rozbudowanej realizacji hardwerowej systemu redukcji redundancji i długich czasach przetwarzania. Dlatego intensywnie rozwijane są prace mające na celu opracowanie metody

* W pracach dotyczących redukcji redundancji prezentowane są tzw. obrazy testowe. Cytowane wartości wrr odnoszą się do tego typu obrazów o wymiarach 256 x 256 elementów i 8 bitach /element obrazu.



Rys.2.6. Wyniki uzyskiwane przy stosowaniu różnych metod redukcji redundancji obrazu

redukcji redundancji obrazu zapewniającej zbudowanie optymalnego systemu redukcji redundancji, tj. systemu o obiektach rozłożonych, małym stopniu komplikacji hardwerowej, prostym oprogramowaniu i dostatecznie krótkim czasie przetwarzania informacji. Próby /częściowo udane/ opracowania nowej metody redukcji redundancji podejmowane była przez szereg autorów w wielu ośrodkach. Najbardziej dotychczas znacząca jest metoda Kunta, bazująca na wcześniejszych pracach Walperta, Grahama i Schreibera [10,18, 63,92]. Polega ona na podziale obrazu na dwie części: "low-pass picture" - zawierający cały obszar jaskrawości bez ostrych zmian i "high - pass picture" zawierający informację o dużych zmianach jaskrawości. Pierwszy z tych obrazów kodowany był metodą PCM, drugi opisywany był przez składowe gradientu. Położenie i składowe każdego gradientu były kodowane. Zakodowany obraz reprezentowany był przez cztery zbiory danych.

Autor opracował metodę redukcji redundancji polegającą na kodowaniu składowych częstotliwościowych obrazu [18]. Składowa o małej częstotliwości kodowana była metodą adaptacyjnej DPCM, natomiast składowa wielkiej częstotliwości reprezentowana przez linie konturowe, określana była przez współczynniki krzywej aproksymującej. Mimo znacznego stopnia komplikacji /w porównaniu np. z metodami transformacji/ metoda ta umożliwiła uzyskanie zadowalających rezultatów.

W szeregu prac [20,25,30,31,35,37,39,46] związanych z zastosowaniem przetwarzania obrazów rozpatrywane są N-obrazy. Również prace prowadzone przez autora w większości dotyczyły przetwarzania N-obrazów i zawierały, np. zagadnienia związane z rozpoznawaniem części maszynowych, opracowanie systemu wizyjnego robota, rozpoznawanie kodów pocztowych, transmisję obrazów sytuacji technicznych i procesów technologicznych. W pracach tych pojawiła się konieczność redukcji redundancji obrazu, przy

czym zastosowanie dotychczasowych metod redukcji redundancji nie przyniosło spodziewanych rezultatów.

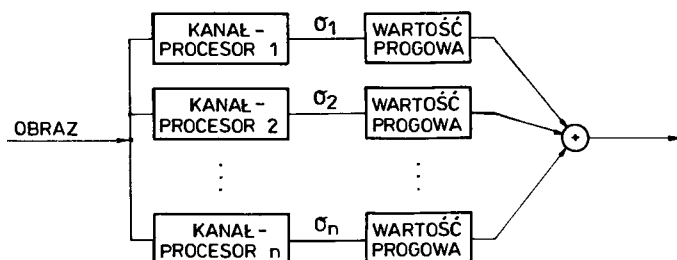
Obserwując przetwarzane obrazy możemy stwierdzić:

- punkty tła zawierają dużą redundancję obrazu,
- punkty konturowe są podstawą procesu rozpoznawania obrazu*.

Punkty tła można grupować, tworząc względnie duże jednorodne obszary, podczas gdy punkty konturowe określają granice między sąsiednimi obszarami, przy czym zmiany jasności pomiędzy tymi obszarami są subiektywnie zwiększane przez system wzrokowy człowieka**.

Dotychczas obrazy były przetwarzane dla celów redukcji redundancji bez należytego rozważenia aktualnych właściwości obrazu. Rozważenie działania systemu wzrokowego człowieka oraz stworzenie odpowiedniego modelu systemu przetwarzania odpowiadającego systemowi wzrokowemu człowieka są czynnikami wyjściowymi do opracowania nowej metody redukcji redundancji.

Badania systemu wzrokowego człowieka przeprowadzane metodą psychometryczną, przy bardzo dużej liczbie eksperymentów, pozwalają udokumentować hipotezę, że system wzrokowy ma pewną liczbę niezależnych równoległych mechanizmów /kanałów, procesorów/ wykrywania bodźców. Są one nastrojone na różne przestrzenne częstotliwości i posiadają różne kąty orientacji. Prowadzi to do modelu systemu wzrokowego jak na rys.2.7. Za każdym ra-



Rys.2.7. Model systemu wzrokowego człowieka

zem, kiedy jeden lub kilka sygnałów σ_k , $k=1\dots n$ są większe od progu czułości, odbiorca wykrywa bodziec.

Wyniki badań nad systemem wzrokowym człowieka zostały dokładnie udokumentowane, można więc przyjąć, że prezentowany model systemu wzrokowego człowieka odpowiada rzeczywistemu systemowi /jest prawdziwy/. Na tej podstawie przyjęto założenie, że system redukcji redundancji obrazu po-

* Punkty przedstawiające ostry skok jasności są charakteryzowane przez bardzo małą redundancję. Punkty takie nazywamy punktami konturowymi, w przeciwieństwie do punktów nazwanych punktami tła obrazu. Dokładne definicje zostaną przedstawione w dalszej części pracy w rozdziale 3.

** Zjawisko to określone jest mianem zjawiska Macha [78,82].

winien posiadać strukturę analogiczną do struktury systemu wzrokowego człowieka. Dodatkowo założono, mając na uwadze zwiększenie szybkości przetwarzania, że pewne parametry przetwarzanych obrazów mogą być przesyłane po między poszczególnymi procesorami /kanałami/ obrazu.

Zgodnie z pracami [48,54,70,72,77,82,86] możliwe jest zrozumienie i zinterpretowanie niekompletnego obrazu przez człowieka. Oglądając obraz przedstawiający nieciągłą linię konturową pewnego obiektu nie mamy w większości przypadków żadnych trudności z określeniem nazwy obiektu. Analogiczna sytuacja występuje w przypadku oglądania obrazu z "dziurami" - nie mamy problemów z wypełnieniem "dziur" treścią obrazową.

W wielu zastosowaniach cyfrowego przetwarzania obrazów nie wymagane jest dokładne odtworzenie przetwarzanego obrazu, tj. uzyskanie "kopii" obrazu wejściowego. Konieczne jest natomiast zinterpretowanie obrazu, czyli określenie jakie obiekty przedstawia obraz, w jakiej sytuacji, itp. Dla zinterpretowania obrazu nie jest konieczna cała informacja zawarta w obrazie. Wysłunięto tezę, że dekompozycja obrazu do postaci obrazu o dwóch poziomach jaskrawości i pewnej, określonej liczby obrazów-okien o odpowiednich wymiarach, umożliwi uzyskanie dużych wrr przy jednoczesnej prawidłowej interpretacji obrazu.

3. REDUKCJA REDUNDANCJI OBRAZU CYFROWEGO - METODA DEKOMPOZYCJI OBRAZU

W niniejszym rozdziale omawiamy operacje przetwarzania obrazu przy redukcji redundancji metodą dekompozycji. Dziedzina przetwarzania obrazu posiada bardzo bogatą literaturę [6,8,10,13,36,38,45,54,56,63,71,78,82, 88,89]. To obszerne piśmiennictwo podaje szereg różnych metod przetwarzania obrazu o różnym stopniu szczególności teoretycznego opracowania i różnej przydatności praktycznej. Z punktu widzenia dalszej dykusji interesujące są tylko niektóre operacje przetwarzania obrazu. Omówimy w kolejności operację obliczania histogramu obrazu, operację filtracji medianowej obrazu, obliczanie gradientu obrazu i tworzenie obrazów binarnych, segmentację obrazu oraz tworzenie „okien-obrazu.

3.1. Histogram obrazu

Definicja 3.1.a

$h : \{0,1,\dots,N\} \rightarrow Z$ reprezentuje histogram obrazu F , gdzie $h(k)$ jest liczbą elementów obrazu posiadających jaskrawość k , $0 \leq k \leq N$ i Z jest zbiorem nieujemnych liczb całkowitych.

Definicja 3.1.b

$h_1 : \{0,1,\dots,N\} \rightarrow Z$ reprezentuje histogram gradientu, gdzie $h_1(k)$ jest sumą wartości gradientu dla wszystkich elementów obrazu mających wartość jaskrawości k

$$h_1(k) = \sum_{(r,o) \in X(k)} d_{r,o} \quad (3.1)$$

$$J(k) = \{(r,o) \mid f_{r,c} = k\} \quad (3.2)$$

$d_{r,c}$ jest wartością gradientu jaskrawości elementu obrazu o współrzędnych (r,c) .

Definicja 3.2

Niech $M(F)$ będzie pewną funkcją umożliwiającą określenie zawartości informacji obrazowej w obrazie daną przez

$$M(F) = \sum_{k=0}^N h(k) - \max_k h(k) \quad (3.3)$$

Jeżeli $\bigwedge_{i,j \in R} f_{i,j} = \text{const}$, to $M(F) = 0$. Jeżeli $\bigwedge_{k \in G} h(k) = \text{const}$, to $M(F) = \max 1$ wtedy $M(F) = \frac{m \cdot n \cdot N}{N+1}$.

$M(F)$ przyjmuje wartości bliskie minimalnej dla obrazów zawierających mało informacji, natomiast bliskie wartości maksymalnej dla obrazów zawierających dużo informacji obrazowych.

Definicja 3.3a

Wartością progową t funkcji jaskrawości obrazu nazywamy wartość jaskrawości określającą położenie pierwszego minimum histogramu h następującego po wartości maksymalnej histogramu.

Definicja 3.3b

Wartością progową t_1 funkcji jaskrawości obrazu nazywamy wartość jaskrawości, dla której histogram gradientu h_1 przyjmuje wartość maksymalną.

3.2. Filtracja medianowa (FM) obrazu

Podstawowymi pracami dotyczącymi filtracji medianowej FM obrazu nie poruszającymi jednak wszystkich aspektów, zarówno teoretycznych, jak i praktycznych tego procesu są prace Huanga [51,52], Atamana [4], Reevesa [80] i innych [13,85,92]. FM jest operacją nieliniową i ten fakt komplikuje matematyczną analizę jej właściwości. Realizowana jest najprościej przez przesuwanie pewnego "okna" wzdłuż wierszy cyfrowego obrazu i zmianę wartości elementu obrazu w środku "okna" przez wartość mediany elementów wewnątrz "okna". Otrzymuje się przy tym obraz bardziej gładki w porównaniu z obrazem wejściowym. W porównaniu z liniową filtracją małej częstotliwości, FM umożliwia zachowanie ostrych zmian jaskrawości oraz dużą efektywność przy eliminacji szumu impulsowego.

Definicja 3.4

Dwuwymiarowy FM_{A_1} obrazu $\{f_{i,j}, (i,j) \in R\}$ jest definiowany jak

$$y_{i,j} = \underset{A_1}{\text{mediana}} f_{i,j} = \text{mediana} [f_{i+r,j+s}; (r,s) \in A_1] \quad (3.4)$$

gdzie:

A_1 określa tzw. okno FM.

Przykładowe kształty A_1 przedstawiono poniżej

i bardzo szybko zmniejsza się ze zwiększeniem liczby elementów A_1 .

Dowód:

Szum impulsowy w punkcie (i, j) obrazu występuje z prawdopodobieństwem P , które nie zależy ani od występowania szumu w innych punktach obrazu ani też od obrazu wejściowego. Zakłócony punkt obrazu ma wartość a . Jeżeli $\{f'_{i,j}\}$ będzie obrazem zakłóconym to

$$f'_{i,j} = \begin{cases} a & \text{z prawdopodobieństwem } P \\ f_{i,j} & \text{z prawdopodobieństwem } (1-P) \end{cases} \quad (3.6)$$

Niech punkt (i', j') będzie położony na części obrazu ze stałą wartością jaskrawości

$$f_{i'+r, j'+s} = f_{i', j'} = c \neq d, \quad (r, s) \in A_1 \quad (3.7)$$

i niech

$$y_{i', j'} = \underset{A_1}{\text{mediana}} (f'_{i', j'}) \quad (3.8)$$

Mamy

$y_{i', j'} = f_{i', j'} = c$ tylko w przypadku, jeżeli liczba impulsów szumu w A_1 ze środkiem w (i', j') będzie mniejsza od połowy liczby punktów w A_1 , tj. mniejsza lub równa $(L-1)/2$, gdzie L -wymiar A_1 . Ponieważ liczba zakłóconych punktów w A_1 ma rozkład dwumianowy mamy

$$P(y_{i', j'} = f_{i', j'}) = \sum_{k=0}^{(L-1)/2} \binom{L}{k} p^k (1-p)^{L-k} \quad (3.9)$$

Prawdopodobieństwo wystąpienia błędu wynosi

$$1 - \sum_{k=0}^{(L-1)/2} \binom{L}{k} p^k (1-p)^{L-k} \quad (3.10)$$

W pracy [51] przedstawiono zależności liczbowe ilustrujące zależność prawdopodobieństwa wystąpienia błędu przy FM od L i P .

Definicja 3.5

Jeżeli mamy

$$\{f'_{i,j}\} = \{f_{i,j}\} + \{n_{i,j}\} \quad (3.11)$$

gdzie:

$\{n_{i,j}\}$ reprezentuje pewien szum, to oszacowanie obrazu oryginalnego jest dane przez

$$\{f_{1,j}\} = \text{mediana } \{f'_{1,j}\} + \text{mediana } [\{f'_{1,j}\} - \text{mediana } \{f'_{1,j}\}] \quad (3.12)$$

FM obrazu wejściowego \underline{F} daje w wyniku obraz \underline{Y} określony następująco

$$FM : \underline{F} \rightarrow \underline{Y} \quad (3.13)$$

gdzie:

$$\underline{Y} = \left\{ \begin{array}{l} y_{1,j} = 0 \\ y_{1,j} = 0 \\ y_{1,j} = 0 \\ y_{1,j} = 0 \\ y_{1,j} \\ y_{1,j} = \text{mediana } f_{r,s} \\ \quad (r,s) \in A_2 \end{array} \right. \begin{array}{l} i = \{1, \dots, ((L-1)/2)\} \\ i = \{[m - ((L-1)/2) + 1], \dots, m\} \\ j = \{1, \dots, ((L-1)/2)\} \\ j = \{[\lfloor n - \frac{L-1}{2} \rfloor + 1], \dots, n\} \\ \frac{L-1}{2} < i \leq m - \frac{L-1}{2} \\ \frac{L-1}{2} < j \leq n - \frac{L-1}{2} \\ A_2 = \left\{ (r,s) \left| \left(i - \frac{L-1}{2} \leq r \leq i + \frac{L-1}{2} \right) \right. \right. \\ \quad \left. \left. \wedge \left(j - \frac{L-1}{2} \leq s \leq j + \frac{L-1}{2} \right) \right\} \right. \end{array} \quad (3.14)$$

3.3. Wydzielanie zmian jaskrawości

Liczba metod wydzielenia zmian jaskrawości w obrazie jest bardzo duża [33,35,48,53,64,66], przy czym wszystkie metody można podzielić na: lokalne, obszarowe, globalne, sekwencyjne, heurystyczne, dynamiczne. Zostały one omówione w pracy [71,78,82], która daje porównanie omawianych metod.


Układ wydzielenia zmian jaskrawości powinien realizować dokładne wydzielenie zmian jaskrawości, umożliwiające zlokalizowanie i zdefiniowanie obiektu w możliwie krótkim czasie. Z tego powodu algorytmy realizując operacje wydzielenia zmian jaskrawości nie mogą być zbyt skomplikowane. Pozostawiając na uboczu kwestię omówienia i wyboru metod wydzielenia zmian jaskrawości w niniejszym rozdziale proponujemy nowy algorytm wydzielenia zmian jaskrawości. Algorytm ten pozwala na wyeliminowanie operacji pociekania konturu.

Definicja 3.6

Niech D będzie obrazem, uzyskanym w wyniku operacji wydzielenia zmian jaskrawości, określonym następująco:

$$D = \left\{ \begin{array}{l} d_{i,j} \\ \left. \begin{array}{l} d_{i,j} = 0 \quad i = \left\{ 1, \dots, \left(\frac{L-1}{2} \right) \right\} \\ d_{i,j} = 0 \quad i = \left\{ \left[\left(m - \frac{L-1}{2} \right) + 1 \right], \dots, m \right\} \\ d_{i,j} = 0 \quad j = \left\{ 1, \dots, \left(\frac{L-1}{2} \right) \right\} \\ d_{i,j} = 0 \quad j = \left\{ \left[\left(n - \frac{L-1}{2} \right) + 1 \right], \dots, n \right\} \\ d_{i,j} = \begin{cases} \sum_{k=0}^3 |y(k) - y(7-k)| & \text{jeżeli } \left(\sum_{k=0}^3 |y(k) - y(7-k)| \right) > t_1 \\ 0 & \text{w przypadku przeciwnym} \end{cases} \end{array} \right\} \quad (3.15)$$

dla elementów obrazu ponumerowanych zgodnie z rys.3.1.



Rys.3.1. Numeracja elementów obrazu oraz oznaczających punkt /i,j/

Definicja 3.7

Wskaźnikiem punktu konturowego nazywamy sumę

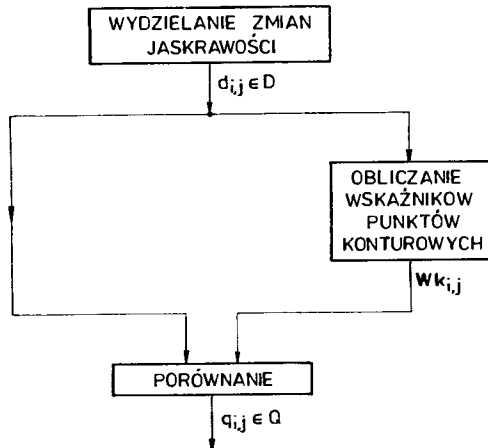
$$W_{k_{i,j}} = \left[\frac{1}{8} \sum_{k=0}^7 d^2(k) \right]^{1/2} \quad (3.16)$$

dla elementów obrazu D ponumerowanych analogicznie jak na rys.3.1. Dokonując porównania elementów obrazu D z ich wskaźnikami konturów, otrzymujemy obraz konturowy.


Mamy

$$q_{i,j} = \begin{cases} 1 & \text{jeżeli } d_{i,j} > W_{k_{i,j}} \\ 0 & \text{w przypadku przeciwnym} \end{cases} \quad (3.17)$$

Algorytm wydzielenia zmian jaskrawości przedstawiono na rys.3.2, natomiast na rys.3.3 przedstawiono przypadkowo wybrany fragment obrazu oryginalnego i obraz uzyskany w wyniku wydzielenia zmian jaskrawości. Wydzielenie zmian jaskrawości jest równoznaczne z wydzieleniem obiektów obrazu [35,71,82,88]. Dla scharakteryzowania obiektu ważny jest jego kształt. Wprowadzamy szereg definicji umożliwiających realizację algorytmów przetwarzania obrazów konturowych.



Rys.3.2. Algorytm wydzielenia zmian jaskrawości



Rys.3.3. Fragment obrazu oryginalnego /a/ i obraz uzyskany w wyniku wydzielenia jaskrawości /b/

Definicja 3.8

Określmy obrazy

$$Q = \{q_{i,j}, 1 \leq i \leq m, 1 \leq j \leq n\} \quad (3.18)$$

$$i \quad B = \{b_{i,j}, 1 \leq i \leq m, 1 \leq j \leq n\} \quad (3.19)$$

gdzie:

 $q_{i,j}$ - jest określone przez (3.17) i

$$b_{i,j} = \begin{cases} 1 & \text{dla } y_{i,j} > t \\ 0 & \text{w przypadku przeciwnym} \end{cases} \quad (3.20)$$

Zbiór $Q = Q1 \cup Q0$ gdzie $Q1 = \{q_{i,j} ; q_{i,j} = 1\}$ i $Q0 = \{q_{i,j} ; q_{i,j} = 0\}$ jest nazywany binarnym obrazem gradientu lub obrazem konturowym. Zbiór $B = B1 \cup B0$ gdzie $B1 = \{b_{i,j} ; b_{i,j} = 1\}$ i $B0 = \{b_{i,j} ; b_{i,j} = 0\}$ jest nazywany obrazem binarnym.

Definicja 3.9

Odległością lub metryką Θ pomiędzy każdą parą punktów należących do R jest liczba rzeczywista nieujemna, taka, że dla wszystkich elementów (i,j) , (h,k) , (l,p) mamy

$$\begin{aligned} \Theta((i,j), (h,k)) &= 0 \text{ jeżeli i tylko jeżeli } (i,j) = (h,k) \\ \Theta((i,j), (h,k)) &= \Theta((h,k), (i,j)) \\ \Theta((i,j), (l,p)) &\leq \Theta((i,j), (h,k)) + \Theta((h,k), (l,p)) \end{aligned} \quad (3.21)$$

Definicja 3.10


Konturem nazywamy podzbiór $C = \{q_{i,j} ; q_{i,j} \in Q1, \Theta(q_{i,j}, D0) = 1\}$ gdzie

Θ jest odległością określoną jako

$$\Theta(q_{i,j}, q_{h,k}) = |i-h| + |j-k| \quad (3.22)$$

Definicja 3.11

Otoczeniem /sąsiedztwem/ punktu obrazu o współrzędnych (i,j) ; $V(i,j)$, jest zbiór wszystkich punktów o współrzędnych $(h,k) \in R$ zawartych w dwuwymiarowym "oknie" o punkcie środkowym (i,j) /rys.3.4/.



Rys.3.4. Otoczenie /sąsiedztwo/ punktu (i,j)

$$V(i,j) = \{(h,k) \mid (h,k) \in R, \Theta((i,j), (h,k)) \leq 1\} \quad (3.23)$$

Posługując się tą definicją możemy wprowadzić pojęcie 4-elementowego i 8-elementowego otoczenia punktu (i,j) . Odpowiednio mamy

$$V_4(i,j) = \{(h,k) ; \Theta_4((i,j), (h,k)) \leq 1\} \quad (3.24)$$


$$\Theta_4((i,j), (h,k)) = |i-h| + |j-k| \quad (3.25)$$

$$1 \quad V_B(1,j) = \{(h,k) \mid \Theta_B((1,j), (h,k)) \leq 1\} \quad (3.26)$$

$$\Theta_B((1,j), (h,k)) = \max(|1-h|, |j-k|) \quad (3.27)$$

Definicja 3.12

Otoczenie /sąsiedztwo/ obszaru E , $V(E)$, jest połączeniem otoczeń $V(1,j)$ wszystkich elementów $(1,j) \in E$ /rys.3.5/



Rys.3.5. Otoczenie /sąsiedztwo/ obszaru E obrazu

$$V(E) = \{(h,k) \mid \exists (1,j) \in E, (h,k) \in V(1,j)\} \quad (3.28)$$

Definicja 3.13

Obszar $E \subset R$ jest α -połączonym podzbiorem R , jeżeli dla dwóch punktów $(1,j) \in E$, $(h,k) \in E$, istnieje skończona sekwencja /ścieżka/ $(1,j) \dots (1,p) (s,t) \dots (h,k)$ punktów $(1,p) \in E$ taka, że $(1,p) \in V(s,t)$. Będziemy mówili, że $(1,j)$ jest połączone z (h,k) rozumiejąc przez to relację taką, że:

- $(1,j)$ jest połączone z $(1,j)$ - ścieżka długości zero,
- $(1,j)$ jest połączone z (h,k) to (h,k) jest połączone z $(1,j)$,
- $(1,j)$ jest połączone z (h,k) a (h,k) z $(1,p)$ wtedy $(1,j)$ jest połączone z $(1,p)$.

Definicja 3.14

Punkt izolowany obszaru konturowego jest punktem spełniającym następujące warunki

$$P_{izol} = \{(1,j) \mid (1,j) \in R, q_{1,j} = 1, LL_B(1,j) < 2\} \quad (3.29)$$

gdzie:

$$LL_B(1,j) = \#\{(h,k) \in V_B(1,j) \mid q_{h,k} = 1\} \quad (3.30)$$

Punkty izolowane są usuwane z obrazu konturowego.

3.4. Segmentacja obrazu

Matematyczny opis zadania segmentacji obrazu jest następujący:

Definicja 3.15

Segmentacją obrazu $\{y_{1,j} \mid (1,j) \in R\}$ według pewnej reguły Reg nazywamy podział $S = \{S_1, S_2, \dots, S_K\}$, spełniający warunki

$$1/ \bigcup_{u=1}^K S_u = R \quad (3.31)$$

$$2/ S_u \cap S_v = \emptyset \quad \wedge u \neq v \quad (3.32)$$

$$3/ \text{Reg}(S_u) = \text{true} \quad \wedge u \quad (3.33)$$

$$4/ \text{Reg}(S_u \cap S_v) = \text{false} \quad \wedge u \neq v \quad (3.34)$$

gdzie:

$S = \{S_1, S_2, \dots, S_K\}$ - podział R na K niepustych, połączonych podzbiorów S_u , $u=1 \dots K$.

Reg - reguła, określona na zbiorze S i przyjmująca znaczącą /prawdziwą/ wartość wtedy i tylko wtedy, kiedy para punktów z każdego podzbioru S_u spełnia kryterium jednorodności.

Sygnal fizyczny wygodnie jest rozpatrywać w postaci sumy składowej statycznej /tzn. niezależnej od czasu/ i składowej dynamicznej. Składową statyczną można opisać przez wartość średnią; składową dynamiczną przez wariancję sygnału równą średniemu kwadratowi odchylenia jego wartości od wartości średniej. Wartość bezwzględna pierwiastka kwadratowego z wariancji nazywa się odchyleniem standardowym.

Definicja 3.16

Obszary jednorodne obrazu, są to obszary, dla których różnice między jaskrawościami elementów i średnią wartością jaskrawości obszaru obrazu są mniejsze od określonego progu.

$$\text{Reg}(S_u) = \begin{cases} \text{true} & \text{jeżeli } |f_{s,t} - F_{S_u}| < t_{S_u} \\ \text{false} & \text{w przypadku przeciwnym} \end{cases} \quad (3.35)$$

gdzie:

$$(s,t) \in S_u,$$

F_{S_u} - średnia wartość jaskrawości obszaru S_u ,

t_{S_u} - wartość progowa dla obszaru S_u .

Definicja 3.17

Średnia jaskrawość F_{S_u} elementów obrazu \in do obszaru S_u i standardowe odchylenie σ_{S_u} są określone jak następuje

$$F_{S_u} = \frac{1}{N} \sum_{(s,t) \in S_u} f_{s,t} \quad (3.36)$$

$$\sigma_{S_u} = \frac{1}{N} \left[\sum_{(s,t) \in S_u} [f_{s,t} - F_{S_u}]^2 \right]^{1/2} \quad (3.37)$$

dla obszaru S_u zawierającego N elementów.

Analizę rozpoczynamy od lewego górnego elementu obrazu, przy czym w chwili początkowej wszystkie elementy obrazu mają zerową etykietę. Algorytm segmentacji obrazu jest następujący:

1. Analizujemy kolejne punkty linii obrazu od lewej do prawej i kolejno z góry w dół. Dla każdego analizowanego punktu (s,t) stosujemy punkty 2 + 7 algorytmu.
2. Obliczamy wartość F'_S i σ'_S dla każdego obszaru będącego obszarem sąsiednim do elementu (h,k)

$$F'_{S_u} = \frac{1}{N+1} [f_{h,k} + NF_{S_u}] \quad (3.38)$$

$$\sigma'_{S_u} = \frac{1}{N+1} \left[[f_{h,k} - F_{S_u}]^2 + \sum_{(s,t) \in S_u} [f_{s,t} - F_{S_u}]^2 \right]^{1/2} \quad (3.39)$$

F'_{S_u} i σ'_{S_u} są odpowiednio wartością średnią i odchyleniem standardowym jakrawości obszaru S_u zawierającego nowy element (h,k) .

3. Obliczamy wartość progową t_{S_u} obszaru

$$t_{S_u} = \left(1 - \frac{\sigma'_{S_u}}{F'_{S_u}} \right) \cdot t_0 \quad (3.40)$$

gdzie:

t_0 jest stałą wartością progową.

4. Dla każdego obszaru obliczamy

$$\Delta F_{S_u} = |f_{h,k} - F_{S_u}| \quad (3.41)$$

5. Jeżeli $\Delta F_{S_u} \leq t_{S_u}$, wtedy etykieta obszaru S_u jest możliwą etykietą elementu (h,k) .

6. Jeżeli jest więcej niż jeden obszar sąsiedni do elementu (h,k) to etykieta punktu (h,k) jest etykietą obszaru, dla którego różnica ΔF_{S_u} jest minimalna.
7. Jeżeli żaden z obszarów nie spełnia warunków określonych w p.5 i 6, elementowi (h,k) przydzielona jest nowa etykieta i staje się on pierwszym elementem nowego obszaru.

Dla rozpatrywanych w pracy obrazów testowych doświadczalnie stwierdzono /badając zależność pomiędzy ilością obszarów o określonej liczbie elementów a ilością elementów obszaru/, że ok.70% wszystkich obszarów zawiera mniej niż 15 elementów. Obszary takie eliminowane są z obrazu przez dołączenie do jednego z obszarów sąsiednich.

3.5. Wybór punktów określających położenie "okien" - obrazu

Definicja 3.19

Możliwymi punktami położenia "okien" - obrazu /mppo/ będą punkty spełniające następujące warunki:

$$\text{mppo} = \{ (i,j) \mid (i,j) \in R, b_{i,j} \in B_1, LL'_B(i,j) > 5 \} \quad (3.42)$$

$$LL'_B(i,j) = \# \{ (h,k) \in V_B(i,j) \mid b_{h,k} = 1 \} \quad (3.43)$$

Ilość /mppo/ w obrazie jest stosunkowo duża, przy czym położone są one w różnej odległości od siebie. Zastosujemy algorytm grupowania /mppo/, w wyniku którego uzyskujemy punkt centralny grupy /mppo/. Kryterium grupowania jest minimalna suma kwadratów odległości wszystkich punktów, wchodzących w skład grupy do punktu środkowego grupy. Algorytm składa się z następujących kroków:

1. Wybiera się T początkowych punktów środkowych grup $p_1(1), p_2(1), \dots, p_T(1)$. Jest to T pierwszych /kolejność wynika z określonej kolejności analizy punktów obrazu/ /mppo/.
2. W k -tym kroku iteracji, zbiór /mppo/ przydziela się do T grup zgodnie z regułą

$$(mppo) \in S_z(k) \text{ jeżeli } \|(mppo) - p_z(k)\| < \|(mppo) - p_x(k)\| \quad (3.44)$$

dla wszystkich $x = 1, 2, \dots, T, x \neq z$

gdzie:

$S_z(k)$ - zbiór punktów wchodzących do grupy z punktem środkowym $p_z(k)$ *

* Równanie (3.44) dla /mppo/ zdefiniowanych przez (3.42) i
$$p_z(k) = \{ (h,k) \mid (h,k) \in Z \} \text{ i } p_x(k) = \{ (t,s) \mid (t,s) \in Z \} \quad (3.44a)$$
 gdzie: Z - zbiór liczb rzeczywistych może być zapisane jak

$$\sqrt{(i-h)^2 + (j-k)^2} < \sqrt{(i-t)^2 + (j-s)^2} \quad (3.44b)$$

W przypadku równości w (3.44) /mppo/ przydziela się albo do $S_z(k)$ albo do $S_x(k)$ /dowolnie/.

3. Na podstawie wyników p.2 obliczane są nowe punkty środkowe grup $p_z(k+1)$ $z=1,2, \dots, T$, wychodząc z założenia, że suma kwadratów odległości pomiędzy wszystkimi /mppo/ $\in S_z(k)$, a nowym punktem środkowym grupy musi być minimalna.

Kryterium jakości jest następujące

$$J_z = \sum_{(mppo) \in S_z(k)} \|(mppo) - p_z(k+1)\|^2 \quad z=1,2,\dots,T \quad (3.45)$$

$p_z(k+1)$ minimalizujący kryterium jakości jest określony przez

$$p_z(k+1) = \frac{1}{W_z} \sum_{(mppo) \in S_z(k)} (mppo) \quad z=1,2,\dots,T \quad (3.46)$$

gdzie:

W_z - liczba punktów wchodzących w skład grupy $S_z(k)$.

4. Równość $p_z(k+1) = p_z(k)$ przy $z=1,2,\dots,T$ jest warunkiem zbieżności algorytmu, kończącym procedurę grupowania /mppo/. W przypadku przeciwnym powtarzane są p.2÷4 algorytmu.

W wyniku zastosowania powyższego algorytmu grupowania uzyskujemy pewną liczbę grup punktów /mppo/, z których każda określona jest przez jej punkt środkowy. Grupy, które zawierają mniej niż 15 /mppo/ nie są rozpa - trywane.

Definicja 3.20

Punktami położenia „okien” obrazu /ppo/ są punkty

$$ppo = \{([h], [k]) \mid ([h], [k]) \in R\} \quad (3.47)$$

gdzie:

(h,k) - określają współrzędne punktu środkowego z-tej grupy /mppo/ i operator $[\cdot]$ oznacza najbliższą wartość całkowitą mniejszą od argumentu tego operatora.

Definicja 3.21

„Okno” - obrazu O_0 wymiaru $[x]$ tworzą elementy obrazu określone następująco^{*}:

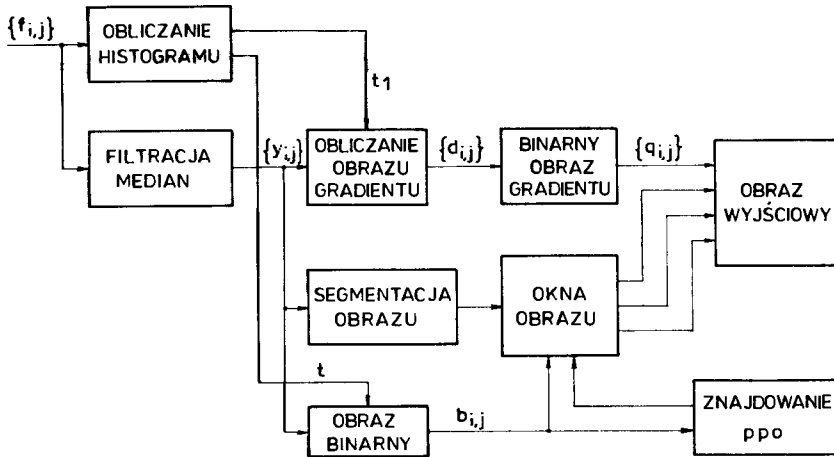
$$O_0 = \left\{ y_{i,j} \mid (i,j) \in [x], \left([h] - \frac{L}{2} \leq i \leq [h] + \frac{L}{2} \right), \right. \\ \left. \left([k] - \frac{L}{2} \leq j \leq [k] + \frac{L}{2} \right), (i,j) \in R \right\} \quad (3.48)$$

^{*} W tym przypadku tworzone jest „okno” - obrazu po filtracji median. Można utworzyć inne „okna” - obrazu, np. O_0 binarnego, O_0 gradientu itp., wtedy w (3.48) zamiast $y_{i,j}$ odpowiednio będzie $b_{i,j}$ lub $d_{i,j}$

3.6. Uwagi końcowe dotyczące redukcji redundancji metodą dekompozycji

Na początku tego rozdziału celowo nie zamieszczono schematu blokowego układu realizującego redukcję redundancji metodą dekompozycji, a wspomniano tylko, że ma on strukturę podobną do schematu blokowego systemu wzrokowego człowieka. Obecnie, po omówieniu operacji realizowanych w układzie redukcji redundancji metodą dekompozycji pora na wypełnienie tej luki.


Na rys.3.6 przedstawiono schemat blokowy układu realizującego redukcję redundancji metodą dekompozycji. Redukcja redundancji metodą dekompo-




Rys.3.6. Schemat blokowy układu realizującego redukcję redundancji metodą dekompozycji

zycji realizowana była dla obrazu testowego wymiaru 256 x 256 elementów o 256 poziomach jasności. Obraz uzyskano przy wykorzystaniu urządzenia do analizy /syntezy/ obrazu monochromatycznego z wykorzystaniem światłowodów, opracowanego przez zespół pod kierunkiem autora [29]. Do punktowej analizy obrazu wykorzystano w tym urządzeniu parę światłowodów o bardzo małej średnicy. Do skanowania wykorzystano układ mechaniczny w postaci walca o ruchu obrotowo-posuwistym. Światłowody zastępują układ optyczny kształtujący wiązkę świetlną. Zastosowano parę światłowodów, z których jeden jest nadajnikiem światła na analizowaną powierzchnię obrazu, drugi natomiast odbiornikiem światła od analizowanej powierzchni obrazu. Początkowo wszystkie operacje przetwarzania obrazu cyfrowego realizowane były programowo przy wykorzystaniu e.m.c. Później jednak operacja obliczania histogramu i filtracji medianowej realizowana była hardware'owo /rys.3.7/, przy wykorzystaniu pewnych fragmentów znajdującego się w budowie systemu przetwarzania obrazów.

Na rys.3.8 przedstawiono analogowy obraz wejściowy, z którego po dyskretyzacji i kwantowaniu uzyskano cyfrowy obraz wejściowy o wymiarach




Rys. 3.7. Hardware'owa realizacja filtracji medianowej




Rys.3.8. Obraz oryginalny

256 x 256 elementów i 8 bitach /element obrazu. Urządzeniem wyjściowym, jakim dysponowano przy realizacji operacji przetwarzania obrazów była drukarka wierszowa. Jaskrawość elementu obrazu przedstawiono w postaci prostokąta o odpowiednim stopniu zaczernienia uzyskiwanym przez kilkunastokrotne drukowanie symboli literowych. Uzyskanie w taki sposób 256 poziomów jaskrawości okazało się niemożliwe, dlatego też drukowano tylko cyfrowe obrazy wyjściowe, uzyskane w wyniku zastosowania omawianej metody redukcji redundancji. Rys.3.9 przedstawia obraz konturowy. Rys.3.10 i 3.11 przedstawiają obraz konturowy z oknami obrazu odpowiednio o wymiarach 64 x 64



Rys.3.9. Obraz konturowy


i 100 x 100 elementów. Okna obrazu zawierają elementy obrazu po segmentacji. Rys.3.12 - 3.13 przedstawiają obraz konturowy z oknami obrazu, przy czym dwa okna obrazu zawierają 64 x 64 elementy obrazu binarnego, natomiast pozostałe okna obrazu odpowiednio 64 x 64 i 100 x 100 elementów obrazu po segmentacji. Na koniec, na rys.3.14 przedstawiono obraz konturowy z oknami obrazu zawierającymi elementy obrazu binarnego, przy czym jedno




Rys.3.10. Obraz konturowy z oknami obrazu po segmentacji wymiaru 64×64 elementów



Rys.3.11. Obraz konturowy z oknami obrazu po segmentacji wymiaru 100×100 elementów



Rys.3.12. Obraz konturowy z 2 oknami obrazu binarnego i oknem obrazu po segmentacji. Wszystkie okna obrazu wymiaru 64×64 elementów



Rys.3.13. Obraz konturowy z 2 oknami obrazu binarnego wymiaru 64×64 elementów i oknem obrazu po segmentacji wymiaru 100×100 elementów



Rys.3.14. Obraz konturowy z 2 oknami obrazu binarnego wymiaru 64×64 elementów; oknem obrazu binarnego wymiaru 100×100 elementów i oknem obrazu po segmentacji wymiaru 64×64 elementów

okno obrazu wymiaru 100×100 elementów zawiera 64×64 elementów obrazu po segmentacji.

Współczynniki redukcji redundancji definiowane jako stosunek liczby bitów obrazu wejściowego /cyfrowego/ do liczby bitów wymaganych do zakodowania okien obrazu i liczby bitów wymaganych do zakodowania linii konturowych dla obrazów z rys. 3.10 - 3.14 wynoszą odpowiednio: 13,05 /0,61 bit/el/; 6,15 /1,3 bit/el/; 22,06 /0,36 bit/el/; 15,18 /0,52 bit/el/; 19,34 /0,41 bit/el/. Uzyskane wartości wrz pozwalają na stwierdzenie, że prezentowana metoda jest konkurencyjna w stosunku do innych metod prezentowanych wcześniej [10,15,63,78,82,88,89].

4. KRYTERIA JAKOŚCI ODTWARZANEGO OBRAZU

Rozpatrując kryteria jakości obrazu należy zdawać sobie sprawę, że pojęcie "jakości obrazu" jest wieloznaczne. Oceniając jakość obrazu możemy powiedzieć, że np. obraz jest "dobry" lub "przyjemny dla oka" lub "odpowiedni dla realizacji określonego celu". Obraz "dobry" dla celów np. nadzoru procesu technologicznego może być, i zwykle jest "nieakceptowany" dla celów np. telewizji programowej. Oczywiście odwrotnie też może być. Subiektywne kryteria oceny jakości obrazu są kryteriami względnymi, proces oceny subiektywnej jakości obrazu jest bardzo uciążliwy. Obiektywne kryteria jakości obrazu, oparte w większości na określeniu błędu średniokwadratowego, cechuje matematyczna prostota i w licznych przypadkach zgodność z kryteriami subiektywnymi. Rozpatrując dowolny system przetwarzania obrazów staramy się uzyskać odpowiedzi na szereg pytań, np. w przypadku redukcji redundancji obrazu pojawiają się pytania typu:

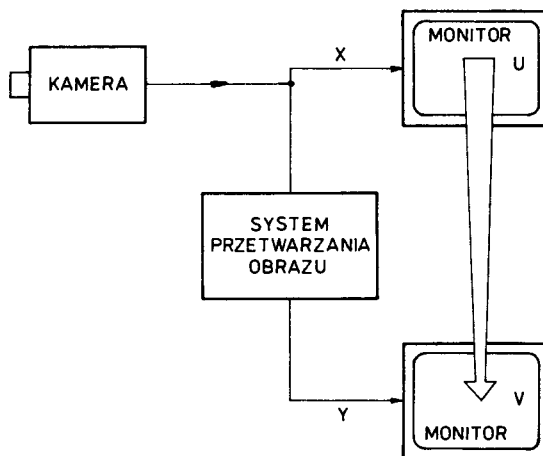
"Jak dobra jest metoda redukcji redundancji?",

"Jak dobra jest transmisja?",

"Jak dobre jest przetwarzanie A/D i D/A?",

itp.

Na rysunku 4.1 przedstawiono typową strukturę dowolnego systemu przetwarzania obrazu, przy czym X, Y - reprezentują sygnały, natomiast U, V - ja-

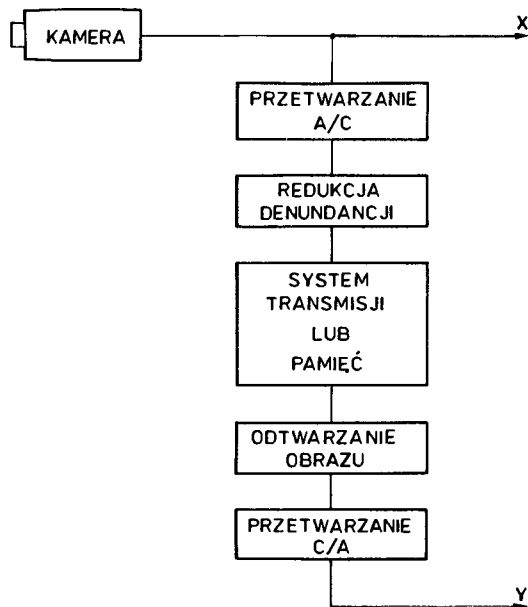


Rys.4.1. Struktura dowolnego systemu przetwarzania obrazów

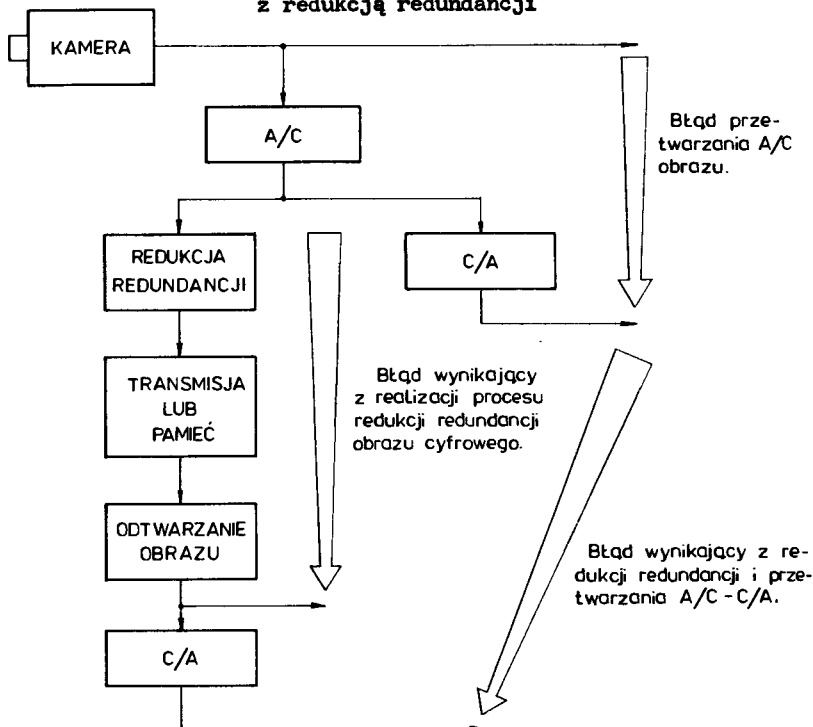
skrawości na ekranie monitora lub komputerowy wydruk obrazu. Układ blokowy systemu przetwarzania obrazów z redukcją redundancji przedstawiono na rys.



4.2. Rys.4.3 przedstawia możliwości pomiaru błędów pomiędzy poszczególnymi sygnałami w systemie przetwarzania obrazu.



Rys.4.2. Układ blokowy systemu przetwarzania obrazów z redukcją redundancji



Rys.4.3. Możliwości pomiaru błędów w systemie przetwarzania obrazów

Poniżej przedstawimy proponowane przez autora subiektywne i obiektywne kryteria do oceny jakości obrazów cyfrowych, głównie obrazów odtworzonych w procesie redukcji redundancji obrazu.

4.1. Kryteria subiektywne

Istnieje bardzo duża różnorodność subiektywnych kryteriów oceny jakości obrazu. Możliwe jest np. bezpośrednie subiektywne porównanie odtworzonego obrazu /w ogólnym przypadku pojedynczy odtworzony obraz należy do zbiorów obrazów odtworzonych będących "gorszymi kopiami" obrazu wejściowego/ z pewnym "doskonałym" obrazem wzorcowym. Wynik porównania przedstawiany jest w postaci oceny wyrażonej za pomocą subiektywnej skali oceny jakości obrazu. Podstawowe subiektywne skale oceny jakości obrazu przedstawiono na rys.4.4, natomiast rys.4.5 przedstawia porównanie niektórych skal.*

W licznych pracach prowadzonych przez autora, związanych z przetwarzaniem obrazów, również istniał problem subiektywnej oceny jakości odtwarzanego obrazu. Rozwiązaniem tego problemu zaproponowanym przez autora jest następująca procedura:

- wszystkie obrazy porównuje się w parach,
- dla każdej pary wyznacza się obraz, który "jest lepszy niż...",
- obliczany jest wskaźnik subiektywnej oceny jakości obrazu.

<u>Table 1</u>	scale, which is used at Bell Telephone Laboratories
1. Not perceptible	
2. Just perceptible	
3. Definitely perceptible, but only slight impairment to picture	
4. Impairment to picture but not objectionable	
5. Somewhat objectionable	
6. Definitely objectionable	
7. Extremely objectionable	

<u>Table 2</u>	Another scale used at Bell Telephone Laboratories
5. Excellent	
4. Good	
3. Fair	
2. Poor	
1. Unsatisfactory	


Rys.4.4. Podstawowe subiektywne skale oceny jakości obrazu

* Na rysunkach tych zachowano oryginalną nomenklaturę angielską, żeby uniknąć nieporozumień wynikłych z niedoakonałości przetłumaczenia na jęz. polski nazw poszczególnych stopni skal ocen subiektywnej jakości obrazu.

TABLE 3

Category-Judgment Scales in Current Use, as Compiled by the C.C.I.R.^{14,15}

- A. Five-grade quality scale
- | | |
|---|-------------|
| A | (Excellent) |
| B | (Good) |
| C | (Fair) |
| D | (Poor) |
| E | (Bad) |
- B. Six-grade impairment scale
- | | |
|---|---|
| 1 | Imperceptible |
| 2 | Just perceptible |
| 3 | Definitely perceptible but not disturbing |
| 4 | Somewhat objectionable |
| 5 | Definitely objectionable |
| 6 | Unusable |
- C. Six-grade quality scale
- | | |
|---|-------------|
| 1 | Excellent |
| 2 | Good |
| 3 | Fairly good |
| 4 | Rather poor |
| 5 | Poor |
| 6 | Very poor |
- D. Five-grade impairment scale
- | | |
|---|------------------------------|
| 5 | Imperceptible |
| 4 | Perceptible but not annoying |
| 3 | Somewhat annoying |
| 2 | Severely annoying |
| 1 | Unusable |
- E. Five-grade quality scale
- | | |
|---|-----------|
| 5 | Excellent |
| 4 | Good |
| 3 | Fair |
| 2 | Bad |
| 1 | Very Bad |
- F. Six-grade quality scale
1. Excellent - The picture is of extremely high quality, as good as you could desire.
 2. Fine - The picture is of high quality providing enjoyable viewing. Interference is perceptible.
 3. Passable - The picture is of acceptable quality. Interference is not objectionable.
 4. Marginal - The picture is poor in quality and you wish you could improve it. Interference is somewhat objectionable.
 5. Inferior - The picture is very poor but you could watch it. Definitely objectionable interference is present.
 6. Unusable - The picture is so bad that you could not watch it.



Rys.4.5. Porównanie niektórych skal subiektywnej oceny jakości obrazu

Definicja 4.1

Wskaźnik subiektywnej oceny jakości obrazu określamy wzorem

$$S_F = \frac{\text{ilość relacji typu ("F jest lepszy niż ...")}}{\text{ilość porównań obrazu F}} \quad (4.1)$$

Porównanie w parach można realizować w różny sposób, np. każdy obraz z każdym lub stopniowo: obrazy, które zostały uznane za "lepsze niż ..." grupuje się w pary i uzyskuje kolejne obrazy "lepsze niż..." aż do otrzymania jednego obrazu, który "jest lepszy niż ...". Procedura ta zakłada, że istnieje nie-zwrotna i niesymetryczna relacja "jest lepszy niż...". Natomiast nie można powiedzieć nic na temat przechodniości tej relacji. Należy zdawać sobie sprawę, że w dalszym ciągu istnieje /co prawda, znacznie prostszy, gdyż wybór lepszego obrazu spośród dwóch nie następuje trudności/ problem wyboru obrazu "lepszego niż...". Stosując opisaną procedurę łatwo można uzyskać skalę ocen subiektywnej jakości obrazu. Mianowicie, najgorszy obraz uzyskuje ocenę 0, najlepszy ocenę 1. Pozostałym obrazom przypisywane są oceny określone wartościami odpowiednich punktów na skali.

4.2. Kryteria obiektywne

Obiektywną ocenę jakości obrazu uzyskuje się na podstawie pomiaru i/lub obliczeń pewnych określonych wielkości charakteryzujących jakość obrazu. Badania eksperymentalne i rozważania teoretyczne pozwoliły stwierdzić, że jakość obrazu zależy przede wszystkim od różnicy pomiędzy obrazami po przetworzeniu i wejściowym. Dlatego też kryteria tego typu bazują na pojęciu błędu pomiędzy dwoma obrazami, z których jeden /zwykle wejściowy/ traktowany jest jako obraz wzorcowy. W wielu przypadkach tego typu proste matematyczne kryteria, np. kryterium błędu średniokwadratowego są zgodne z subiektywnymi ocenami jakości obrazu. Jednak trzeba mieć na uwadze, że obiektywne kryteria oceny jakości obrazu posiadają liczne niedostatki, np. nie nadają się do oceny zniekształceń geometrycznych obrazu. Większa wartość błędu, np. średniokwadratowego nie zawsze wskazuje na gorszą subiektywną jakość odtworzonego obrazu, gdyż subiektywna ocena jakości obrazu może być wystarczająca dla danego odbiorcy. W tabelicy 4.1 przedstawiono za [78] najczęściej stosowane, obiektywne kryteria oceny jakości obrazów dyskretnych.

Tabela 4.1

Obiektywne kryteria oceny jakości obrazu dyskretnego

$$Q = \frac{\sum_i \sum_j f_{i,j}}{\sum_i \sum_j (f_{i,j})_{id}}$$

$(f_{i,j})_{id}$ - obraz idealny

$$K = \frac{\sum_i \sum_j f_{i,j} \cdot \hat{f}_{i,j}}{\sum_i \sum_j (f_{i,j})^2}$$

$$P = \frac{1}{n \cdot m} \frac{\sum_i \sum_j [f_{i,j} - \hat{f}_{i,j}]^2}{A^2}$$

A - max. wartość $f_{i,j}$

$$L = \frac{\sum_i \sum_j [G_{i,j} - \hat{G}_{i,j}]^2}{\sum_i \sum_j [G_{i,j}]^2}$$

c.d. tablicy 4.1

$$G_{i,j} = f_{i+1,j} + f_{i-1,j} + f_{i,j+1} + f_{i,j-1} - 4f_{i,j}$$

$$LL = \frac{\sum_i \sum_j [f_{ij} - \hat{f}_{ij}]^2}{\sum_i \sum_j (f_{ij})^2}$$

Do oceny jakości obrazów cyfrowych, uzyskanych w wyniku przetwarzania, przy wykorzystaniu różnych metod i środków przetwarzania, w szczególności obrazów prezentowanych w tej pracy zaproponowano szereg nowych obiektywnych kryteriów oceny jakości obrazu.

Definicja 4.2

Obiektywnymi kryteriami oceny jakości obrazu są:

A. Średni bezwzględny błąd pomiędzy elementami i-tej linii obrazu oryginalnego i obrazu odtworzonego

$$e_a^{(i)} = \frac{1}{n} \sum_{j=1}^n |f_{i,j} - \hat{f}_{i,j}| \quad (4.2)$$

i średni bezwzględny błąd dla obszaru obrazu zawierającego m' linii obrazu

$$e_a = \frac{1}{m'} \sum_{i=1}^{m'} e_a^{(i)} \quad 1 \leq m' \leq m \quad (4.3)$$

B. Pierwiastek z błędu średniokwadratowego pomiędzy elementami i-tej linii obrazu oryginalnego i obrazu odtworzonego

$$e_r^{(i)} = \sqrt{\frac{1}{n} \sum_{j=1}^n (f_{i,j} - \hat{f}_{i,j})^2} \quad (4.4)$$

i średni błąd e_r dla obszaru obrazu zawierającego m' linii obrazu

$$e_r = \frac{1}{m'} \sum_{i=1}^{m'} e_r^{(i)} \quad (4.5)$$

C. Histogram błędów $h_b : \{0, 1, \dots, N\} \rightarrow Z$
gdzie:

$$h_b t = \begin{cases} \{\text{liczba błędów } \varepsilon_{1,j} \in [t, t+10)\} & \text{dla } t = 0, 10, 20, 30, 40, 50, 60, 70, 80, 90 \\ \text{liczba błędów } \varepsilon_{1,j} \geq 100 & \text{dla } t = 100 \end{cases} \quad (4.6)$$

gdzie:

$$\varepsilon_{1,j} = |f_{1,j} - \hat{f}_{1,j}|$$

Każdy z przedstawionych w definicji(4.2) błędów może być znormalizowany. Dla 256 poziomów jasności, tj. 8 bit/element obrazu znormalizowany błąd e_{NOR} może być przedstawiony jak

$$e_{\text{NOR}} = \frac{e}{255} \cdot 100 [\%] \quad (4.7)$$

gdzie:

e - odpowiedni błąd nienormalizowany.

Przedstawione w definicji(4.2) obiektywne kryteria oceny jakości obrazu można uzupełnić wprowadzając dodatkowo

$$\text{SNR}_1^{(1)} = 20 \log_{10} \frac{255}{e_r^{(1)}} \quad (4.8)$$

$$\text{SNR}_2^{(1)} = 10 \log_{10} \frac{\sum_{j=1}^n f_{1,j}^2}{\sum_{j=1}^n (f_{1,j} - \hat{f}_{1,j})^2} \quad (4.9)$$

$$\text{SNR}_k^{\text{ob}} = \frac{1}{m'} \sum_{i=1}^{m'} (\text{SNR})_k^{(i)} \quad (4.10)$$

$$1 \leq m' \leq m$$

$$k = \begin{cases} 1 \\ 2 \end{cases}$$

4.3. Ocena jakości obrazu w przypadku redukcji redundancji metodą dekompozycji

Wykorzystamy, omówione w poprzednich punktach tego rozdziału kryteria do oceny obrazów uzyskanych w procesie redukcji redundancji obrazu metodą dekompozycji. Pierwotnie obrazy z rys.3.10-3.14 oceniane były w sposób subiektywny przez 10 dwudziestoosobowych grup studentów nie mających nic wspólnego z przetwarzaniem obrazu i których członkowie nie zna-

li wcześniej prezentowanego obrazu. Członkowie 5 grup opisywali w/w obraz-
zy, natomiast członkowie pozostałych grup dysponując obrazem wejściowym
/analogowym/ porównywali te opisy z opisem obrazu wejściowego. Skala ocen
była czterostopniowa. Uzyskane wyniki przedstawiono w tabeli 4.2.

Tabela 4.2

Liczba odpowiednich ocen subiektywnych poszczególnych
obrazów wejściowych

Ocena \ Obraz z rys.	3.10	3.11	3.12	3.13	3.14
5	-	3	2	1	3
4	12	13	7	8	8
3	8	4	11	11	9
2	-	-	-	-	-

5 - opis obrazu odpowiadający rzeczywistości
4 - opis umożliwiający zrozumienie obrazu-opis poprawny
3 - opis umożliwiający zrozumienie fragmentów obrazu
2 - opis niezrozumiały

Następnie przeprowadzono subiektywną ocenę obrazów z rys. 3.10 - 3.14
według kryterium określonego przez definicję 4.1, uzyskując wyniki przed-
stawione w tabeli 4.3.

Tabela 4.3

Skala ocen subiektywnych jakości obrazów

Obraz z rys.	3.10	3.11	3.12	3.13	3.14
S_F	0,225	0,95	0,06125	0,59375	0,6625
Wartość skali ocen subiektywnych	0,2368	1	0	0,6250	0,6973

Przeprowadzone również obiektywną ocenę jakości rozpatrywanych ob-
razów wykorzystując do tego celu obiektywne kryteria określone przez de-
finicję 4.2, przy czym obrazem wzorcowym był cyfrowy odpowiednik obrazu
z rys. 3.8. W tabeli 4.4 przedstawiono wartości poszczególnych błędów
dla fragmentu obrazu z rys. 3.11 w postaci wąskiego paska zawierającego 16
linii obrazu. W tabeli 4.5 przedstawiono średnie błędy i histogramy błę-
dów poszczególnych obrazów.

Tablica 4. 4

Wartości błędów dla fragmentu obrazu z rys.3.11

Linia obrazu 1	$e_a^{(1)}$		$e_a^{(1)}$ NOR [%]		$e_r^{(1)}$		$e_r^{(1)}$ NOR [%]		$SNR_1^{(1)}$ [dB]		$SNR_2^{(1)}$ [dB]	
1	145,875		57,205		145,951		57,235		4,846		0,237	
2	115,968		45,477		116,067		45,516		6,836		0,289	
3	85,937		33,700		86,069		33,752		9,433		0,387	
4	55,992		21,957		56,198		22,038		13,136		0,568	
5	24,062		9,436		26,458		10,375		19,679		1,213	
6	34,023		13,342		36,294		14,232		16,934		0,844	
7	64,015		25,103		66,142		25,938		11,721		0,492	
8	93,953		36,844		96,023		37,656		8,483		0,352	
9	127,925		50,166		126,063		49,436		6,119		0,267	
10	157,953		61,942		156,074		61,205		4,264		0,215	
11	167,945		65,860		166,061		65,121		3,725		0,203	
12	137,976		54,108		136,109		53,376		5,453		0,244	
13	106,046		41,586		106,157		41,630		7,611		0,308	
14	76,054		29,825		76,209		29,885		10,490		0,421	
15	46,035		18,052		46,288		18,152		14,821		0,669	
16	16,015		6,280		16,726		6,559		23,662		1,552	
Średni błąd dla rozpa- trywanego fragmentu o- brazu	e_a		(e_a) NOR [%]		e_r		(e_r) NOR [%]		SNR_1 [dB]		SNR_2 [dB]	
	90,985		35,680		91,180		35,756		10,450		0,516	
Histogram błędu	t	0	10	20	30	40	50	60	70	80	90	100
	$h_b(t)$	0	100	276	266	241	267	262	234	286	264	1900

Tablica 4. 5

Średnie błędy i histogramy błędów obrazów

Obraz z rys.	3.10	3.11	3.12	3.13	3.14
e_a	87,070	77,673	91,25	88,247	85,544
(e_a) NOR [%]	34,153	30,460	35,784	34,606	33,546
e_r	87,521	77,827	93,903	89,041	86,019
(e_r) NOR [%]	34,321	30,520	36,824	34,918	33,732

c.d.tablicy 4.5

Histogram błędu	$h_p(t)$	$h_p(t)$	$h_p(t)$	$h_p(t)$	$h_p(t)$
t					
0	0	0	0	0	0
10	2549	1843	1849	2549	2549
20	2436	1621	1436	2436	2436
30	5698	3843	3698	4698	5428
40	3200	2211	3200	3309	3604
50	3867	2643	3867	3662	4067
60	4826	6743	5518	5355	5126
70	6124	7812	7424	6335	6294
80	6684	7748	7408	6063	5024
90	12426	7536	10300	11505	12711
100	17736	23536	20736	19627	18297

Przedstawione wyżej subiektywne kryteria oceny jakości obrazów dają wyniki podobne. Można oczywiście się sprzeczać, czy przyjęty sposób oceny subiektywnej jakości obrazów jest prawidłowy i optymalny. Zdaniem autora, pozwala on ocenić czy zastosowana metoda redukcji redundancji obrazu umożliwia uzyskanie obrazu o dobrej jakości, jak również pozwala ocenić, która z metod redukcji redundancji jest najlepsza, w tym sensie, że umożliwia uzyskanie obrazów o największej subiektywnej jakości. Zwykle jednak, wybór najlepszej metody redukcji redundancji jest pewnym kompromisem pomiędzy metodami umożliwiającymi uzyskiwanie największych współczynników wrr, a metodami umożliwiającymi uzyskiwanie obrazów o najlepszej subiektywnej jakości. W szczególnym przypadku prezentowane kryteria subiektywnej oceny jakości obrazu pozwalają stwierdzić, czy redukcja redundancji obrazu metodą dekompozycji umożliwia prawidłową interpretację obrazu.

Natomiast, ocena wyników uzyskanych przy zastosowaniu obiektywnych kryteriów jakości obrazu jest sprawą trudną i wymaga wyjaśnienia. Obiektywne kryteria oceny jakości obrazu nie nadają się do oceny obrazu przetwarzanego w procesie interpretacji, gdyż interpretacja przetworzonego obrazu powinna być i jest prawidłowa, pomimo bardzo dużej różnicy pomiędzy obrazami: wejściowym i przetworzonym. Mamy więc zawsze do czynienia z sytuacją, w której wartość błędu pomiędzy obrazami wejściowym i przetworzonym jest bardzo duża i interpretacja obrazu przetworzonego prawidłowa. Prawidłową interpretację obrazu umożliwia przedstawiony w rozdz.1 tzw. mechanizm interpretacji. Dlatego też duże wartości błędów nie powinny wywoływać zastrzeżeń, ponieważ duża wartość błędu nie zawsze wskazuje na gorszą subiektywną jakość odtwarzanego obrazu.

W pracy [30] przedstawiono porównanie błędów uzyskiwanych przez różnych autorów przy przetwarzaniu obrazów różnymi metodami w zależności od uzyskiwanych wrr. Przetwarzane obrazy były obrazami typu telewizyjnego,

metody przetwarzania /redukcji redundancji/ to predykcyjne i transformacyjne metody kodowania obrazów. Zastosowano obiektywne kryteria oceny jakości obrazu oznaczone w tabelicy 4.1 przez LL i P. Dla $wrr = 8 / 1 \text{ bit/element obrazu/}$ minimalna wartość błędu wynosiła $P = 0,05$ i została uzyskana przez Chan'a i odpowiednio $LL = 0,4-0,8$ uzyskane przez Narasinhana, i $LL = 0,6$ uzyskane przez Reisa. Dla $wrr = 5,3 / 1,5 \text{ bita/ element obrazu/}$ Persons uzyskał $LL = 0,17$ w przypadku metody nieadaptacyjnej i $LL = 0,08$ dla metody adaptacyjnej kodowania obrazu. Subiektywna jakość odtwarzanego obrazu we wszystkich przypadkach była dobra. Stosując kryteria LL i P do oceny jakości obrazów z rys.3.10 i 3.11, dla których wrr są zbliżone do wrr z cytowanej pracy, tj. dla obrazu z rys.3.10 $wrr = 13,05 / 0,61 \text{ bita/ element obrazu/}$ i dla obrazu z rys.3.11 $wrr = 6,15 / 1,3 \text{ bita/element obrazu/}$ uzyskujemy następujące wyniki: dla obrazu z rys.3.10 $P = 0,8019$, $LL = 0,8806$, natomiast dla obrazu z rys.3.11 $P = 0,3379$, $LL = 0,9274$.

Dla maksymalnej wartości błędu określonej na podstawie kryteriów $4+2 - 4+7$, tj dla obrazu z rys.3.12 błędy obliczone na podstawie kryteriów LL i P wynoszą odpowiednio $LL = 0,929$, $P = 0,857$. Oglądając prezentowane obrazy stwierdzamy, że wartość błędu wynosząca $(e_a)_{NOR} = 35,78\%$ lepiej oddaje różnicę pomiędzy obrazem wejściowym a przetworzonym. Zdaniem autora zaproponowane przez definicję 4.2 obiektywne kryteria jakości obrazu bardziej nadają się do oceny jakości obrazów w procesie redukcji redundancji.

Należy podkreślić fakt, że prezentowana w rozdz.3 metoda redukcji redundancji nie ma odpowiednika w dostępnej literaturze, dlatego też wszelkiego rodzaju porównania mają tylko bardzo orientacyjne znaczenie.

Przeprowadzone eksperymenty pozwalają stwierdzić, że zwiększenie liczby okien nie powoduje wzrostu liczby najlepszych ocen subiektywnych. Zmniejszenie wymiarów okien można realizować w przypadku obrazów zawierających obiekty o małych wymiarach.

5. REDUKCJA REDUNDANCJI PARAMETRÓW OPISUJĄCYCH OBIEKTY OBRAZU

Rozpatrujemy sytuację, kiedy w zbiorze parametrów wybranych do opisu i/lub identyfikacji obiektów jeden parametr jest nadmiarowy w stosunku do pozostałych parametrów. Parametr taki może być wyeliminowany bez zwiększenia błędu identyfikacji obiektu. Przedstawimy teoretyczne podstawy procesu obliczania redundancji parametrów opisujących obiekty obrazu. Problem ten nie znalazł odzwierciedlenia w literaturze.

Niech (X, Y) będą losowymi zmiennymi reprezentującymi parametry. X jest wektorową losową zmienną, mającą wartość w q -wymiarowej przestrzeni Euclidesa E^q , Y jest skalarną zmienną losową mającą wartość w E^1 . Obserwacje (x, y) mają wartości w E^{q+1} . Niech $F_{x,y}$ będzie funkcją łącznego rozkładu prawdopodobieństwa X . Wszystkie funkcje rozkładów prawdopodobieństw są prawostronnie ciągłe.

D e f i n i c j a 5.1

Y będzie nadmiarowe /redundantne/ względem X jeżeli

$$\text{Prob } [F(X, Y) = F(X)] = 1 \quad (5.1)$$

T w i e r d z e n i e 5.1

Y jest nadmiarowe względem X , jeśli i tylko jeśli istnieje rzeczywista, niemalejąca funkcja g taka, że*

$$\text{Prob } [Y = g(X)] = 1 \quad (5.2)$$

Dowód:

Założmy, że Y jest nadmiarowe względem X . Wtedy

$$\begin{aligned} 1 &= \text{Prob } [F(X, Y) = F(X)] = \text{Prob } [F(Y|X) F(X) = F(X)] = \\ &= \text{Prob } [F(Y|X) = 1] = \\ &= \text{Prob } [Y = \inf \{t : F(t|X) = 1\}] \end{aligned} \quad (5.3)$$

* Wprowadzimy oznaczenie „co należy czytać... jest nie mniejsze niż...”. Jeżeli $u = (u_1, u_2, \dots, u_l)$, $v = (v_1, v_2, \dots, v_l)$ to $u \prec v$ jeżeli $u_i \leq v_i$ dla $i = 1, 2, \dots, l$.

Funkcja g jest niemalejąca, jeżeli

$$g(u) \leq g(v) \quad \text{dla } u \prec v \quad (5.4)$$

Niech $g(x) = \inf \{t: F(t|x) = 1\}$. Na podstawie definicji $F(x,y)$ możemy stwierdzić, że $g(x)$ jest funkcją niemalejącą. Następnie założmy, że istnieje rzeczywista, niemalejąca funkcja g taka, że $\text{Prob}[Y = g(X)] = 1$. Ponieważ g jest niemalejąca to $\text{Prob}[F(X, \infty) = F(X, g(X))] = 1$

Stąd

$$\begin{aligned} \text{Prob}[F(X,Y) = F(X)] &= \text{Prob}[F(X,Y) = F(X, \infty), Y = g(X)] \\ &= \text{Prob}[F(X, g(X)) = F(X, g(X))] = 1 \end{aligned} \quad (5.5)$$

co kończy dowód.

T w i e r d z e n i e 5.2

Niech Y będzie nadmiarowe względem X . Niech d będzie regułą decyzyjną przyporządkowującą obserwacji (x,y) decyzję-klasę, do której będzie zakwalifikowany obiekt i niech r będzie prawdopodobieństwem błędnej decyzji*. Istnieje reguła decyzyjna d' przyporządkowująca obserwacji x taką samą decyzję z prawdopodobieństwem błędnej decyzji r .

Dowód:

Reguła decyzyjna d dzieli przestrzeń obserwacji E^{q+1} na $\{D_1, D_2, \dots, D_M\}$ tak, że jeśli $(x,y) \in D_j$ dla pewnego j , $1 \leq j \leq M$, wtedy (x,y) jest zaliczone /sklasyfikowane/ do klasy oznaczonej przez j .

Niech dla $j = 1, 2, \dots, M$

$$D'_j = \{x \in E^q : (x,y) \in D_j\} \quad (5.6)$$

wtedy $\{D'_1, D'_2, \dots, D'_M\}$ jest podziałem E^q .

Faktycznie, ponieważ y jest nadmiarowe względem x to zgodnie z twierdzeniem 5.1 istnieje rzeczywista funkcja g taka, że $Y = g(X)$ z p. 1.

Dla $k \neq i$, $D_k \cap D_i = \emptyset$, gdzie \emptyset jest zbiorem pustym, mamy $\text{Prob}[X \in D'_k \cap D'_i] = \text{Prob}[(X, U) \in D_k, (X, V) \in D_i]$, dla pewnych skalarnych zmiennych losowych $U, V] = \text{Prob}[(X, g(X)) \in D_k, (X, g(X)) \in D_i] = 0$ tj. $D'_k \cap D'_i = \emptyset$ z p. 1 dla $k \neq i$. Inaczej $E^q = \bigcup_{j=1}^M D'_j$.

Dla $1 \leq j \leq M$

$$(5.7)$$

$$d'(x) = j \text{ wtedy i tylko wtedy } x \in D'_j$$

gdzie:

$d'(x) = j$ oznacza, że x jest zakwalifikowane do klasy j .

* Niech $\pi_1, \pi_2, \dots, \pi_M$ oznacza M klas. Dla $j=1, 2, \dots, M$ niech ζ_j oznacza prawdopodobieństwo, że obserwacja z należy do π_j . Wtedy $r = 1 - \sum_{j=1}^M \text{Prob}(z \text{ jest klasyfikowane w } \pi_j | z \text{ należy do } \pi_j) \zeta_j$.

Wtedy $z p_1$ d i d' mają takie same r .

Z twierdzenia wynika, że odrzucając nadmiarową losową zmienną nie powodujemy zwiększenia błędu klasyfikacji.

Definicja 5.2

Testem nadmiarowości parametru Y względem parametru X będzie

$$T_{X,Y} = E [F(X) - F(X,Y)] \quad (5.8)$$

Mamy $0 \leq F(x,y) \leq F(x) \leq 1$ i $0 \leq T_{X,Y} \leq 1$.

$T_{X,Y} = 0$ wtedy i tylko wtedy $F(X) = F(X,Y)$ $z p_1$ i jeżeli $T_{X,Y} = 0$ to Y jest nadmiarowe względem X . $T_{X,Y}$ jest współczynnikiem nadmiarowości.

Niech (X_i, Y_i) , $i = 1, 2, \dots, n$ będą sekwencją niezależnych zmiennych losowych o jednakowych rozkładach, przy czym każda (X_i, Y_i) ma rozkład identyczny jak (X, Y) . Niech $F_n(\cdot, \cdot)$ będzie empiryczną funkcją rozkładu (X, Y) zdefiniowaną dla $u \in E^q$, $v \in E^1$ w następujący sposób:

$$F_n(u, v) = \frac{1}{n} \left\{ \text{liczba } (x_i, y_i) \text{ takich, że } (x_i, y_i) \prec (u, v) \right\} \quad (5.9)$$

Analogicznie $F_n(\cdot)$ będzie empiryczną funkcją rozkładu X zdefiniowaną dla $u \in E^q$

$$F_n(u) = \frac{1}{n} \left\{ \text{liczba } x_i \text{ takich, że } x_i \prec u \right\} \quad (5.10)$$

Wtedy

$$T_{X,Y}^n = \frac{1}{n} \sum_{i=1}^n [F_n(X_i) - F_n(X_i, Y_i)] \quad (5.11)$$

Z mocnego prawa wielkich liczb mamy

$$\frac{1}{n} \sum_{i=1}^n [F(X_i) - F(X_i, Y_i)] \xrightarrow{z p_1} E [F(X) - F(X, Y)] \quad (5.12)$$

dla $n \rightarrow \infty$ $z p_1$.

Z p_1 mamy

$$T_{X,Y}^n \xrightarrow{z p_1} T_{X,Y} \quad n \rightarrow \infty \quad (5.13)$$

Jeżeli Y jest nadmiarowe względem X wtedy $T_{X,Y}^n = 0$ z p1 dla wszystkich n .
Mamy z p1

$$T_{X,Y}^n = \frac{1}{n} \sum_{i=1}^n [F_n(X_i) - F_n(X_i, g(X_i))] \quad (5.14)$$

ponieważ $Y_i = g(X_i)$ z p1, gdzie g jest funkcją rzeczywistą i niemalejącą.
Mamy $T_{X,Y}^n = 0$ z p1 dla wszystkich n , więc jeżeli dla pewnego n znajdziemy $T_{X,Y}^n > 0$ wtedy z p1 możemy odrzucić hipotezę Hip: Y jest nadmiarowe względem X . Inaczej mówiąc, dla danego n akceptujemy lub odrzucamy hipotezę Hip, w zależności od tego czy $T_{X,Y}^n = 0$ lub $T_{X,Y}^n > 0$. Współczynnik redundancji jest przydatny do usunięcia lub wybrania parametrów obiektu w przypadkach, kiedy te parametry są "prawie nadmiarowe" w tym sensie, że $T_{X,Y}^n$ jest małe.

6. OPIS OBIEKTÓW OBRAZU

Ponieważ systemy przetwarzania obrazów, których głównym zadaniem jest rozpoznawanie obiektów znajdujących się w obrazie, zazwyczaj realizują to zadanie przez porównanie parametrów obiektów obrazu z parametrami modelu, to redukcja redundancji informacji o obiektach sprowadza się głównie do zdefiniowania parametrów pozwalających dokładnie opisywać obiekty obrazu i zmniejszenia ilości parametrów opisujących te obiekty.

Nie ma formalnych metod pozwalających określić, które z parametrów są bardziej przydatne do opisu określonych obiektów, a które do tego celu się nie nadają. Określenia "bardziej przydatne" i "nie nadają się" są określeniami subiektywnymi jednak pozwalają zrozumieć istotę rzeczy.

W licznych pracach [21,35,36,37,39,42,46,59,61,70,74,81,82,88,95] przedstawione zagadnienia opisu obiektu na podstawie jego parametrów. Można wyróżnić trzy zasadnicze kierunki rozwiązania tego problemu. Pierwszy, to opis obiektów za pomocą parametrów geometrycznych i topologicznych [21,35] [37,39]. Drugi, to opis obiektu przez określenie pewnych zależności statystycznych pomiędzy elementami konturu i określenie prawdopodobieństw występowania tych elementów [45,48,77]. Trzeci kierunek wykorzystuje podejście syntaktyczne do opisu obiektów [42,43,71,88,89].

Oceniając kierunki rozwiązania problemu opisu obiektu można stwierdzić, że:

- kierunek pierwszy, tj. opis obiektu przy wykorzystaniu parametrów geometrycznych i topologicznych obiektu jest najbardziej naturalnym kierunkiem rozwiązania tego problemu. Obiekty reprezentowane są przez pewne twory geometryczne /proste, łuki, okręgi, kąty / i/lub topologiczne, łatwe do zdefiniowania z pomocą pojęć geometrii i/lub topologii,
- kierunek drugi, wymaga znajomości a priori pewnych prawdopodobieństw, co nie zawsze jest możliwe,
- kierunek trzeci pozwala na uzyskanie poprawnych wyników, szczególnie przy opisie skomplikowanych obiektów, przy czym czas przetwarzania jest stosunkowo niewielki.

W rozdziale poprzednim przedstawiłem teoretyczne podstawy redukcji redundancji parametrów opisujących obiekty obrazu, obecnie zdefiniujemy parametry umożliwiające opis obiektów obrazu.

6.1. Parametry opisujące obiekty obrazu

Rozpatrujemy obrazy określone przez równanie (3.50)

D e f i n i c j a 6.1

Ogólna liczba punktów obiektu, tj. obszaru ograniczonego liniami konturowymi nazywana jest powierzchnią obiektu

$$A = \sum_{i=1}^M \delta_i \quad (6.1)$$

gdzie:

$$\delta_i = \delta_{i1} + \delta_{i2} + \dots + \delta_{ir} \quad (6.2)$$

δ_{ir} - jest maksymalną liczbą charakteryzującą r-tą serię elementów niezerowych,

r - jest liczbą serii elementów niezerowych i-tej linii.

Przeprowadzamy uporządkowaną liniową analizę obrazu. Niech dla i-tej linii obrazu wartości jasności elementów obrazu są następujące

000 111 00 11111111 00 111 0000

Zliczamy ilość elementów niezerowych w każdej serii

000 12300 12345678 00 123 0000

a następnie obliczamy sumę maksymalnych wartości liczb występujących w każdej serii, tj.

$$\delta_i = 3 + 8 + 3 = 14$$

Powierzchnia obiektu obliczana jest na podstawie (6.1).

D e f i n i c j a 6.2


Niech (i, j) będzie elementem pewnego obiektu, tj. $(i, j) \in O$ i niech $z_{i,j}$ będzie liczbą elementów nie należących do obiektu w $V_4(i, j)$. Obwód Ob obiektu O określamy przez

$$Ob = \sum_{(i,j) \in O} z_{i,j} \quad (6.3)$$

D e f i n i c j a 6.3

Współczynnik e zależny tylko od konturu obiektu jest ilorazem długości max. cięciwy b i długości min. cięciwy a obiektu O. Max. cięciwa b obiektu jest linią łączącą dwa punkty konturu najdalej oddalone jeden od drugiego. Min. cięciwa a jest prostopadła do max. cięciwy b i ma długość

taką, że prostokąt tworzony przez te cięciwy jest opisany na obiekcie (rys.6.1) $e = b/a$ jest zawsze większe lub równe 1.



Rys.6.1. Max. i min. cięciwy obiektu

Definicja 6.4

Współrzędne środka ciężkości układu punktów $(i,j) \in O$ o jaskrawościach $b_{i,j}$ (lub $q_{i,j}$) określamy następująco:

$$I_0 = \frac{\sum_{i=1}^m \sum_{j=1}^n i \cdot b_{i,j}}{\sum_{i=1}^m \sum_{j=1}^n b_{i,j}} \quad (6.4)$$

$$J_0 = \frac{\sum_{i=1}^m \sum_{j=1}^n j \cdot b_{i,j}}{\sum_{i=1}^m \sum_{j=1}^n b_{i,j}} \quad (6.5)$$

Zgodnie z [37,47,54,70] istnieje jednocznaczna relacja pomiędzy obrazem a zbiorem momentów $\{m_{pq} \mid p,q = 0,1,2 \dots\}$. Obraz może być opisany za pomocą przestrzennych momentów jego funkcji jaskrawości. "Ogólny" moment rzędu pq obrazu, np. $b_{i,j}$ określamy przez

$$m_{pq} = \sum_i \sum_j b_{i,j} Z_{pq}(i,j) \quad (6.6)$$

gdzie:

$Z_{pq}(i,j)$ jest pewną funkcją (i,j) , dla przykładu, $i^p j^q$ co daje określenie momentu zwykłego; funkcją sinus i cosinus argumentów $\pi i, \pi j$ co powoduje, że m_{pq} są współczynnikami dwuwymiarowego rzędu - nięcia Fouriera funkcji obrazu, itp.

D e f i n i c j a 6.5

Niech $b_{\xi, \varphi}$ będzie obrazem przedstawionym we współrzędnych biegunowych /patrz Dodatek B/. Momenty, niezależne względem geometrycznych transformacji obrazu definiujemy następująco:

$$C'_{pq} = \frac{\sum_{\xi} \sum_{\varphi} \rho^{p+1} \cdot \cos(\varphi - \theta) \cdot b_{\xi, \varphi}}{\sum_{\xi} \sum_{\varphi} b_{\xi, \varphi}} = \frac{S'_{pq} \sin q\theta + C'_{pq} \cos q\theta}{\sum_{\xi} \sum_{\varphi} b_{\xi, \varphi}} \quad (6.7)$$

$$S'_{pq} = \frac{\sum_{\xi} \sum_{\varphi} \rho^{p+1} \cdot \sin q(\varphi - \theta) b_{\xi, \varphi}}{\sum_{\xi} \sum_{\varphi} b_{\xi, \varphi}} = \frac{S'_{pq} \cos q\theta - C'_{pq} \sin q\theta}{\sum_{\xi} \sum_{\varphi} b_{\xi, \varphi}} \quad (6.8)$$

gdzie:

$$\theta_{pq} = \arctg \frac{S'_{pg}}{C'_{pg}} \quad (6.9)$$

$$C'_{pq} = \sum_{\xi} \sum_{\varphi} \rho^{p+1} \cdot \cos q\varphi \cdot b_{\xi, \varphi} \quad (6.10)$$

$$S'_{pq} = \sum_{\xi} \sum_{\varphi} \rho^{p+1} \cdot \sin q\varphi \cdot b_{\xi, \varphi} \quad (6.11)$$

$$p = 0, 1, 2, \dots,$$

$$0 \leq q \leq p$$

Momenty S'_{pq} i C'_{pq} związane są z momentami centralnymi następująco:

$$C_{00} = \mu_{00} \quad S_{00} = 0 \quad (6.12)$$

$$C_{11} = \mu_{10} \quad S_{11} = \mu_{01} \quad (6.13)$$

$$C_{20} = \mu_{20} + \mu_{02} \quad S_{20} = 0 \quad (6.14)$$

$$C_{31} = \mu_{30} + \mu_{12} \quad S_{31} = \mu_{03} + \mu_{12} \quad (6.15)$$

$$C_{22} = \mu_{20} - \mu_{02} \quad S_{22} = 2\mu_{11} \quad (6.16)$$


$$C_{33} = \mu_{30} - 3\mu_{12} \quad S_{33} = 3\mu_{21} - \mu_{03} \quad (6.17)$$

Każdy punkt linii konturowej będzie przedstawiony w przestrzeni Hougha /przestrzeni parametrów/. Punkt (i, j) będzie transformowany w krzywą na płaszczyźnie (ϱ, φ) określoną równaniem

$$\varrho = i \cos \varphi + j \sin \varphi \quad (6.18)$$

Jeżeli punkty (i_1, j_1) , (i_2, j_2) ... (i_n, j_n) leżą na jednej prostej /odcinku linii konturowej/, to w przestrzeni Hougha można znaleźć taki punkt (ϱ_1, φ_1) , że wszystkie krzywe $i_k \cos \varphi + j_k \sin \varphi = \varrho$, $k = 1 \dots n$, które są obrazami punktu (i_k, j_k) , przecinają się. Można więc prosty odcinek linii konturowej przedstawić w przestrzeni Hougha w postaci punktu o współrzędnych (ϱ_1, φ_1) . W celu uproszczenia tej procedury będziemy kolejne punkty linii konturowej /tworzące linię łamaną/ aproksymowali odcinkami linii prostej. W procesie aproksymacji cyfrowego konturu wykorzystamy wyniki wcześniejszych prac dotyczących tego zagadnienia [32, 35, 40, 67, 68, 76, 89].

Rozważamy krzywą przedstawioną na rys.6.2, która jest fragmentem pewnego konturu. Pierwszy punkt jest punktem startu, od którego rozpoczy-



Rys.6.2. Aproksymacja konturu odcinkami linii prostych

namy generację odcinka linii prostej $\overline{13}$. Indeks punktu 3 jest zapamiętywany, po czym wskaźnik k reprezentujący kolejne punkty krzywej przyjmuje wartość $k + 1$. Szukamy zbioru wskaźników, który minimalizuje długość odcinków tworzących liniową aproksymację konturu przy zadanym błędzie ε . Porównujemy odległości pomiędzy punktami 2 i 3 z odcinkiem linii prostej $\overline{14}$. Jeżeli odległości d_2 i d_3 są mniejsze od ustalonego progu, to zapamiętywany jest indeks 4. Algorytm powtarza się, aż do znalezienia ostatniego punktu spełniającego ten warunek. Ponieważ dla odcinka linii prostej $\overline{19}$ odległości d_3 , d_5 , d_6 i d_7 są większe od ustalonego progu, wobec tego ostatnia zapamiętana wartość indeksu punktu wynosi 8 i odcinek linii prostej $\overline{18}$ jest optymalną liniową aproksymacją rozważanych punktów. Punkt 8 jest nowym punktem startowym do aproksymacji kolejnych punktów odcinkiem linii prostej. Sprecyzujemy reguły aproksymacji:

1. Odcinek linii prostej /OLP/ aproksymujący sekwencję punktów $1 \dots k$ musi przecinać lub być stycznym do wszystkich okręgów o promieniu ε odpowiadającym punktom tworzącym sekwencję,

2. Punkty aproksymujemy odcinkiem linii prostej o równaniu $j = a_0 + a_1 i$,
3. Aproksymujemy sekwencję $(k+1)$ punktów (i_t, j_t) $t=0 \dots k$ przy założeniu $i_a \neq i_b$,
4. Najmniejsza długość OLP wynosi $k=2$, tj. aproksymujemy 3 punkty danych,
5. O ile $i_a = i_b$ dla $a = 0$ i $b = 2$, tj. $i_0 = i_2$, to zwiększamy wskaźnik k do momentu znalezienia pierwszego punktu b , dla którego $i_a \neq i_b$. Dalej proces aproksymacji rozpoczynamy od punktu 1 reguł aproksymacji.
6. Obliczamy dla danego OLP \overline{Ok} odległości $d_0, d_1, \dots, d_{k-1}, d_k$ i porównujemy je z progiem ε . O ile mamy $d_0 < \varepsilon, d_1 < \varepsilon, \dots, d_{k-1} < \varepsilon, d_k < \varepsilon$, to OLP \overline{Ok} aproksymuje punkty $0 \dots k$. Zwiększamy wskaźnik punktu o 1 rozpatrując, czy OLP $\overline{O(k+1)}$ będzie aproksymował punkty $0 \dots (k+1)$,
7. O ile nie, to OLP aproksymującym jest odcinek \overline{Ok} , punkt k będzie pierwszym punktem startowym następnego OLP. Zapamiętywane są dane aproksymującego OLP: punkt początkowy, punkt końcowy, współczynniki a_0 i a_1 ,
8. Proces jest powtarzany do chwili, gdy punktem końcowym aproksymującego OLP będzie punkt o współrzędnych (i_0, j_0) lub końcowy punkt danych.

Odległość d_k obliczmy ze wzorów

$$i_1 = \frac{a_1}{1 + (a_1)^2} \left(j_k + \frac{1}{a_1} i_k - a_0 \right) \quad (6.19)$$

$$j_1 = \frac{a_1^2}{1 + (a_1)^2} \left(j_k + \frac{1}{a_1} i_k - a_0 \right) + a_0 \quad (6.20)$$

$$d_1 = \left[\left(i_k - i_1 \right)^2 + \left(j_k - j_1 \right)^2 \right]^{1/2} \quad (6.21)$$

Własności transformacji Hougha są następujące:

W ł a s n o ś ć 1. Punkt w płaszczyźnie obrazu odpowiada sinusoidalnej krzywej w przestrzeni parametrów.

W ł a s n o ś ć 2. Punkt w przestrzeni parametrów odpowiada linii prostej w płaszczyźnie obrazu.

W ł a s n o ś ć 3. Punkty leżące na tej samej linii prostej w przestrzeni obrazu odpowiadają krzywym przechodzącym przez wspólny punkt w przestrzeni parametrów.

W ł a s n o ś ć 4. Punkty leżące na tej samej krzywej w płaszczyźnie parametrów odpowiadają liniom prostym przechodzącym przez ten sam punkt w płaszczyźnie obrazu.

T w i e r d z e n i e 6.1

Parametry (ξ, φ) określają wzory

$$\xi^2 = \frac{(j_2 i_1 - j_1 i_2)^2}{[(i_2 - i_1)^2 + (j_2 - j_1)^2]} \quad (6.22)$$

$$\varphi = \arctg \left(\frac{|i_2 - i_1|}{|j_2 - j_1|} \right) \quad (6.23)$$

Dowód:

Obliczymy współczynniki a_0 i a_1 prostej aproksymującej /rys.6.3/

Mamy

$$j_1 = a_0 + a_1 i_1 \quad (6.24)$$

$$j_2 = a_0 + a_1 i_2 \quad (6.25)$$

i stąd

$$a_1 = \frac{j_1 - a_0}{i_1} \quad ; \quad a_0 = \frac{j_1 i_2 - j_2 i_1}{i_2 - i_1} \quad (6.26)$$

Po dalszych przekształceniach otrzymujemy

$$a_1 = \frac{j_2 - j_1}{i_2 - i_1} \quad (6.27)$$

Dla punktu $(c, 0)$ mamy

$$j = a_1 c + a_0 \quad (6.28)$$

$$0 = a_1 c + a_0 \quad (6.29)$$

i stąd

$$c = \frac{j_2 i_1 - j_1 i_2}{j_2 - j_1} \quad (6.30)$$

Równanie linii prostopadłej do prostej $j = a_1 i + a_0$ i przechodzącej przez punkt $(0, 0)$ jest następujące

$$j = \frac{1}{a_1} (i_0 - i) + j_0 \quad (6.31)$$

Rozwiązanie równania dwóch linii przecinających się w punkcie (i_1, j_1) jest


$$i_1 = \frac{a_1}{1 + (a_1)^2} \left(j_c + \frac{1}{a_1} i_o + a_c \right) \quad (6.32)$$

$$j_1 = \frac{(a_1)^2}{1 + (a_1)^2} \left(j_o + \frac{1}{a_1} i_o - a_o \right) + a_c \quad (6.33)$$

i stąd

$$\rho^2 = (i_o - i_1)^2 + (j_o - j_1)^2 \quad (6.34)$$

i w rezultacie prowadzi do wyniku postaci (6.22). Z rys.6.3 mamy



Rys.6.3. Parametry (ρ, φ) prostej aproksymującej kontur obiektu

$$\operatorname{tg} \varphi = \frac{\sqrt{c^2 - \rho^2}}{\sqrt{\rho^2}} = \frac{\sqrt{(i_2 - i_1)^2}}{\sqrt{(j_2 - j_1)^2}} \quad (6.35)$$

$$\varphi = \operatorname{arc} \operatorname{tg} \frac{|(i_2 - i_1)|}{|(j_2 - j_1)|} \quad (6.36)$$

co jest równoznaczne z dowodem twierdzenia 6.1.

6.2. Analiza parametrów obiektów


W poprzednich rozdziałach stwierdziliśmy, że w przypadku rozpoznawania obiektów redukcja redundancji informacji o obiektach polega na zmniejszeniu ilości parametrów opisujących te obiekty. Zdefiniowaliśmy szereg parametrów opisujących obiekty i obliczyliśmy te parametry /tablica 6.1 /

Tablica 6.1

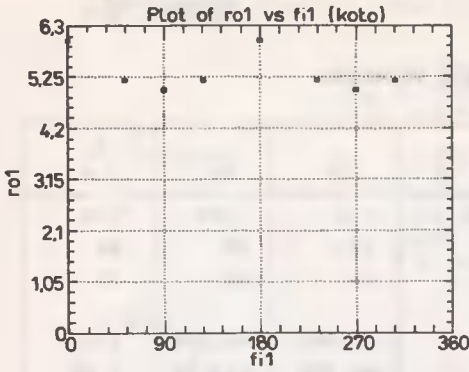
Wartości parametrów modeli obiektów

Parametry / Modele	○	□	△	△	△
Współczynnik e	1.18	1.4	1.2	1.44	1.4
Obwód Ob	48	24	22	44	24
Powierzchnia A	115	35	18	61	21
Momenty:					
S ₀₁	0	0	-2.981	-19.979	1.01
S ₁₁	0	0	-7.397	-115.29	7.52
S ₂₁	0	0	-18.668	-621.92	45.26
C ₀₁	0	0	3.99	0	2
C ₁₁	0	0	13.25	0	2
C ₁₀	899.8	169.44	66.71	537.14	80.68
C ₂₀	4.988.27	516.8	171.34	2600.15	217.92
C ₂₁	0	0	44.7	0	2
Parametry (ρ, φ)					
ρ ₁	6	3	1.093	3	1.26
φ ₁	0°	0°	38.65°	36.86°	18.46°
ρ ₂	5.19	2	1	3	1.26
φ ₂	53.13°	90°	180°	143.14°	161.57°
ρ ₃	5	3	2	3	2
φ ₃	90°	180°	270°	270°	270°
ρ ₄	5.19	2			
φ ₄	126.87°	270°			
ρ ₅	6				
φ ₅	180°				
ρ ₆	5.19				
φ ₆	233.13°				
ρ ₇	5				
φ ₇	270°				
ρ ₈	5.19				
φ ₈	306.87°				

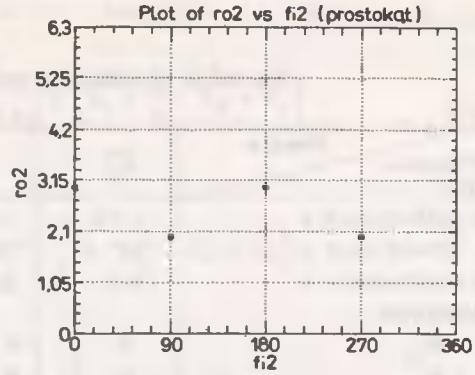
dla pięciu modeli obiektów przedstawionych na rys.6.4. Na rysunkach 6.5 - 6.9 przedstawione każdy z modeli w przestrzeni Hough'a. Następnie, rozpatrywano obraz testowy wymiaru 128 x 128 elementów zawierający szereg obiektów geometrycznych różnie położonych /rys.6.10/.



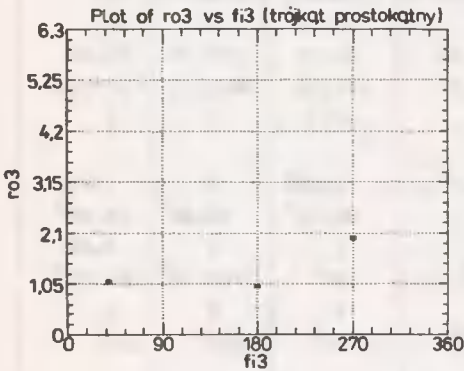
Rys.6.4. Modele obiektów



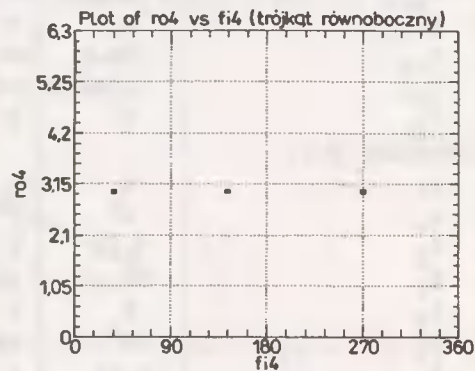
Rys.6.5. Parametry (ξ, φ) modelu koła




Rys.6.6. Parametry (ξ, φ) modelu prostokąta




Rys.6.7. Parametry (ξ, φ) modelu trójkąta prostokątnego



Rys.6.8. Parametry (ξ, φ) modelu trójkąta równobocznego



Rys.6.9. Parametry (ξ, φ) modelu trójkąta równoramiennego



Rys.6.10. Obraz testowy wymiaru 128x128 elementów

Niech P_q będzie q -tym parametrem obiektu, P_{qm} będzie q -tym parametrem modelu obiektu i $d(q)$ będzie maksymalną tolerowaną różnicą pomiędzy parametrem modelu obiektu i obiektu analizowanego. Niech

$$M(q) = \begin{cases} 1 & \text{dla } |P_q - P_{qm}| \leq d(q) \\ 0 & \text{w przypadku przeciwnym} \end{cases} \quad (6.37)$$

Definicja 6.6

Współczynnikiem prawidłowości identyfikacji obiektu jest


$$C = \frac{\sum_q M(q) W(q)}{\sum_q W(q)} \quad (6.38)$$

gdzie:

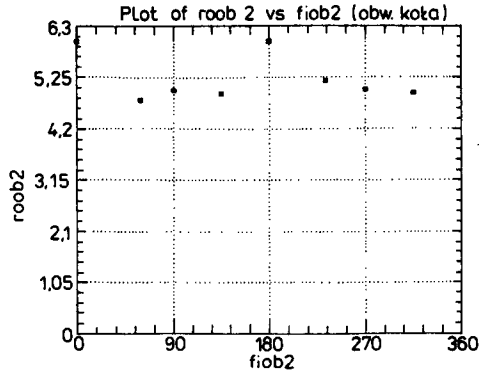
$W(q)$ jest w ogólnym przypadku wagą określającą stopień ważności q -tego parametru. Zwykle $W(q) = 1$.

Porównując parametry obiektu i modeli obiektów mamy do czynienia z sytuacją, gdy różne parametry kilku modeli obiektów i różne ilości parametrów będą odpowiadały obiektowi. Będziemy przyjmowali, że obiekt będzie identyczny z pewnym, np. i -tym modelem obiektu, o ile dla takiej "dwójki" obiektów współczynnik C będzie największy. C przyjmuje wartość z przedziału $0 \leq C \leq 1$.

Przetwarzając obraz testowy metodami omówionymi w rozdz.3 uzyskano obraz zawierający szereg obiektów geometrycznych /rys.6.11/. Dla każdego obiektu znajdującego się w tym obrazie obliczono omówione wyżej parametry i porównano je. Na rys.6.12 przedstawiono w przestrzeni Hough'a o-




Rys.6.11. Obraz z wydzielonymi obiektami geometrycznymi



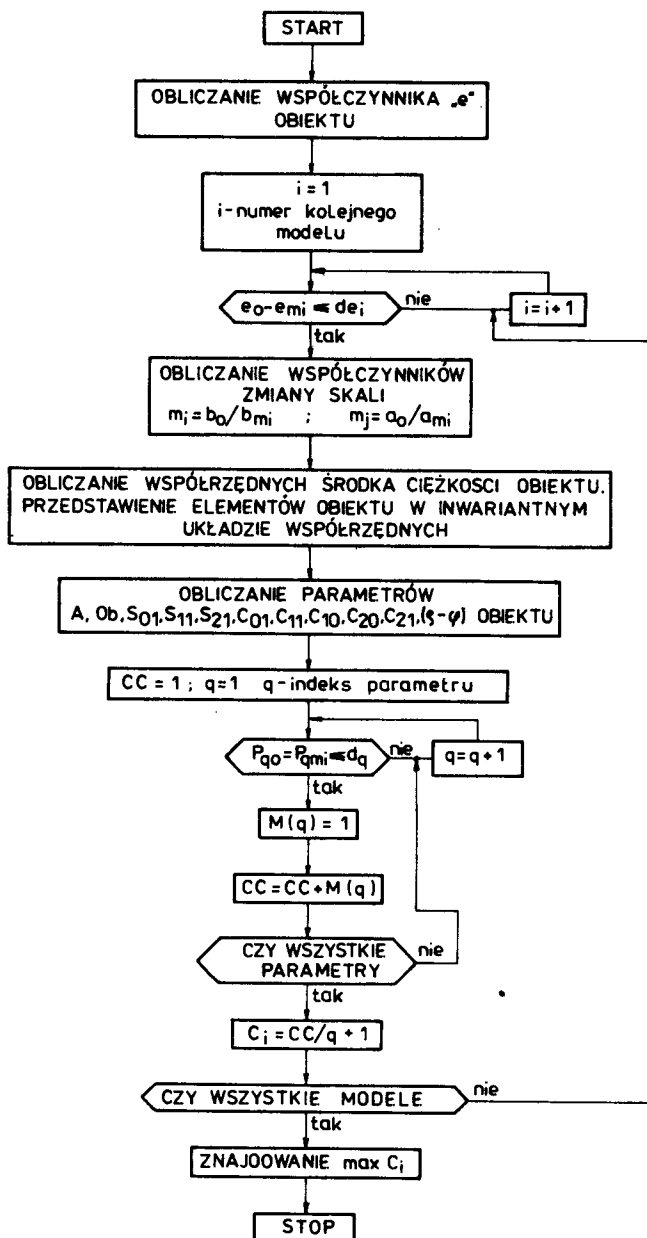
Rys.6.12. Parametry (ϱ, φ) obiektu zbliżonego do koła

biękt zbliżony do koła, położony w dolnej części lewej górnej ćwiartki obrazu. Porównanie rys.6.12 i rys.6.5 pozwala stwierdzić, że ten obiekt i model koła posiadają parametry (ϱ, φ) bardzo podobne. W wyniku porównania wszystkich parametrów obiekt ten zidentyfikowany został jako koło. Analogicznie, na rys.6.13 przedstawiono w przestrzeni Hough'a obiekt położony w górnej części lewej dolnej ćwiartki obrazu zbliżony do trójkąta. Para -




Rys.6.13. Parametry (ϱ, φ) obiektu zbliżonego do trójkąta

metry (ϱ, φ) tego obiektu obliczone są dla inwariantnego układu współrzędnych /podobnie zresztą jak każdego obiektu/ - kąt obrotu wynosi w tym przypadku -90° , natomiast współczynnik zmiany skali $\frac{1}{3.05}$. Porównanie rys.6.13 i rys.6.7 pozwala stwierdzić, że parametry (ϱ, φ) tego obiektu i modelu trójkąta prostokątnego mają zbliżone wartości. Porównanie wszystkich parametrów prowadzi do zidentyfikowania tego obiektu rzeczywiście jako trójkąta prostokątnego.



Rys.6.14. Algorytm identyfikacji obiektu



Rys.6.15. Obraz odtworzony

Wynikiem porównania parametrów obiektu z parametrami modeli obiektów jest informacja, że dany obiekt jest identyfikowany z odpowiednim modelem obiektu. Algorytm identyfikacji obiektu przedstawione na rys.6.14. W obrazie odtworzonym obraz obiektu zastępowano obrazem modelu obiektu przedstawionym w odpowiedniej skali. Obraz odtworzony przedstawiono na rys.6.15. Dla rozpatrywanych obiektów uzyskane współczynniki prawidłowości identyfikacji obiektu nie mniejsze niż 0,95.

7. PODSUMOWANIE

Przed przystąpieniem do podsumowania wyników tej monografii przy -
pomnijmy, że została ona napisana z zamiarem osiągnięcia dwóch celów. Ce -
lem pierwszym jest zwrócenie uwagi na nowe, dotychczas nie wykorzystywa -
ne obszary zastosowania redukcji redundancji obrazów, a mianowicie reduk -
cję redundancji obrazów cyfrowych /w szczególności N-obrazów/ w procesach
interpretacji obrazów i identyfikacji ich obiektów. Obecnie jest to bar -
dzo ważne zadanie przy rozwiązywaniu problemów związanych z komputerową
wizją, a w najbliższych latach znaczenie jego będzie wzrastało w związku
z rozwojem badań nad sztuczną inteligencją.

Ten pierwszy cel osiągnięto przez:

- przedstawienie teoretycznych podstaw nowej oryginalnej metody re -
dukcji redundancji możliwej do wykorzystywania w przypadkach in -
terpretacji obrazów zarówno przez człowieka, jak i maszynę,
- zaproponowanie algorytmów umożliwiających identyfikację obiektów w
obrazie,
- przedstawienie osiągniętych wyników.

Celem drugim jest przedstawienie możliwie kompletnego opisu pewnych
aspektów redukcji redundancji w sposób umożliwiający poznanie zagadnień
komplementarnych, jak i innych problemów związanych z przetwarzaniem ob -
razów cyfrowych.

Z interpretacją obrazu mamy do czynienia w tych przypadkach, w któ -
rych na podstawie analizy obrazu spodziewamy się uzyskać informacji;/i/co
przedstawia obraz, /ii/ czy w obrazie znajdują się interesujące nas ob -
iekty, /iv/ o treści obrazu mimo, że jest to obraz o niepełnym wymiarze.

Z identyfikacją obiektów spotykamy się wszędzie tam, gdzie interesu -
je nas odpowiedź na pytanie, jaki obiekt znajduje się w obrazie i czy
jest podobny do obiektów, które zostały uznane za wzorcowe, tj. za modele
obektów lub obiektów, które wcześniej zostały zidentyfikowane.

Rozdział 1 zawiera krótką genezę problematyki redukcji redundancji
z podkreśleniem ważności redukcji redundancji obrazów cyfrowych /w szcze -
gólności N-obrazów/ w procesach interpretacji i identyfikacji ich obiek -
tów.

W rozdziale 2 wprowadzono czytelnika w zagadnienia związane z reduk -
cją redundancji obrazu. Przedstawiono ogólne rozważania związane z re -
dukcją danych i możliwościami realizacji redukcji danych. Dokonano klasy -
fikacji i porównania metod redukcji redundancji. Przedstawiono problema -
tykę redukcji redundancji obrazu. Wysunięto tezę, że dekompozycja obrazu
do postaci obrazu konturowego i pewnej liczby obrazów-okien¹ umożliwi uzys -
kanie dużych wartości wrr przy prawidłowej interpretacji obrazu.

W rozdziale 3 omówione przetwarzanie obrazu cyfrowego metodą dekompozycji, m.in. zaproponowane algorytm wydzielenia zmian jaskrawości /rozd.3.3/, algorytm segmentacji obrazu /rozd.3.4/ oraz procedurę tworzenia okien-obrazu /rozd.3.5/. W rozdz.3.6 zamieszczone wyniki przetwarzania obrazu testowego uzasadniające wysuniętą tezę.

W rozdziale 4 przedstawiono detychozas stosowane subiektywne i obiektywne kryteria oceny jakości obrazu oraz kryteria jakości obrazu zaproponowane przez autora /pkt.4.2/. Dokonano, przy wykorzystaniu zaproponowanych kryteriów, oceny obrazu w przypadku redukcji redundancji metodą dekompozycji.

W rozdziale 5 przedstawiono teoretyczne podstawy redukcji redundancji parametrów opisujących obiekty obrazu.

Dla określenia i opisu obiektów wprowadzono szereg parametrów opisujących te obiekty /pkt.6.1/. Wykorzystując pojęcie transformacji Hough'a zaproponowano do opisu obiektów m.in. parametry (ρ, θ) , zaproponowano algorytm apromksymacji punktów konturowych odcinkami linii prostych /pkt.6.1/. Rozpatrzone szereg obiektów geometrycznych i praktycznie zweryfikowano drugą tezę pracy, że na podstawie zredukowanej ilości danych możliwa jest identyfikacja obiektów obrazu /pkt. 6.2/. W rozpatrywanych przypadkach uzyskano zadowalające wyniki.

Zasadnicze wyniki tej pracy podsumować można następująco:

1. Stwierdzone, że najważniejszym zadaniem w zakresie redukcji redundancji obrazów cyfrowych /w szczególności N-obrazów/ jest redukcja redundancji obrazów w procesach interpretacji i identyfikacji ich obiektów. Zagadnienie to nabiera szczególnej ważności wraz z rozwojem prac nad systemami komputerowej wizji jednak nie zostało detychczas przedstawione w literaturze. Uzasadniono podejście omówione następnie w pracy.
2. Wyczerpująco przedstawiono zagadnienia związane z redukcją redundancji i zamieszczono klasyfikację metod redukcji redundancji.
3. Przedstawiono oryginalną koncepcję dekompozycji obrazu, w której elementami są obrazy-okna. Podstawą tej koncepcji jest założenie, że dla prawidłowej i jednoznacznej interpretacji obrazu konieczna i wystarczająca jest informacja zawarta w obrazach-oknach. Przedstawiony mechanizm interpretacji wykorzystywany jest zarówno przez człowieka, jak i w systemach komputerowej wizji, np. w systemach wizyjnych robotów.
4. Zmodyfikowano znane metody wydzielenia zmian jaskrawości / wzór 3.15/ i wprowadzono pojęcie wskaźnika punktu konturowego /def.3.7 i wzór 3.16/. Zaproponowano oryginalny algorytm wydzielenia zmian jaskrawości /rys.3.2/.
5. Zaproponowano algorytm określania położenia obrazów-okienⁿ /m.in. wzory 3.42, 3.47 i 3.48 /.
6. Przedstawiono oryginalny algorytm segmentacji obrazu /wzory 3.38 i 3.41/.

7. Porównano różne obiektywne kryteria oceny jakości obrazu i zaproponowano nowe kryteria /def.4.2/ pozwalające, zdaniem autora, na bardziej obiektywną ocenę jakości obrazu, niż kryteria stosowane dotychczas. Przedstawiono uzyskane oceny jakości dla obrazów prezentowanych w pracy, demonstrując w ten sposób szeroki zakres przydatności prezentowanej metody redukcji redundancji.
8. Wprowadzono pojęcie nadmiarowości parametrów /def.5.1/ i testu nadmiarowości parametrów /def.5.2/.
9. Przedstawiono algorytm aproksymacji sekwencji punktów konturowych odcinkami linii prostych.
10. Zaproponowano zbiór parametrów opisujących modele i obiekty obrazu /def.6.1 i def.6.5 - 6.11/, i wykorzystanie do opisu obiektów parametrów (φ, θ) /wzory 6.22, 6.23/. Otrzymano wyniki pozwalające stwierdzić, że zaproponowane parametry są wystarczające do opisu obiektów i zapewniają identyfikację różnych obiektów obrazu wejściowego.

Zaprezentowane rozważania i metody są oryginalne, tam gdzie było to konieczne i możliwe zostały zilustrowane przykładami. Autor wyraża przekonanie, że przedstawione w pracy zagadnienia będą mogły być zrealizowane praktycznie. Wykorzystaniem wyników pracy, przy wyposażeniu robota przemysłowego w komputerową wizję, zainteresowane jest Centrum Robotyzacji, Automatyzacji i Modernizacji Procesów Wytwarzania Zakładów Rowerowych "ROMET" w Bydgoszczy.

DODATEK A

Macierzowa reprezentacja obrazu cyfrowego

Definicja A1

Raster R jest produktem kartezjańskim zbiorów $L_W = \{1, 2, \dots, 1, \dots, m\}$ i $L_K = \{1, 2, \dots, j, \dots, n\}$ liczb naturalnych. Dwójka całkowita (i, j) jest pojedynczym punktem rastru.

$$R = L_W \times L_K \quad (A.1)$$

$$R = \{(i, j) \mid 1 \leq i \leq m, \quad 1 \leq j \leq n\} \quad (A.2)$$

Definicja A2

Cyfrowy obraz jest określony przez funkcję F przyporządkowującą elementom zbioru R wartości jaskrawości $G = \{0, 1, 2, \dots, N\}$

$$F : L_W \times L_K \rightarrow G \quad (A.3)$$

$$F : R \rightarrow [0, N] \quad (A.4)$$

Macierz \underline{F} obrazu zawiera $m \cdot n$ liczb otrzymanych w wyniku dyskretyzacji obrazu analogowego i skwantowania próbek umieszczonych w punktach rasteru R do jednego z $N + 1$ poziomów jaskrawości

$$\underline{F} = \begin{bmatrix} f_{1,1} & f_{1,2} & \dots & f_{1,n} \\ f_{2,1} & f_{2,2} & \dots & f_{2,n} \\ \vdots & & & \\ f_{i,1} & f_{i,2} & \dots & f_{i,j} & \dots & f_{i,n} \\ \vdots & & & & & \\ f_{m,1} & f_{m,2} & \dots & & & f_{m,n} \end{bmatrix} \quad (A.5)$$

Niech \underline{f} będzie $1 \cdot mn$ wymiarowym wektorem-kolumną macierzy \underline{F}

$$\underline{f} = [\underline{f}^1 \quad \underline{f}^2 \quad \dots \quad \underline{f}^n]^t \quad (A.6)$$

$$\underline{f}^j = [f_{1,j} \quad f_{2,j} \quad \dots \quad f_{m,j}] \quad (A.7)$$

Możemy zapisać, że

$$\underline{F} \underline{v}_j = \underline{f}^j \quad (\text{A.8})$$

gdzie

$$\underline{v}_j = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{bmatrix} \begin{array}{l} \text{1-szy element} \\ \text{2-gi element} \\ \vdots \\ \text{j-ty element} \\ \vdots \\ \text{n-ty element} \end{array} \quad (\text{A.9})$$

T w i e r d z e n i a A.1

Niech $[A_j]$ będzie $(m \cdot n) \cdot m$ wymiarową macierzą zawierającą $m \cdot m$ wymiarowe podmacierze i niech $[I]$ i $[\phi]$ będą odpowiednio macierzami jednostkową i zawierającą same zera.

Wówczas

$$\underline{f} = \sum_{j=1}^n [A_j] \underline{F} \underline{v}_j \quad (\text{A.10})$$

1

$$\underline{F} = \sum_{j=1}^n [A_j]^t \underline{f} \underline{v}_j^t \quad (\text{A.11})$$

gdzie

$$[A_j] = \begin{bmatrix} [\phi] \\ [\phi] \\ \vdots \\ [I] \\ \vdots \\ [\phi] \end{bmatrix} \begin{array}{l} \text{1-sza podmacierz} \\ \text{2-ga podmacierz} \\ \vdots \\ \text{j-ta podmacierz} \\ \vdots \\ \text{n-ta podmacierz} \end{array} \quad (\text{A.12})$$

$$[I] = \begin{bmatrix} 1 & & & 0 \\ & \ddots & & \\ & & \ddots & \\ 0 & & & 1 \end{bmatrix}_{m \times m} \quad [\phi] = \begin{bmatrix} \phi \\ \phi \\ \vdots \\ \phi \end{bmatrix}_{m \times m} \quad (\text{A.13})$$


Bardzo prosty dowód tego twierdzenia polegający na wymnożeniu odpowiednich macierzy przedstawiono w [47,78].

Ważnym rezultatem twierdzenia A.1 jest następujący wniosek [47,78]: L1 - niowa transformacja łańcucha danych może być zawsze przedstawiona w postaci produktu macierzy i wektora.

DODATEK B

Inwariantny układ współrzędnych

W stosunku do położenia modelu obiektu, obiekt w obrazie rzeczywistym może być liniowo przesunięty, skręcony o pewien kąt, lub przedstawiony w innej skali /rys.B.1/. Należy znaleźć sposoby na porównanie tych obiekt-



Rys.B.1. Przekształcenia układu współrzędnych:
 a/ liniowe przesunięcie, b/ obrót o kąt,
 c/ zmiana skali $m_1 \neq m_2$, d/ zmiana skali
 $m_1 = m_2$

tów i/lub parametrów. Można to zrobić następująco:

- mechanicznie; przemieszczając obraz względem obrazu wzorcowego i zmieniając ogniskową obiektywów urządzeń odczytujących,
- elektronicznie; przekształcając obraz przy wykorzystaniu specjalizowanych układów optycznych i procesorów elektronicznych,
- analitycznie; wydzielając takie parametry obiektów, które są inwariantne względem przesunięcia, obrotu i zmiany skali.

Znając wielkość liniowego przesunięcia obiektu, kąt obrotu i współczynnik zmiany skali można określić nowe współrzędne obiektu następująco

$$[i', j', 1] = [i, j, 1] \cdot \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ I & J & 1 \end{bmatrix} \begin{bmatrix} \cos & \sin & 0 \\ -\sin & \cos & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} m_1 & 0 & 0 \\ 0 & m_2 & 0 \\ 0 & 0 & 1 \end{bmatrix} =$$

$$= \left[\left((i-1) m_i \cos \varphi - (j-J) m_i \sin \varphi \right), \left((i-1) m_i \sin \varphi + (j-J) m_j \cos \varphi \right), 1 \right] \quad (\text{B.1})$$

gdzie odpowiednie macierze oznaczają w kolejności liniową transformację początku układu współrzędnych, obrót obiektu o kąt oraz zmianę skali przedstawienia obiektu.

Zazwyczaj jednak wartości liniowego przesunięcia, kąta obrotu i współczynników zmiany skali nie są znane, dlatego chcąc porównywać różne położone i różnej wielkości obiekty obrazu należy określić układ współrzędnych, położenie których w przestrzeni określone będzie przez środek ciężkości i oś inercji obiektu, a także znormalizować obraz /niezależność od zmiany skali obrazu/ w tym układzie współrzędnych względem średniej odległości jego punktów od środka ciężkości.

Przekształcamy układ współrzędnych do postaci

$$\begin{aligned} i' &= i \cos \alpha + j \sin \alpha - I_0 \\ j' &= j \cos \alpha - i \sin \alpha - J_0 \end{aligned} \quad (\text{B.2})$$

gdzie

α jest określone następująco

$$\alpha = \text{arc tga}_1 \quad (\text{B.3})$$

przy czym a_1 jest współczynnikiem kierunkowym prostej $j = a_0 + a_1 i$ będącej osią inercji obiektu.

Współczynnik a_1 określamy rozwiązując następujący układ równań

$$\begin{aligned} \bar{j} &= a_0 + a_1 \bar{i} \\ \bar{i}j &= a_0 \bar{i} + a_1 \bar{i}^2 \end{aligned} \quad (\text{B.4})$$

gdzie \bar{i}, \bar{j} są średnimi wartościami współrzędnych i, j oraz

$$\bar{i}j = \frac{\sum_{i=1}^m \sum_{j=1}^n i j b_{i,j}}{\sum_{i=1}^m \sum_{j=1}^n b_{i,j}} ; \quad \bar{i}^2 = \frac{\sum_{i=1}^m \sum_{j=1}^n i^2 b_{i,j}}{\sum_{i=1}^m \sum_{j=1}^n b_{i,j}} \quad (\text{B.5})$$

Równania (B.2) określają układ współrzędnych, w którym opis obiektu jest inwariantny względem liniowego przesunięcia i obrotu. Następnie dokonujemy normalizacji obrazu. Układ współrzędnych kartezjańskich (B.2) przekształcamy do układu współrzędnych biegunowych. Jest

$$\rho_{i,j} = \sqrt{i'^2 + j'^2} \quad (\text{B.6})$$

$$\varphi_{i,j} = \text{arc tg } \frac{j'}{i'} \quad (\text{B.7})$$

Obliczamy

$$\rho_{i,j}^* = \frac{\rho_{i,j}}{\frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n \rho_{i,j}} \quad (\text{B.8})$$

a następnie

$$\begin{aligned} i'' &= \rho_{i,j}^* \cos \varphi_{i,j} \\ j'' &= \rho_{i,j}^* \sin \varphi_{i,j} \end{aligned} \quad (\text{B.9})$$

Obraz przedstawiony we współrzędnych i'', j'' jest inwariantny względem liniowego przesunięcia, obrotu i zmiany skali.

LITERATURA

- [1] Amin A.T.: An algorithm for grey-level transformations in digitized images, IEEE Trans. Computers, C-26, 1977, 1158-1161
- [2] Andrews H.C.: Introduction to mathematical techniques in pattern recognition. Wiley Interscience, New York, 1972
- [3] Andrews H.C., Hunt B.R.: Digital Image Restoration. Printice-Hall Inc. New Jersey, 1977
- [4] Ataman E., Alparslan E.: Application of median filtering algorithm to images, Tech. Report UJ-78/10. T.B.T.A.K
- [5] Braccini G., Marino G.: Fast geometrical manipulations of digital images, Computer Graphics, Image Processing, 13, 1980, 127-141
- [6] Batchelor B.G./ed/: Pattern Recognition. Plenum, New York, 1978
- [7] Birkhoff G., Bartee T.C.: Współczesna algebra stosowana. PWN Warszawa, 1983
- [8] Bolc L., Kulpa Z./eds/: Digital Image Processing Systems. Lecture Notes in Computer Science vol. 109. Springer, Berlin, 1981
- [9] Brown CH.M.: Inherent bias and noise in the Hough transform, IEEE Trans. Pattern Analysis and Machine Intelligence, PAMI-5, 1983, 493-505
- [10] Cappellini V., Constantinides A.G./eds/: Digital Signal Processing - 84. North-Holland, Amsterdam, 1984
- [11] Chang S.K., Fu K.S./eds/: Pictorial Information Systems, Lecture Notes in Computers Science vol. 80, Springer, Berlin, 1980
- [12] Chassery J.M.: Connectivity and consecutivity in digital pictures, Computer Graphics, Image Processing, 9, 1979, 294-300
- [13] Chen C.H./ed/: Pattern Recognition nad Signal Processing /Proc. NATO ASI, Paris, France, 1978/ Sijthoff & Noordhoff, The Netherlands, 1978
- [14] Chen P.C., Pavlidis T.: Segmentation by texture using a cocurrence matrix and a split-and-merge algorithm, Computer Graphics, Image Processing, 10, 1979, 172-182
- [15] Chen W.H., Pratt W.K.: Scene Adaptive Coder, IEEE Trans. Communications COM-32, 1984, 225-232
- [16] Choraś R.: Zastosowanie teorii informacji dla celów transformacji obrazów, Zeszyty Naukowe ATR, nr 56, 1979, str. 13-25
- [17] Choraś R.: Transformacje liniowe Hadamarda, Haara, Hadamarda - Haara w zastosowaniu do kodowania obrazów monochromatycznych Archiwum Automatyki i Telemekhaniki, z. 1-2, 1978, 141 - 157
- [18] Choraś R.: Redukcja redundancji informacji graficznej /obrazu/ metodą kodowania składowych częstotliwościowych w zastosowaniu do transmisji obrazów graficznych /rozprawa doktorska/ Preprinty nr 66. ICT Polit. Wrocławska, Wrocław, 1979

- [19] Choraś R.: Roboty inteligentne a problem przetwarzania informacji graficznej. Z. Nauk.Polit.Sląskiej - Automatyka 56,1980, 101-108
- [20] Choraś R.: System wizyjny robota przemysłowego. Z.Nauk.Polit. Śląskiej - Automatyka 64, 1982, 183-188
- [21] Choraś R.: Przetwarzanie informacji graficznej w systemie wizyjnym robota przemysłowego, Z.Nauk.Polit.Sląskiej - Automatyka 64, 1982, 189-200
- [22] Choraś R.: Cyfrowe metody przetwarzania obrazów cz.1. Bydgoskie Towarzystwo Naukowe. Prace Wydziału Nauk Technicznych, Seria C, nr 11, PWN. Warszawa-Poznań,1986
- [23] Choraś R.:Two dimensional recursive filtering of images. Revue Roumaine des Sciences Techniques: D'electrotechnique et énergetique, 4, 1982, 443-448
- [24] Choraś R.: Rozpoznawanie obiektów w systemie wizyjnym robota przemysłowego. Biuletyn Mera-PIAP, 3/98, 1983, 45-53
- [25] Choraś R.:Image Processing System for industrial robots. Image and Vision Computing, 2, 1984, 31-34
- [26] Choraś R.:Topologiczne właściwości obrazów dyskretnych, Postępy Cybernetyki, 7,1984, 129-139
- [27] Choraś R.: Identyfikacja i lokalizacja obiektów w systemie wizyjnym robota przemysłowego. Z.Nauk.Polit.Sląskiej - Automatyka 75, 1984, 191-197
- [28] Choraś R.:Image bandwidth compression by coding of low pass and high pass picture, Journal of the Institute of Engineers /J/ vol.65 pt. ET 2, 1984, 34-39
- [29] Choraś R.,Derewienko A.,Polaszek E.:Analiza i synteza obrazu monochromatycznego i kolorowego z wykorzystaniem światłowodów, Mat. III Krajowego Sympozjum "Światłowody i ich zastosowanie" tom 3,1983,55-62
- [30] Clarke R.J.:Transform Coding of Images. Academic Press, London,1985
- [31] Connors R.W.,Trivedi M.M.,Harlow Ch.A.:Segmentation of a high resolution urban scene using texture operators, Computer Vision, Graphics Image Processing, 25, 1984, 225-232
- [32] Danielsson P.E.:Euclidean distance mapping, Computer Graphics, Image Processing, 14, 1980, 248-277
- [33] Davis L.S.,Rosenfeld A.,Weszks J.S.:Region extraction by averaging and thresholding, IEEE Trans.Syst.Man Cybern.SMC-5,1975, 383-388
- [34] Davis L.S.,Mitiche A.:MITES: A model-driven iterative texture segmentation algorithm, Computer Graphics, Image Processing, 19,1982,95-110
- [35] Dessimoz J.D.:Traitement de contours en reconnaissance de formes visuelles:applicationen robotique;Ph. D. dissert, Zurich
- [36] Duda R.O, Hart P.E.: Pattern Classification and Scene Analysis.Wiley, New York, 1972
- [37] Dudani S.A., Breeding K.J.,Ghee R.B.Mc.:Aircraft identification by moment invariants, IEEE Trans. Computers, C-26, 1977, 39-45
- [38] Duff M.J.B.,Levialdi S./eds/: Languages and Architectures for Image Processing, Academic, London, 1981

- [39] Dyer Ch.R.:Gauge Inspection using Hough transorms, IEEE Trans.Pattern Analysis and Machine Intelligence, PAMI-5, 1983, 621-630
- [40] Freeman H.:Computer processing of line-drawing images, Computing Surreys, 6, 1974, 57-97
- [41] Frei W.,Chen C.C.:Fast boundary detection: a generalization and a new algorithm, IEEE Trans. Computers, C-26, 1977, 988-998
- [42] Fu K.S./ed/: Digital Pattern Recognition. Communication Cybernetics vol.10. Springer, New York, 1976
- [43] Fu K.S.,Kunii T.L./eds/: Picture Engineering. Springer,Berlin 1982
- [44] Fu K.S.,Mui J.K.:A survey on image segmentation, Pattern Recognition, 13, 1983, 3-16
- [45] Galsena E.S.,Kanal L.N./eds/: Pattern recognition in practice, North - Holland. Amsterdam,1980
- [46] Groch W.D.:Extraction of line shaped objects from aerial images using a special operator to analyze the profiles of functions, Computer Graphics, Image Processing, 18, 1982, 347-358
- [47] Hall E.L.:Computer Image Processing and Recognition, Academic, New York, 1979
- [48] Haralick R.M.:Edge and region analysis for digital image data, Computer Graphics, Image Processing, 12, 1980, 60-73
- [49] Huang T.S./ ed/: Picture Processing and Digital Filtering, Topics in Applied Physics vol.6, Springer, Berlin, 1975
- [50] Huang T.S. : Image Sequence Analysis, Series in Information Sciences vol.5, Springer, Berlin, 1981
- [51] Huang T.S.: Two-Dimensional Digital Signal Processing II. Topics in Applied Physics vol 43, Springer, Berlin, 1981
- [52] Huang T.S.,Yong G.J., Tang G.Y.:A fast two-dimensional median filtering algorithm, IEEE Trans. Acoust. Speech Signal Process. ASSP -27, 1979, 13-18
- [53] Ikonomopoulos A.:An approach to edge detection based on the direction of edge elements, Computer Graphics, Image Processing 19,1982,179-195
- [54] Johansen P.,Becker P.W./eds/:Proceedings of the Third Scandinavian Conf.on Image Analysis, Copenhagen, Studentlitteratur,Lund,Sweden , 1983
- [55] Kaufman A./ed/: Proceedings of the First IPA Conf. on Image Processing, Computer Graphics and Pattern Recognition. Beersheva. 1983
- [56] Kazmierczak H. /ed/: Erfassung und maschinelle verarbeitung von Bilddaten. Akademie,Berlin,1980
- [57] Kawai S.:On the topology preservation property of local parallel operations, Computer Graphics, Image Processing, 19, 1982, 265-280
- [58] Klette R.:Parallel Operations on binary images, Computer Graphics, Image Processing, 14, 1980, 145-158
- [59] Kuhl F.P.,Giardina Ch.R.:Elliptic Fourier features of a closed contour.Computer Graphics, Image Processing, 18, 1982, 236-258
- [60] Kulikowski J.L.: Cybernetyczne układy rozpoznające.PWN,Warszawa,1972

- [61] Kulikowski J.K.: Algebraic methods in pattern recognition. International Centre Mechanical Sciences. Courses and Lectures no 85- Springer, Wien, 1972
- [62] Kulikowski J.L.: Naprawienia rozwoju awtomatyzowanych system obrabotki wizualnych obrazow. Perspektywy rozwoju wyziszlitelnoj techniki, 1983, 99-120
- [63] Kunt M., Coulon F.D.: Signal Processing: Theories and Applications, North-Holland, Amsterdam, 1980
- [64] Martelli A.: An application of heuristic search methods to edge and contour detection, Commun. ACM, 19 (2), 1976, 73-83
- [65] Melter R.A., Tomescu I.: Metric bases in digital geometry, Computer Vision, Graphics, Image Processing, 25, 1984, 113-121
- [66] Milgram D.L., Herman M.: Clustering edge values for threshold selection, Computer Graphics, Image Processing, 10, 1972, 272-280
- [67] Montanari U.: On the optimal detection of curves pictures, Commun. ACM, 14 (5), 1971, 335-345
- [68] Mori S., Doh M.: A sequential tracking extraction of shape features and its constructive description, Computer Graphics, Image Processing, 19, 1982, 349-366
- [69] Nagao M., Matusyama T.: Edge preserving smoothing, Computer Graphics, Image Processing, 9, 1979, 394-407
- [70] Niemann H.: Klassifikation von Mustern. Springer, Berlin, 1983
- [71] Niemann H.: Pattern Analysis. Springer Series in Information Sciences vol. 4. Springer, Berlin, 1981
- [72] Pavlidis T.: Segmentation of pictures and maps through functional approximation, Computer Graphics, Image Processing, 1, 1972, 360-372
- [73] Pavlidis T.: A thinning algorithm for discrete binary images, Computer Graphics, Image Processing, 13, 1980, 142-157
- [74] Perkins W.A.: A model-based vision system for industrial parts, IEEE Trans. Computer, C-27, 1978, 126-143
- [75] Popow E.P. i dr.: Manipulacionnyie raboty, Nauka, Moskwa, 1978
- [76] Pinski J.Sz.: Opoznavanie i opisanie linii, Nauka, Moskwa, 1972
- [77] Pratt W.K., Faugeras O.D., Gagalowicz A.: Visual discrimination of stochastic texture fields, IEEE Trans. Systems Man Cybern. SMC-8, 1978, 796-804
- [78] Pratt W.K.: Digital Image Processing, Wiley-Interscience, New York, 1978
- [79] Pratt W.K./ed/: Image Transmission Techniques, Academic, New York 1979
- [80] Reeves A.P.: The local median and other window operations on SIMD computers, Computer Graphics, Image Processing, 19, 1982, 165-178
- [81] Rosen D.: On the areas and boundaries of quantized objects, Computer Graphics, Image Processing, 13, 1980, 94-98
- [82] Rosenfeld A., Kak A.C.: Digital Picture Processing vol. 1 i vol. 2 Academic. New York, 1979
- [83] Rosenfeld A./ed/: Digital Picture Analysis Topics in Applied Physics vol. 11. Springer, Berlin, 1976

- [84] Rosenfeld A./ed/: Survey. Picture Processing: 1985: Computer Vision , Graphics and Image Processing, 34, 1986, 204-251
- [85] Rosenfeld A./ed/: Survey. Picture Processing: 1986, Computer Vision, Graphics and Image Processing, 38, 1987, 147-225
- [86] Rosenfeld A./ed/: Clusters in digital pictures, Information and Control, 39, 1978, 19-34
- [87] Scollar J., Weidner B., Huang T.S.: Image enhancement using the median and the interquartile distance, Computer Vision, Graphics, Image Processing, 25, 1984, 236-251
- [88] Serra J.: Image Analysis and Mathematical Morphology. Academic. London, 1982
- [89] Sevigny L., Hvedstrup-Jensen G., et all: Discrimination and classification of vehicles in natural scenes from thermal imagery, Computer Vision, Graphics, Image Processing, 23, 1983, 229-243
- [90] Simon J.C., Rosenfeld A.: /eds/: Digital Image Processing and Analysis. Leyden, Noordhoff, 1977
- [91] Simon J.C., Haralick R.M./eds/: Digital Image Processing /Proc.NATO ASI Bonas, France 1980/. Dordrecht, Holland, 1981
- [92] Slansky J.: Image segmentation and feature extraction, IEEE Trans. Systems Man. Cybern., SMC 8, 1978, 237-247
- [93] Szibanow J.P.: Rozpoznawanie w sistemach awtokontrola, Maszynostroenie, Moskwa, 1973
- [94] Schlüssler H.W./ed/: Signal procesing II: Theories and applications North-Holland, Amsterdam, 1983
- [95] Timochin W.J.: Primenienie EWM dla reszenia zadacz rozpoznawania obrazów. Izd. Leningradskogo Uniwiersiteta, 1983
- [96] Tu D., Gonsales R.: Principy rozpoznawania obrazow /pieriowod s ang./ Mir, Moskwa, 1978
- [97] Wallace T.P., Wintz P.A.: An efficient three-dimensional aircraft recognition algorithm using normalized Fourier descriptors. Computer Graphics, Image Processing, 13, 1980, 99-126
- [98] Weszka J.S., Rosenfeld A.: Histogram modification for threshold selection, IEEE Trans. Systems Man Cybern., SMC-9, 1979
- [99] Yokokawa K., Kuni T.L.: A definition of neighborhood of a region for picture processing, Computer Graphics, Image Processing, 14, 1980, 112-144

REDUKCJA REDUNDANCJI W CYFROWYCH SYSTEMACH PRZETWARZANIA OBRAZÓW

Streszczenie

Problematyka cyfrowego przetwarzania obrazów obejmuje szeroki zakres zagadnień powiązanych ze sobą m.in. poprzez wspólne problemy występujące w każdym z tych zagadnień. Jednym z takich problemów jest redukcja redundancji obrazu cyfrowego. Nabiera on szczególnego znaczenia w przypadkach interpretacji obrazu i identyfikacji jego obiektów, w szczególności obrazów, w których informacja użyteczna i niezbędna z punktu widzenia użytkownika systemu przetwarzania obrazów skoncentrowana jest na niewielkim obszarze ich powierzchni, tzw. N-obrazów. Interpretacja obrazów i identyfikacja jego obiektów ma bardzo duże znaczenie w systemach komputerowej wizji. Termin "komputerowa wizja" obejmuje cały szereg problemów związanych z przetwarzaniem obrazów w różnych zastosowaniach, od oceny obrazów satelitarnych, poprzez zastosowania dla celów medycznych i systemów wizyjnych robotów. Systemy komputerowej wizji zawierają m.in. bloki realizujące automatyczną identyfikację obiektów obrazu i analizę złożonych sytuacji przedstawionych w postaci obrazów i ich interpretację.

Z interpretacją obrazu mamy do czynienia w tych przypadkach, w których na podstawie analizy obrazu spodziewamy się uzyskać informacji/ co przedstawia obraz, ii/ czy w obrazie znajdują się interesujące nas obiekty, iii/ w jakim otoczeniu znajdują się interesujące nas obiekty, iv/ o treści obrazu mimo, że jest to obraz o niepełnym wymiarze.

Dla prawidłowej i jednoznacznej interpretacji obrazu konieczna i wystarczająca jest tylko informacja zawarta w pewnym fragmencie obrazu. Możliwa jest redukcja redundancji polegająca m.in. na wydzieleniu fragmentów obrazu zawierających informacje istotne z punktu widzenia interpretacji obrazu, tj. fragmentów zawierających obiekty obrazu.

Z identyfikacją obiektów spotykamy się wszędzie tam, gdzie interesuje nas odpowiedź na pytanie, jaki obiekt znajduje się w obrazie i czy jest to obiekt podobny do obiektów, które zostały uznane za wzorcowe, tj. za modele obiektów lub obiektów, które wcześniej zostały zidentyfikowane. Obrazy /obiekty obrazów/ opisywane są przez parametry. Występuje problem nadmiarowości tych parametrów i aktualna staje się problematyka redukcji redundancji parametrów obiektu i opisu obiektów obrazu.

Rozdział 1 zawiera krótką genezę problematyki redukcji redundancji z podkreśleniem ważności redukcji redundancji obrazów cyfrowych /w szczególności N-obrazów/ w procesach interpretacji i identyfikacji ich obiektów.

W rozdziale 2 wprowadzono czytelnika w zagadnienia związane z redukcją redundancji obrazu. Przedstawiono ogólne rozważania związane z redukcją danych i możliwościami realizacji redukcji danych. Dokonano klasyfikacji i porównania metod redukcji redundancji. Przedstawiono problematykę redukcji redundancji obrazu. Wysunięto tezę, że dekompozycja obrazu do postaci obrazu konturowego i pewnej liczby obrazów-okien umożliwi uzyskanie dużych wartości wrr przy prawidłowej interpretacji obrazu.

W rozdziale 3 omówiono przetwarzanie obrazu cyfrowego metodą dekompozycji, m.in. zaproponowano algorytm wydzielenia zmian jaskrawości /rozd.3.3/, algorytm segmentacji obrazu /rozd.3.4/ oraz procedurę tworzenia „okien”-obrazu /rozd.3.5/. W rozdz.3.6 zamieszczono wyniki przetwarzania obrazu testowego uzasadniające wysuniętą tezę.

W rozdziale 4 przedstawiono dotychczas stosowane subiektywne i obiektywne kryteria oceny jakości obrazu oraz kryteria jakości obrazu zaproponowane przez autora /pkt.4.2/. Dokonano, przy wykorzystaniu proponowanych kryteriów oceny obrazu w przypadku redukcji redundancji metodą dekompozycji.

W rozdziale 5 przedstawiono teoretyczne podstawy redukcji redundancji parametrów opisujących obiekty obrazu. Dla określenia i opisu obiektów wprowadzono szereg parametrów opisujących te obiekty /pkt.6.1/. Wykorzystując pojęcie transformacji Hougha zaproponowano algorytm aproksymacji punktów konturowych odcinkami linii prostych. Rozpatrzono szereg obiektów geometrycznych i praktycznie zweryfikowano drugą tezę pracy, że na podstawie zredukowanej ilości danych możliwa jest identyfikacja obiektów obrazu /pkt.6.2/. W rozpatrywanych przypadkach uzyskano zadowalające wyniki.

REDUNDANCE REDUCTION IN DIGITAL SYSTEMS OF IMAGE PROCESSING

Summary

The process of image digital processing embraces a wide range of problems connected with one another by, among others, common problems occurring in each of them. One of them is the problem of redundancy reduction in a digital image. It is particularly important in case of image interpretation and identification of its objects, specially for images in which useful and necessary information, from the user's point of view, is focused on a small area of the so-called N-images. An interpretation of image and an identification of its objects plays a significant role in systems of computer vision.

For a correct and faultless interpretation of image, only the information included in an image fragment is necessary and sufficient. A redundancy reduction due to, among others, separating the fragments of image containing essential information from the point of view of the image interpretation, i.e. fragments containing the objects of the image, is possible.

An identification of objects takes place whenever we want to know which object is in the image and whether it is the object similar to those which are considered to be reference objects, i.e. models of objects or objects which were previously identified. Images /objects of images/ are described by parameters, thus the problems of reducing the redundancy of object parameters is of great significance.

Chapter I gives a short description of origins of redundancy reduction problems stressing the significance of redundancy reduction in digital images /particularly N-images/ in the processes of interpretation and identification of their objects.

Chapter II includes problems connected with the redundancy reduction of an image. There are presented general considerations on data reduction and possibilities of data reduction realization. There were made a classification and comparison of redundancy reduction methods. Problems of redundancy reduction of image are presented. There is put forward the thesis that image decomposition, to the shape of a contour image and some number of window images, makes it possible to obtain large values of redundancy reduction coefficient with proper image interpretation.

Chapter III discusses digital image processing by the decomposition method and, among others, there were suggested: an algorithm of separating brightness changes /Chapter III.3/, an algorithm of image segmentation /Chapter III.4/ and the procedure of forming image windows /Chapter III.5/.

In Chapter III.6, there are presented the results of the test image processing justifying the thesis made.

In Chapter IV, the author presents the hitherto applied subjective and objective criteria of image quality evaluation as well as criteria of image quality suggested by the author /4.2/.

Taking advantage of the criteria suggested, an image evaluation in case of redundancy reduction by decomposition was made.

In Chapter V, there are presented theoretical principles of redundancy reduction of parameters describing image objects.

For defining and describing of objects, there were introduced parameters describing these objects /6.1/. Taking advantage of the Hough transformation, the author suggested the algorithm of approximation of contour points by straight line sections. There were considered geometrical objects and the second thesis of the work, saying that, on the basis of reduced number of data, an identification of image objects was possible, was practically verified.

РЕДУКЦИЯ ИЗБЫТОЧНОСТИ В ЦИФРОВЫХ СИСТЕМАХ ПЕРЕРАБОТКИ ИЗОБРАЖЕНИЙ


Резюме

Проблематика цифровой переработки изображений охватывает широкий диапазон проблем связанных между собой общими проблемами, выступающими в каждом из этих вопросов. Одной из таких проблем является проблема редукции избыточности цифрового изображения. Приобретает оно особое значение в случаях интерпретации изображения и идентификации его объектов, а особенно изображений, в которых информация полезна и необходима с точки зрения потребителя системы переработки изображений и концентрируется на небольшой территории их поверхности так называемых N - изображений. Интерпретация изображения и идентификация его объектов имеет очень большое значение в видео системах компьютерного видения.

Для правильной и однозначной интерпретации изображения необходима и достаточна только информация, содержащаяся в определённом обзоре изображения. Возможна редукция избыточности, заключающаяся, между прочим, в видеении фрагментов изображения, содержащих информации существенные с точки зрения интерпретации изображения, т.е. фрагментов содержащих объекты изображений.

С идентификацией объектов встречаемся везде там, где интересуется нас ответ на вопрос, какой объект находится на изображении и похож ли этот объект на объекты, которые были признаны эталонными, т.е. моделями объектов, или объектов, которые ранее были идентифицированы. Изображения /объекты изображений/ описываются параметрами и актуальной становится проблематика редукции избыточности параметров объекта.

раздел содержит краткий генезис проблематики редукции избыточности. Подчёркивается важность редукции избыточности цифровых изображений /особенно N - изображений/ в процессах интерпретации и идентификации их объектов. Во второй части читатель знакомится с проблемами, связанными с редукцией избыточности изображения. Представлены общие рассуждения связанные с редукцией данных и возможностями реализации редукции данных. Проведена классификация и сравнение методов редукции избыточности цифрового изображения. Выдвинут тезис, что декомпозиция цифрового изображения до формы контурного изображения и определённого числа изображений - окон представит возможность получить большие значения w_{tt} при правильной интерпретации изображения. В 3 разделе рассмотрено трансформирование цифрового изображения методом декомпозиции и предложен алгоритм вычленения изменений яркости /раздел 3.3/, алгоритм сегментации изображения /раздел 3.4/, а также процедура образования окон изображения /раздел 3.5/. В разделе 3.6 даны результаты переработки тестового изображения обосновывающие предложенный тезис. В 4 разделе представлены применяемые до сих пор субъективные и объективные критерии качества изображения предложенные автором /пункт 4.2/. Для определения и описания объектов введён ряд параметров описывающих эти объекты /пункт 6.1/. Используя понятие трансформации Хауга предложен алгоритм аппроксимации контурных пунктов отрезками прямых линий. Рассмотрен ряд геометрических объектов и практически установлен второй тезис работы, что на основе сокращённого количества данных возможна идентификация объектов изображения.



Biblioteka Główna ATR
w Bydgoszczy

72786

ISSN 0209-0597