



Rozpoznawanie obszarów obrazu na podstawie charakterystyk zmiennych statystycznych

KAROL ONOSZKO, RAFAŁ ŚLÓSZARZ, DAWID KAMROWSKI

Politechnika Poznańska, Wydział Elektryczny, 60-965 Poznań, ul. Piotrowo 3A,
karol.onoszko@doctorate.put.poznan.pl

Streszczenie. W ostatnich latach wyraźnie widoczny jest wzrost zainteresowania metodami opartymi na przetwarzaniu obrazów. Dzięki dzisiejszej technice są one coraz szybsze, dokładniejsze, a rezultaty badań prostsze w interpretacji. W artykule opisano autorską metodę rozpoznawania obszarów w obrazie z użyciem charakterystyk zmiennych statystycznych powstałych w wyniku obserwacji zmian tych obszarów.

Słowa kluczowe: rozpoznawanie obrazu, autokorelacja, analiza sygnału

DOI: 10.5604/12345865.1131476

1. Wprowadzenie

W ostatnich latach wyraźnie widoczny jest wzrost zainteresowania metodami opartymi na przetwarzaniu obrazów. Dzięki dzisiejszej technice są one coraz szybsze, dokładniejsze, a rezultaty badań prostsze w interpretacji.

W artykule opisano metodę rozpoznawania obszarów w obrazie, z użyciem charakterystyk zmiennych statystycznych powstałych w wyniku analizy wszystkich pikseli w funkcji czasu. Pod pojęciem „obraz” w kontekście poniższego tekstu należy rozumieć nie tylko to, co widoczne jest na ekranie, lecz przede wszystkim macierz punktów pomiarowych, która przedstawia wartości pewnej wielkości fizycznej, np. wilgotności, temperatury czy ciśnienia. Obserwując zmiany tych wielkości na powierzchni lub w przestrzeni, można określić właściwości badanego obiektu, np. uszkodzenia.


Opisane w artykule doświadczenie ma charakter symulacyjny, jego zadaniem jest sprawdzenie jedynie słuszności określonych założeń. W warunkach rzeczywistego

badania byłoby to trudne w realizacji, gdyż nie ma możliwości dokładnego i przejrzystego kształtowania przebiegów charakterystyk punktów pomiarowych, przez co niektóre z wniosków mogłyby być niezauważone.

2. Ograniczenia w obserwowanym obrazie

Warunkiem do zastosowania proponowanej metody jest konieczność stałości obserwowanej sceny. Wszelkie przemieszczenia na obrazie powodują generację dodatkowych niepożądanych charakterystyk, które utrudniają prawidłową analizę.

Problem wyjaśniony jest na rysunku 1. W ramce „a” pokazana jest prosta scena składająca się z pięciu obszarów oraz tła, których charakterystyki parametrów każdego z regionów w dziedzinie czasu są takie same lub zbliżone do siebie. W takim przypadku możliwe jest jednoznaczne określenie poszczególnych rejonów. W ramce „b” przedstawiona jest podobna scena z zakłóceniem polegającym na poruszaniu się w osi pionowej jednego z obszarów. W wyniku tego ruchu po uśrednieniu w czasie następuje rozmycie krawędzi. Nie byłoby to tak dużym problemem, gdyby miejsca zaznaczone na rysunku 1 w ramce „b” miały ten sam charakter zmian co obszar pierwotny. Jednak w wyniku ruchu regionu następuje wprowadzenie niepożądanych oscylacji, które całkowicie zmieniają przebiegi charakterystyk w miejscach rozmycia. Oscylacje pikseli w tych obszarach tworzą się przez to, że piksele w zależności od chwili czasu znajdują się na zmianę w obszarze regionu lub tła. To w znacznym stopniu utrudnia użycie metody opisaną w dalszej części artykułu.




Rys. 1. a — przykładowa scena nieruchoma; b — zakłócenia spowodowane poruszaniem się jednego z obszarów na obrazie

3. Algorytm

Pierwszą czynnością, którą należy wykonać przed zastosowaniem zaproponowanego algorytmu, jest sprowadzenie trójkanałowej ramki do postaci macierzy $M \times N$, gdzie te wymiary odpowiadają rozdzielczości analizowanej ramki. Jest to proste w przypadku obrazów monochromatycznych, gdyż wystarczy jedynie przetworzyć wartość luminancji. W momencie gdy analizowany obraz jest kolorowy, konieczna jest skala, względem której następuje przetworzenie informacji, np. legenda na mapie pogodowej opisująca temperaturę odpowiednią barwą. W przypadku macierzy czujników wystarczy jedynie przypisać daną wartość z czujnika do odpowiedniej komórki w macierzy.

Każda komórka otrzymanej macierzy odpowiada jednemu pikselowi, którego zmiany kolorystyki generują różne wartości komórki. Mając do czynienia z serią obrazów (pomiarów) — filmem, możliwe jest utworzenie macierzy trójwymiarowej, gdzie trzeci wymiar stanowi oś czasu — kolejna klatka. Można w ten sposób utworzyć charakterystykę zmian dla każdego piksela z osobna. Jest to przedstawione na rysunku 2.



Rys. 2. Zasada tworzenia charakterystyk zmiany wartości poszczególnych komórek w macierzy


W oparciu o to założenie możliwe jest typowanie za pomocą autokorelacji pikseli, których charakterystyki są do siebie podobne. Gdy grupujemy takie komórki, powstają obszary o zbliżonych właściwościach. Na tej podstawie można wykreślić podobną charakterystykę dla wybranego obszaru w całości po uwzględnieniu pola powierzchni danego regionu, czyli liczebności pikseli w regionie. Zależność tę można wyrazić za pomocą wzoru:

$$x(t) = \frac{\sum_{i=1}^n x_i(t)}{n}, \quad (1)$$

gdzie: $x(t)$ — średnia wartość obszaru w danej chwili czasu (w klatce);

$x_i(t)$ — wartość pojedynczego piksela w danej chwili czasu (w klatce);
 n — liczba pikseli w grupie.

Przykład takich charakterystyk pokazany jest na rysunku 3.



Rys. 3. Charakterystyki grupowych zmian analizowanego obrazu w funkcji czasu


Należy zwrócić uwagę, że wartości w tych obszarach powinny zmieniać się w czasie. Jeżeli funkcje regionów będą stałe, czyli analizowana seria obrazów będzie identyczna, wówczas algorytm opierający się na autokorelacji sklasyfikuje cały obraz jako jeden obszar, gdyż nie będzie różnic między charakterystykami w poszczególnych pikselach.

4. Symulacja


W celu przetestowania działania algorytmu posłużono się obrazem sztucznie wygenerowanym o rozdzielczości 64×48 pikseli, gdzie znalazło się siedem obszarów, których rozmieszczenie pokazano na rysunku 4.

Zmiany wartości każdego regionu odbywały się w odmienny sposób, według charakterystyk z rysunku 3. Funkcje zostały tak dobrane, aby było można zaobserwować wpływ zmian funkcji (opóźnienie, amplituda itp.) na wykrywalność obszaru przez algorytm. Następnie na obraz nałożono szum, dzięki któremu funkcje dla poszczególnych pikseli różniły się między sobą. Efekty generacji widoczne są na rysunku 5, na którym przedstawiono wybrane klatki.


Na rysunku 6 przedstawione są charakterystyki wszystkich pikseli. Odchylenia od charakterystyk pierwotnych (rys. 3) spowodowane są wprowadzonym szumem, jednak wyraźnie widać, że są skupione wokół pożądaných wartości.



Rys. 4. Rozmieszczenie obszarów na obrazie



Rys. 5. Zmiany wyglądu obrazu w poszczególnych chwilach czasu



Rys. 6. Charakterystyki wszystkich pikseli analizowanego obrazu w funkcji czasu


5. Wyniki symulacji

Jak można było przypuszczać, charakterystyki obrazów wejściowych oraz po dokonaniu grupowania są identyczne, co widoczne jest na rysunku 7. Jest to oczywiste, gdyż algorytm w żaden sposób nie dokonuje zmian informacji w obrazie. Przypisywane są jedynie piksele do odpowiedniej grupy na podstawie przebiegu charakterystyk.


Inaczej sytuacja wygląda, jeżeli będzie rozpatrywana każda grupa z osobna. Algorytm grupujący w większości przypadków potrafił prawidłowo rozpoznać poszczególne obszary. Regiony widoczne na rysunku 4 pod numerami 5 i 6 zostały właściwie rozdzielone, pomimo że różnice w przebiegach ich funkcji polegały na różnych fazach początkowych. Podobnie jest w przypadku obszarów 3, 4 oraz 7. Tu również obszary o zbliżonych funkcjach zastały właściwie wykryte.

Potwierdzają to charakterystyki znajdujące się na rysunku 8, które są identyczne jak na rysunku 3. Jedyna różnica między tymi wykresami polega na połączeniu charakterystyk 1 i 2, czyli potraktowaniu dwóch regionów, do których były przypisane te funkcje, jako jednego. Charakterystyki połączonych obszarów miały charakter inercyjny o różnym wzmocnieniu. Oznacza to, że algorytm jest nieczuły na wielkość wzmocnienia, a jedynie na sposób zmiany przebiegu funkcji. Należy tu zwrócić uwagę na to, że w przypadku połączenia dwóch lub więcej obszarów wpływ na wygląd funkcji wynikowej ma powierzchnia łączonych regionów. Można to zaobserwować, analizując „wartości ustalone” funkcji 1 oraz 2. W przypadku pierwszej wartość ta wynosi 3, a w drugim 5. Gdyby połączone obszary miały identyczną powierzchnię,

„wartość ustalona” połączonych funkcji wynosiłaby 4. Jednakże obszar 2 jest większy, dlatego proporcjonalnie „wartość ustalona” przesunęła się w kierunku drugiej funkcji i wyniosła 4,2.



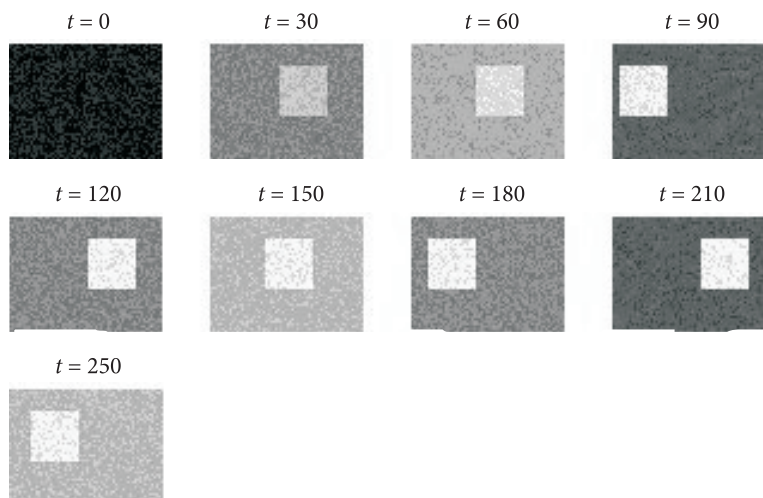
Rys. 7. Charakterystyka zmian wartości średniej dla serii obrazów pierwotnych oraz wtórnych w funkcji czasu




Rys. 8. Charakterystyki wartości średnich poszczególnych grup po segmentacji w funkcji czasu

6. Symulacja działania algorytmu z zakłóceniem wywołanym poruszonym obszarem

Sposób przeprowadzenia symulacji jest podobny do tego opisanego w poprzednich rozdziałach. Różnica polega na wprowadzeniu oscylacji obszaru.




Rys. 9. Zmiany wyglądu obrazu w poszczególnych chwilach czasu z zaburzeniem w postaci oscylacji obszaru



Rys. 10. Charakterystyki grupowych zmian analizowanego obrazu w funkcji czasu


W rzeczywistych warunkach taka sytuacja może mieć miejsce w momencie, gdy nastąpi przesunięcie matrycy czujników względem obserwowanej sceny, np. zostanie poruszona kamera termowizyjna. Na rysunku 9 pokazane są zmiany w wyglądzie obrazu, natomiast rysunek 10 przedstawia charakterystyki, według których zmiany te następują. Przeprowadzając analizę, otrzymano wykres widoczny na rysunku 11. Oprócz zakłóceń wynikających z nałożonego na obraz szumu, znacznie wyraźniejsze są zaburzenia powstałe w wyniku przemieszczania się obszaru. Cała powierzchnia między wykresami tła oraz regionu zajęta jest przez charakterystyki „przejściowe”. Wskutek tego niemożliwa jest jednoznaczna segmentacja regionów.




Rys. 11. Charakterystyki wszystkich pikseli analizowanego obrazu w funkcji czasu z zaburzeniem w postaci oscylacji obszaru

Potwierdzenie tej tezy widoczne jest na rysunku 12, na którym przedstawione są charakterystyki wyodrębnionych grup. Należy zwrócić uwagę na to, że granice obszaru zajętego przez charakterystyki grup wytyczone są przez funkcje tła oraz poruszającego się regionu.

Kolejny wykres (rys. 13) przedstawia liczbę pikseli znajdujących się w wyznaczonych grupach. Liczebność jednej z grup w wyraźny sposób przewyższa pozostałe. Są to piksele znajdujące się w obszarze tła, na których wartości nie wpływał poruszający się obszar. Liczebność pozostałych wyodrębnionych grup jest na podobnym poziomie. Niewielkie różnice wynikają z charakteru ruchu obszaru znajdującego się na obrazie.



Rys. 12. Charakterystyki wartości średnich poszczególnych grup po segmentacji w funkcji czasu z zaburzeniem w postaci oscylacji obszaru



Rys. 13. Liczebność grup

7. Podsumowanie

Opisany w powyższym artykule algorytm pozwala na określenie przynależności piksela do regionu. Metody rozpoznawania funkcji za pomocą autokorelacji są od dawna znane i chętnie stosowane. Są to jednak analizy mające jedynie charakter

identyfikacji sygnału, np. analiza akustyczna, magnetyczna itp. Zaproponowane rozwiązanie, oprócz wspomnianych wyżej cech, dodatkowo skupia się na lokalizacji sygnału w przestrzeni oraz grupowaniu miejsc wykazujących podobne właściwości. Może znaleźć to zastosowanie w różnych dziedzinach, np. przy analizie obrazów satelitarnych czy w badaniach materiałowych.

Oprócz niewątpliwych zalet przedstawiona metoda posiada pewne niedoskonałości, które ograniczają jej użycie. Ruch obserwowanej sceny uniemożliwia właściwe wyznaczenie granic regionów, dlatego konieczne jest dalsze udoskonalanie algorytmu, które zniwelowałoby wpływ zakłóceń w postaci przemieszczeń. Co za tym idzie, wszelkie próby porównania i oceny jakości rozpoznawania tej metody są przedwczesne. Niewątpliwą zaletą algorytmu jest odporność na szumy, a także możliwość jednoznacznej lokalizacji granicy pomiędzy sąsiadującymi regionami, co nie zawsze jest możliwe i proste przy użyciu klasycznych metod analizy obrazów.

Artykuł wpłynął do redakcji 1.07.2014 r. Zweryfikowaną wersję po recenzji otrzymano 23.09.2014 r.

Artykuł opracowany na podstawie referatu wygłoszonego na X Szkole–Konferencji „Metrologia Wspomagana Komputerowo — MWK’2014” Waplewo, 27-30 maja 2014.

LITERATURA

- [1] WRÓBEL Z., KOPROWSKI R., *Praktyczne przetwarzanie obrazów w programie Matlab*, EXIT, Warszawa, 2004,
- [2] TADEUSIEWICZ R., KOROHODA P., *Komputerowa analiza i przetwarzanie obrazów*, fpt, Kraków, 1997.

K. ONOSZKO, R. ŚLÓSZARZ, D. KAMROWSKI

Identification of image areas based on characteristics of statistical variables

Abstract. In recent years increasing interest in the methods based on image processing has been observed. With today's technology, these methods are becoming faster, more accurate, and the results of the tests are easier to interpret. The article describes an original method for identifying areas of an image, using the characteristics of statistical variables resulting from the observation of these areas.

Keywords: image recognition, auto-correlation, signal analysis

