

ANALIZA PRZYDATNOŚCI ALGORYTMÓW DETEKЦИИ KRAWĘDZI W ZASTOSOWANIACH FOTOGRAMETRII BLISKIEGO ZASIĘGU

USEFULNESS ANALYSIS OF EDGE DETECTION ALGORITHMS IN CLOSE-RANGE PHOTOGRAMMETRY APPLICATIONS

Anna Czechowicz, Sławomir Mikrut

Zakład Fotogrametrii i Informatyki Teledetekcyjnej, Akademia Górniczo-Hutnicza w
Krakowie

SŁOWA KLUCZOWE: detekcja krawędzi, obraz cyfrowy, fotogrametria cyfrowa, fotogrametria bliskiego zasięgu, automatyczna wektoryzacja,

STRESZCZENIE: Jednym z ważniejszych tematów badawczych ostatnich lat jest próba automatyzacji zagadnień związanych z przetwarzaniem obrazów. Dotyczy ona również fotogrametrii bliskiego zasięgu. Niniejszy artykuł ma na celu zaprezentowanie wyników badań porównujących metody detekcji krawędzi na obrazach cyfrowych oraz weryfikację ich przydatności w procesie automatycznej wektoryzacji. W ramach eksperymentu dokonano implementacji, opisanych w punkcie drugim, znanych algorytmów detekcji krawędzi bazujących na analizie pochodnych funkcji jasności obrazu jak również nowych rozwiązań (algorytm SUSAN). Opracowany w środowisku Matlab program autorski umożliwił uzyskanie punktowego opisu krawędzi, aproksymację ich przebiegu prostymi oraz analizę jakości uzyskanych wyników. Badania przeprowadzono na dwudziestu dwóch obiektach, które podzielono na dwie grupy – obiektów typowych i nietypowych. Obiekty (zdjęcia pozyskane metodą bezpośrednią – aparatem cyfrowym Canon EOS 300D z obiektywami Canon EF 14mm L USM lub Canon EF 50mm L USM oraz pośrednią – kamerą analogową Rolleiflex 6006 metric i skanerem PHOTOSCAN – TD) stanowiły część projektów wykonanych w ramach inwentaryzacji zabytków. Dla sprawdzenia poprawności wyznaczonych krawędzi dokonano ich ręcznej wektoryzacji. Obliczono współczynniki określające dokładność ilościowo – jakościową algorytmów detekcji krawędzi przy zadanych parametrach. Umożliwiło to wytypowanie optymalnych ustawień detekcji. Obliczanymi współczynnikami były: kompletność (*ang. completeness*), poprawność (*ang. correctness*) i jakość (*ang. quality*). Otrzymany w wyniku detekcji krawędzi obraz binarny porównano z obrazem zawierającym informacje o rzeczywistych krawędziach obiektu. Wyniki zestawiono i na ich podstawie wytypowano optymalny algorytm detekcji krawędzi oraz określono w procentach ilość uzyskanych automatycznie wektorów, które mogą być wykorzystane w dalszych etapach opracowań fotogrametrycznych. Praca została sfinansowana ze środków na naukę w latach 2004-2007, jako projekt badawczy Nr 4T12E 001 27 „Ocena efektywności wykorzystania sieci neuronowych w procesach automatycznej korelacji zdjęć lotniczych”.

1. WSTĘP

Zagadnienia związane z detekcją cech (w tym krawędzi) są jednym z ważniejszych tematów badawczych ostatnich lat w wielu ośrodkach naukowych na całym świecie. Próba

automatyzacji pewnych etapów produkcyjnych związanych z przetwarzaniem obrazów cyfrowych dotyczy również fotogrametrii bliskiego zasięgu. Detekcję cech wykorzystuje się w wielu algorytmach np. *matchingu*, automatycznej wektoryzacji obiektów na obrazach cyfrowych czy coraz bardziej popularnej w ostatnim czasie klasyfikacji obiektowej obrazu.

Zagadnienia te, od lat już są przedmiotem prac badawczych prowadzonych w Zakładzie Fotogrametrii i Informatyki Teledetekcyjnej AGH. Już pod koniec lat osiemdziesiątych podjęto próby idące w kierunku rozwoju algorytmów detekcji cech. Konstrukcja autografu cyfrowego VSD, była pierwszym krokiem w rozpowszechnieniu prac na obrazach cyfrowych. Następstwem tego było prowadzenie badań związanych z automatyczną lokalizacją siatki reseau z podpikselową dokładnością, zakończonych rozprawą doktorską mgr inż. W. Trochy (Trocha, 1993). Kolejne lata to próby wykorzystania drugiej pochodnej obrazu cyfrowego do lokalizacji krawędzi z podpikselową dokładnością (Jachimski et al., 1998), śledzenie linii wysokiego napięcia na obrazie cyfrowym (Cieślak, 2000) oraz dalsze testy z zaimplementowaniem algorytmów do ekstrakcji cech na kolorowych obrazach zdjęć lotniczych i satelitarnych (Mikrut, 2003). W pracach tych autorom zawsze przyświecał cel tworzenia własnego oprogramowania. W niniejszych badaniach, będących w pewnym sensie rozszerzeniem dotychczasowych algorytmów, również stworzono własne aplikację wykorzystując możliwości programistyczne środowiska „Matlab”. Aplikacje te pozwalają m.in. na wykrywanie krawędzi z podpikselową dokładnością jak również na podjęcie prób automatycznej wektoryzacji (Czechowicz, 2006).

W zaprezentowanych tutaj eksperymentach dokonano implementacji, opisanych w punkcie drugim, znanych algorytmów detekcji krawędzi bazujących na analizie pochodnych funkcji jasności obrazu jak również nowych rozwiązań (algorytm SUSAN). Opracowany w środowisku „Matlab” program autorski umożliwił uzyskanie punktowego opisu krawędzi, aproksymację ich przebiegu prostymi oraz analizę jakości uzyskanych wyników. Zaprezentowano wyniki badań porównujących metody detekcji krawędzi na obrazach cyfrowych oraz weryfikację ich przydatności w procesie automatycznej wektoryzacji.

2. CHARAKTERYSTYKA ALGORYTMÓW DETEKЦИИ CECH

Testom poddano pięć procedur, które opierają swoje działanie na analizie nieciągłości funkcji jasności obrazu – krawędź lokalizowana jest w miejscach nagłej zmiany jej wartości. Cztery z nich to znane metody, które bazują na rachunku różniczkowym i analizują pierwszą lub drugą pochodną obrazu. Piąta to nowe rozwiązanie, algorytm SUSAN, w którym koncepcja detekcji krawędzi opiera się na analizie lokalnego obszaru, związanego z badanym pikselem, zwanego rejonem USAN. Wśród operatorów różniczkowych sprawdzono gradienty, tu przedstawicielami są procedury Sobela, Kircha i Canny’ego i laplasjany – algorytm Marr-Hildretha. Badano również wspomniany wyżej algorytm SUSAN (ang. *Univalve Segment Assimilating Nucleus*). Algorytmy Sobela i Kircha należą do grupy prostych metod detekcji krawędzi. Są to tzw. metody oparte na wzorcu (ang. *template based edge detektor*). W zależności od wartości i układu współczynników w maskach filtrujących, wykrywają linie mające określony kierunek, na przykład pionowe, poziome lub ukośne. Algorytm Sobela wykorzystuje dwie maski

filtrującą poziomą S_x i pionową S_y . Składnik S_x wyznacza wartość gradientu w kierunku wierszy, natomiast składnik S_y w kierunku kolumn. Wartość odpowiedzi krawędzi i jej kierunek wyznaczone są zgodnie z wzorami (2.1) oraz (2.2):

$$G_{mag} = \sqrt{(S_x)^2 + (S_y)^2} \quad (2.1)$$

$$G_{dir} = \arctan S_y/S_x \quad (2.2)$$

W przypadku algorytmu Kircha analiza obrazu odbywa się przy pomocy nie dwóch, lecz ośmiu masek filtrujących. Współczynniki w maskach są tak dobrane, aby wykryć różnicę w skali szarości w każdym z ośmiu możliwych zwrotów, w sąsiedztwie badanego piksela. Innymi słowy, algorytm modeluje zmiany jasności, w każdej z możliwych orientacji. W celu lokalizacji pikseli, które mogą być pikselami krawędzi, analizowany obraz, jest splatany z każdą z masek. Wartością odpowiedzi krawędzi, jest maksymalna wartość uzyskana dla danego piksela:

$$G_{mag} = \max\{k_0, k_1, k_2, k_3, k_4, k_5, k_6, k_7\} \quad (2.3)$$

Orientacja krawędzi ograniczana jest do ośmiu możliwości i obliczana jest według wzoru:

$$G_{dir} = \pi/4 \cdot i \quad (2.4)$$

Gdzie „ i ” jest numer maski, dla której piksel uzyskał maksymalną odpowiedź.

Złożone procedury detekcji krawędzi reprezentują algorytmy Canny’ego oraz Marr-Hildretha. Na obie metody składa się kilka etapów.

W przypadku algorytmu Canny’ego pierwszym etapem jest redukcja szumów filtrem Gaussa, a następnie wyznaczenie pierwszej pochodnej obrazu, jako pochodnej tej funkcji. Oba działania wykonywane są z wykorzystaniem masek jednowymiarowych działających oddzielnie w kierunku wierszy i w kierunku kolumn. Wartości pierwszej pochodnej dla maski pionowej wyznaczone są zgodnie ze wzorem:

$$G_\sigma(x)' = \left(-\frac{x^2}{\sigma^2} \right) \cdot e^{-\frac{x^2}{2\sigma^2}} \quad (2.5)$$

Gdzie „ σ ” to odchylenie standardowe, a „ x ” pozycja piksela w masce w kierunku wierszy. Analogicznie według wzoru (2.5) wyznaczone są wartości dla maski poziomej. W wyniku konwolucji obrazu z każdą z masek, otrzymujemy składowe gradientu w dwóch prostopadłych do siebie kierunkach. Wartości odpowiedzi i kierunek krawędzi obliczane są zgodnie z wzorami (2.1) oraz (2.2). Kolejnym etapem jest proces polegający na „tłumieniu” lokalnych wartości nie-maksymalnych (ang. *non-maximum suppression*). Pikselem krawędzi będzie ten, dla którego wartość odpowiedzi krawędzi będzie większa od wartości pikseli sąsiednich, leżących w tym samym kierunku. Końcowy etap to procedura binaryzacji z histerezą z wykorzystaniem dwóch wartości progowych, wysokiego progu T_h oraz niskiego T_l . Obrazy powstałe na tym etapie wykorzystywane są podczas grupowania pikseli krawędzi metodą śledzenia (ang. *edge tracking*).

W przypadku procedury Marr-Hildretha pierwszym etapem jest wygładzenie oraz obliczenie drugiej pochodnej obrazu cyfrowego z wykorzystaniem laplasjanu funkcji Gaussa. Wartości współczynników filtru wyznaczone są według wzoru:

$$\nabla^2 G_\sigma = \left(\frac{r^2 - 2\sigma^2}{\sigma^4} \right) e^{\left(\frac{-r^2}{2\sigma^2} \right)} \quad (2.6)$$

Gdzie wartość „ r ” jest pierwiastkiem sumy kwadratów pozycji piksela w masce w kierunku wierszy i kolumn. Końcowy etap to identyfikacja pikseli, dla których następuje zerowanie drugiej pochodnej obrazu. Procedura przeprowadzana jest najczęściej dla dwóch wartości odchylenia standardowego σ . Otrzymane wyniki wykorzystywane są przy grupowaniu piksele w łańcuchy tworzące krawędź.

W procesie detekcji krawędzi algorytm SUSAN wykorzystuje maskę kołową o promieniu 3.4 piksela, co daje obszar 37 pikseli. Obraz analizowany jest piksel po pikselu. Pierwszym etapem jest porównanie jasności każdego piksela znajdującego się wewnątrz maski, z jasnością jądra, w celu wyznaczenia rejonów USAN. Równanie opisujące ten proces ma postać:

$$c(\vec{r}, \vec{r}_o) = e^{-\left(\frac{I(\vec{r}) - I(\vec{r}_o)}{t} \right)^6} \quad (2.7)$$

Każdemu pikselowi przypisywana jest wartość n , określająca ilość pikseli o podobnej jasności, czyli ilość pikseli w rejonie USAN.

$$n(\vec{r}_o) = \sum_r c(\vec{r}, \vec{r}_o) \quad (2.8)$$

Następnie wartość n porównywana jest z tzw. progiem geometrycznym g , którego wartość wynosi $\frac{3}{4}$ maksymalnej wartością jaką przyjmie n . Odpowiedź krawędzi określana jest w następujący sposób:

$$R(\vec{r}_o) = \begin{cases} g - n(\vec{r}_o) & \text{dla } n(\vec{r}_o) < g \\ 0 & \text{w innym przypadku} \end{cases} \quad (2.9)$$


Oprócz odpowiedzi krawędzi, wyznaczana jest również jej orientacja. Kierunek wyznaczany jest poprzez analizę rejonów USAN na dwa sposoby. W przypadku gdy obszar USAN jest większy od średnicy maski wyznaczany jest wektor pomiędzy środkiem ciężkości rejonu USAN a jądrem maski. Dla tych pikseli, dla których obszar rejonu USAN jest mniejszy od średnicy maski obliczany jest kierunek najdłuższej osi symetrii. Gdy posiadamy już informację o wartości odpowiedzi krawędzi i jej orientacji, dalszym postępowaniem jest procedura tłumienia wartości nie-maksymalnych.

3. MATERIAŁ BADAWCZY

Wybrane w ramach pracy badawczej algorytmy detekcji krawędzi przetestowano na obrazach cyfrowych pochodzących z projektów wykonanych przez krakowską firmę DEPHOS Sp. z o.o. w ramach inwentaryzacji obiektów zabytkowych. Są to zdjęcia pozyskane metodą bezpośrednią – aparatem cyfrowym Canon EOS 300D z obiektywami Canon EF 14mm L USM lub Canon EF 50mm L USM oraz pośrednią – kamerą analogową Rolleiflex 6006 metric i skanerem PHOTOSCAN – TD.

Kompleksowej analizie poddano 22 obszary testowe. Obiekty podzielono na dwie grupy. Pierwszą stanowiły obiekty typowe takie jak: stolarka okienna, drzwiowa, proste elewacje budynków, boniowanie, elewacje z kamienia, drugą zaś obiekty nietypowe:

malowidła ścienne, płaskorzeźba, elementy ozdobne (rys. 1). Przyjęty sposób podziału wydaje się uzasadniony. Można założyć, że wynik detekcji krawędzi będzie bardziej poprawny na obiektach typowych, ze względu na mniejszy stopień ich skomplikowania.



Rys. 1: Przykład obszarów testowych (a) dla obiektów typowych – elewacja Pałacu Lubomirskich Opole Lubelskie (b) dla obiektów nietypowych – Kaplica Mariacka Kraków

4. PRZEBIEG DOŚWIADCZEŃ


Ocenę przydatności metod automatycznego wykrywania i pomiaru elementów liniowych na obrazach cyfrowych przeprowadzono w trzech etapach. Dwa pierwsze tj. analiza ilościowo – jakościowa obejmująca obrazy binarne zawierające piksele krawędzi oraz analiza dokładności położenia punktów krawędzi, których pozycja została wyznaczona z subpikselową dokładnością, pozwoliły na wytypowanie optymalnego algorytmu detekcji. Etap trzeci – analiza poprawności wektorów otrzymanych w wyniku aproksymacji prostymi – pozwolił na wyrażenie w procentach poprawnie otrzymanych krawędzi, które mogą być wykorzystane w dalszych etapach opracowań.

4.1 Analiza ilościowo – jakościowa

Aby przeprowadzić analizę ilościowo – jakościową, konieczne było pozyskanie informacji o istniejących na obiektach testowych krawędziach. W tym celu wykonano wektoryzację obiektów w środowisku AutoCad oraz import pliku wektorowego do środowiska Idrisi, a następnie rasteryzację.

Algorytmy testowano przy różnych ustawieniach parametrów. Uzyskane w ten sposób obrazy binarne zawierające wykryte krawędzie, porównywano z obrazami krawędzi rzeczywistych. Analiza dokładności ujawniała krawędzie wykryte poprawnie, pominięte przez algorytm oraz mylnie zaklasyfikowane jako krawędzie istniejące na obiekcie. Poprawność detekcji została określona trzema współczynnikami: współczynnikiem kompletności – wyrażającym stosunek pozytywnie wykrytych krawędzi do ilości wykrytych szumów; współczynnikiem poprawności – uwzględniającym ilość krawędzi pominiętych; współczynnikiem jakości - biorącym pod uwagę wszystkie trzy typy

elementów liniowych. Ostatni z nich uznany został za optymalny, jako że daje pełny obraz detekcji.



Rys. 2: Ilustracja przebiegu analizy ilościowo – jakościowej dla przykładowego obiektu testowego

Otrzymane wyniki zestawiono w formie wykresów obrazujących poprawność detekcji krawędzi w zależności od progu binaryzacji oraz parametru sigma i przyjętej wielkości maski filtrującej dla poszczególnych składowych obrazu.

Zależność między progiem binaryzacji, a jakością detekcji jest zgodna z przewidywaniami. Przy niskiej wartości progowej algorytmy wykrywają dużą ilość poprawnych krawędzi, ale jednocześnie znaczną liczbę szumów. Wraz ze wzrostem progu, maleje ilość jednych i drugich, ale w taki sposób, że ilość poprawnych krawędzi przewyższa ilość szumów. Przy optymalnej wartości progu jakość osiąga swoje maksimum, jednak jego dalszy wzrost powoduje spadek tego współczynnika. Przy maksymalnej wartości progowej ilość szumów ulega redukcji, ale jednocześnie algorytm pomija mniej wyraźne krawędzie – rośnie liczba tych, które na obiekcie występują, ale nie zostały wykryte. Proces ten obrazują dwa pozostałe współczynniki dokładności detekcji krawędzi: współczynnik kompletności – uwzględniający ilość szumów i poprawności – uwzględniający ilość pominiętych punktów krawędzi. Pierwszy z nich jest funkcją rosnącą (wraz ze wzrostem progu, maleje ilość szumów), drugi zaś malejącą (wraz ze wzrostem progu, rośnie ilość punktów krawędzi pominiętych przez algorytm).

Dla dwóch z badanych algorytmów tj. Canny'ego i Marr–Hildretha, przeprowadzono testy wpływu parametru sigma oraz wielkości maski na jakość detekcji. Oba parametry biorą udział w wygładzeniu oraz aproksymacji wartości I lub II pochodnej obrazu. W przypadku algorytmu Canny'ego wyniki pozwalają sformułować następujący wniosek: optymalnym rozwiązaniem jest stosowanie niewielkich (np. 3x3 piksele) masek filtrujących z dowolną wartością parametru sigma, bądź większych – z kolei bardziej wygładzających obraz, lecz przy niskim odchyleniu standardowym. W przypadku algorytmu Marr-Hildretha im niższa wartość parametru sigma tym piksel centralny ma większy wpływ na aproksymację wartości II pochodnej funkcji jasności obrazu. Z testów wynika jednak, że stosowanie parametrów poniżej 0.5 dla niższej wartości sigma i 1.0 dla wyższej, prowadzi do słabych wyników.

Niezależnie od algorytmu, dla większości obrazów, można wskazać składową (tj. skala szarości, kanały R, G lub B), w której detekcja krawędzi osiąga najlepsze rezultaty. Wyniki wskazują, że maksimum współczynnika jakości przypada: w 37% na kanał

czerwony, w 31% na kanał niebieski, w 15% na kanał zielony i w 13% na skalę szarości. Jak widać, w przypadku zdjęć naziemnych, korzystniejsze, dla detekcji krawędzi są kanały czerwony, a zaraz za nim niebieski. Analiza w kanałach zielonym i na obrazie w skali szarości rzadziej prowadzi do dobrych rezultatów.

W oparciu o wartość współczynnika jakości, dla każdego obiektu testowego, dokonano porównania dokładność detekcji krawędzi między algorytmami. Wyniki zestawiono w tabeli poniżej.

Tabela 1: Porównanie wyników analizy ilościowo-jakościowej (współczynnika jakości) między testowanymi algorytmami


Nazwa	Wartość współczynnika jakości				
	Sobel	Kirch	Canny	Marr-Hildreth	SUSAN
Test_1	0.623	0.496	0.646	0.582	0.513
Test_2	0.605	0.374	0.631	0.570	0.539
Test_3	0.561	0.479	0.563	0.524	0.427
Test_4	0.715	0.512	0.729	0.686	0.559
Test_5	0.371	0.312	0.363	0.290	0.293
Test_6	0.491	0.433	0.488	0.398	0.409
Test_7	0.504	0.420	0.512	0.431	0.409
Test_8	0.478	0.384	0.495	0.397	0.380
Test_9	0.601	0.404	0.605	0.492	0.474
Test_10	0.541	0.468	0.599	0.340	0.412
Test_11	0.460	0.348	0.457	0.407	0.357
Test_12	0.391	0.365	0.398	0.272	0.300
Test_13	0.597	0.508	0.605	0.560	0.502
Test_14	0.472	0.439	0.486	0.428	0.345
Test_15	0.495	0.458	0.528	0.492	0.347
Test_16	0.421	0.428	0.438	0.380	0.239
Test_17	0.549	0.396	0.547	0.450	0.333
Test_18	0.496	0.397	0.506	0.407	0.367
Test_19	0.369	0.313	0.381	0.353	0.266
Test_20	0.720	0.654	0.751	0.728	0.615
Test_21	0.567	0.404	0.580	0.556	0.483
Test_22	0.430	0.420	0.415	0.328	0.319

Według przeprowadzonych badań na 22 obiekty testowe, w 17 przypadkach algorytm Canny'ego okazał się najlepszy. W pozostałych 5 procedura Sobela dała najwyższe wyniki. Otrzymane rezultaty pozwoliły uszeregować algorytmy w następującej kolejności: Canny, Sobel, Marr-Hildreth, SUSAN, Kirch.

Na podstawie analizy pozostałych współczynników dokładności detekcji krawędzi, określono średni stosunek poprawnie wykrytych punktów do wszystkich zlokalizowanych przez algorytm (w procentach): dla obiektów typowych wynosi on 73%, dla nietypowych 66% oraz średni stosunek poprawnie wykrytych punktów do wszystkich istniejących na obiekcie testowym (w procentach) – dla obiektów typowych wynosi 69%, dla nietypowych 68%.

4.2 Analiza dokładności współrzędnych punktów zlokalizowanych z subpikselową dokładnością

Na podstawie wyników analizy ilościowo – jakościowej, dla każdego algorytmu oraz obrazu, wybrano optymalne parametry, przy których dokonano wyznaczenia punktów krawędzi z subpikselową dokładnością. Rysunek 3 ilustruje rezultat tej operacji dla przykładowych obiektów testowych.



Rys. 3: Punkty krawędzi zlokalizowane z subpikselową dokładnością

Kontrola poprawności lokalizacji punktów obejmowała krawędzie łatwe do identyfikacji i polegała na porównaniu współrzędnych tych punktów ze współrzędnymi rzeczywistych odpowiedników. Na każdym obiekcie, dla każdego testowanego algorytmu, dokonano pomiaru 30 punktów, w oparciu o które wyznaczono odchyłki na współrzędnych, wypadkową tych różnic oraz odchylenie standardowe. Dodatkowo wyznaczono średnią dokładność lokalizacji punktów dla obiektów typowych oraz nietypowych. W oparciu o wszystkie pomiary (tj. 660 punktów) wyznaczono średnią dokładność dla każdego z pięciu algorytmów. Uzyskane wyniki zestawiono w tabeli prezentowanej poniżej.

Tabela 2: Średnia dokładność lokalizacji punktów krawędzi dla badanych algorytmów

Algorytmy	Obiekty typowe			Obiekty nietypowe			Średnia dokładność		
Sobel	0.574	±	0.074	0.658	±	0.153	0.616	±	0.159
Kirch	0.500	±	0.129	0.575	±	0.193	0.537	±	0.165
Canny	0.540	±	0.134	0.590	±	0.175	0.565	±	0.154
Marr-Hildreth	0.702	±	0.187	0.792	±	0.327	0.747	±	0.264
SUSAN	0.764	±	0.309	0.890	±	0.289	0.827	±	0.299

Uzyskane wyniki wskazują, że dokładność lokalizacji punktów dla obiektów typowych i nietypowych jest porównywalna i pozwala uszeregować algorytmy w następującej kolejności, zaczynając od najdokładniejszego: Kirch, Canny, Sobel, Marr-Hildreth, SUSAN.

Algorytm Kircha, który w analizie ilościowo-jakościowej uzyskał najsłabsze rezultaty, najdokładniej lokalizował punkty krawędzi, zaraz po nim algorytm Canny'ego, którego dokładność była zaledwie o 0.03 piksela niższa. Najmniej dokładny okazał się algorytm

SUSAN. Warto zastanowić się, czy przy różnicy rzędu dziesiątych części piksela, szeregowanie algorytmów pod względem dokładności współrzędnych, jest zasadne. Jeżeli różnice są tak nieznaczne, w takim razie, o tym który z algorytmów jest optymalny, będzie decydować poprawność lokalizacji krawędzi (analiza ilościowo-jakościowa).

4.3 Automatyczna wektoryzacja

Proces automatycznej wektoryzacji obejmował wszystkie obiekty testowe. W oparciu o wyniki wcześniejszych analiz, dla każdego obiektu wybrano najbardziej poprawny opis punktowy, stanowiący dane wejściowe. Poniżej zaprezentowano rezultat aproksymacji przebiegu krawędzi na przykładzie fragmentu obiektu testowego.

Wyniki zostały poddane ocenie wizualnej. Eliminacja błędnych wektorów pozwoliła na wyznaczenie w procentach stosunku ilości poprawnie otrzymanych wektorów do wszystkich uzyskanych automatycznie, stosunku sumy długości poprawnie otrzymanych wektorów do sumy wszystkich uzyskanych automatycznie oraz stosunku sumy długości poprawnie otrzymanych wektorów do sumy uzyskanych w wyniku ręcznej wektoryzacji. Dodatkowo dla każdego obiektu testowego porównano położenie kilku wybranych wektorów względem ich odpowiedników otrzymanych w procesie ręcznej wektoryzacji.

Tabela 3: Stosunek poprawnie otrzymanych wektorów do wszystkich uzyskanych automatycznie

Obiekty	[%]	
	Ilość	Długość
typowe	47.7%	75.3%
nietypowe	53.6%	72.0%

Tabela 4: Stosunek poprawnie otrzymanych wektorów do wszystkich uzyskanych w wyniku ręcznej wektoryzacji

Obiekty	Długość [%]
typowe	69.9%
nietypowe	72.7%

Zarówno dla obiektów typowych jak i nietypowych około 50% ilości otrzymanych w sposób automatyczny wektorów jest poprawna – o 5% wyższa dla obiektów nietypowych. Porównanie długości daje dużo lepsze rezultaty tj. średnio 75% dla obiektów typowych i 72% dla nietypowych (tabela 3). Uzyskane wyniki sugerują, że dużą ilość niepoprawnych wektorów stanowią krótkie odcinki, obrazujące najczęściej teksturę materiałów z jakich wykonane są obiekty. Ostatecznie porównanie rezultatów wektoryzacji automatycznej z manualną (tabela 4) pozwala stwierdzić, że około 70% otrzymanych wektorów jest prawidłowa.

5. PODSUMOWANIE I WNIOSKI

Niniejsza publikacja dotyczy problematyki wykrywania elementów liniowych w sposób możliwie automatyczny. W zaprezentowanych tutaj eksperymentach dokonano implementacji, opisanych w punkcie drugim, znanych algorytmów detekcji krawędzi bazujących na analizie pochodnych funkcji jasności obrazu jak również nowych rozwiązań (algorytm SUSAN). Opracowany w środowisku „Matlab” program autorski umożliwił uzyskanie punktowego opisu krawędzi, aproksymację ich przebiegu prostymi oraz analizę jakości uzyskanych wyników.

Przeanalizowano również wpływ rodzaju obiektów na uzyskane wyniki. Podziału dokonano na obiekty typowe i nietypowe. Otrzymane dokładności lokalizacji punktów dla obiektów typowych i nietypowych są porównywalne i pozwalają uszeregować algorytmy w następującej kolejności, zaczynając od najdokładniejszego: Kirch, Canny, Sobel, Marr-Hildreth, SUSAN. Algorytm Kircha, który w analizie ilościowo-jakościowej uzyskał najstabsze rezultaty, najdokładniej lokalizował punkty krawędzi, zaraz po nim algorytm Canny’ego, którego dokładność była zaledwie o 0.03 piksela niższa. Najmniej dokładny okazał się algorytm SUSAN.

Obliczono również współczynniki określające dokładność ilościowo – jakościową algorytmów detekcji krawędzi przy zadanych parametrach. Umożliwiło to wytypowanie optymalnych ustawień detekcji. Otrzymany w wyniku detekcji krawędzi obraz binarny porównano z obrazem zawierającym informacje o rzeczywistych krawędziach obiektu. Wyniki zestawiono i na ich podstawie wytypowano optymalny algorytm detekcji krawędzi oraz określono w procentach ilość uzyskanych automatycznie wektorów, które mogą być wykorzystane w dalszych etapach opracowań fotogrametrycznych.

Przedstawiono również wyniki analizy procesu automatycznej wektoryzacji, na przykładzie wybranych algorytmów. Uzyskane w badaniach wyniki prowadzą do wniosków, że zautomatyzowany proces wykrycia i pomiaru krawędzi dla obiektów fotogrametrii bliskiego zasięgu daje stosunkowo dobre rezultaty. Uzyskany na drodze automatycznej opis symboliczny obiektu jest poprawny w około 50 %. Po manualnych korektach błędnych elementów, opis symboliczny obiektów jest kompletny w 70 %, a dokładność położenia wektorów uzyskanych automatycznie względem położenia przyjętego jako referencyjne jest zbliżona do przyjętej wartości odchylenia standardowego. Świadczy to tym, że obrany kierunek badań daje nadzieję za uzyskanie zadowalających rezultatów, jednak wymaga dalszych prac związanych z podniesieniem efektywności algorytmów.

6. LITERATURA

Cieślak J., 2000, Automatyzacja śledzenia linii na obrazach cyfrowych. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 10, s. 31-1 - 31-7

Czechowicz A., 2006. Analiza przydatności algorytmów detekcji krawędzi w zastosowaniach fotogrametrii bliskiego zasięgu. *Praca magisterska*, AGH.

Jachimski J., Mikrut S., 1998, Próba subpikselowej lokalizacji linii konturowych z wykorzystaniem drugiej pochodnej obrazu cyfrowego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 8.

Mikrut S., 2003. Wpływ skanowania i kompresji według standardu JPEG na wykrywanie obiektów liniowych i punktowych na obrazach cyfrowych. *Rozprawa doktorska*, AGH.

Trocha W., 1993, Automatyzacja pomiaru wzorców reseau na zdjęciach fotogrametrycznych z wykorzystaniem kamery CCD i autografu analitycznego. *Rozprawa doktorska*, Zakład Fotogrametrii i Informatyki Teledetekcyjnej AGH

USEFULNESS ANALYSIS OF EDGE DETECTION ALGORITHMS IN CLOSE-RANGE PHOTOGRAMMETRY APPLICATIONS

KEY WORDS: edge detection, digital image, digital photogrammetry, close-range photogrammetry, automatic vectorization

Summary

One of the important research subjects in the last years has been an attempt at the automatization of image processing. This concerns also the close-range photogrammetry. The aim of this paper is to present the results of research comparing methods of edge detection on digital images and verification of their use in automatic vectorization. Within the framework of this experiment, the known algorithms of edge detection, based on the derivative-based analyses of image brightness function, as described in section two, were implemented, and the same about new solutions (the SUSAN algorithm). The original software, developed under Matlab, allowed to get the point description of edges, as well as the approximation of their routes by means of lines and the analysis of received results. The tests were conducted on 22 objects, divided into two categories: typical and non-typical ones. The objects (images obtained by means of a direct method, with the use of Canon EOS 300D digital camera, provided with Canon EF 14 mm L USM or Canon EF 50 mm L USM lens, and by means of an indirect method, with the use of an analogue Rolleiflex 6006 metric camera and PHOTOSCAN – TD scanner) constituted part of projects implemented under the historic monument inventory scheme. In order to check the correctness of evaluated edges, they were subjected to manual vectorization. The quantity and quality accuracy of the edge detection algorithm coefficients with known parameters were calculated. The calculated coefficients were: completeness, correctness, and quality. The binary image received as the result of edge detection was compared with the image containing information about real object edges. The results were put together and, based on them, the optimum edge detection algorithm was selected, and the percentage amount of automatically gained vectors to be used in next steps of photogrammetric works was determined.

This project was financed from financial resources allocated towards research in 2004-2007, as the research project No. 4T12E 001 27 "The Evaluation of the Effective Use of Neural Networks in Processes of Automatic Correlation of Air Images".

Dane autorów:

Mgr inż. Anna Czechowicz
e-mail: eire02@op.pl
telefon: (012) 617 23 02
fax: (012) 633 17 91

Dr inż. Sławomir Mikrut
e-mail: smikrut@agh.edu.pl
telefon: (012) 617 23 02
fax: (012) 633 17 91