

ANALIZA PRZYDATNOŚCI ALGORYTMÓW DETEKCJI KRAWĘDZI W ZASTOSOWANIACH FOTOGRAMETRII BLISKIEGO ZASIĘGU

THE USE 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: obraz cyfrowy, detekcja krawędzi, automatyczna wektoryzacja, fotogrametria cyfrowa, fotogrametria bliskiego zasięgu

STRESZCZENIE: Niniejszy artykuł prezentuje wyniki badań porównujących metody detekcji krawędzi na obrazach cyfrowych oraz weryfikację ich przydatności w procesie automatycznej wektoryzacji. W ramach eksperymentu dokonano implementacji znanych algorytmów detekcji krawędzi bazujących na analizie pochodnych funkcji jasności obrazu (Sobela, Kircha, Canny'ego, Marr-Hildretha) 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 te pochodzą z projektów wykonanych w ramach inwentaryzacji zabytków. Zdjęcia zostały pozyskane metodą bezpośrednią – aparatem cyfrowym Canon EOS 300D z obiektywami Canon EF 14 mm L USM i Canon EF 50mm L USM oraz pośrednią – kamerą analogową Rolleiflex 6006 metric i skanerem PHOTOSCAN – TD. 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 (*completeness*), poprawność (*correctness*) i jakość (*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 (Canny) oraz określono w procentach ilość uzyskanych automatycznie wektorów, które mogą być wykorzystane w dalszych etapach opracowań fotogrametrycznych.

1. WSTĘP

Zagadnienia związane z detekcją (ekstrakcją) cech na obrazie cyfrowym 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.

Problem sprowadza się do działań na trzech głównych typach obiektów: homogenicznych obszarach, krawędziach (liniach) obiektów lub punktach obrazu cyfrowego (Rottensteiner, 2001). Istnieje również podział ze względu na trójpoziomowy system przetwarzania z uwzględnieniem typów wykrywanych obiektów podany w literaturze (Fuchs, 1998). W zależności od typów wykrywanych obiektów, rozwijano odpowiednie algorytmy, które pozwoliły na rozwiązanie wielu zadań praktycznych. W latach dziewięćdziesiątych powstał system do automatycznej budowy modeli szkieletowych do celów inwentaryzacji architektonicznych. Wykrywano krawędzie budynków z bardzo wysoką precyzją celem m.in. ich późniejszej wizualizacji (Streilein, 1994). Prowadzono również prace nad samym zwiększeniem wydajności algorytmów czy nawet definiowaniem nowych, takich jak np. operator Förstnera. Rozwijano również metody ekstrakcji krawędzi z podpikselową dokładnością (Kraus, 1997; Steger, 2000).

Również w Zakładzie Fotogrametrii i Informatyki Teledetekcyjnej AGH od wielu lat są prowadzone badania w tym kierunku. 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 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. Cztery z nich to znane metody, które bazują na rachunku różniczkowym i analizują pierwszą lub drugą pochodną obrazu (algorytmy Sobela, Kircha,

Canny'ego, Marr-Hildretha). Piąta to nowe rozwiązanie, algorytm SUSAN, w którym koncepcja detekcji krawędzi opiera się na analizie lokalnego obszaru, związanego z badanym pikselem, zwanego rejonem USAN. Algorytmy Sobela i Kircha (Parker, 1996) należą do grupy prostych metod detekcji krawędzi. Są to tzw. metody oparte na wzorcu (*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 filtrujące 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 równaniami (1) oraz (2):

$$G_{mag} = \sqrt{(S_x)^2 + (S_y)^2} \quad (1)$$

$$G_{dir} = \arctan S_y/S_x \quad (2)$$

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:

$$G_{mag} = \max\{k_0, k_1, k_2, k_3, k_4, k_5, k_6, k_7\} \quad (3)$$

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

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

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

Złożone procedury detekcji krawędzi reprezentują algorytmy: Canny'ego oraz Marr-Hildretha (Parker, 1996). 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 z równaniem:

$$G_{\sigma}(x)' = \left(-\frac{x^2}{\sigma^2}\right) \cdot e^{-\frac{x^2}{2\sigma^2}} \quad (5)$$

gdzie „ σ ” to odchylenie standardowe, a „ x ” pozycja piksela w masce w kierunku wierszy. Analogicznie według wzoru (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 (1) oraz (2). Kolejnym etapem jest proces polegający na „tłumieniu” lokalnych wartości nie-maksymalnych (*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 (*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:

$$\nabla^2 G_\sigma = \left(\frac{r^2 - 2\sigma^2}{\sigma^4} \right) e^{-\frac{r^2}{2\sigma^2}} \quad (6)$$

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 (Smith, 1995) 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:

$$c(\bar{r}, \bar{r}_o) = e^{-\left(\frac{I(\bar{r}) - I(\bar{r}_o)}{t}\right)^6} \quad (7)$$

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

$$n(\bar{r}_o) = \sum_r c(\bar{r}, \bar{r}_o) \quad (8)$$

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

$$R(\bar{r}_o) = \begin{cases} g - n(\bar{r}_o) & \text{dla } n(\bar{r}_o) < g \\ 0 & \text{w innym przypadku} \end{cases} \quad (9)$$

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 algorytmy detekcji krawędzi przetestowano na obrazach cyfrowych pochodzących z projektów inwentaryzacji obiektów zabytkowych, wykonanych przez krakowską firmę DEPHOS Sp. z o.o. Są to zdjęcia pozyskane metodą bezpośrednią –

aparatem cyfrowym Canon EOS 300D z obiektywami Canon EF 14mm L USM i Canon EF 50 mm L USM oraz pośrednią – kamerą analogową Rolleiflex 6006 metric i skanerem PHOTOSCAN – TD.

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). Można założyć, że wynik detekcji krawędzi będzie bardziej poprawny na obiektach typowych, ze względu na mniejszy stopień skomplikowania kształtu.



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 ilości poprawnie otrzymanych krawędzi, które mogą być wykorzystane w dalszych etapach opracowań, na przykład orientacji wzajemnej, orientacji bezwzględnej, rekonstrukcji obiektów.

4.1. Analiza ilościowo – jakościowa

Dla przeprowadzenia analizy 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 (wielkość maski, σ , próg binaryzacji). Uzyskane w ten sposób obrazy binarne zawierające wykryte krawędzie,

porównywano z obrazami krawędzi rzeczywistych. Analiza dokładności ujawniała krawędzie wykryte poprawnie (TP), pominięte przez algorytm (FP) oraz mylnie zaklasyfikowane jako krawędzie istniejące na obiekcie (FN). Poprawność detekcji została określona trzema współczynnikami: współczynnikiem kompletności (10), poprawności (11) oraz jakości (12). Ostatni z nich uznany został za optymalny, jako że daje pełny obraz detekcji.

$$K = \frac{TP}{(TP + TN)} \quad (10)$$

$$P = \frac{TP}{(TP + FP)} \quad (11)$$

$$J = \frac{TP}{(TP + FP + FN)} \quad (12)$$



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 σ i przyjętej wielkości maski filtrującej dla poszczególnych składowych obrazu.

Zależność między progiem binaryzacji, a jakością detekcji jest zgodna z przewidywaniami. Przy niskiej wartości progowej algorytm wykrywa dużą ilość poprawnych krawędzi, ale jednocześnie znaczną liczbę szumów. Wraz ze wzrostem progu, maleje ilość jednych i drugich. 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. Zjawisko to obrazują również zależności między progiem binaryzacji, a współczynnikiem kompletności i poprawności. Pierwszy z nich jest funkcją rosnącą, drugi zaś malejącą.

Dla dwóch z badanych algorytmów Canny’ego i Marr-Hildretha, przeprowadzono testy wpływu odchylenia standardowego 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. 3×3 piksele masek filtrujących z dowolną wartością parametru sigma, bądź większych, z kolei bardziej

wygładzających obraz, lecz przy wartości odchylenia standardowego mniejszej niż 0.8. W przypadku algorytmu Marr-Hildretha, im niższa wartość odchylenia standardowego 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 σ i 1.0 dla wyższej, nie eliminuje w sposób znaczący ilości pikseli mylnie zaklasyfikowanych jako piksele krawędzi.

Niezależnie od algorytmu, dla większości obrazów, można wskazać składową, tj. skalę szarości, kanały R, G lub B, w której współczynnik jakości osiąga wartość maksymalną. 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 i niebieski.

Tabela 1. Wyników analizy ilościowo-jakościowej (współczynnik jakości) testowanych algorytmów

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


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

Według przeprowadzonych badań, w 17 przypadkach na 22 obiekty testowe, algorytm Canny'ego okazał się najlepszy. W pozostałych 5 procedura Sobela uzyskała najwyższą wartość współczynnika jakości. Otrzymane rezultaty pozwoliły uszeregować algorytmy pod względem jakości detekcji w następującej kolejności: Canny, Sobel, Marr-Hildreth, SUSAN, Kirch.

Na podstawie analizy współczynników poprawności i kompletności, 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 (wielkość maski, σ , próg binaryzacji), 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 różnice współrzędnych, wartość średnią różnic oraz odchylenie standardowe dla obiektów typowych i nietypowych. Uzyskane wyniki zestawiono w tabeli 2.

Tabela 2. Wartość średnia różnic współrzędnych i odchylenie standardowe dla badanych algorytmów

Algorytmy	Obiekty typowe [pxl]		Obiekty nietypowe [pxl]		Średnia dokładność [pxl]	
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 wartość średnia różnic współrzędnych 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 pod względem jakości detekcji został uszeregowany na ostatnim miejscu, najdokładniej lokalizuje punkty krawędzi, zaraz po nim algorytm Canny'ego, którego dokładność jest 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 (tabela 3) oraz stosunku sumy długości poprawnie otrzymanych wektorów do sumy uzyskanych w wyniku ręcznej wektoryzacji (tabela 4). 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 wyższe współczynniki 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 praca dotyczy problemu wykrywania krawędzi w trybie automatycznym. Opracowany w środowisku „Matlab” program autorski umożliwił uzyskanie punktowego opisu krawędzi z wykorzystaniem algorytmów Sobela, Kircha, Canny’ego, Marr-Hildretha oraz SUSAN, aproksymację ich przebiegu prostymi oraz analizę jakości uzyskanych wyników.

W eksperymentach analizowano wpływ rodzaju obiektów na uzyskane dokładności wektoryzacji. 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 najniższe wartości współczynnika jakości, 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 obraz binarny porównano z obrazem zawierającym informacje o rzeczywistych krawędziach obiektu. Na podstawie analizy wyników badań określono optymalny algorytm detekcji krawędzi oraz wyznaczono w procentach ilość uzyskanych automatycznie wektorów, które mogą być wykorzystane w dalszych etapach opracowania fotogrametrycznego.

Przedstawiono również wyniki analizy procesu automatycznej wektoryzacji, na przykładzie wybranych algorytmów. Na podstawie uzyskanych wyników badań można wnioskować, że zautomatyzowany proces wykrycia i pomiaru krawędzi dla obiektów fotogrametrii bliskiego zasięgu daje zadawalające 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 w procesie wektoryzacji wartości odchylenia standardowego. Nie należy jednak traktować tych wyników jako ostateczne. Przyjmujemy, że obrany kierunek badań daje nadzieję na dalszy rozwój metod ekstrakcji. W kolejnych krokach badań planuje się podnieść efektywność stosowanych algorytmów poprzez optymalizację oraz wcześniejsze prace związane z przygotowaniem obrazu cyfrowego poprzez zastosowanie filtrów adaptacyjnych.

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 w Krakowie.
- Jachimski J., Mikrut S., 1998, Próba subpikselowej lokalizacji linii konturowych z wykorzystaniem drugiej pochodnej obrazu cyfrowego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 8, s. 25/1-25/7.
- Fuchs K., Heuel S., 1998. Feature Extraction, Third Course in Digital Photogrammetry, Institute for Photogrammetry, University Bonn.
- Kraus K., 1997. *Photogrammetry*, Ferd. Dummlers Verlag, Bonn, Fourth Edition
- Mikrut S., 2003. Wpływ skanowania i kompresji według standardu JPEG na wykrywanie obiektów liniowych i punktowych na obrazach cyfrowych. *Rozprawa doktorska*, AGH.
- Parker J.R., 1996. *Algorithms for Image Processing and Computer Vision*. Wiley
- Smith S.M. Brady J.M., 1995. SUSAN – A New Approach to Low Level Image Processing. *Technical Report TR95SMS1c*.
- Rottensteiner F., 2001. Semi-automatic extraction of buildings based on hybrid adjustment using 3D surface models and management of building data In a TIS, *Rozprawa doktorska*, Instytut Fotogrametrii i Teledetekcji, Uniwersytet Wiedeński.
- Streilein A., 1994. Towards automation in architectural photogrammetry: CAD – based 3D – feature extraction. *ISPRS Journal of Photogrammetry and Remote Sensing* Vol. 49.
- 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 w Krakowie.

Praca wykonywana w ramach projektu badawczego KBN Nr 4T12E 001 27 pt. „Ocena efektywności wykorzystania sieci neuronowych w procesach automatycznej korelacji zdjęć lotniczych”.

THE USE OF EDGE DETECTION ALGORITHMS IN CLOSE RANGE PHOTOGRAMMETRY APPLICATIONS

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

Summary

This paper presents the results of research work that compares methods of edge detection on digital images, as well as verification of their use in the automatic vectorization process. Within the experiment framework, known algorithms of edge detection that are based on the analysis of image brightness function derivatives (Sobel, Kirch, Canny, Marr-Hildreth) were implemented, as well as new solutions (the SUSAN algorithm) were considered.

The original software, developed in the Matlab environment, obtained the point description of edges, the approximation of their routes by means of straight lines, as well as a quality analysis of the obtained results. Tests were performed on 22 objects, which were divided into two groups: typical and atypical ones. The objects were derived from projects in the historical monument inventory scheme. Images were acquired both by means of a direct method (Canon EOS 300D digital camera, provided with Canon EF 14 mm L USM and Canon EF 50 mm L USM lenses), and by means of an indirect method (analogue Rolleiflex 6006 metric camera and PHOTOSCAN-TD scanner).

In order to check the accuracy of the evaluated edges, they were subjected to manual vectorization. Coefficients determining the quantitative and qualitative accuracy of edge detection algorithms at set parameters were calculated. This made it possible to single out optimum detection settings. The calculated coefficients included completeness, correctness, and quality. The binary image received as a result of the edge detection was compared with the image containing information about actual object edges.

The results were put together and, based on them, the optimum edge detection algorithm was selected (Canny). In addition, the percentage amount of automatically gained vectors which may be used in further steps in the photogrammetric process was determined.

Mgr inż. Anna Czechowicz
e-mail: eire02@op.pl
tel. +12 6172302

Dr inż. Sławomir Mikrut
e-mail: smikrut@agh.edu.pl
tel. +12 6172302