

Janusz M. Zieliński

STRATEGIA AUTOMATYZACJI POMIARÓW NA STEREOGRAMACH CYFROWYCH Z ZASTOSOWANIEM METOD KORELACYJNYCH*

Wstęp

Wspomaganie komputerowe pomiaru wykonywanego w obszarze wizji przestrzennej powstającej podczas obserwowania pary zdjęć stereoskopowych podnosi komfort i szybkość pracy operatora oraz zwiększa dokładność wyników i pewność ich poprawności. Obok systemów tworzonych dla uzyskania pełnej automatyzacji pewnych zadań pomiarowych jak orientacja zdjęć czy tworzenie numerycznego modelu powierzchni, powstają strategie automatyzacji cząstkowej procesu pomiarowego prowadzonego przez człowieka, szczególnie dla systemów autografów cyfrowych. Wobec złożoności uwarunkowań związanych ze specyfiką danych obrazowych, dobre wyniki daje połączenie osobowych zdolności percepcji treści obrazu z cechami analitycznymi procedur matematycznych obiektywizujących proces pomiarowy. Uzupełnianie się człowieka - obserwatora i komputera wyposażonego w procedury oparte na dostatecznie szybkich algorytmach daje dobre wyniki przy właściwie zaprojektowanym (ergonomicznym) środowisku pomiarowym. Stosunkowo proste i dzięki temu szybkie realizacyjnie procedury uzyskuje się przy zastosowaniu uproszczonych metod korelacji obrazów cyfrowych.

Stereo-matching jest jedną z najczęściej badanych dziedzin przez naukowców zajmujących się fotogrametrią cyfrową i „widzeniem” komputerowym (*computer vision*). W odniesieniu do poszukiwania dokładnego położenia punktu w przestrzeni 3D, traktuje o technice matching’u, która znajduje punkty homologiczne na dwóch (stereo) lub więcej obrazach (2D) zawierających ten sam obszar przestrzeni. Tradycyjnie, technika matching’u zaliczana jest do dwu grup: opartej na obszarze i opartej na cechach. Ta klasyfikacja odnosi się głównie do strategii, które używane są w odniesieniu do znajdowania przybliżenia finalnego, dokładnego wyniku matching’u. Końcowe wyznaczenie punktu w przestrzeni obiektu uzyskiwane jest zawsze przez matching obszarowy, który może zapewnić dokładność podpixselową.

Podział zautomatyzowanych metod pomiarowych

Zadaniem pomiaru realizowanego przez metody automatyczne jest wybranie punktu (elementu, szczegółu) na jednym obrazie i odszukanie jego odpowiednika na drugim obrazie.

* Praca zrealizowana w ramach projektu KBN: „Dokumentacja zabytków w ramach systemu informacji terenowej z wykorzystaniem kamer niemetrycznych i fotografii cyfrowej”

Procedura ta określana jest pojęciem „matching” (znajdowanie odpowiednika, rozpoznanie podobnej cechy). Odzworowaniu może podlegać obszar grupy pikseli obrazu zarejestrowany w tablicy (ABM - Area Based Matching) lub cecha obrazu (FBM - Feature Based Matching), w tym cecha lokalna (punkt, elementy krawędziowe, krótkie krawędzie lub odcinki, małe regiony) lub też globalna (poligon, złożona struktura). [Heipke, 1996].

Technika matching'u w odniesieniu do pary lub większej liczby obrazów służy rekonstrukcji powierzchni obiektów 3D na podstawie dwuwymiarowych zdjęć. W procesie wykonywania zdjęć pewna część informacji zostaje utracona. Proces odwrotny jest określany jako źle uwarunkowany, gdyż nie gwarantuje istnienia pełnego rozwiązania, rozwiązań jednoznacznych i może być niestabilny wskutek istnienia niewielkich zakłóceń danych. Przyczynami złego uwarunkowania są występujące braki w kompletności odzworowań punktów na obu zdjęciach, występowanie wielokrotnych rozpoznań wskutek powtarzalności struktury obszarów zdjęcia, niestabilność rozwiązań wywołana szumami skanowania, itp. Poprawianie uwarunkowania procesu matching'u odbywa się poprzez wprowadzenie do tego procesu dodatkowych informacji, przy czym zakres klas tej informacji jest stosunkowo szeroki:

- wartości półtonowe pikseli monochromatycznych mogą być uzyskiwane poprzez filtrowanie tym samym lub zbliżonym pasmem spektralnym;
- zmiany oświetlenia obiektu i oddziaływania innych efektów atmosferycznych mogą być zminimalizowane przez wykonywanie zdjęć w przybliżeniu jednocześnie;
- przyjęcie założenia, że obiekty i ich zespoły rejestrowane na zdjęciach cechuje niezmienniczość kształtu i sztywność wewnętrznych relacji geometrycznych;
- powierzchnie obiektów są fragmentami gładkie, nieprzezroczyste i niektóre ich cechy, jak np. rozpraszanie oświetlenia, są powtarzalne na obu zdjęciach;
- wartości początkowe procesu, takie jak zgrubne nałożenie obszarów (lokalne pokrycie) oraz średnie wysokości obiektów, są znane.

W analizowanych poniżej metodach zwłaszcza klasa dodatkowych informacji wymieniona na ostatnim miejscu szczególnie silnie oddziałuje na sprawność algorytmu, a niekiedy wykorzystanie jej jest wręcz koniecznością.

Klasyfikacja metod matching'u dokonywana jest poprzez analizę:

- jakie formy znaków (primitives) są stosowane do rozpoznawania;
- jakie modele (geometryczne czy radiometryczne) służą do rozpoznawania znaków na różnych obrazach;
- jak mierzone jest podobieństwo pomiędzy znakami zidentyfikowanymi na różnych obrazach i jak znajdowane jest optymalne podobieństwo;
- jaka strategia jest stosowana do sterowania algorytmem rozpoznawania.

Generalny podział rodzajów rozpoznawanych znaków wydziela dwie kategorie metod:

- A) metody oparte na rozpoznawaniu znaków będących obszarami (oknami) opisywanymi wartościami zgrupowanych monochromatycznych pikseli;
- B) metody oparte na porównywaniu cech rozpoznanych na każdym zdjęciu oddzielnie.

W obu przypadkach metody mogą być stosowane lokalnie, tj. w odniesieniu do obszarów nie większych niż ok. 50*50 pikseli lub globalnie, w odniesieniu do obszarów większych.

Jedną z metod należących do grupy A zostanie rozwinięta w dalszych punktach. W grupie B jako znaki dla działań lokalnych można wymienić punkty, elementy krawędziowe, odcinki, niewielkie obszary, dla globalnych - poligony i złożone struktury zwykle będące kompleksami elementów wcześniej wymienionych. Znaki te winny posiadać wyraźne cechy wyróżniające je z otoczenia, niezmiennie w odniesieniu do zakłóceń geo- czy radiometrycznych, stabilnie w odniesieniu do szumów informacyjnych i występować w miarę rzadko w analizowanym obszarze.

Każdą cechę charakteryzuje zbiór atrybutów. Głównym atrybutem jest położenie znaku w układzie współrzędnych obrazu. Innymi mogą być - ukierunkowanie krawędzi, wyrazistość krawędzi (gradient jasności pikseli liczony poprzecznie do krawędzi), długość i zakrzywienie krawędzi i grup odcinków, rozmiar i średnia jasność dla obszarów pikseli.

Cechy globalne są zwykle zespołami różnych cech lokalnych. Dochodzą tu atrybuty określające relacje geometryczne lub radiometryczne pomiędzy cechami lokalnymi. Nb. matching pomiędzy globalnymi cechami zwany jest często relacyjnym.

Rezultatem rozpoznawania cech jest lista cech i ich atrybutów dla każdego obrazu. W kolejnym etapie procesu przetwarzaniu / analizie podlegają już tylko takie listy. Cecha jest dyskretną funkcją położenia geometrycznego w układzie współrzędnych (po rozpoznaniu cechy istotne jest czy występuje ona w danym położeniu, czy też nie). Listy cech są uproszczonym opisem zawartości obrazu.

W porównaniu z obszarami pikseli, cechy są zwykle bardziej inwariantne w odniesieniu do zakłóceń geo- i radiometrycznych. Techniki matching'u oparte na rozpoznawaniu cech rozwijają się od początku lat osiemdziesiątych.

Miara podobieństwa w metodach obszarowych jest miarą różnic pomiędzy wartościami odpowiadających sobie pikseli monochromatycznych. Funkcją miary może być kowariancja wartości odpowiadających sobie pikseli, funkcja autokorelacji zastosowana do obszarów pochodzących z dwu obrazów, suma bezwzględnych wartości różnic lub wreszcie suma kwadratów różnic stosowana przez metody najmniejszych kwadratów. Dla metod analizujących podobieństwo cech definicje miary podobieństwa są bardziej złożone. Bazują na atrybutach cech i są zwykle funkcjami kosztów - heurystycznymi lub opartymi na progowaniu. Położenie optymalne wskazuje minimum podanych wyżej miar podobieństwa obszarów lub cech.

Sposób wykorzystywania metod matching'u jest związane silnie ze strategią postępowania. Wyróżnia się w szczególności metody hierarchiczne posługujące się piramidami obrazów dla działań w skali mikro lub makro oraz metody redundancyjne, wykorzystujące zasób informacji nadmiarowej. Metoda redundancyjna może np. wspomagać działania operatora lub algorytm wyszukiwania automatycznego poprzez wykorzystywanie informacji nadmiarowej dla procesu pomiarowego. W procesie automatycznego pozyskiwania DTM wykorzystywanie informacji nadmiarowej, w postaci większej niż jest konieczne liczby punktów, umożliwia filtrowanie nieciągłości takich jak np. budynki. Innym przykładem może być automatyczne utrzymywanie na wysokości powierzchni obiektu znacząca pomiarowego prowadzonego przez operatora w płaszczyźnie XY.

Metody korelacji w przestrzeni dwuwymiarowej

Znane ze statystyki matematycznej metody korelacyjne stosowane w odniesieniu do dwuwymiarowych dyskretnych obiektów, jakimi są obrazy cyfrowe, jest zadaniem stawiającym przed projektantem swoiste wyzwania zwłaszcza, gdy metody te mają być zastosowane w procedurach działających w czasie rzeczywistym. Redundancja informacyjna obrazu cyfrowego z jednej strony i permanentnie złe uwarunkowanie problemu dopasowywania fragmentów zdjęć tego samego obiektu (matching) z drugiej, wymagają stosowania radykalnych kompromisów pomiędzy dążeniem do ograniczenia liczby danych wejściowych a koniecznością wzbogacenia informacji wejściowej w celu poprawienia uwarunkowania postawionego zadania.

Wszystkie algorytmy korelacji cyfrowej opierają się na kryteriach podobieństwa pomiędzy dwoma rozpoznawanymi (analizowanymi) obrazami. Jednym z takich kryteriów jest powierzchnia pod iloczynem dwóch obrazów, jako funkcja względnego przesunięcia przestrzennego pomiędzy nimi. Ta szczególna definicja korelacji $r(x,y)$ pomiędzy dwoma podobnymi obrazami $f_1(x,y)$ i $f_2(x,y)$, jest określona jako:

$$r(x,y) = f_1(x,y) \otimes f_2(x,y) = \iint_{-\infty}^{\infty} f_1(x',y') f_2(x+x',y+y') dx' dy' \quad [\text{Schwengerdt, 1983}]$$

Jeśli f_1 i f_2 są dostatecznie podobne, wyjąwszy względne przesunięcie przestrzenne, powyższe równanie winno dać rozwiązanie w postaci maksimum $r(x,y)$ w punkcie najlepszego przylegania. Znaczne zmiany średniego poziomu obrazu w okolicy obszaru korelowania mogą jednak wprowadzać fałszywe ekstrema. Definicja miary podobieństwa, która jest mniej czuła na średni poziom, może być zaproponowana np. jako suma bezwzględnych różnic:

$$r(x,y) = \iint_{-\infty}^{\infty} |f_1(x',y') - f_2(x+x',y+y')| dx' dy' \quad [\text{Schwengerdt, 1983}]$$

Ponieważ obliczanie korelacji jest kosztowne dla dużych obszarów, stosowane są relatywnie małe obszary wybrane z pełnego obszaru pokrycia. Obszary te są na tyle małe aby różnice geometryczne pomiędzy obrazami nie uniemożliwiały przeprowadzenia korelacji pomiędzy nimi.

Transformata Fouriera wyrażenia korelacji tworzy wynik podobny do transformaty spłotu, tj. widmo korelacji wzajemnej:

$$R(u_x, u_y) = F1(u_x, u_y) F2^*(u_x, u_y)$$

Z faktu, że żadna z funkcji f_1 , f_2 nie jest odwrócona w wyrażeniu korelacji, wynika iż zespolona funkcja F_2 występuje w postaci sprzężonej. Prostota wzoru transformaty w porównaniu z wyrażeniem korelacji wskazuje pozornie obliczeniową przewagę reprezentacji w przestrzeni Fouriera. Równanie to jednak jest rzadko używane w praktyce do korelacji fragmentów obrazów. Prostota reprezentacji transformaty Fouriera dla spłotu i korelacji jest często dodatkiem do globalnych analiz matematycznych obrazów, natomiast operatory dostosowania są często bardziej efektywnie implementowane komputerowo w dziedzinie przestrzennej.

Metody korelacji wzajemnej obrazów oparte są na pojęciach rachunku prawdopodobieństwa. Teoretyczną miarą zależności (korelacji) pomiędzy zmiennymi losowymi jest współczynnik korelacji ρ zdefiniowany dla dwuwymiarowej zmiennej losowej (X, Y) jako stosunek mieszanego momentu centralnego (kowariancji) tej zmiennej do pierwiastka z iloczynu momentów centralnych drugiego rzędu (wariancji):

$$\rho = \frac{\text{cov}(X, Y)}{[\text{var}(X) \text{var}(Y)]^{1/2}}$$

Korelacja byłaby doskonała, gdyby dwa przeszukiwane obrazy były duplikatami tego samego zdjęcia. Jeżeli stosunek bazowy (iloraz bazy i odległości fotografowania) zwiększa się, to instrumentalny system korelacji jest mniej efektywny i może się stać zupełnie niesprawny [Sitek, 1991]. Istnienie lokalnych różnic pomiędzy obrazami stereogramu w postaci paralaks i przesunięć radialnych oraz afinizmów i obrotów wzajemnych powoduje potrzebę ograniczenia zakresu porównywanych obszarów tak, by zbyt duże odchylenia nie uniemożliwiły automatycznego porównania.

Praktyczne zastosowanie definicji współczynnika korelacji wymaga jego przekształcenia do formy dyskretnej, właściwej dla dyskretnego charakteru obrazów cyfrowych składających się z pikseli, których wartości, odpowiadające cechom radiometrycznym obrazów, będą porównywane. Dla uproszczenia zakłada się, że analizowane obrazy są monochromatyczne, czyli wartość piksela reprezentuje poziom jasności elementu obrazu.

W celu obliczenia korelacji, na jednym obrazie jest wybierany obszar okna $N \times N$ i obszar poszukiwania $M \times M$, gdzie $M > N$, na drugim. Korelacja jest wykonywana pomiędzy oknem i obszarem wyszukiwania, w centrum obszaru wyszukiwania $L \times L$, gdzie $L = M - N + 1$. Obliczenia korelacji dla wszystkich L^2 możliwych przesunięć wymagają wykonania $N^2 L^2$ operacji. Oczywiście okno i obszar poszukiwań nie muszą być kwadratowe, jedynie obszar poszukiwań musi być większy od okna.

Traktując obrazy jako realizacje zmiennej losowej (odpowiednio X - lewy obraz, Y - prawy), o charakterze dyskretnym, cyfrowym, możemy stosować odpowiednie przekształcenie wzoru określającego teoretyczny współczynnik korelacji jako miarę podobieństwa obrazów lub ich fragmentów. Wprawdzie poszukiwane przesunięcie pomiędzy obrazami jest wektorem dwuwymiarowym na płaszczyźnie, jednak przestrzeń wyszukiwania może być przestrzenią jednowymiarową, gdy przyjmie się kryterium podobieństwa niezależne od wzajemnego rozlokowania pikseli obrazu. Niektóre miary podobieństwa nie spełniają tego warunku, lecz tu dla prostoty zapisu możemy przyjąć:

$$r(k) = \frac{[\sum f_1(m) f_2(k+m) - M F_{1k} F_{2k}]}{S_{1k} S_{2k}}$$

gdzie M - liczba pikseli porównywanych fragmentów obrazów,

$$S_{1k} = \left| \left[\sum f_1^2(m) \right] - M F_{1k}^2 \right|^{1/2}, \quad S_{2k} = \left| \left[\sum f_2^2(k+m) \right] - M F_{2k}^2 \right|^{1/2},$$

$$F_{1k} = \left[\sum f_1(m) \right] / M, \quad F_{2k} = \left[\sum f_2(k+m) \right] / M$$

a wszystkie sumowania bieżą dla $m = 1, \dots, M$.

Wartość k dla której $r(k)$ przyjmuje wartość maksymalną jest uznawana za rozwiązanie, a odpowiadające jej przemieszczenie (i, j) jest poszukiwanym wynikiem. Wcześniejsze przetworzenie:

$$f_1^{\wedge} = (f_1 - F_1) / S_1, \quad f_2^{\wedge} = (f_2 - F_{2,k}) / S_{2,k}$$

normalizujące obrazy co do wartości średniej ($F_1^{\wedge} = 0, F_{2,k}^{\wedge} = 0$) i co do współczynnika proporcjonalnego do wariancji ($S_1^{\wedge 2} = 1, S_{2,k}^{\wedge 2} = 1$), jeszcze bardziej upraszcza zapis korelacyjnego kryterium podobieństwa dla standaryzowanych $f_1^{\wedge}, f_2^{\wedge}$:

$$r(k) = \sum f_1^{\wedge}(m) f_2^{\wedge}(k+m)$$

Należy zauważyć, że o ile F_1 jako niezależne od k jest stałe i może być obliczone jednokrotnie, o tyle $F_{2,k}$ zależy od przesunięcia k , wobec tego normalizacja cząstkowa obrazu f_2 powinna być wykonywana oddzielnie dla każdego sumowania $r(k)$. W przypadkach, w których ostatnio podany zapis kryterium podobieństwa będzie modyfikowany w kierunku uzależnienia od wzajemnego położenia pikseli stosuje się jego formę odpowiednią dla dwuwymiarowej przestrzeni poszukiwań:

$$r(i,j) = \sum \sum f_1^{\wedge}(m,n) f_2^{\wedge}(i+m,j+n)$$

Strategie automatyzacji korelacji wzajemnej fragmentów obrazów cyfrowych

Poprzez strategię automatycznego dopasowywania fragmentów obrazów należy rozumieć wybór, czy też konstrukcję miary korelacji lub zespołu tych miar, dobór parametrów zastosowanych miar oraz sposób przemieszczania położenia okna wzorcowego w obszarze wyszukiwania.

W poprzednim punkcie przedstawiono dwie dyskretne miary korelacyjne dla fragmentów obrazów cyfrowych. Pierwsza została sformułowana w oparciu o teoretyczny wzór współczynnika korelacji i określana jest mianem normalizowanego współczynnika korelacji wzajemnej NCC (Normalized Cross-Correlation). Uniezależnia ona obliczaną wartość współczynnika od lokalnych zmian jasności i kontrastu fragmentów obrazów. Podana postać wzoru jest określana również jako FNCC (Fast Normalized Cross-Correlation) z uwagi na zapis wyrażen wariancji i kowariancji dla obliczonych wcześniej wartości średnich co zmniejsza liczbę odejmowań o $4*(M-1)$ (Changming Sun [2] i Lewis [12]).

Druga przedstawiona miara, wymagająca wstępnego przetworzenia normalizującego obrazy, pomimo prostoty zapisu nie wpływa w sposób istotny na liczbę obliczeń w odniesieniu do FNCC.

Duża liczba koniecznych obliczeń, uniemożliwiająca działania w czasie rzeczywistym, prowadzi do poszukiwania miary uproszczonej, w konsekwencji tego mniej dokładnej, lecz znacznie szybszej. Pierwszym uproszczeniem dla drugiej miary może być jednorazowa normalizacja całego obszaru wyszukiwania na obrazie f_2 . Zakłada się w ten sposób stałość takich cech radiometrycznych całego obszaru wyszukiwania jak średnia jasność i średni kontrast. Kolejne radykalne uproszczenie to zastosowanie drugiej miary z pominięciem normalizacji, a więc w stosunku do obrazów oryginalnych. Jest to jednoznaczne z dalszym rozszerzeniem tych samych założeń co poprzednio.

Powszechna krytyka miary korelacyjnej stosowanej do dopasowywania obrazów dotyczy wielkiej liczby obliczeń, które muszą być realizowane, jeżeli okno i obszar wyszukiwania jest duży. Stosując miarę korelacyjną nie można podjąć decyzji, dopóki

nie zostanie obliczona tablica korelacji $r(i,j)$ dla wszystkich (i,j) . Co więcej, liczba obliczeń $r(i,j)$ jest taka sama dla wszystkich niedopasowań. Te wady standardowej miary korelacji prowadziły do poszukiwań sekwencyjnego algorytmu, który mógłby zapewnić estymację niedopasowania przy mniejszej liczbie obliczeń [Pratt, 1978].

Metodę sekwencyjnego badania zaproponowali Barnea i Silverman [Barnea, Silverman, 1972]. Zasadniczy zapis tego algorytmu jest nadspodziewanie prosty. Błąd

$$\epsilon_s(i,j) = \sum_m \sum_n |F_1(m,n) - F_2(m+i,n+j)|$$

jest akumulowany dla kolejnych wartości pikseli w obszarze okna. Jeśli błąd przekroczy określoną wcześniej wartość graniczną zanim wszystkie $I \cdot J$ punktów w obszarze okna zostaną sprawdzone, przyjmuje się, że sprawdzenie dało wynik negatywny dla danego okna i przystępuje się do sprawdzania kolejnego okna. Jeśli błąd narasta powoli, wówczas liczba punktów sprawdzonych do momentu przekroczenia limitu jest odnotowywana jako parametr sprawdzenia okna. Wreszcie, kiedy wszystkie okna zostały sprawdzone, okno, które otrzymało największą wartość parametru zostaje uznane za właściwie dopasowane. Najwyższa możliwa wartość parametru jest równa liczbie punktów okna $M \cdot N$. Należy odnotować, że tylko relatywnie niewielka liczba obliczeń jest konieczna dla okien cechujących się znacznym niedopasowaniem.

Istnieją różne rozszerzenia sekwencyjnego algorytmu sprawdzania, które zostały opracowane dla przyspieszenia i podniesienia niezawodności. Naturalnym rozszerzeniem jest hybrydowy system stosujący sekwencyjny algorytm sprawdzania do odrzucania znacznych niedopasowań a następnie realizujący miarę statystyczną korelacji dla pozostałych sprawdzanych punktów. Taki system może zapewnić połączenie użyteczności miary statystycznej korelacji z szybkością sprawdzania sekwencyjnego.

Technikę która znacząco zwiększa szybkość korelacji w dziedzinie przestrzennej opisali Barnea i Silverman, z powodzeniem zastosował do obrazów z Landsata Bernstein (1976). Ten algorytm sekwencyjnie wykrywający dopasowanie (SSDA - Sequential Similarity Detection Algorytm) używa niewielkiej liczby pikseli wybranych losowo z obszaru okna i obszaru poszukiwań do szybkiego odnalezienia przybliżonego punktu dopasowania, uzupełnianego następnie pełnymi obliczeniami używającego wszystkich pikseli okna dla precyzyjnego dopasowania [Schowengerdt, 1983].

Ogólnie, liczba obliczeń korelacji zwiększa się z rozmiarem N okna. Z drugiej strony N musi być dostatecznie małe dla zapobieżenia obecności znaczących wewnętrznych dystorsji wewnątrz obszaru okna. Okno 51 na 51 pikseli było pokazane przez Bonruda i Hendriksona (1974) do usunięcia średnich błędów dopasowania od jednej czwartej do jednej drugiej piksela pomiędzy dwoma obrazami Landsata MSS z różnych przelotów (tamże).

Dokładność dopasowania metodami korelacji może się znacznie zmieniać przy przejściu pomiędzy obszarami z uwagi na różnice kontrastu i szczegółów. Filtry uwydatniające krawędzie mogą być użyte w technice wstępnego przetworzenia dla poprawienia jakości korelacji [Pratt, 1978].

Wspomniana modyfikacja miary SSDA polegała m.in. na losowej redukcji porównywanych pikseli w obszarze okna. Niezależnie od tej strategii stosowane są powszechnie inne polegające na zredukowaniu liczby obliczeń miary podobieństwa obrazów w obszarze okna wyszukiwania. Pomiary wykonywane w sytuacji, gdy znane są elementy orientacji wzajemnej obrazów tworzących stereogram, mogą być ograniczone do miejsc

tworzących linie o znanym położeniu na zdjęciach. Metody resamplingu oparte na wyszukiwaniu współrzędnych na podstawie równań kolinearności noszą nazwę metod parametrycznych. Per analogiam omawiane tutaj metody będą nazywane strategiami parametrycznymi korelacji obrazów.

Teoria płaszczyzny rdzennej i promieni rdzennych pozwala na obliczenie w obszarze wyszukiwania położenia prostej, na której leży poszukiwane rozwiązanie odpowiadające obszarowi okna, a więc wybranemu punktowi pierwszego obrazu. Znajomość położenia takiej linii redukuje wymiar problemu wyszukiwania odpowiedników obszarów z dwu wymiarów do jednego [Cho, Shenk, Madani, 1992]. Liczba wartości miary podobieństwa koniecznych do obliczenia maleje tak bardzo, że staje się możliwa rozbudowa algorytmu wyszukiwania czasu rzeczywistego w celu zwiększenia jego dokładności i pewności. Praktyczna metoda oparta o teorię zdjęć ekwiwalentnych pozwalająca na zbudowanie parametrycznej strategii wyszukiwania na zdjęciach nieprzetworzonych została podana w pozycji [Zieliński, 1997].

Inną jednowymiarową strategię parametryczną można zbudować w oparciu o układ odniesienia 3D, zdefiniowany w procesie orientacji bezwzględnej stereogramu. Dla stereogramu lotniczego można ustalić współrzędne sytuacyjne X i Y, a następnie zmieniając współrzędną Z poszukiwać odpowiadających sobie obszarów na obu zdjęciach. Cechą tej strategii nazywanej VLL (Vertical Line Locus) są zmienne okna na obu obrazach [Kraus, 1992]. W tej ostatniej metodzie, jak i w innych postuluje się wstępne przetworzenie porównywanych obrazów operatorem Laplace'a lub podobnym, pełniącym zadanie filtru górnoprzepustowego uwydatniającego krawędzie szczegółów w treści obrazów.

Procedury implementowane w autografie cyfrowym VSD

Wspomaganie komputerowe procesu pomiaru w autografie cyfrowym VSD realizowane jest w kilku trybach pomiarowych. Różnią się one stanem orientacji stereogramów, celem pomiaru, oraz poziomem automatyzacji. Wspólną cechą tych trybów jest uzyskiwanie dokładności podpikselowych w stosunku do pikseli obrazu pierwotnego przy wyszukiwaniu prowadzonym na ekranowych powiększeniach obrazu.

Chronologicznie pierwszy wspomagany tryb pomiarowy ma miejsce podczas pomiaru punktów homologicznych dla orientacji wzajemnej i jest półautomatyczną strategią nieparametryczną dwuwymiarową. Przed uruchomieniem procedury wyszukiwania operator autografu musi ustawić znaczniki pomiarowe odpowiednio na lewym i prawym zdjęciu w pobliżu punktów homologicznych (z dokładnością ok. 25 pikseli ekranowych) oraz wybrać czy wyszukiwanie ma się odbywać na lewym, czy prawym obrazie (klawisz Tab). Po uruchomieniu procedury wyszukiwania (klawisz F9), która trwa do kilku sekund, operator musi ocenić, czy poszukiwanie zakończyło się powodzeniem. Ocena ta wykonywana jest wzrokowo i polega na porównaniu ustawienia kursorów względem tego samego szczegółu treści obrazu. Wykrycie sytuacji niepowodzenia nie następuje zwykle trudnościami, gdyż w takim przypadku zwykle położenie kursorów różni się znacznie od oczekiwanego. Innym kryterium odrzucenia niepowodzenia może być ocena poziomu wartości współczynnika autokorelacji dla znalezionej rozwiązania. Strategia tego trybu jest oparta na kryterium podobieństwa zaproponowanym przez Barne'ę i Silvermana z sekwencyjną akumulacją błędów i miarą obliczaną dla obrazów nieprzetworzonych.

Drugi tryb wspomagania wymaga istnienia prawidłowej orientacji wzajemnej stereogramu i uruchomienia autogrametrycznego trybu sterowania. Jest półautomatyczną

Komentarz [JMZ1]:

strategią parametryczną jednowymiarową opartą tym samym kryterium podobieństwa jak poprzednio i realizowaną na promieniu rdzennym drugiego obrazu odpowiadającym wskazanemu punktowi na pierwszym obrazie. Dla uniknięcia zgubienia rozwiązania poszukiwania spowodowanego zaokrągleniami dyskretyzacji lub niedokładnościami orientacji wzajemnej, poszukiwania są prowadzone również na liniach przechodzących przez piksele położone w najbliższym sąsiedztwie linii wyznaczonej przez promień rdzenny.

Ustawienie zgrubne kursorów, uruchomienie procedury wyszukiwania i ocena powodzenia wykonywane są przez operatora w sposób opisany powyżej. Dzięki sterowaniu w układzie odniesienia 3D łatwiejsze jest wstępne ustawianie kursorów kombinacją przesunięć sytuacyjnych i przesunięcia wysokościowego.

Trzeci tryb wspomagania ma charakter automatyczny z ręczną korekcją w przypadku utracenia nawiązania pomiędzy obrazami. Jest strategią parametryczną jednowymiarową z kontrolą poprawności dostosowania i dołączaniem dodatkowych kryteriów podobieństwa. Jakość wspomagania zależy tu jeszcze silniej niż dla poprzednich trybów od treści obrazów, struktury szczegółów i odkształceń geometrycznych.

Przytoczone w niniejszym artykule kryteria podobieństwa obrazów przeznaczone są przede wszystkim do pomiarów na obrazach monochromatycznych. Niestety, w przypadku palety barwnej realizacja funkcji autokorelacji jest trudniejsza. Przestrzeń wartości piksela jest tu przestrzenią trójwymiarową i typowe metody autokorelacyjne wymagają sprowadzenia wartości piksela barwnej do przestrzeni jednowymiarowej - monochromatycznej. O ile obraz barwny typu True Color przetransformowany do postaci monochromatycznej:

$$a R + b G + c B = S$$

gdzie składowe barwy R, G i B oraz wypadkowa wartość jasności monochromatycznej S należą do przedziału [0,255] nadaje się wprost do analizy funkcją współczynnika autokorelacji 2D ew. funkcją semi-autokorelacji (tj. z zastosowaniem uproszczonego, szybkiego w sensie obliczeniowym współczynnika) o tyle obrazy indeksowane paletą o nieokreślonym następie barw wymagają odpowiedniego przygotowania.

Wizualizacja jednoczesna dwóch obrazów barwnych indeksowanych wymaga uzgodnienia ich palet prowadzącego do wypracowania wspólnej palety ekranowej - kompromisowej dla optymalnego wyświetlania obu obrazów. Istniejący w VSD algorytm początkowo sumuje - zestawia obok siebie obie palety, redukuje ewentualne wspólne barwy, a następnie analizując tablice frekwencji pikseli obrazu o jednakowych barwach, redukuje kolejno najslabiej reprezentowane pozycje aż do osiągnięcia liczby pozycji palety równej 248 (256-8). Zmniejszenie liczby pozycji o osiem jest konieczne z uwagi na barwy przeznaczone do wizualizacji warstwy wektorowej oraz na czarną barwę tła, która nb. musi zajmować najniższą pozycję w paletce ekranowej.

W trakcie opisanej wyżej redukcji barw budowane są tablice kodujące dla zamiany kodów barw z oryginalnych zarejestrowanych palet indeksowanych obrazów na kody barw ekranowych. Aby umożliwić zastosowanie metody autokorelacyjnej dla pary obrazów z paletami indeksowanymi powyższy algorytm doboru tablic kodujących uzupełniono procedurą porządkującą pozycje barw palety ekranowej wg. wartości luminancji S poszczególnych barw obliczonych zgodnie z podanym wzorem oraz o procedurę transformującą zmiany uporządkowania palety ekranowej na odpowiednie zmiany w tablicach kodujących kolory dla obu obrazów stereogramu.

Opisywane modyfikacje nie zmieniają cech obrazu na ekranie, a jednocześnie umożliwiają zastosowanie funkcji szacującej współczynnik autokorelacji odpowiadających sobie fragmentów obrazów w odniesieniu do wartości pikseli ekranowych, których następstwo wartości cechuje porządek narzucony przez luminancję, czyli monochromatyczną jasność pikseli obrazów.

Sprawdzenie zmodyfikowanego w powyższy sposób algorytmu wizualizacji obrazów barwnych na szeregu stereogramach barwnych wykazało jego skuteczność i cechy operacyjne zbliżone do działania na obrazach monochromatycznych.

Literatura

1. Barnea D.I., Silverman H.F., *A class of algorithms for fast image registration*, IEEE Transaction of Computers, 1972
2. Changming Sun, *A fast stereo matching method*, Digital Image Computing T & A, Massey University, Auckland, New Zealand 1997 (www.dms.csiro.au/~changs/st...ngdicta97a/matching-dicta97a.html)
3. Cho W ., Schenk T., Madani M., *Resampling digital imagery to epipolar geometry*, International Archives of Photogrammetry and Remote Sensing, Commission III, ISPRS XVIIth Congress, Washington 1992
4. Dare P.M., *A brief history of registration*, University College London, 1997/98 (www.ge.ucl.ac.uk/~pdare/work/registration.html)
5. Heipke Ch., *Overview of image matching techniques*, Uniwersytet Techniczny w Monachium, WWW-DGR-PHOT, 26.04.1996, (dgrwww.epfl.ch/PHOT/publicat/wks96/Art_3_1.html)
6. Hellwig Z., *Elementy rachunku prawdopodobieństwa i statystyki matematycznej*, PWN, Warszawa 1975
7. Jachimski J., *Video Stereo Digitizer - a small digital Stereophotogrammetric Working Station for the needs of SIT and other application*, Geodesy, Phtogrammetry and Monitoring of Environment, Geodezja 38, 1995, PAN Oddział Kraków, Prace Komisji Geodezji i Inżynierii Środowiska
8. Jachimski J.J., Zieliński J.M., *Digital stereoploter for historic monuments recording*, International Archives of Photogrammetry and Remote Sensing, Commission V, ISPRS XVIIIth Congress,
9. Kraus K., *Photogrammetry*, Ferd. Dümmler's Verlag, Bonn 1992
10. Krupnik A., Schenk T., *Predicting the reliability of matched points*, ASPRS/ACSM 1994, (www.sgi.ursus.maine.edu/gisweb/spatdb/acsm/ac94038.html)
11. Lemmens M., *A survey on stereo matching techniques*, International Archives of Photogrammetry and Remote Sensing, Commission V, ISPRS XVIIIth Congress, Vienna, Austria 1996

12. Lewis J.P., *Fast normalized cross-correlation*, Industrial Light & Magic (www.idiom.com/~zilla/Papers/nvisionInterface/nip.html)
13. Pratt W.K., *Digital Image processing*, John Wiley & Sons, New York 1978
14. Schowengerdt R.A., *Techniques for image processing and classification in remote sensing*, Academic Press Inc. 1983
15. Sitek Z., *Fotogrametria ogólna i inżynierska*, PPWK, Warszawa-Wrocław 1991
16. Zieliński J.M., *Internal structure of the VSD program, Geodesy, Photogrammetry and Monitoring of Environment*, Geodezja 38, 1995, PAN Oddział Kraków, Prace Komisji Geodezji i Inżynierii Środowiska
17. Zieliński J.M., *Analiza metod podwyższania dokładności pomiaru stereoskopowego na obrazach cyfrowych*, Zeszyty Naukowe AGH, Geodezja tom 3, 1997

Recenzował: dr inż. Krystian Pyka