

Dopasowanie chmur punktów do powierzchni dla potrzeb przetwarzania i analizy obrazów medycznych oraz systemów wizyjnych

Streszczenie. W artykule przedstawiono metodę dopasowania chmur punktów do powierzchni na przykładzie zagadnienia konstrukcji danych uczących w algorytmie ASM w zastosowaniu do segmentacji danych tomograficznych dla potrzeb planowania leczenia radioterapeutycznego. Zaproponowany algorytm składa się z 3 etapów: generacji chmur punktów dla danych uczących, sztywnego dopasowania (rotacji, przesunięcia) z wykorzystaniem ICP oraz lokalnej korekty wyników. Cała metodologia została przetestowana, a skuteczność oceniona na podstawie odległości punktów charakterystycznych w danych po dopasowaniu.

Abstract. This paper addresses a problem of automatic point clouds matching in context of training data construction in Active Shape Model algorithm. An algorithm was applied to CT data segmentation for radiotherapy planning. Proposed methodology consists of 3 steps: point clouds generation, rigid matching (rotation, translation) based on ICP and local corrections of points location. Algorithm was tested and validated using distance between points in data after matching. **Point clouds matching for medical image processing, analysis and vision systems.**

Słowa kluczowe: dopasowanie chmur punktów, dopasowanie obrazów, tomografia komputerowa, ICP, ASM.

Keywords: point clouds matching, image registration, Computed Tomography, ICP, ASM.

doi:10.12915/pe.2014.05.38

Wstęp

Zagadnienie dopasowania chmury punktów (ang. *points cloud*) do powierzchni, chmury lub samego obrazu jest zagadnieniem niezwykle istotnym w laserowych systemach pomiarowych, systemach wizyjnych czy też w przetwarzaniu i analizie obrazów. Punkty pomiarowe w przestrzeni 2D/3D zwykle są generowane przez zewnętrzne urządzenia pomiarowe. Innym źródłem są punkty wygenerowane na podstawie danych obrazowych (stereowizja, algorytmy rekonstrukcji powierzchni, ręczne obrysy struktur anatomicznych wykonywane na obrazach medycznych, skanery optyczne) [1-3].

W prezentowanej pracy proces dopasowania będzie analizowany pod kątem generowania punktów charakterystycznych dla zbiorów testowych, wykorzystujących model PDM (ang. *Point Distribution Model*) w kontekście segmentacji obrazowych danych medycznych dla potrzeb radioterapii nowotworu prostaty.

Jako inny przykład tego samego zagadnienia można podać problem segmentacji danych tomograficznych dla potrzeb modelowania struktury serca czy też planowania leczenia radioterapeutycznego [4-5]. W przypadku radioterapii, jednym z pierwszych etapów procesu jest planowanie leczenia.

Przed rozpoczęciem planowania, pacjent ma wykonywane badanie tomograficzne, na którym lekarz obrysowuje struktury zajęte zmianą nowotworową oraz te, które powinny być przed promieniowaniem chronione. Przykładowo, dla pacjentów z nowotworem prostaty lekarz obrysowuje prostatę i ewentualnie pęcherzyki nasienne (struktury napromieniane) oraz głowy kości udowych, pęcherz i odbytnicę, które powinny być chronione [6-8]. Proces ten jest czasochłonny. Wskazanie granicy pomiędzy niektórymi strukturami w trójwymiarowych danych tomograficznych nie jest zadaniem trywialnym. Ze względu na niewielkie różnice w wartościach przypisanych do prostaty i pęcherza powstaje problem dokładnego wskazania wspomnianej granicy pomiędzy tymi strukturami.

Jednym z możliwych rozwiązań jest wykorzystanie automatycznych algorytmów segmentacji. W przypadku danych medycznych, ze względu na charakter danych i problemy w nich występujące, konieczne jest zwykle stosowanie algorytmów wykorzystujących wiedzę *a priori* o wyodrębnianych strukturach. Dostarczenie dodatkowych informacji o geometrii, rozkładzie wartości w ramach

struktur znacząco zwiększa skuteczność półautomatycznej lub automatycznej segmentacji.

Jedną z często stosowanych metod w kontekście segmentacji struktur promieniowrażliwych oraz tych, do których powinna być dostarczona dawka terapeutyczna (np. [4,5]), są algorytmy wykorzystujące technikę aktywnych modeli kształtu (ang. *Active Shape Model*, ASM) [9] lub wyglądu (ang. *Active Appearance Model*, AAM) [10].

Aktywne Modele Kształtu i Wyglądu


ASM i AAM są metodami ekstrakcji wiedzy [9,10] umożliwiającymi wydobywanie informacji z przykładów (danych treningowych) na drodze uczenia. Aktywny model kształtu w wyniku zwraca informację o średnim kształcie obiektu danego typu (np. twarzy, struktury anatomicznej itd.) oraz dane zawierające informację o zmienności tego modelu zaobserwowane w zbiorze uczącym.

W procesie segmentacji model w iteracyjnym procesie jest modyfikowany w taki sposób, aby dostosować się do rzeczywistego kształtu obiektu reprezentowanego w danych, jednocześnie zapewniając uniknięcie nienaturalnych (nie zaobserwowanych w zbiorze uczącym) deformacji. Sam model tworzy się poprzez zbudowanie wzorców obiektów (wektorów przypisanych do punktów w danych uczących wraz z cechą charakteryzującą dany punkt np. poprzez rozkład wartości) reprezentujących obiekt. W ten sposób otrzymujemy zbiór kształtów uczących, zapisanych w postaci wektorów zawierających współrzędne punktów charakterystycznych. Szczegóły algorytmu można znaleźć w [9].

Głównym problemem występującym w tym podejściu jest konieczność zapewnienia odpowiedniości elementów wektorów w danych uczących. Innymi słowy, kolejność zapisu punktów w wektorze musi być zgodna w każdym danych uczących. O ile w przypadku dwuwymiarowym istnieje możliwość ręcznego wskazania punktów, to w przypadku trójwymiarowym, którego dotyczy artykuł, jest to praktycznie niemożliwe. Co więcej proces ten jest bardzo czasochłonny.

W artykule przedstawiono metodę automatycznego generowania punktów (wektorów) uczących wraz z zapewnieniem odpowiedniości punktów. W prezentowanym podejściu sprowadza się to rozwiązania problemu dopasowania chmury punktów do powierzchni. Rozwiązanie to może zostać wykorzystane również w przypadku zagadnień technicznych np. rozpoznawanie

tworzy, dopasowanie danych pomiarowych z laserowych skanerów do modelu obiektu, czy też dopasowanie modeli CAD.



Rys.1. Schemat ideowy generacji chmury punktów. $T_1 - T_N$ transformacje (pola deformacji) umożliwiające mapowanie obrazów uczących do obrazu uśrednionego. Opis w tekście

Generowanie chmury punktów

Chmura punktów może zostać automatycznie wygenerowana np. przez wspomniane laserowe systemy skanujące. W przypadku danych obrazowych konieczne jest wyznaczenie punktów na podstawie obrazów. W prezentowanej pracy zaproponowano generację punktów zgodnie z ideą przedstawioną na rysunku 1 [4].

Na podstawie N trójwymiarowych obrazów oraz powiązanych do nich ręcznych obrysów (w tym wypadku wykonanych przez lekarzy) wyznaczany jest średni obraz tomograficzny, z wykorzystaniem metod dopasowania obrazów. W pierwszej kolejności wykonywane jest jednoczesne dopasowanie N obrazów (ang. *Groupwise registration*) [11]: każdy z obrazów jest dopasowywany do jednego układu współrzędnych przez wyznaczenie transformacji T_i .

Jako model transformacji przyjęto złożenie transformacji lokalnej i globalnej:

$$(1) \quad \mathbf{T}(x, y, z) = \mathbf{T}_{local}(\mathbf{T}_{global}(x, y, z))$$


gdzie \mathbf{T}_{global} oznacza transformację afiniczną natomiast \mathbf{T}_{local} model deformacji wykorzystujący funkcje B-sklejane (2) [12]. Transformacja afiniczna pozwala skompensować globalne różnice w ułożeniu pacjenta, natomiast funkcje sklejane – lokalne deformacje pomiędzy obrazami:

$$(2) \quad \mathbf{T}_{local}(x, y, z) = (x, y, z) + \sum_{l=0}^3 \sum_{m=0}^3 \sum_{n=0}^3 B_l(u) B_m(v) B_n(w) \Gamma_{i+l, j+m, k+n}$$

gdzie Γ reprezentuje $n_x \times n_y \times n_z$ równomierną siatkę punktów kontrolnych $\varphi_{i,j,k}$, $i = \lfloor x/n_x \rfloor - 1$, $j = \lfloor y/n_y \rfloor - 1$, $k = \lfloor z/n_z \rfloor - 1$, $u = x/n_x - \lfloor x/n_x \rfloor$, $v = y/n_y - \lfloor y/n_y \rfloor$, $w = z/n_z - \lfloor z/n_z \rfloor$. B_l jest l -tą sześcienną B-sklejaną funkcją bazową.

Wyznaczone transformacje T_i wykorzystano do mapowania obrysów struktur do jednego układu współrzędnych. W wyniku tej operacji powstała mapa

prawdopodobieństwa przynależności wokseli do poszczególnych struktur. Stosując wartość progową równą 0.8 wygenerowano średnie modele struktur (maski binarne, 1 - struktura, 0 - tło).



Rys. 2. Głowa kości udowej z wygenerowanymi punktami na powierzchni struktury

Na podstawie tak przygotowanych masek konieczne jest wyznaczenie punktów (siatki) rozłożonych na powierzchni struktury. Punkty mogą zostać wyznaczone poprzez równomierne próbkowanie powierzchni (rys. 2) (ten wariant zastosowano w pracy), na podstawie punktów charakterystycznych lub np. krzywizny.

Wyznaczona chmura punktów musi zostać przeniesiona na dane uczące z zachowaniem jednakowej liczby oraz zgodności punktów w każdym zbiorze danych.

Dopasowanie chmury punktów do powierzchni

W celu dopasowania chmury punktów wygenerowanych z modelu średniego do obrysów w danych uczących zaproponowano wykorzystanie trójstopniowej procedury:

- generacja chmur punktów w danych uczących,
- sztywne dopasowanie z wykorzystaniem iteracyjnej metody najbliższego punktu (ang. *Iterative Closest Point ICP*) [13], wykorzystującej metodologię Procrusta [14,15],
- lokalna korekcja położenia punktów z wykorzystaniem k -najbliższych sąsiadów (ang. *k-nearest neighbors*) [16].

W prezentowanym podejściu chmura punktów uczących została wygenerowana na podstawie masek binarnych przedstawiających struktury anatomiczne powstałe w wyniku ręcznych obrysów wykonanych przez lekarza. Na podstawie tak przygotowanych danych wyznaczono siatki metodą maszerujących sześcianów (ang. *marching cubes*) [17]. W konsekwencji otrzymano reprezentację wierzchołki-wielokąty (ang. *verices-faces*), wykorzystaną w dalszej części algorytmu.

W celu przeniesienia chmur (siatek) do wspólnego układu współrzędnych wykorzystano iteracyjną metodę najbliższego punktu, przeprowadzającą sztywne dopasowanie umożliwiające wyznaczenie macierzy rotacji \mathbf{R} , wektora translacji \mathbf{T} oraz współczynnika skalowania s . Wskaźnik błędu dopasowania można zdefiniować jako:

$$(3) \quad \varepsilon = s\mathbf{AR} + i\mathbf{T}^T - \mathbf{B}$$

gdzie \mathbf{A} i \mathbf{B} są macierzami o wymiarach $(p \times l)$, i -wektor jednostkowy $(p \times 1)$. Wyrażenie (3) można uzupełnić o czynniki ważące (WEOP - ang. *Weighted Extended Orthogonal Procrustes Analysis*) [15]:

$$(4) \quad \varepsilon' = \text{tr} \left((s\mathbf{AR} + i\mathbf{T}^T - \mathbf{B})^T \mathbf{W}_p (s\mathbf{AR} + i\mathbf{T}^T - \mathbf{B}) \mathbf{W}_l \right)$$

W_p i W_l są macierzami ważącymi o wymiarach odpowiednio $(p \times p)$, $(l \times l)$. Szczegóły tego podejścia można znaleźć w [15].

Po wyznaczeniu parametrów rotacji, przesunięcia i skali otrzymujemy globalne parametry informujące o wyżej wymienionych cechach pomiędzy zbiorami punktów. W celu uwzględnienia lokalnych różnic w rozkładzie przestrzennym (różnice osobnicze w geometrii i objętości struktur) przeprowadzana jest, w iteracyjnym procesie, korekcja umożliwiająca zmianę wzajemnych relacji pomiędzy punktami jednej z chmur. Korekcja bazuje na wykorzystaniu algorytmu k-najbliższych sąsiadów [16].

Wyniki dopasowania oraz walidacja

Opisana metodologia została przetestowana na danych tomograficznych pacjentów z nowotworem prostaty leczonych w Świętokrzyskim Centrum Onkologii. Wykorzystane dane cechowały się rozdzielczością przestrzenną 0.95 mm w płaszczyźnie poprzecznej oraz odległością pomiędzy przekrojami 3 mm.


Jakościowe wyniki dopasowania przedstawiono na rysunku 3 i 4. Rysunek 3 przedstawia wyniki dopasowania powierzchni prostaty średniego modelu do przykładowych danych uczących. Rysunek 4 obrazuje różnice przed dopasowaniem oraz po dopasowaniu dla struktury pęcherza. Prezentowane jakościowe wyniki potwierdzają skuteczność opisywanego podejścia.

Dodatkowo przeprowadzono analizę jakościową uzyskanych wyników analogicznie do pracy [18]. Dla struktur po dopasowaniu (pęcherza, prostaty, głów kości udowych, odbytnicy) wyznaczono 103 pary punktów w danych dopasowywanych i danych, do których dopasowywano, reprezentujących miejsca charakterystyczne w wymienionych organach. Na podstawie odpowiadających sobie punktów wyznaczono odległości pomiędzy chmurami po dopasowaniu. W idealnym przypadku odległość powinna wynosić zero. Otrzymane wyniki przedstawiono na rysunku 5 w formie unormowanego histogramu. Jak można zaobserwować dla większości punktów odległość nie przekracza 1,08 mm. Na dokładność wyznaczenia odległości wpływa również niedokładność wskazania punktów przez eksperta oraz liczba punktów wykorzystywanych do dopasowania. W sytuacji gdy odległość w chmurach jest duża (niewielka liczba punktów wygenerowanych na powierzchni struktury) może to spowodować niedopasowanie powierzchni pomiędzy punktami.


Podsumowanie

W artykule przedstawiono metodologię dopasowania chmur punktów do powierzchni na przykładzie problemu generacji punktów charakterystycznych na potrzeby uczenia modelu w przestrzeni trójwymiarowej. Budowa modelu została przedstawiona w zastosowaniu do segmentacji z wykorzystaniem metody ASM i AAM.


Skuteczność rozwiązania przetestowano na trójwymiarowych danych tomograficznych pacjentów z nowotworem prostaty. Została ona potwierdzona jakościowo jak i ilościowo. Prezentowany algorytm może również zostać wykorzystany w problemach typowo technicznych takich jak: dopasowanie danych pomiarowych pochodzących ze skanerów optycznych, rozpoznawaniu twarzy czy też w zagadnieniach związanych z rekonstrukcją powierzchni obiektów.



Rys. 3. Średni model prostaty dopasowany do danych uczących. Górny wiersz: po dopasowaniu sztywnym; Dolny wiersz: po lokalnej korekcji; Jasne fragmenty rysunku przedstawiają miejsca niezgodności dopasowania.



Rys. 4. Wyniki dopasowania pęcherza: a) struktury przed dopasowaniem; b) po dopasowaniu; c) 2D przekrój przed dopasowaniem; d) 2D przekrój po dopasowaniu. Białe piksele reprezentują niedopasowanie.



Rys. 5. Unnormowany histogram odległości pomiędzy punktami po dopasowaniu dla prostaty, głów kości udowych, odbytnicy i pęcherza.

Autorzy chcieliby podziękować dr Piotrowi Kędzierawskiemu ze Świętokrzyskiego Centrum Onkologii za wykonanie obrysów struktur anatomicznych w danych medycznych. W implementacji całościowego rozwiązania wykorzystano kod umieszczony w [19].

W pracy wykorzystano dane pozyskane w ramach projektu finansowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego / Narodowe Centrum Nauki, projekt numer NN518 497739. Praca sfinansowana z Grantu Dziekańskiego nr 15.11.120.346.

LITERATURA

- [1] Diez Y., Martí J., Salvi J., Hierarchical Normal Space Sampling to speed up point cloud coarse matching. *Pattern Recognition Letters*, 33 (2012), 2127-2133
- [2] Fantoni S., Castellani U., Fusiello A.: Automatic multi-view surface matching. *Eurographics* (2012), 1-4
- [3] Winkelbach S., Molkenstruck S., Wahl FM., Low-cost laser range scanner and fast surface registration approach. *Pattern Recognition*. Springer Berlin Heidelberg, (2006), 718-728
- [4] Skalski A., Kos A., Zieliński T., Using ASM in CT data segmentation for prostate radiotherapy. *Computer Vision and Graphics*. Springer Berlin Heidelberg, LNCS 7594, (2012), 610-617.
- [5] Frangi A.F., Rueckert D., Schnabel J.A., Niessen W.J., Automatic construction of multiple-object three-dimensional statistical shape models: application to cardiac modeling. *Medical Imaging, IEEE Transactions on*, 21(9), (2002), 1151-1166
- [6] Horwich V.A., Parker C., Kataja V., Prostate cancer: ESMO clinical recommendations for diagnosis, treatment and follow-up, *Annals of Oncology* 20 (2009) iv76-iv78, DOI=http://annonc.oxfordjournals.org/content/20/suppl_4/iv76.full.pdf+html
- [7] Skalski A., Lagwa J., Zielinski T., Kędzierawski P., Kuszewski T., Automatic prostate segmentation in MR images based on 3D active contours with shape constraints, *Signal Processing: Algorithms, Architectures, Arrangements, and Applications* (SPA), 26-28 Sept. (2013), 246-249
- [8] Skalski A., Zieliński T., Kukulowicz P., Kędzierawski P., Computer tomography-based radiotherapy planning on the example of prostate cancer: application of level-set segmentation method guided by atlas-type knowledge, *ISABEL: 4th Int. Symp. on Applied Sciences in Biomedical and Communication Technologies*, Barcelona, 26-29 October (2011), DOI:10.1145/2093698.2093840.
- [9] Cootes T.F., Cooper D., Taylor C.J., Graham J., Active Shape Models Their Training and Application, *Computer Vision and Image Understanding* 61(1), (1995), 38-59
- [10] Cootes T.F., Edwards G.J., Taylor C.J., Active Appearance Models, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 23(6), (2001), 681-685
- [11] Balci S.K., Golland P., Wells W.M.: Non-rigid Groupwise Registration using B-Spline Deformation Model. *The Insight Journal*. (2007) DOI: <http://hdl.handle.net/1926/568>
- [12] Rueckert D., Sonoda, L.I., Hayes, C., et al.: Nonrigid Registration Using Free-Form Deformations: Application to Breast MR Images. *Medical Imaging, IEEE Transactions on*, 18(8), (1999), 712-721
- [13] Besi P.J., McKay N.D., A method for registration of 3-D shapes, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 14(2), (1992), 239-256
- [14] Kendall D.G. A Survey of the Statistical Theory of Shape. *Statistical Science*, 4(2), (1989), 87-99
- [15] Toldo, R., Beinat A., Crosilla F., Global registration of multiple point clouds embedding the Generalized Procrustes Analysis into an ICP framework. *3DPVT 2010 Conference*. (2010)
- [16] Friedman, J.H., Bentely, J., Finkel, R. A. An Algorithm for Finding Best Matches in Logarithmic Expected Time, *ACM Transactions on Mathematical Software* 3, (1977), 209
- [17] Lorensen W.E., Cline H.E. Marching Cubes: A high resolution 3D surface construction algorithm. *Computer Graphics*, 21(4) (1987)
- [18] Shen, J-K, Matuszewski B.J., Shark L-K., Skalski A., Zielinski T., Moore C.J., Deformable Image Registration-A Critical Evaluation: Demons, B-Spline FFD and Spring Mass System. *BioMedical Visualization, 2008. IEEE MEDVIS'08. Fifth International Conference*, (2008) 77-82.
- [19] Manu. Nonrigid ICP. <http://www.mathworks.com/matlabcentral/fileexchange/41396-nonrigidicp>

Autorzy: dr inż. Andrzej Skalski, dr inż. Mirosław Socha, AGH Akademia Górniczo-Hutnicza w Krakowie, Katedra Metrologii i Elektroniki, al. Mickiewicza 30, 30-059 Kraków, E-mail: skalski@agh.edu.pl, socha@agh.edu.pl.