

POLITECHNIKA WARSZAWSKA

DYSCYPLINA NAUKOWA INŻYNIERIA BIOMEDYCZNA

DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

Rozprawa doktorska

mgr inż. Aleksandra Wilczewska

**Metoda wyznaczania przemieszczeń i odkształceń lewej komory serca,
z użyciem danych echokardiograficznych poprzez elastyczne
dopasowanie obrazów, wzbogacone o informację z segmentacji**

Promotor

dr hab. inż. Jakub Żmigrodzki

Promotor pomocniczy

dr inż. Szymon Cygan

WARSZAWA 2024

Podziękowania

Chciałabym serdecznie podziękować wszystkim osobom, które wspierały mnie w trakcie pracy nad niniejszą rozprawą, w szczególności:

Panu dr. hab. inż. Jakubowi Żmigrodzkiemu, promotorowi tej pracy, za wsparcie merytoryczne, ogromne zaangażowanie, skrupulatność, uwagę i poświęcony czas.

Panu dr. inż. Szymonowi Cyganowi, promotorowi pomocniczemu i dobremu duchowi tej pracy, za zaangażowanie, wsparcie we wszystkich aspektach pracy, pomoc merytoryczną i nieskończone pokłady optymizmu.

Panu prof. dr. hab. inż. Krzysztofowi Kałużyńskiemu, pierwszemu opiekunowi naukowemu mojego doktoratu, za cenne wskazówki, wsparcie i poświęcony czas.

Panu prof. dr. hab. inż. Gerardowi Cybulskiemu, dziekanowi Wydziału Mechatroniki Politechniki Warszawskiej za umożliwienie mi prac nad tą rozprawą i ogromną życzliwość.

Firmie PMOD Technologies, w szczególności Panu dr. inż. Tomaszowi Kubikowi, Pani Małgorzacie Stawik-Kilian i Panu Olgierdowi Leonowiczowi za udostępnienie narzędzi, wsparcie oraz wykonanie segmentacji części danych wykorzystanych w tej pracy.

Maćkowi, bez którego tej pracy by nie było, za wiarę we mnie.

Streszczenie

Echokardiografia stanowi bezpieczną i nieinwazyjną metodę, umożliwiającą kompleksową ocenę funkcji serca. Badanie pozwala lekarzom monitorować siłę skurczu, rozmiar komór, sprawność zastawek oraz identyfikować potencjalne nieprawidłowości strukturalne i zakrzepy krwi. Jest powszechnie stosowana w diagnostyce chorób serca oraz monitorowaniu postępu terapii. Echokardiografia umożliwia również wyznaczanie przemieszczeń i odkształceń mięśnia sercowego, dostarczając cennych informacji o jego funkcji. Istnieje szereg metod, zarówno manualnych, jak i automatycznych, do pomiaru tych parametrów. Niniejsza praca koncentruje się na jednej z automatycznych technik, znanej jako technika śledzenia spekli (Speckle Tracking Echocardiography – STE), umożliwiającej zautomatyzowane określanie przemieszczeń i odkształceń mięśnia sercowego.

Celem niniejszej pracy było opracowanie nowej metody wyznaczania przemieszczeń i odkształceń mięśnia lewej komory serca na podstawie dwuwymiarowych danych echokardiograficznych typu B-mode, poprzez rozwinięcie jednej z wykorzystywanych w tym celu metod tj. elastycznego dopasowania obrazów, opartego na krzywych B-sklejanych. W algorytmie zaproponowanym w niniejszej pracy poprawę jakości wyznaczania przemieszczeń i odkształceń starano się uzyskać przez wykorzystanie, oprócz samych obrazów, również wyników segmentacji obszaru mięśnia komory. Maski uzyskane w procesie segmentacji wykorzystane zostały poprzez dodanie do funkcji kosztu algorytmu elastycznego dopasowania obrazów nowej funkcji kary tj. kary niedopasowania masek, penalizującej niedopasowanie masek obrazów transformowanego i docelowego. Dla nowej funkcji kary opracowana została formuła wagi, określającej jej udział w funkcji kosztu, uwzględniająca różnice w intensywnościach pikseli pomiędzy kolejnymi parami obrazów z sekwencji echokardiograficznej oraz pomiędzy kolejnymi parami odpowiadających im masek. Uzyskano dzięki temu zwiększoną odporność opracowanego algorytmu na wykorzystanie masek z segmentacji, cechujących się niską dokładnością.

Badania zaproponowanego algorytmu, zaimplementowanego w środowisku MATLAB, przeprowadzone zostały z użyciem kilku rodzajów danych echokardiograficznych, różnego pochodzenia. W pracy użyto 1) syntetycznych danych ultrasonograficznych, przedstawiających fantom lewej komory serca – jednorodny i z wtrąceniem symulującym obszar o mniejszej kurczliwości, 2) danych pochodzących z obrazowania ultrasonograficznego fantomu lewej

komory serca, 3) danych semi-syntetycznych, czyli danych generowanych numerycznie, ale opartych na danych klinicznych oraz 4) danych klinicznych.

Przeprowadzone badania podzielone zostały na dwa etapy: doboru wartości hiperparametrów metody oraz jej walidację. W pierwszym etapie wykorzystano dane, dla których dostępna była pełna informacja referencyjna o polu przemieszczeń materiału lub tkanki podlegającej obrazowaniu – dane syntetyczne i semi-syntetyczne. Do walidacji metody wykorzystano dane z obrazowania fantomu, dane semi-syntetyczne oraz dane kliniczne. Uzyskane wyniki odnoszono między innymi do wyników uzyskiwanych obecnie stosowaną metodą niewykorzystującą informacji pochodzącej z segmentacji.

Badanie na danych syntetycznych wykazało, że błędy wyznaczania przemieszczeń zaproponowaną metodą przy właściwie dobranych wartościach współczynników kary niedopasowania masek oraz gładkości (odpowiednio 1 i 0,1), wynoszące ok. $0,429 \pm 0,018$ mm są blisko dwukrotnie niższe niż w przypadku algorytmu niewykorzystującego informacji z segmentacji. W badaniu na danych semi-syntetycznych analogiczne błędy sięgały wartości 1,4 mm.

Wykazano, że zaproponowane w ramach pracy rozwiązanie zwiększa nawet o 40% dokładność wyznaczania przemieszczeń i odkształceń mięśnia sercowego, w sytuacji, w której wykorzystane maski nie są obciążone znacznymi błędami segmentacji. Wyniki lepsze lub porównywalne do uzyskanych przy wykorzystaniu metody referencyjnej, niewykorzystującej kary niedopasowania masek zostały uzyskane zarówno dla danych syntetycznych, danych semi-syntetycznych, jak i danych klinicznych. Pewnym ograniczeniem metody jest zależność efektów jej działania od jakości wykorzystanych masek z segmentacji. Kluczowe znaczenie dla decyzji o zastosowaniu zaproponowanej metody ma zatem wiedza, dotycząca sposobu działania wykorzystanego algorytmu segmentacji i wpływu błędów segmentacji, występujących w zastosowanych maskach, na wynik. Oba te kluczowe aspekty zostały szeroko omówione w niniejszej pracy.

Dokonano również porównania czasu wykonania obliczeń potrzebnych do uzyskania wyniku dla zaproponowanej w niniejszej pracy metody oraz metody dotychczas stosowanej. Czas wykonywania obliczeń przy zastosowaniu zaproponowanego rozwiązania jest istotnie (od 30% do 50%) krótszy niż czas wykonywania obliczeń przy zastosowaniu standardowego algorytmu jedynie z karą gładkości. Stanowi to ważny atut opisywanego algorytmu zwiększający jego

użyteczność oraz rozszerzający możliwości jego stosowania w systemach cechujących się ograniczoną mocą obliczeniową np. w systemach mobilnych.

Słowa kluczowe: echokardiografia, wyznaczanie przemieszczeń i odkształceń, śledzenie spekli, elastyczne dopasowanie obrazów, segmentacja

Abstract

Echocardiography is a safe and non-invasive method, enabling a comprehensive assessment of heart function. The examination allows physicians to monitor the strength of contractions, chamber size, valve efficiency, and identify potential structural abnormalities and blood clots. It is widely used in the diagnosis of heart diseases and the monitoring of therapy progress. Echocardiography also enables the estimation of displacements and deformations of the heart muscle, providing valuable information about its function. There are various methods, both manual and automatic, for measuring these parameters. This thesis focuses on one of the automatic techniques, known as Speckle Tracking Echocardiography (STE), allowing for the automated determination of displacements and deformations of the heart muscle.

This study aimed to develop a new method for determining displacements and deformations of the left ventricle, based on two-dimensional B-mode echocardiographic data, by expanding one of the methods used for this purpose, namely B-spline based elastic image registration. In the algorithm proposed in this thesis, improvements in the quality of displacement and deformation estimation were sought by utilizing, in addition to the images themselves, the results of segmentation of the ventricular muscle area. Masks obtained in the segmentation process were incorporated by adding a new penalty function to the cost function of the elastic image registration algorithm, penalizing the mismatch of masks between the transformed and target images. A weighted formula for the new penalty function was developed, determining its contribution to the cost function, considering differences in pixel intensities between successive pairs of images in the echocardiographic sequence and between corresponding pairs of masks. This increased the robustness of the developed algorithm against the use of masks with low accuracy.

The proposed algorithm was tested using several types of echocardiographic data from different sources. The study utilized 1) synthetic ultrasound data depicting a phantom of the left ventricle with a homogeneous structure and an inclusion simulating an area of reduced contractility, 2) data from ultrasound imaging of a phantom of the left ventricle, 3) semi-synthetic data generated numerically but based on clinical data, and 4) clinical data.

The conducted research was divided into two stages: the selection of hyperparameter values for the method and its validation. In the first stage, data with complete reference information on the displacement field of the imaged material or tissue were used – synthetic and semi-synthetic data. For validation, data from imaging the phantom, semi-synthetic data, and clinical data were

used. The obtained results were compared, among other things, with the results obtained by the currently used method that does not utilize information from segmentation.

The study on synthetic data showed that errors in estimating displacements using the proposed method, with properly chosen weight coefficients for mask mismatch and smoothness penalties (1 and 0.1, respectively), were approximately 0.429 ± 0.018 mm, nearly two times lower than those with the algorithm not utilizing segmentation information. In the study on semi-synthetic data, similar errors reached values of 1.4 mm.

It was demonstrated that the proposed solution increases the accuracy of determining displacements and deformations of the heart muscle by up to 40%, in situations where the used masks are not burdened with significant segmentation errors. Results better or comparable to those obtained using the reference method, without mask mismatch penalty, were achieved for both synthetic, semi-synthetic, and clinical data. One limitation of the method is the dependence of its effectiveness on the quality of the utilized segmentation masks. Therefore, knowledge about how the segmentation algorithm works and the impact of segmentation errors in the applied masks on the result is crucial. Both key aspects were extensively discussed in this work.

A comparison of the computation time required to obtain results for the proposed method and the previously used method was also conducted. The computation time of the proposed solution is significantly (30% to 39%) shorter than the computation time of the standard algorithm with only a smoothness penalty. This is an important advantage of the described algorithm, enhancing its utility and expanding its applicability in systems characterized by limited computational power, such as mobile systems.

Keywords: echocardiography, determination of displacements and deformations, speckle tracking, elastic image matching, segmentation

Spis treści

1	Wstęp.....	13
1.1	Cel i zakres pracy	14
1.1.1	Zaproponowany algorytm	14
1.1.2	Walidacja wyników	15
1.2	Podstawy fizyczne obrazowania ultradźwiękowego	16
1.2.1	Struktura speklowa	17
1.3	Płaszczyzny obrazowania w echokardiografii.....	18
1.4	Echokardiograficzne metody regionalnej oceny funkcji mięśnia sercowego	19
1.4.1	Wall Motion Score Index (WMSI).....	19
1.4.2	Tissue Doppler Imaging (TDI).....	21
1.4.3	Śledzenie spekli.....	21
1.5	Wyznaczanie odkształceń w STE.....	23
1.5.1	Wyznaczanie przemieszczeń	23
1.5.2	Wyznaczanie odkształceń	24
1.5.3	Zależność pomiędzy dokładnością wyznaczania odkształceń a ich wartością ..	25
1.6	Segmentacja w STE.....	26
1.7	Techniki segmentacji w echokardiografii.....	26
1.7.1	Ocena dokładności segmentacji	26
1.7.2	Segmentacja metodą aktywnego konturu.....	27
1.7.3	Metody segmentacji oparte na sieciach neuronowych i uczeniu maszynowym	28
1.8	Algorytm elastycznego dopasowania obrazów	28
1.8.1	Transformacja.....	28
1.8.2	Interpolacja.....	32
1.8.3	Funkcja kosztu.....	32
1.8.4	Optymalizacja.....	35
1.9	Wykorzystanie informacji o konturze w elastycznym dopasowaniu obrazów.....	35

2	Proponowany algorytm i jego implementacja.....	38
2.1	Segmentacja.....	40
2.2	Transformacja.....	40
2.3	Interpolacja.....	41
2.4	Funkcja kosztu.....	42
2.4.1	Kara niedopasowania masek.....	43
2.5	Optymalizacja.....	44
2.6	Wyznaczanie przemieszczeń i odkształceń.....	45
2.6.1	Punkty charakterystyczne.....	45
2.6.2	Wyznaczanie przemieszczeń.....	45
2.6.3	Wyznaczanie odkształceń.....	46
3	Walidacja opracowanej metody.....	48
3.1	Dane walidacyjne.....	48
3.1.1	Dane syntetyczne.....	48
3.1.2	Dane pochodzące z obrazowania fantomu materialnego.....	56
3.1.3	Dane semi-syntetyczne.....	59
3.1.4	Dane kliniczne.....	62
3.2	Metody i miary oceny dokładności estymacji przemieszczeń i odkształceń.....	64
3.2.1	Ocena dokładności estymacji przemieszczeń i odkształceń w danych z dostępną referencją numeryczną.....	64
3.2.2	Ocena działania algorytmu z użyciem danych klinicznych.....	65
4	Dobór wartości hiperparametrów algorytmu.....	67
4.1	Wpływ rodzaju danych obrazowych.....	67
4.1.1	Dane syntetyczne, fantom jednorodny.....	68
4.1.2	Dane syntetyczne, fantom z wtrąceniem.....	72
4.1.3	Dane semi-syntetyczne.....	73
4.1.4	Podsumowanie.....	74

4.2	Wpływ błędów segmentacji.....	75
5	Wyniki walidacji algorytmu.....	80
5.1	Dane z obrazowania fantomu z referencją numeryczną.....	80
5.1.1	Błędy wyznaczania przemieszczeń w danych z obrazowania fantomu lewej komory serca, z referencją numeryczną.....	81
5.1.2	Błędy wyznaczania odkształceń w danych z obrazowania fantomu lewej komory serca, z referencją numeryczną.....	82
5.1.3	Podsumowanie.....	86
5.2	Dane semi-syntetyczne.....	86
5.2.1	Błędy wyznaczania przemieszczeń w danych semi-syntetycznych.....	87
5.2.2	Błędy wyznaczania odkształceń w danych semi-syntetycznych.....	93
5.3	Dane kliniczne.....	113
5.3.1	Podsumowanie.....	117
5.4	Czas wykonania algorytmu.....	117
5.5	Dyskusja.....	119
6	Podsumowanie.....	121
7	Bibliografia.....	124
8	Dodatki.....	131
8.1	Dodatek A.....	131

1 Wstęp

Echokardiografia jest badaniem ultrasonograficznym mięśnia sercowego, pozwalającym na uzyskanie obrazów serca, umożliwiającym przeprowadzenie oceny strukturalnej i funkcjonalnej tego narządu. Współcześnie dostępna jest zarówno aparatura, pozwalająca na wykonywanie badań dwuwymiarowych, jak i umożliwiająca badania trójwymiarowe. Niniejsza praca skupia się na wariantcie dwuwymiarowym, który jest szeroko stosowany w praktyce klinicznej, ze względu na dostępność aparatury, stosunkowo niskie koszty przeprowadzania badań i obecność wypracowanych na przestrzeni lat standardów i metryk pozwalających na sprawne przeprowadzenie procesu diagnostycznego [1], [2], [3], [4]. Echokardiografia dwuwymiarowa jest uznaną metodą, pozwalającą na ocenę funkcjonalną mięśnia sercowego, wykorzystywaną w kardiologii, m. in. w diagnostyce choroby wieńcowej, niewydolności mięśnia sercowego i chorób zastawek serca [5], monitorowaniu stanu mięśnia sercowego pacjentów w trakcie chemioterapii [1] oraz w kwalifikowaniu pacjentów do terapii resynchronizacyjnej serca [3].

Echokardiografia dwuwymiarowa umożliwia wykonanie pomiarów kluczowych parametrów funkcjonalnych serca, takich jak frakcja wyrzutowa, czy objętość wyrzutowa, wykorzystywanych powszechnie w praktyce klinicznej [6], [7], [8]. Badanie echokardiograficzne pozwala także na wyznaczenie przemieszczeń i odkształceń mięśnia sercowego, które niosą za sobą cenne informacje o stanie mięśnia sercowego. Do wyznaczania przemieszczeń i odkształceń mięśnia sercowego wykorzystywany jest szereg metod, zarówno manualnych jak i automatycznych. Niniejsza praca skupia się na jednej z podgrup metod, pozwalających na wyznaczenie przemieszczeń i odkształceń mięśnia sercowego w sposób zautomatyzowany z użyciem tzw. techniki śledzenia spekli¹. Aplikacje tej techniki do celów diagnostyki kardiologicznej znane są w literaturze jako echokardiografia śledzenia spekli (Speckle Tracking Echocardiography – STE) [5]. Wyznaczane przy użyciu metod STE globalne wartości odkształceń mięśnia sercowego są szeroko stosowane w diagnostyce licznych schorzeń, takich jak nadciśnienie tętnicze, zawał serca, choroby zastawek, niewydolność serca, migotanie przedsionków, jak również w monitorowaniu stanu pacjentów po przeszczepie serca [5], a ich wykorzystanie jest uwzględnione w rekomendacjach American Society of

¹ Anglojęzyczne określenie „speckle” może być tłumaczone na różne sposoby, m.in. jako plamka. W polskojęzycznych publikacjach wykorzystywane bywa określenie „markery akustyczne” [9], jednak sformułowanie to może mylnie sugerować wykorzystanie zewnętrznych markerów umieszczonych w tkance, czy na obrazie, dlatego też z uwagi na największą jednoznaczność, w pracy zastosowane zostało określenie „speckle”, stanowiące bezpośrednie zapożyczenie z języka angielskiego.

Echocardiography [10]. Metody STE pozwalają również na wyznaczanie regionalnych parametrów przemieszczeń i odkształceń, które, choć nie są jeszcze powszechnie wykorzystywane w praktyce klinicznej [10], mogą nieść za sobą dodatkowe istotne informacje o stanie mięśnia sercowego, których uzyskanie nie jest możliwe na podstawie parametrów globalnych [3].

Głównymi ograniczeniami w stosowaniu metod śledzenia spekli są [5], [10]:

- zależność wyników, uzyskiwanych za ich pośrednictwem, od jakości danych obrazowych oraz liczby klatek rejestrowanych na sekundę,
- ograniczona powtarzalność obserwowana w przypadku pomiarów części parametrów oraz różnice w wynikach uzyskiwanych przy użyciu urządzeń różnych producentów.

Z powyższych względów metody te są przedmiotem prac badawczych, których głównym celem jest zwiększanie dokładności i powtarzalności wyznaczania przemieszczeń i odkształceń.

Celem tej pracy, szczegółowo opisanym w rozdziale 1.1, jest zwiększenie dokładności wyznaczania przemieszczeń i odkształceń mięśnia sercowego poprzez modyfikację metody elastycznego dopasowania obrazów.

1.1 Cel i zakres pracy

Celem pracy było opracowanie i weryfikacja nowej metody wyznaczania przemieszczeń i odkształceń mięśnia lewej komory serca. Nowym, zaproponowanym w niniejszej pracy rozwiązaniem było włączenie do obecnie stosowanego algorytmu elastycznego dopasowania obrazów informacji pochodzącej z procesu segmentacji analizowanych obrazów echokardiograficznych. Na podstawie dostępnych danych literaturowych (patrz rozdział 1.8) założono, że takie wzbogacenie metody powinno zwiększyć dokładność wyznaczania przemieszczeń i odkształceń mięśnia sercowego na podstawie danych echokardiograficznych.

1.1.1 Zaproponowany algorytm

W opracowanej metodzie, do poprawy dokładności wyznaczania przemieszczeń i odkształceń wykorzystane zostały informacje, pochodzące z segmentacji obrazów echokardiograficznych. Choć w literaturze opisane są przypadki zastosowania danych z segmentacji do poprawy działania algorytmów elastycznego dopasowania obrazów, zaproponowane w tej pracy podejście, polegające na zawarciu informacji pochodzącej z segmentacji, w funkcji kosztu algorytmu elastycznego dopasowania obrazów, opartego na krzywych B-sklejanych, nie było

dotychczas stosowane. Zaproponowane rozwiązanie polega na dodaniu do funkcji kosztu nowego komponentu – kary niedopasowania masek, w ramach której porównywane są maska obrazu dopasowywanego (poddana takiej samej transformacji jak obraz dopasowywany) oraz maska obrazu docelowego.

Nowością, zaproponowaną w ramach pracy, jest również formuła wagi kary niedopasowania masek, zawierająca iloraz sumy kwadratów różnic pikseli wszystkich sąsiadujących ze sobą par obrazów z sekwencji oraz sumy kwadratów różnic pikseli wszystkich sąsiednich masek z sekwencji. Zaproponowana formuła wagi kary niedopasowania masek pozwala na stosowanie tych samych wartości tej wagi przy zestawach danych o zróżnicowanych charakterystykach intensywności pikseli, co ułatwia aplikację metody do danych pochodzących od różnych pacjentów lub zarejestrowanych z użyciem różnej aparatury. Dodatkowo zastosowanie zaproponowanego w pracy sposobu wyznaczania wartości wagi kary niedopasowania masek skutkuje ograniczeniem błędów estymacji przemieszczeń i odkształceń, wynikających z ewentualnych błędów segmentacji.

1.1.2 Walidacja wyników

W związku z tym, że stosowane klinicznie oraz badawczo metody segmentacji danych echokardiograficznych mogą cechować się niską dokładnością, konieczne było przeprowadzenie badania wpływu jakości masek na wyznaczanie przemieszczeń i odkształceń przy użyciu zaproponowanego algorytmu. Opracowana w tym celu nowatorska metoda walidacji polega na poddaniu masek pochodzących z segmentacji kilku rodzajom deformacji o zróżnicowanym nasileniu i porównaniu uzyskanych wartości przemieszczeń i odkształceń z wartościami referencyjnymi.

Do badania dokładności wyznaczania przemieszczeń i odkształceń w danych echokardiograficznych przy wykorzystaniu zaproponowanego w pracy algorytmu posłużył szereg zestawów danych, cechujących się zróżnicowanym poziomem realizmu i dostępnością danych referencyjnych tj.: wygenerowane numerycznie dane, przedstawiające fantom lewej komory serca (patrz rozdział 3.1.1), dane semi-syntetyczne (patrz rozdział 3.1.3), dane z akwizycji fantomu lewej komory serca, z referencją numeryczną (patrz rozdział 3.1.2), jak również dane kliniczne (patrz rozdział 3.1.4).

Walidacja efektów wyznaczania przemieszczeń i odkształceń w przypadku danych syntetycznych oraz danych z akwizycji fantomu z referencją numeryczną, została zrealizowana

poprzez porównanie uzyskanych wartości przemieszczeń i odkształceń z wartościami referencyjnymi. Walidacja wyników działania algorytmu z danymi klinicznymi stanowiła wyzwanie, ze względu na brak dokładnej referencji numerycznej, czy wyników badań tych samych pacjentów metodami, uznanymi za złoty standard. W wykorzystanym w pracy zestawie danych klinicznych jedyną informacją, którą można uznać za referencję są maski, wyznaczone przez specjalistów w klatkach sekwencji, odpowiadających fazom końcowo-skurczowej i końcowo-rozkurczowej cyklu pracy serca. W związku z tym walidacja wyników wyznaczania przemieszczeń i odkształceń została w przypadku tych danych zrealizowana przy użyciu nowej, zaproponowanej w ramach tej pracy, formy walidacji, opartej na maskach. Polega ona na poddaniu wyznaczonej przez specjalistę maski końcowo-rozkurczowej transformacji, stanowiącej wynik działania algorytmu elastycznego dopasowania obrazów i porównaniu uzyskanej maski transformowanej z maską końcowo-skurczową, wyznaczoną przez specjalistę.

Dzięki zaproponowanym rozwiązaniom, dotyczącym walidacji wyników, możliwe było porównanie opracowanego algorytmu z klasycznym algorytmem elastycznego dopasowania obrazów, opisanym w literaturze [11], [12], jak również weryfikacja powtarzalności uzyskiwanych wyników.

1.2 Podstawy fizyczne obrazowania ultradźwiękowego

U podstaw obrazowania ultradźwiękowego leży zjawisko odbicia i rozproszenia fali propagującej w tkankach. Rejestracja odbitych i rozproszonych fal dźwiękowych umożliwia uzyskanie informacji o obrazowanych obiektach oraz jej przedstawienie w postaci obrazu.

Tkanki miękkie cechują się zróżnicowaną impedancją akustyczną, dzięki czemu możliwe jest ich obrazowanie z wykorzystaniem ultrasonografii. Jednocześnie różnice w impedancji akustycznej w tkankach są na tyle niewielkie, że jedynie nieznaczna część (rzędu 1%) natężenia fali padającej ulega odbiciu i rozproszeniu. Pozostała część przenika przez kolejne partie tkanek, wywołując dalsze odbicia i rozproszenia [13], pozwalając tym samym na uzyskiwanie obrazów struktur tkankowych położonych w głębi ciała pacjenta.


W medycznym obrazowaniu ultradźwiękowym, do generowania i rejestracji sygnału wykorzystywane są przetworniki, zbudowane z materiału piezoelektrycznego, który zmienia swoje wymiary pod wpływem przyłożonego pola elektrycznego, zaś pod wpływem przyłożonej siły mechanicznej generuje pole elektryczne. Dzięki tej właściwości materiał piezoelektryczny

może służyć zarówno jako nadajnik, generujący fale ultradźwiękowe, jak i odbiornik, przetwarzający energię mechaniczną echa na sygnał elektryczny.

Emisja fali ultradźwiękowej w wybranym kierunku, a następnie rejestracja ech, powstałych w wyniku jej odbicia i rozproszenia, pozwala na uzyskanie informacji o właściwościach akustycznych obiektu wzdłuż kierunku propagacji fali. Informacje te są następnie mapowane wzdłuż odcinka, leżącego na prostej, wzdłuż której przemieszczała się fala mechaniczna. W ten sposób tworzona jest tzw. linia obrazu. Na dwuwymiarowy obraz ultrasonograficzny składa się szereg takich linii, których rejestracja jest możliwa dzięki mechanicznemu lub elektronicznemu odchyłaniu wiązki ultradźwiękowej [13].

1.2.1 Struktura speklowa

Charakterystycznym elementem obrazów ultrasonograficznych jest tzw. struktura speklowa (Rysunek 1), widoczna w obszarach obrazu, odpowiadających jednorodnym w skali makroskopowej obszarom tkanki. Obserwowana ziarnistość obrazu jest efektem interferencji ech powstałych na skutek odbicia i rozproszenia propagującej fali mechanicznej na występujących w skali mikro niejednorodnościach właściwości akustycznych (zazwyczaj mniejszych od długości emitowanej fali mechanicznej) w danym obszarze [13]. Ze względu na możliwość opisywania jej przy użyciu metod statystycznych, bywa ona nazywana szumem speklowym, określenie to sugeruje jednak całkowitą losowość zjawiska, która w tym przypadku nie występuje. Położenie spekli na obrazie jest deterministycznie powiązane z ułożeniem tkanek, których struktura stanowi układ elementów rozpraszających, oraz konfiguracją układu obrazującego. Przy niezmienniej konfiguracji układu obrazującego, jedynym czynnikiem determinującym układ spekli jest tkanka, a zatem układ spekli na obrazie można jednoznacznie powiązać z obrazowaną tkanką. W przypadku małych odkształceń i przemieszczeń tkanki można przyjąć, że przemieszczenie tkanki wywoła analogiczne przemieszczenie spekli. Przy większych odkształceniach tkanek dochodzi jednak do zmian w strukturze rozpraszaczy w tkance, a co za tym idzie, do dekorelacji sygnału, objawiającej się zmianami w strukturze speklowej.




Rysunek 1 Przykładowy obraz echokardiograficzny lewej komory serca, pochodzący z bazy danych projektu CAMUS [14], ze zbliżeniem na strukturę speklową fragmentu ściany lewej komory serca.

Struktura speklowa jest często uważana za czynnik utrudniający wykorzystanie obrazów ultrasonograficznych w diagnostyce medycznej, przez negatywny wpływ na działanie m.in. algorytmów automatycznej segmentacji danych, a w literaturze opisany jest szereg rozwiązań, pozwalających na jej redukcję [15], [16]. W metodach śledzenia spekli, struktura ta stanowi jednak kluczową informację, umożliwiającą wyznaczanie przemieszczeń i odkształceń mięśnia sercowego, poprzez śledzenie położenia spekli na kolejnych klatkach sekwencji.

1.3 Płaszczyzny obrazowania w echokardiografii

Dwuwymiarowe, przezklatkowe obrazowanie echokardiograficzne może się odbywać w jednej z trzech płaszczyzn: w płaszczyźnie osi krótkiej, w poprzek komór (widok SAX), w płaszczyźnie osi długiej (widok LAX) oraz w płaszczyźnie koniuszkowej (Rysunek 2). Dodatkowo poprzez odpowiednie odchylenie sondy ultrasonograficznej w każdej z tych płaszczyzn możliwe jest uzyskanie obrazów, ukazujących wybrane struktury serca, co pozwala na pełną i kompleksową diagnostykę tego narządu [17].



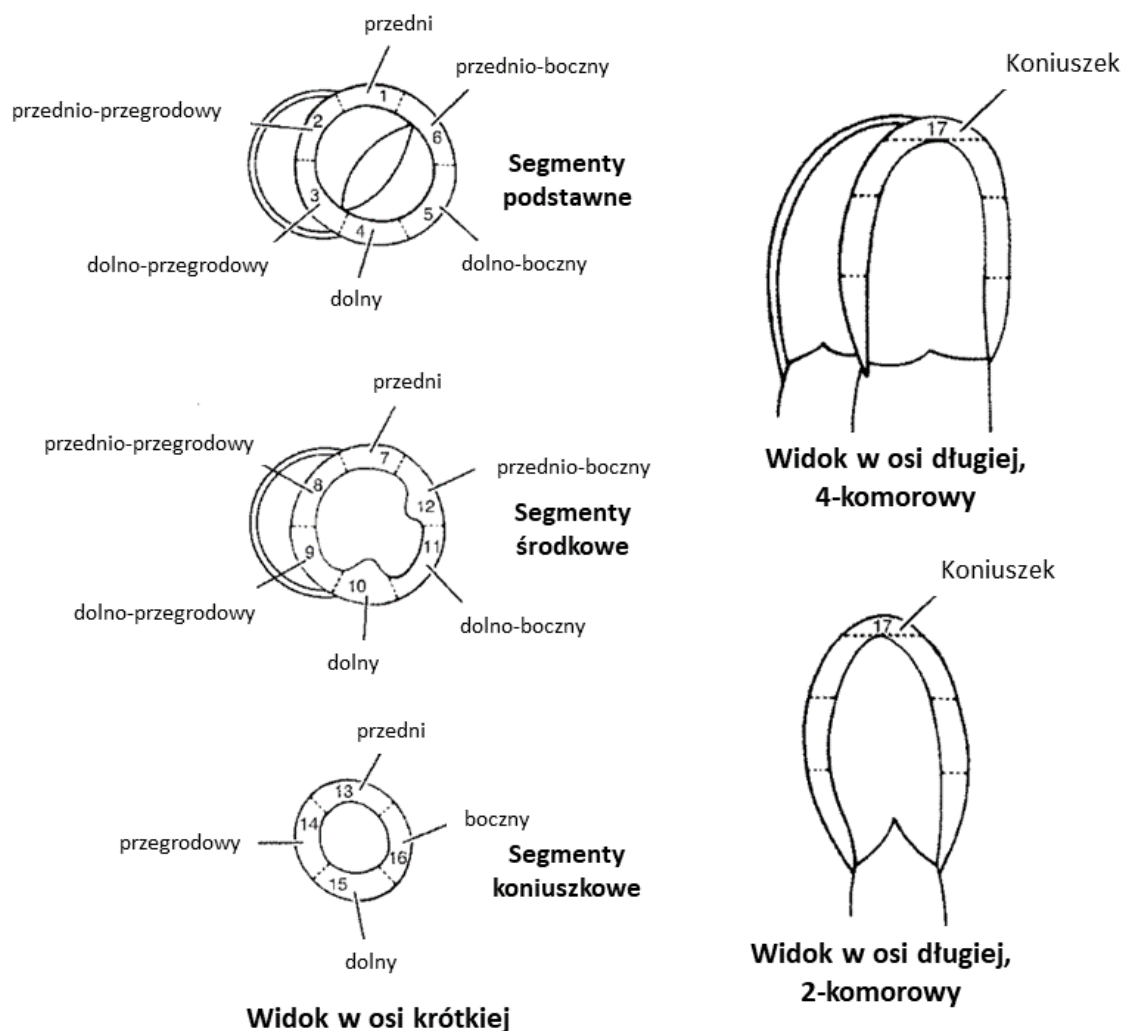
Rysunek 2 Źródło: [17] Płaszczyzny obrazowania wykorzystywane w obrazowaniu echokardiograficznym: Long axis plane (LAX) – płaszczyzna osi długiej, Short axis plane (SAX) – płaszczyzna osi krótkiej, Apical plane – płaszczyzna koniuszkowa.

1.4 Echokardiograficzne metody regionalnej oceny funkcji mięśnia sercowego

1.4.1 Wall Motion Score Index (WMSI)

Najstarszą metodą diagnostyczną, wykorzystującą obrazy ultrasonograficzne do oceny funkcjonalnej mięśnia sercowego jest metoda WMSI (Wall Motion Score Index). Polega ona na ocenie funkcjonowania poszczególnych obszarów mięśnia sercowego przez specjalistę, na podstawie danych obrazowych. Ocenie podlega stopień kurczliwości poszczególnych segmentów mięśnia sercowego określonych zgodnie np. z podziałem AHA-17 (podział mięśnia sercowego na 17 segmentów, zgodnie z wytycznymi American Heart Association [18] – patrz Rysunek 3), przy czym każdemu z segmentów przyporządkowywana jest wartość odpowiadająca jednemu z możliwych stanów kurczliwości: hiperkineza – nadmierna

kurczliwość danego obszaru, normokineza – ruch segmentu, mieszczący się w normie, hipokineza – obniżona kurczliwość, mogąca wynikać z niedokrwienia danego obszaru mięśnia, akineza – całkowita niekurczliwość segmentu, dyskineza – nieprawidłowy ruch danego segmentu (1–3).



Rysunek 3 Źródło: [18] Podział mięśnia sercowego na segmenty, zgodnie z AHA-17 (widok od koniuszka). Numery 1 – 6 odpowiadają segmentom podstawnym: 1 – przedniemu, 2 – przednio-przegrodowemu, 3 – dolno-przegrodowemu, 4 – dolnemu, 5 – dolno-bocznemu, 6 – przednio-bocznemu; numery 7 – 12 odpowiadają segmentom środkowym: 7 – przedniemu, 8 – przednio-przegrodowemu, 9 – dolno-przegrodowemu, 10 – dolnemu, 11 – dolno-bocznemu, 12 – przedniobocznemu; numery 13 – 16 odpowiadają segmentom koniuszkowym: 13 – przedniemu, 14 – przegrodowemu, 15 – dolnemu, 16 – bocznemu, zaś numer 17 – koniuszkowi [19].

Metoda ta umożliwia predykcję śmiertelności oraz konieczności ponownej hospitalizacji pacjentów po przebytych zawale mięśnia sercowego (w tym po zawale mięśnia sercowego bez uniesienia odcinka ST) [20]. Wyniki metody WMSI cechują się korelacją na poziomie 70%,

z frakcją wyrzutową, mierzoną z zastosowaniem wentrykulografii radioizotopowej [21] oraz 74% z wynikami pomiaru wielkości obszaru objętego zawałem, uzyskanymi przy wykorzystaniu rezonansu magnetycznego [22]. Jest to jednak metoda bazująca na wiedzy eksperckiej, w związku z czym uzyskiwane wyniki są zależne od doświadczenia specjalisty, przeprowadzającego proces diagnostyczny, co ogranicza powtarzalność [21].

1.4.2 Tissue Doppler Imaging (TDI)

Inną metodą pozwalającą zarówno na globalną, jak i regionalną ocenę funkcjonowania mięśnia sercowego jest tzw. Doppler tkankowy (Tissue Doppler Imaging – TDI / Tissue Velocity Imaging – TVI) [23]. Jest to metoda, wykorzystująca impulsową technikę dopplerowską do pomiaru prędkości ruchu tkanek – w tym wypadku ścian serca. Dzięki analizie widmowej uzyskanego sygnału, metoda ta pozwala na zbadanie prędkości ruchu tkanek, a dalej, również przemieszczeń i odkształceń mięśnia sercowego. Wyniki uzyskane przy użyciu metody Dopplera tkankowego są skorelowane z frakcją wyrzutową [23]. TDI pozwala na szeroką ocenę parametrów funkcjonalnych mięśnia sercowego [23], diagnostykę nieprawidłowości funkcjonalnych [24], jak również daje podstawę do prognoz długoterminowych przy schorzeniach takich jak nadciśnienie, czy zawał mięśnia sercowego [25]. Najpoważniejszym ograniczeniem metody TDI jest trudność pomiaru kąta pomiędzy kierunkiem propagacji fali, a kierunkiem ruchu tkanki. Z tego względu w praktyce klinicznej najczęściej wyznaczana jest jedynie wartość składowej wektora prędkości, która jest równoległa do kierunku propagacji fali [26]. Skutkuje to niską powtarzalnością uzyskiwanych wyników i trudnościami w porównywaniu wyników badań.

1.4.3 Śledzenie spekli

Innym sposobem wyznaczania przemieszczeń i odkształceń w danych echokardiograficznych jest śledzenie spekli, powstających na obrazach ultrasonograficznych wskutek interferencji odbitych i rozproszonych fal dźwiękowych (rozdział 1.2.1).

Metody analizujące położenie spekli na obrazie (tzw. metody śledzenia spekli), pozwalają na uzyskanie informacji ilościowej na temat przemieszczeń punktów materialnych w obrazowanym obiekcie, na podstawie położenia spekli. Dzięki znajomości przemieszczeń, możliwe jest następnie obliczenie wartości wybranych miar odkształceń obrazowanego obiektu. Uzyskane w ten sposób wyniki są wykorzystywane w praktyce klinicznej m.in. do diagnostyki schorzeń, takich jak choroba niedokrwienna serca, kardiomiopatia,

i dyssynchronia, czy monitorowania wpływu chemioterapii na sprawność mięśnia sercowego [27], [28], [29], [30].

Istnieje szereg metod, wykorzystujących śledzenie spekli na sąsiednich klatkach sekwencji echokardiograficznej do wyznaczania przemieszczeń i odkształceń mięśnia sercowego. Podział i klasyfikacja tych metod mogą być wykonane w zróżnicowany sposób. W poniższym rozdziale zaprezentowany został podział, zdefiniowany w pracy naukowców z KU Leuven – ośrodka, w którym prowadzone są pionierskie prace w tej tematyce [31]. Zgodnie z zaproponowanym przez ten zespół podziałem, metody te można podzielić na dwie grupy: metody bazujące na przepływie optycznym (w tym metody gradientowe oraz block matching) oraz metody bazujące na dopasowaniu obrazów.

1.4.3.1 Przepływ optyczny

Metody bazujące na przepływie optycznym można podzielić na dwie grupy: metody gradientowe oraz metody block-matching, wyznaczające przemieszczenia lokalnie, w ramach określonego sąsiedztwa [31], [32], [33]. Dodatkowo obie grupy metod występują w dwóch wariantach, których działanie jest oparte albo na analizie wartości intensywności pikseli obrazu, albo na analizie na charakterystyki fazowej obrazu [34], [35], [36].

Metody gradientowe

Metody gradientowe polegają na analizie pochodnych przestrzennych i czasowych intensywności pikseli obrazów [33] w połączeniu z określonymi warunkami brzegowymi [37], [38], co pozwala na wyznaczenie pola prędkości punktów obrazu. Szczyt popularności tych metod przypada na lata 90. XX w., kiedy były aplikowane zarówno do syntetycznych [39], jak i klinicznych danych echokardiograficznych [40], [41].

Block matching

Metoda block matching polega na podziale jednej z dwóch sąsiadujących klatek sekwencji echokardiograficznej na tzw. obszary zainteresowania, a następnie poszukiwaniu na drugim obrazie, w ramach odpowiednio zawężonych obszarów poszukiwań, fragmentów najbardziej do nich zbliżonych, zgodnie z wybranym kryterium podobieństwa. Metoda ta ma zastosowanie zarówno w analizie danych 2D jak i 3D, a przemieszczenia mięśnia sercowego wyznaczone przy jej użyciu wykazują korelację z wynikami uzyskanymi przy użyciu sonomikrometrii na poziomie 90% przy wyznaczaniu odkształceń w osi długiej serca i na poziomie 79% przy wyznaczaniu odkształceń w osi krótkiej oraz korelację z wynikami wyznaczania odkształceń, na podstawie danych z rezonansu magnetycznego na poziomie 87% [42]. Block matching

wykazuje użyteczność w zastosowaniach klinicznych, takich jak badanie poprawności odkształceń serca [43], przewidywanie efektów terapii resynchronizacyjnej serca [44], czy detekcja wad serca, takich jak przetrwały przewód tętniczy [45]. Pewne ograniczenie tej metody stanowi dyskretny charakter uzyskiwanych pól przemieszczeń, wymuszający stosowanie dodatkowej regularyzacji i interpolacji wyników.

1.4.3.2 Elastyczne dopasowanie obrazów

Elastyczne dopasowanie obrazów jest metodą polegającą na poddaniu obrazu dopasowywanego deformacji w taki sposób, aby powstały w jej wyniku obraz zdeformowany osiągnął możliwie najwyższe, zgodnie z wybranym kryterium, podobieństwo do drugiego obrazu, który będzie dalej określany mianem obrazu docelowego [46]. Metody tego typu mogą być wykorzystywane m.in. do fuzji wyników badań obrazowych danego pacjenta, uzyskanych przy użyciu różnych technik obrazowych, nakładania danych atlasowych na dane obrazowe, jak również dopasowywania do siebie obrazów, których akwizycja nastąpiła w różnych momentach – jak w echokardiografii [47]. W ostatnim przypadku, dzięki znajomości transformacji, która pozwoliła na dopasowanie obrazów, możliwa jest estymacja wartości przemieszczeń i odkształceń tkanki pomiędzy klatkami. Metoda może być wykorzystywana zarówno do dopasowania obrazów 2D [48], jak i 3D [11]. Wyniki uzyskane przy użyciu algorytmów elastycznego dopasowania obrazów nie wymagają dodatkowej regularyzacji. Metoda umożliwia identyfikację nieprawidłowo funkcjonujących segmentów mięśnia sercowego [48]. Dokładność wyznaczania odkształceń zależy od szczegółów konkretnych implementacji, implementacja opisana w [12] pozwala na czterokrotne zmniejszenie wartości błędu wyznaczania odkształceń w stosunku do metody block matching.

1.5 Wyznaczanie odkształceń w STE


1.5.1 Wyznaczanie przemieszczeń

Pierwszym etapem wyznaczania odkształceń jest wyznaczenie przemieszczeń punktów materialnych, należących do obrazowanego obiektu. W metodach śledzenia spekli, przemieszczenia punktów materialnych są wyznaczone poprzez śledzenie przemieszczeń struktury speklowej na kolejnych klatkach sekwencji echokardiograficznej. Znajomość przemieszczeń poszczególnych punktów materialnych pozwala następnie na wyznaczenie wartości odkształcenia obiektu. Dokładna metodologia wyznaczania przemieszczeń punktów

materialnych jest zależna od zastosowanej metody śledzenia spekli. Metoda wyznaczania przemieszczeń zastosowana w tej pracy została opisana w rozdziale 2.6.2.

1.5.2 Wyznaczanie odkształceń

W aparatach ultrasonograficznych (echokardiograficznych) stosowanych klinicznie, odkształcenia mięśnia sercowego są zazwyczaj wyznaczane jako zmiana długości linii (lub jej odcinków) leżącej wzdłuż epikardium (konturu zewnętrznego), endokardium (konturu wewnętrznego) lub środka ściany [49]. Zdarzają się również implementacje wyznaczające wypadkowe odkształcenie jako wartość uśrednioną z pomiarów wykonanych wzdłuż epikardium, endokardium, i linii środkowej [49]. Najczęściej wykorzystywanym wariantem jest wartość zmiany długości mięśnia wzdłuż środka ściany [10]. Rysunek 4 przedstawia obraz ultrasonograficzny serca, z oznaczonym epikardium, endokardium oraz środkiem ściany.



Rysunek 4 Obraz ultrasonograficzny serca z oznaczonym epikardium, endokardium oraz środkiem ściany.

Wyznaczenie odkształceń globalnych oraz odkształceń w segmentach wzdłuż danej linii jest możliwe dzięki znajomości przemieszczeń przynależnych do niej punktów charakterystycznych. Część punktów charakterystycznych wyznacza granice pomiędzy poszczególnymi segmentami AHA-17, dzięki czemu możliwe jest precyzyjne wyznaczenie całkowitej długości wybranej linii, jak również śledzenie długości poszczególnych segmentów.

Ze względu na to, że wartość odkształcenia jest wyznaczana wzdłuż linii, stosuje się w tym przypadku tzw. odkształcenie inżynierskie [50], opisane wzorem:

$$\varepsilon(t) = \frac{L(t) - L(t_0)}{L(t_0)} \quad 1$$

gdzie:

$\varepsilon(t)$ – odkształcenie inżynierskie obiektu w chwili t

$L(t)$ – długość obiektu w chwili t

$L(t_0)$ – początkowa długość obiektu

Wyznaczanie linii, wzdłuż której wyznaczana jest wartość odkształcenia może być przeprowadzane ręcznie przez specjalistę lub w sposób zautomatyzowany. Śledzenie położenia punktów materialnych, rozmieszczonych wzdłuż wybranej linii pozwala na określenie jej długości w kolejnych klatkach sekwencji echokardiograficznej, a następnie wyznaczenie wartości odkształcenia zgodnie z równaniem 1.

1.5.3 Zależność pomiędzy dokładnością wyznaczania odkształceń a ich wartością

Dokładność wyznaczania odkształceń na podstawie danych echokardiograficznych jest zależna od wartości odkształcenia obiektu i jest najwyższa w przypadku, gdy wartości odkształceń pomiędzy kolejnymi klatkami sekwencji obrazów przyjmują wartości około 1%. Ze względu na charakter zjawisk rozpraszania i interferencji fal dźwiękowych, znaczące modyfikacje kształtu obiektu powodują zmiany w strukturze speklowej, nie odzwierciedlające wprost ruchu obiektu. Dochodzi do dekorelacji sygnału, powodującej pogorszenie dokładności wyznaczania przemieszczeń pomiędzy dwiema klatkami, obrazującymi różne, oddalone w czasie, fazy cyklu pracy mięśnia sercowego. Z kolei wyznaczanie przemieszczeń o niższych wartościach jest obarczone zwiększonym błędem, ze względu na niewystarczającą rozdzielczość przestrzenną obrazów. Wykres przedstawiający stosunek sygnału do szumu w wyjściowej informacji o odkształceniu, w zależności od wartości rzeczywistego odkształcenia obiektu, przyjmuje kształt zbliżony do charakterystyki filtra środkowoprzepustowego – w związku z czym jest w literaturze opisywana jako tzw. strain filter [51]. Śledzenie spekli daje najlepsze efekty w przypadku, gdy wartość odkształcenia obiektu pomiędzy kolejnymi klatkami sekwencji jest zbliżona do optimum, czyli jest na tyle niewielka, że struktura speklowa na sąsiednich klatkach

pozostaje relatywnie niezmieniona, ale jednocześnie na tyle duża, aby rozdzielczość obrazu nie stanowiła czynnika, ograniczającego dokładność wyznaczania przemieszczeń i odkształceń [51], [52]. W związku z tym do uzyskania możliwie wysokiej dokładności wyznaczania przemieszczeń i odkształceń konieczne jest śledzenie spekli pomiędzy klatkami, których akwizycja nastąpiła w odpowiednim odstępnie czasowym, a następnie sumowanie uzyskanych wektorów przemieszczeń.

1.6 Segmentacja w STE

Segmentacja danych echokardiograficznych pozwala na wyodrębnienie z obrazu ultrasonograficznego mięśnia sercowego obszarów, należących do poszczególnych struktur anatomicznych, m.in. ścian komór i przedsionków, czy zastawek. Stanowi ona istotny element procesu diagnostycznego – informacje pochodzące z segmentacji są wykorzystywane do ustalenia obszaru zainteresowania (Region Of Interest, ROI), który jest wykorzystywany do dalszej analizy obrazu i daje informację o tym, który dokładnie obszar obrazu odpowiada tkance mięśnia sercowego [8]. Dane z segmentacji (ręcznej lub automatycznej), pozwalają na wyodrębnienie z obrazu danych, dotyczących lewej komory serca i odseparowanie ich od części obrazu, dotyczących przedsionków, zastawek, wnętrza komory itp., dzięki czemu możliwa jest dalsza analiza danych dotyczących poszczególnych struktur tkankowych, m.in. wyznaczanie ich przemieszczeń i odkształceń.

1.7 Techniki segmentacji w echokardiografii

Segmentacja obrazu echokardiograficznego może być wykonywana ręcznie, przez eksperta. Istnieje również szereg rozwiązań automatycznych i półautomatycznych, pozwalających na szybsze przeprowadzenie tego procesu, spośród których wyróżnić można metody oparte na tzw. aktywnych konturach oraz nowsze metody, bazujące na sieciach neuronowych i uczeniu maszynowym, które zostały wykorzystane w tej pracy.

1.7.1 Ocena dokładności segmentacji

W niniejszej pracy wykorzystywane są pochodzące z segmentacji binarne maski, stanowiące informację o przynależności punktów, odpowiadających określonym współrzędnym na obrazie, do mięśnia lewej komory serca. Przynależność do obszaru zainteresowania - lewej komory serca jest w nich oznaczona wartością 1, zaś jej brak wartością 0. Dokładność segmentacji można ocenić poprzez porównanie masek pochodzących z segmentacji, z maskami

referencyjnymi, które dokładnie określają położenie struktur, stanowiących obiekt zainteresowania. Istnieje szereg miar, służących do oceny jakości segmentacji, takich jak indeks Jaccarda, czy współczynnik Dice'a. W pracy ocena dokładności segmentacji jest wykonywana przy użyciu współczynnika Dice'a, będącego powszechnie stosowaną miarą dokładności segmentacji [53], [54], opisanego wzorem:

$$D_c = \frac{2|A \cap B|}{|A| + |B|} \quad 2$$

gdzie:

D_c – współczynnik Dice'a,

$|A \cap B|$ – liczba pikseli, których wartości w masce referencyjnej i masce uzyskanej w procesie segmentacji są sobie równe,

$|A|$ – liczba pikseli maski referencyjnej,

$|B|$ – liczba pikseli maski uzyskanej w procesie segmentacji.

1.7.2 Segmentacja metodą aktywnego konturu

Metoda aktywnego konturu polega na wykorzystaniu odkształcalnego modelu konturu segmentowanego obszaru, którego postać wejściowa jest predefiniowana. Segmentacja przebiega poprzez zmiany położenia oraz odkształcenia wspomnianego modelu, wykonywane w taki sposób, aby zminimalizować sumę działających na model sił zewnętrznych, w postaci gradientu intensywności pikseli obrazu oraz sił wewnętrznych: energii zginania i rozciągania modelu [55]. Takie podejście gwarantuje uzyskanie ciągłego, zamkniętego konturu, co jest szczególnie istotne w przypadku danych ultrasonograficznych, gdzie niski stosunek sygnału do szumu znacząco utrudnia segmentację [55]. Dzięki temu możliwa jest skuteczna klasyfikacja punktów obrazu jako należących do obszaru zainteresowania oraz jego otoczenia. Użycie aktywnych konturów pozwala na uzyskanie masek, o jakości porównywalnej z maskami, uzyskiwanymi podczas segmentacji ręcznej, wykonywanej przez ekspertów [56], [57].

1.7.3 Metody segmentacji oparte na sieciach neuronowych i uczeniu maszynowym

Metody oparte na sieciach neuronowych i uczeniu maszynowym, polegają na wykorzystaniu tych narzędzi do podziału obrazu na klasy, reprezentujące poszczególne struktury tkankowe. Do wykorzystania tych metod konieczne jest posiadanie licznego zbioru danych referencyjnych, które mogą być użyte jako dane uczące. Metody te pozwalają na uzyskanie masek wysokiej jakości, o wartości współczynnika Dice'a (wzór 2), przekraczającej 0,9 [14], [58].

1.8 Algorytm elastycznego dopasowania obrazów

Niniejsza praca poświęcona jest opracowaniu nowego wariantu metody elastycznego dopasowania obrazów do celów STE. Z tego względu istotne jest zapoznanie czytelnika ze szczegółami, dotyczącymi tej techniki cyfrowego przetwarzania obrazów.

Elastyczne dopasowanie obrazów jest metodą, której wykorzystanie do wyznaczania przemieszczeń i odkształceń w danych echokardiograficznych, jest szeroko opisane w literaturze [11], [12], [59], [60]. Metoda ta polega na dopasowaniu jednego obrazu (obraz odkształcany) do innego obrazu (obraz docelowy), poprzez geometryczne przekształcenie go w taki sposób, aby obraz wynikowy cechował się możliwie największym podobieństwem do obrazu docelowego. W omawianym zastosowaniu informacja o przemieszczeniach punktów obrazu odkształcanego, które pozwoliły na uzyskanie obrazu wynikowego, stanowi informację o przemieszczeniach punktów obrazowanego obiektu. Algorytm elastycznego dopasowania obrazów składa się z czterech zasadniczych elementów: transformacji, interpolacji, funkcji kosztu i optymalizacji. W poniższym rozdziale opisany jest wariant algorytmu uznawany w literaturze tematu za podstawowy [61], [62].

1.8.1 Transformacja

Transformacja polega na przekształceniu geometrycznym obrazu poprzez zmianę położenia węzłów nałożonej na płaszczyznę obrazu siatki kontrolnej. Siatka wejściowa składa się z równomiernie rozłożonych węzłów. Położenia poszczególnych punktów, należących do płaszczyzny obrazu, są powiązane z położeniami węzłów siatki przy użyciu wybranej funkcji, która jest wykorzystywana do interpolacji położenia punktów należących do płaszczyzny obrazu, skutkującej przekształceniem obrazu. Historycznie w algorytmach elastycznego dopasowania

obrazów wykorzystywane były różne typy funkcji, takie jak funkcje wielomianowe [63], funkcje harmoniczne [64], czy falki [65], jednak ze względu na lokalny charakter działania i stosunkowo niską złożoność obliczeniową [61], najpopularniejszym typem funkcji, stosowanych w algorytmach elastycznego dopasowania obrazów są krzywe B-sklejane [47], [48], [60], [66].

1.8.1.1 Krzywe B-sklejane

W pracy zastosowane zostały krzywe B-sklejane o węzłach rozłożonych równomiernie, w odległości równej 1 (odległość między węzłami siatki określa jednostkę w układzie współrzędnych), wszystkie zamieszczone wzory i opisy dotyczą tego przypadku.

Bazowa krzywa B-sklejana n-tego stopnia jest opisana wzorem [67]:

$$\beta^n(x) = \sum_{j=0}^{n+1} \frac{(-1)^j}{n!} \binom{n+1}{j} \left(x + \frac{n+1}{2} - j\right)^n \cdot \mu\left(x + \frac{n+1}{2} - j\right), (x \in R) \quad 3$$

gdzie μ oznacza skok jednostkowy:

$$\mu(a) = \begin{cases} 0, & a < 0 \\ 1, & a \geq 0 \end{cases} \quad 4$$

Istotną własnością krzywych B-sklejanych, jest fakt, że z pomocą sumy ważonej przesuniętych bazowych krzywych B-sklejanych możliwe jest zapisanie dowolnej (n-1) – różniczkowalnej krzywej wielomianowej stopnia n. W przypadku krzywych B-sklejanych, cechujących się równomiernym rozłożeniem węzłów (punktów, w których łączą się poszczególne segmenty krzywej B-sklejanej), takie złożenie przyjmuje postać:


$$f(x) = \sum_{i=-\infty}^{+\infty} c(i)\beta^n(x - i) \quad 5$$

gdzie $f(x)$ – ciągła (n-1) – różniczkowalna funkcja wielomianowa,

$c(i)$ – współczynnik wagowy i-tej krzywej B-sklejanej,

$\beta^n(x - i)$ – bazowa krzywa B-sklejana stopnia n.

Rysunek 5 pokazuje wykres krzywej bazowej trzeciego stopnia. Przyjmuje ona wartości różne od 0 jedynie w obszarze od -2 do 2, zatem jej oddziaływanie ma charakter lokalny, co znacząco przyspiesza działanie opartych na niej algorytmów.



Rysunek 5 Znormalizowana bazowa krzywa B-sklejana trzeciego stopnia

1.8.1.2 Transformacja punktów

Dopasowanie obrazu dopasowywanego, do obrazu docelowego, odbywa się dzięki jego deformacji, przez zmiany położenia węzłów siatki kontrolnej, nałożonej na płaszczyznę obrazu.

Zależność położenia pojedynczego punktu, od położenia węzłów siatki kontrolnej, w której odległość między węzłami wynosi 1, jest opisana jako iloczyn tensorowy krzywych B-sklejanych trzeciego stopnia:

$$T(x, y) = [x_p, y_p]$$

$$x_p = \sum_{m=0}^3 \sum_{n=0}^3 B_m(u) B_n(v) x_{\phi_{i+m, j+n}} \quad 6$$

$$y_p = \sum_{m=0}^3 \sum_{n=0}^3 B_m(u) B_n(v) y_{\phi_{i+m, j+n}}$$

gdzie:

$T(x,y)$ – położenie punktu o współrzędnych początkowych x i y po transformacji,

x_p, y_p – współrzędne x i y punktu po transformacji,

$x_{\emptyset_{i+m,j+n}}$ – współrzędna x węzła siatki o indeksach $i+m$ i $j+n$,

$y_{\emptyset_{i+m,j+n}}$ – współrzędna y węzła siatki o indeksach $i+m$ i $j+n$,

$B_m(u)$ – wartość m -tej bazowej krzywej B-sklejanej trzeciego stopnia w u , wyznaczona równaniami:

$$B_0(u) = \frac{(1-u)^3}{6}$$

$$B_1(u) = \frac{3u^3 - 6u^2 + 4}{6} \quad 7$$

$$B_2(u) = \frac{-3u^3 + 3u^2 + 3u + 1}{6}$$

$$B_3(u) = \frac{u^3}{6}$$

$B_n(v)$ – analogicznie jak w przypadku $B_m(u)$ - wartość n -tej bazowej krzywej B-sklejanej trzeciego stopnia w v ,


i, j, u, v – współrzędne pomocnicze, opisane następującymi wzorami:

$$i = [x] - 1, j = [y] - 1 \quad 8$$

$$u = x - [x], v = y - [y] \quad 9$$

gdzie $[x]$ oznacza zaokrąglenie x w dół, do liczby całkowitej.

Ze względu na charakter wykorzystanych krzywych, przesunięcie jednego węzła siatki ma działanie lokalne – wpływa na położenie punktów obrazu położonych w odległości nie większej niż dwukrotność początkowej odległości między węzłami w każdym z kierunków. Oznacza to, że w wariacie dwuwymiarowym na położenie punktu po transformacji ma wpływ położenie szesnastu położonych najbliższych węzłów (Rysunek 6).



Rysunek 6 Węzły siatki, wpływające na punkt x (niebieski). Czarne punkty oznaczają węzły siatki kontrolnej, czarna, pogrubiona linia – granice obrazu, czerwone punkty – węzły siatki, których położenie ma wpływ na położenie punktu x w przypadku zastosowania krzywych B-sklejanych trzeciego stopnia.

1.8.2 Interpolacja

Typowo dopasowaniu podlegają obrazy rastrowe, jednak współrzędne punktów po transformacji przy użyciu siatki kontrolnej i krzywych B-sklejanych, mogą przyjmować dowolne wartości ze zbioru liczb rzeczywistych, dlatego nowe wartości intensywności w równomiernie rozłożonych punktach płaszczyzny obrazu pierwotnego, odpowiadających położeniu pikseli nie są znane. W związku z tym, aby obraz po przekształceniu mógł być porównany z obrazem docelowym, konieczne jest wykonanie interpolacji obrazu. W tym celu wykorzystywane mogą być algorytmy interpolacji takie jak interpolacja przy użyciu krzywych B-sklejanych [48], [61], czy interpolacja trygonometryczna [12].

1.8.3 Funkcja kosztu

Funkcja kosztu jest miarą, pozwalającą na ilościową ocenę dopasowania obrazów. Jej wartość podlega minimalizacji w procesie optymalizacji położenia węzłów siatki kontrolnej, a jej zastosowanie powinno umożliwiać uzyskanie transformacji obrazu, możliwie najlepiej odzwierciedlającej przemieszczenie obrazowanego obiektu. Typową postacią funkcji kosztu,

w algorytmach elastycznego dopasowania obrazów, stosowanych do wyznaczania przemieszczeń w danych echokardiograficznych, jest funkcja, będąca sumą dwóch miar: miary podobieństwa obrazów – miary pozwalającej na ocenę podobieństwa obrazu dopasowywanego i obrazu docelowego oraz miary gładkości funkcji transformacji [11], [12]:

$$F_c = Q + \omega_s P_s \quad 10$$

gdzie:

Q – miara podobieństwa obrazów dopasowywanego i docelowego,

ω_s – waga miary gładkości funkcji transformacji,

P_s – wartość miary gładkości funkcji transformacji.

Miara gładkości w literaturze jest nazwana karą gładkości i takie nazewnictwo będzie stosowane w dalszej części pracy.

1.8.3.1 Miara podobieństwa obrazów

Kluczowym elementem algorytmu elastycznego dopasowania obrazów jest porównanie obrazu dopasowywanego, podlegającego transformacji oraz obrazu docelowego. Służy temu miara podobieństwa obrazów stanowiąca element funkcji kosztu algorytmu. W przypadku dopasowywania do siebie obrazów uzyskanych przy użyciu tej samej metody obrazowej często stosowaną miarą podobieństwa jest suma kwadratów różnic intensywności pikseli w obrazie dopasowywanym i docelowym (SSD – sum of squared differences) [11], [12], [48], [59], [61]. Jest to miara opisana wzorem:

$$Q = \frac{\sum_{i=1}^{ixmax} \sum_{j=1}^{iymax} (i_1(i, j) - i_2(i, j))^2}{ixmax \cdot iymax} \quad 11$$

gdzie:

i_1, i_2 – porównywane obrazy,

i, j – indeksy pikseli obrazów,

$ixmax$ – całkowita liczba pikseli obrazu w osi x,

$iymax$ – całkowita liczba pikseli obrazu w osi y.

Innym popularnym wariantem miary podobieństwa obrazów, stosowanym w literaturze jest informacja wzajemna [62], jest to jednak metoda odpowiednia do porównywania danych,

pochodzących z różnych modalności, cechujących się odmiennymi charakterystykami intensywności pikseli.

Historycznie wykorzystywane były również inne miary podobieństwa obrazów, takie jak współczynnik korelacji, momenty rozkładu wartości w przestrzeni cech obrazu, czy entropia przestrzeni cech obrazu [68].

1.8.3.2 Kara gładkości

Oparcie funkcji kosztu algorytmu wyłącznie na porównaniu danych obrazowych może nie być wystarczające do uzyskania odpowiedniej dokładności wyznaczania przemieszczeń i odkształceń mięśnia sercowego. Ze względu na błędy estymacji przemieszczeń, prowadzące do niezadowolających wyników estymacji odkształceń, konieczna jest dodatkowa regularyzacja transformacji. Jest ona wprowadzana do algorytmów elastycznego dopasowania obrazów w postaci tzw. kary gładkości [62], [66], [69], która jest opisana następującym wzorem [69]:

$$P_s = \int_x \int_y \left(\frac{\partial^2 T}{\partial x^2} \right)^2 + \left(\frac{\partial^2 T}{\partial y^2} \right)^2 + 2 \cdot \left(\frac{\partial^2 T}{\partial x \partial y} \right)^2 dx dy \quad 12$$

gdzie T oznacza funkcję transformacji, jakiej poddawane są punkty obrazu (równanie 6.).

Wzór ten w przypadku danych dyskretnych, może być zamieniony na:

$$P_s = \frac{1}{N_d} \sum_{x,y \in D} \left[\left(\frac{\partial^2 T}{\partial x^2} \right)^2 + \left(\frac{\partial^2 T}{\partial y^2} \right)^2 + 2 \cdot \left(\frac{\partial^2 T}{\partial x \partial y} \right)^2 \right] \quad 13$$

gdzie N_d – liczba wszystkich punktów obrazu, zaś pochodne transformacji opisanej z użyciem funkcji B-sklejanych są wyznaczane w następujący sposób:

$$\begin{aligned} \frac{\partial^2 T}{\partial x^2} &= \frac{1}{\delta_x^2} \sum_{l=0}^3 \sum_{m=0}^3 \frac{\partial^2 B_l(u)}{\partial u^2} B_m(v) \varphi_{i+l,j+m} \\ \frac{\partial^2 T}{\partial y^2} &= \frac{1}{\delta_y^2} \sum_{l=0}^3 \sum_{m=0}^3 \frac{\partial^2 B_m(v)}{\partial v^2} B_l(u) \varphi_{i+l,j+m} \\ \frac{\partial^2 T}{\partial x \partial y} &= \frac{1}{\delta_x \delta_y} \sum_{l=0}^3 \sum_{m=0}^3 \frac{dB_l(u)}{du} \frac{dB_m(v)}{dv} \varphi_{i+l,j+m} \end{aligned} \quad 14$$

gdzie:

B_m - m-ta bazowa funkcja B-sklejana, zdefiniowana w rozdziale 1.8.1.2,

u, v – współrzędne pomocnicze, zdefiniowane w rozdziale 1.8.1.2,

$\varphi_{i+l,j+m}$ – aktualne współrzędne węzła siatki, o współrzędnych początkowych równych $i+l$ i $j+m$.

Wykorzystanie kary gładkości wiąże się z ryzykiem nadmiernej regularyzacji wyznaczanych przemieszczeń, manifestującej się nadmiernym ograniczeniem lokalnych amplitud wyznaczanych odkształceń. Może to prowadzić do uzyskania niepoprawnych wyników, szczególnie w niewielkich powierzchniowo obszarach mięśnia sercowego, cechujących się zmienioną kurczliwością i utrudnić np. detekcję małych zmian pozawałowych. Dlatego też istotny jest dobór wagi tej kary w taki sposób, aby osiągnąć efekt regularyzacji transformacji, bez jej nadmiernego ograniczenia.

1.8.4 Optymalizacja

Optymalizacja jest elementem algorytmu, pozwalającym na znalezienie takich nowych położeń węzłów siatki kontrolnej, aby funkcja kosztu osiągnęła możliwie najmniejszą wartość (w najbardziej pożądanym przypadku jej minimum globalne). W algorytmach elastycznego dopasowania obrazów wykorzystywane są strategie optymalizacyjne oparte na gradiencie funkcji kosztu, np. metoda gradientu prostego lub cechująca się szybszym działaniem, oszczędnością pamięci oraz dobrą dokładnością w znajdowaniu minimum, funkcji wielu zmiennych [70] quasi-Newtonowska iteracyjna strategia optymalizacyjna Low Memory Broyden-Fletcher-Goldfarb-Shanno (L-BFGS) [11], [12].

1.9 Wykorzystanie informacji o konturze w elastycznym dopasowaniu obrazów

Dane pochodzące z segmentacji obiektu stanowią dodatkową informację o nim, która może być wykorzystywana przy wyznaczaniu przemieszczeń. W literaturze dostępne są wyniki prób łączenia procesów segmentacji i dopasowania obrazów w zróżnicowanych zastosowaniach medycznych. W 2011 Lu i in. [71] opracowali metodę, pozwalającą na połączenie algorytmów segmentacji i dopasowania obrazów, uzyskanych przy użyciu tomografii komputerowej, z korzyścią dla wyników obu procesów. W rozwiązaniu tym zastosowana została metoda

iteracyjna, polegająca na naprzemiennym wykonywaniu operacji segmentacji przy użyciu metody aktywnego konturu oraz elastycznego dopasowania obrazów, opartego na krzywych B-sklejanych trzeciego stopnia i wykorzystaniu wyników z poprzedzającej operacji, jako czynnika wpływającego na operację bieżącą. Takie podejście pozwoliło na uzyskanie dokładniejszej informacji o przemieszczeniach i zmianach wymiarów tkanek pacjenta pomiędzy dniem planowania radioterapii oraz dniem wykonania radioterapii nowotworów prostaty i szyjki macicy, dzięki czemu zabiegi mogły być przeprowadzone w sposób bardziej efektywny, z mniejszym narażeniem pacjentów na efekty uboczne. Połączenie procesów segmentacji i dopasowania obrazów z tomografii komputerowej, wykorzystywanych w radioterapii raka prostaty, zostało również opisane w pracy Elmahdy i in. [72], gdzie zastosowana została sieć neuronowa GAN (Generative Adversarial Network), wykonująca jednocześnie obie operacje, co pozwoliło na uzyskanie lepszych wyników i wyraźne skrócenie czasu wykonywania obliczeń.

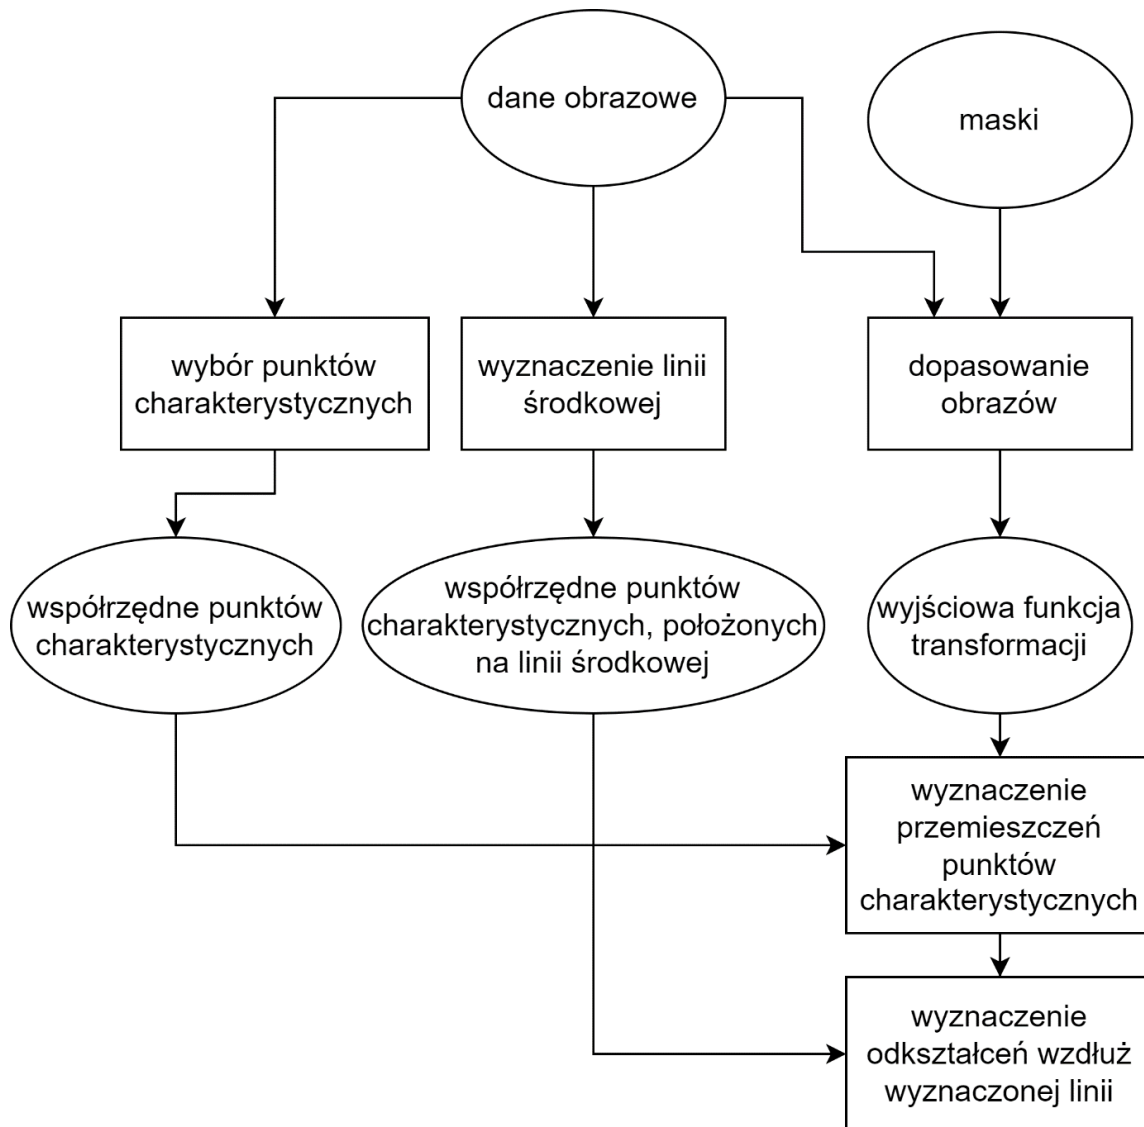
Informacja pochodząca z procesu segmentacji została również wykorzystana do poprawy dokładności i niezawodności algorytmów śledzenia spekli, przy użyciu radialnych funkcji bazowych [73], [74], [75], [76]. Metoda ta polega na połączeniu wyników śledzenia kształtu (wyznaczanie przemieszczeń na podstawie masek uzyskanych z segmentacji danych) oraz śledzenia spekli, przy użyciu interpolacji opartej na radialnych funkcjach bazowych. To podejście było testowane w szeregu prac, gdzie wykorzystywane były dane echokardiograficzne, pochodzące z badań psów, zaś walidacja była przeprowadzana poprzez porównanie z wynikami uzyskanymi przy użyciu rezonansu magnetycznego [73], [75], [76] oraz sonomikrometrii [74]. Zastosowanie tej metody pozwoliło na uzyskanie wyższej, w porównaniu z tradycyjnym śledzeniem spekli, korelacji z metodą odniesienia.

Inne podejście do dołączania informacji z segmentacji do analizy obrazu zostało przyjęte przez Mahapatra i in. [77], którzy opisali w swojej pracy metodę elastycznego dopasowania obrazów, opartą na polach losowych Markowa (MRF). W związku z dyskretnym charakterem procesu dopasowania obrazów opartego na MRF, informacja z segmentacji została włączona do funkcji kosztu algorytmu jako czynnik regularyzujący transformację. Metoda została przez autorów przetestowana na kilku zestawach danych, w tym na prostych obrazach syntetycznych oraz danych z rezonansu magnetycznego serca i mózgu i pozwoliła na uzyskanie wyników lepszych niż inne metody, w szczególności w przypadku danych, cechujących się niskim stosunkiem sygnału do szumu.

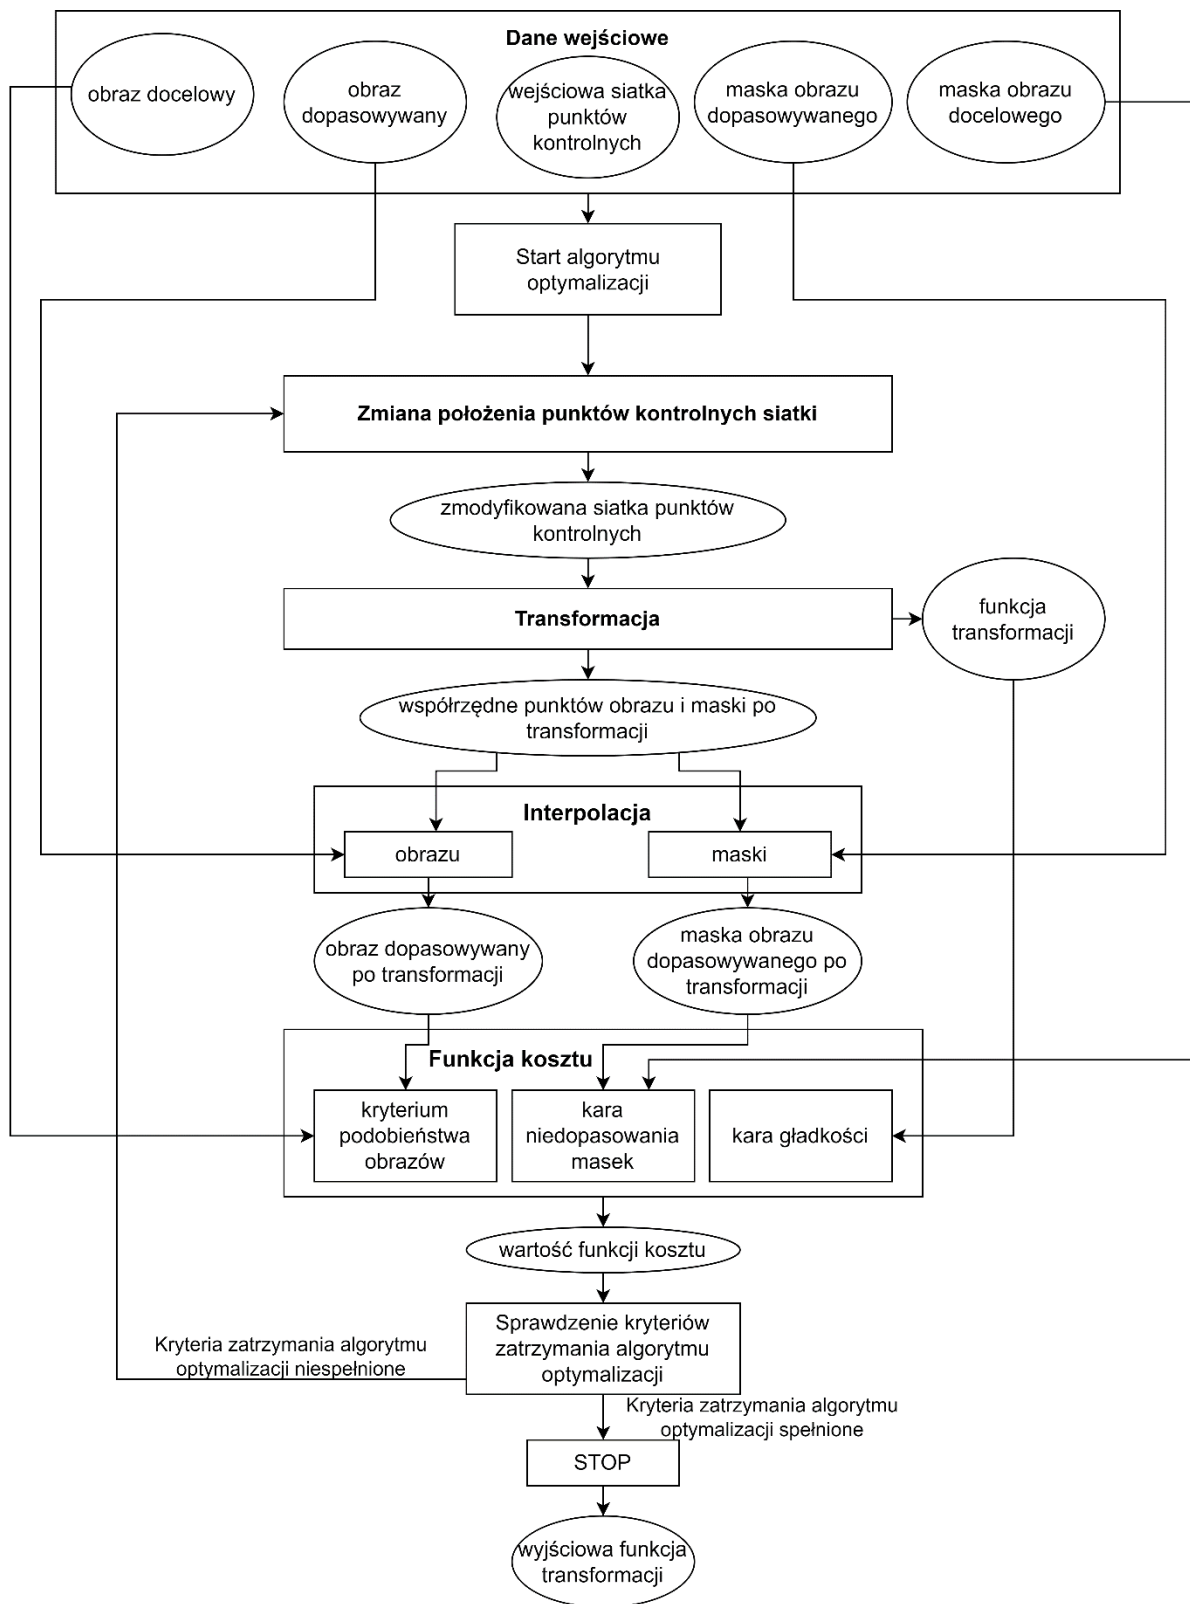
W niniejszej pracy wykorzystane zostało niestosowane wcześniej w algorytmach elastycznego dopasowania obrazów, opartych na krzywych B-sklejanych, służących do dopasowania danych echokardiograficznych podejście, polegające na zawarciu informacji pochodzącej z segmentacji w funkcji kosztu algorytmu.

2 Proponowany algorytm i jego implementacja

Zaproponowana w pracy nowa wersja algorytmu elastycznego dopasowania obrazów została zaimplementowana w środowisku MATLAB. Rysunek 7 przedstawia schemat procedury wyznaczania przemieszczeń i odkształceń, zaś Rysunek 8 przedstawia algorytm dopasowania obrazów stanowiący część procedury przedstawionej na rysunku 7. Szczegóły metody oraz jej implementacji zostały opisane w niniejszym rozdziale.



Rysunek 7 Schemat procesu wyznaczania przemieszczeń i odkształceń




Rysunek 8 Schemat procesu dopasowania obrazów

2.1 Segmentacja

W zaproponowanym w pracy algorytmie, krokiem wstępnym, wykonywanym przed rozpoczęciem procesu dopasowania obrazów, jest segmentacja danych, której wynikiem są binarne maski, odpowiadające kolejnym obrazom sekwencji. W maskach tych wartość 1 odpowiada punktom, należącym do tkanki mięśniowej lewej komory serca, zaś wartość 0 – pozostałej części obrazu. W zależności od typu danych obrazowych, segmentacja była wykonywana przy wykorzystaniu metody aktywnego konturu lub sieci neuronowych. Więcej informacji na temat procesu segmentacji poszczególnych typów danych jest zawarte w rozdziale 3.1.

2.2 Transformacja

W zaimplementowanym w ramach tej pracy wariacie algorytmu elastycznego dopasowania obrazów z użyciem krzywych B-sklejanych, węzły wejściowej siatki punktów kontrolnych są rozłożone równomiernie, zaś odległość między nimi wynosi 1. Współrzędne punktów obrazu podlegają przy tym skalowaniu tak, aby jego obszar mieścił się pomiędzy węzłami od 1 do m w osi x i od 1 do n w osi y (patrz Rysunek 9). W ramach pracy wykorzystywana była siatka o $n=m=15$.



Rysunek 9 Źródło: [78] Położenie węzłów siatki względem płaszczyzny obrazu Ω

W prezentowanej pracy wykorzystany został algorytm, bazujący na krzywych B-sklejanych trzeciego stopnia, a transformacja była przeprowadzana zgodnie z opisem, zamieszczonym w rozdziale 1.8.1.

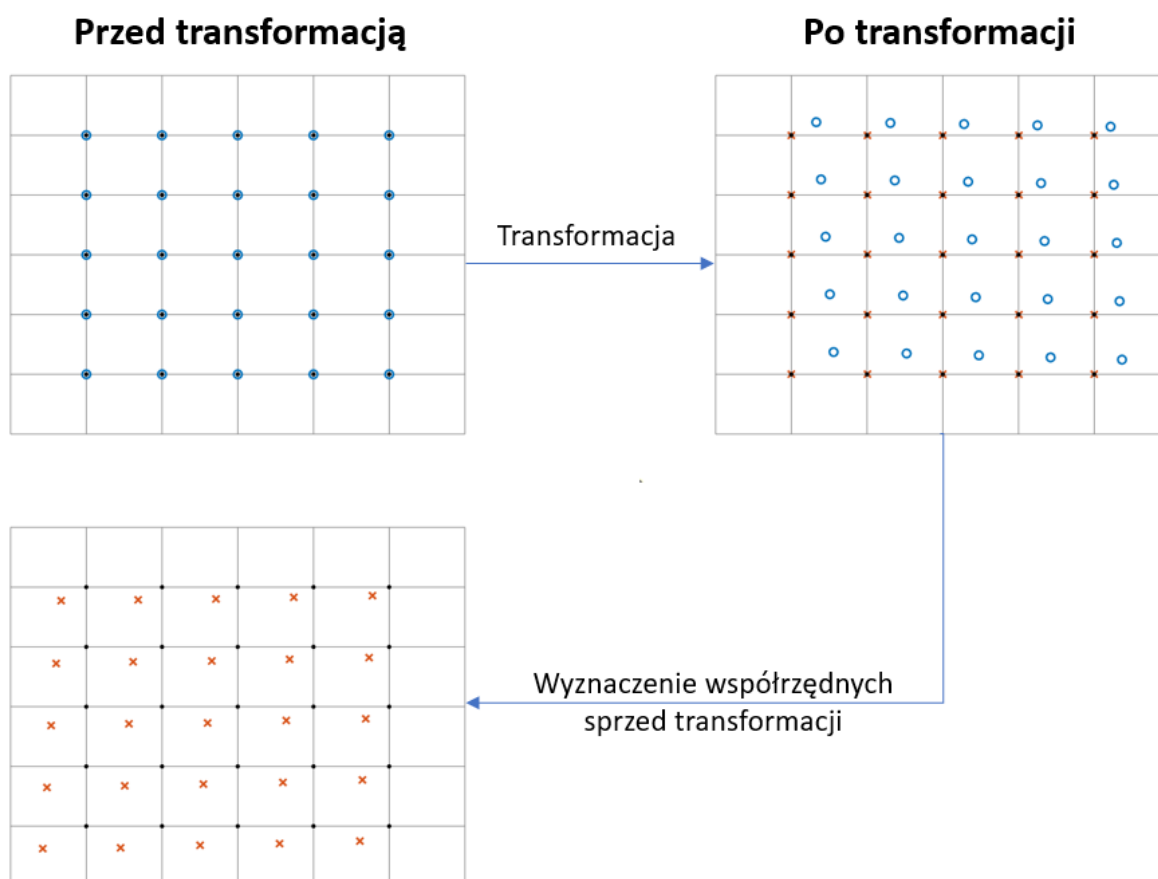
2.3 Interpolacja

W zaproponowanym wariacie algorytmu, transformacji podlegają nie tylko obrazy, ale również odpowiadające im maski. Ze względu na różnice pomiędzy danymi obrazowymi i ich maskami, do każdego rodzaju danych zastosowano inny algorytm interpolacji. Interpolacja obrazów jest wykonywana przy użyciu interpolacji sześcienniej [79], zaś interpolacja masek jest wykonywana przy użyciu metody najbliższego sąsiada.

Etap interpolacji jest realizowany przy użyciu wbudowanej funkcji środowiska MATLAB, służącej do interpolacji dwuwymiarowej: `interp2`, z wykorzystaniem metody ‘cubic’ do interpolacji obrazów i metody ‘nearest’ do interpolacji masek. Została ona wybrana ze względu na wysoką jakość uzyskiwanych wyników oraz szybkość działania.

Ograniczeniem funkcji `interp2` jest wymaganie, aby punkty, których wartość intensywności jest znana, były rozłożone równomiernie. Warunek ten nie jest spełniony w opisywanym zastosowaniu – po zmianie położenia węzłów siatki krzywych B-sklejanych i transformacji, punkty odpowiadające rozłożonym równomiernie pikselom obrazu wejściowego, otrzymują nowe, nierównomiernie rozłożone współrzędne. W związku z tym konieczne jest wyznaczenie współrzędnych początkowych punktów, które po transformacji znalazły się w miejscu pikseli obrazu.

Rysunek 10 obrazuje proces wyznaczania współrzędnych sprzed transformacji. Punkty oznaczone czarnymi znacznikami wskazują położenia pikseli obrazów, punkty oznaczone niebieskimi okrągłymi znacznikami symbolizują punkty, których wartości intensywności są znane, zaś punkty oznaczone pomarańczowymi znacznikami w kształcie x oznaczają punkty, które są położone w miejscu pikseli na obrazie po transformacji.



Rysunek 10 Proces transformacji i wyznaczania współrzędnych sprzed transformacji. Lewy górny róg – piksele obrazu, przed transformacją. Prawy górny róg – stan po transformacji, piksele obrazu wejściowego, których wartości intensywności są znane, znajdują się poza siatką pikseli, w miejscu pikseli znajdują się punkty, oznaczone pomarańczowymi znacznikami, w kształcie x, których wartości intensywności nie są znane. Lewy dolny róg – położenia początkowe punktów, które po transformacji znajdują się w miejscu pikseli.

Znajomość wejściowych współrzędnych punktów, które po transformacji znalazły się w miejscu pikseli, pozwala na wyznaczenie ich wartości intensywności na obrazie wejściowym, dla którego znane są wartości intensywności równomiernie rozłożonych punktów, dzięki czemu możliwe jest skorzystanie z funkcji interp2.

2.4 Funkcja kosztu

Zaproponowana modyfikacja dotychczas wykorzystywanego algorytmu elastycznego dopasowania obrazów polega na dodaniu do funkcji kosztu komponentu, pozwalającego na wykorzystanie informacji o masce, pochodzącej z segmentacji lewej komory mięśnia sercowego, do uzyskania poprawy jakości wyznaczania przemieszczeń i odkształceń. W związku z tą zmianą, funkcja kosztu przyjmuje postać:

$$F_c = Q + \omega_s P_s + \omega_m P_m \quad 21$$

gdzie:

Q – miara podobieństwa obrazów,

ω_s – waga kary gładkości,

P_s – wartość kary gładkości,

ω_m – waga kary niedopasowania masek,

P_m – wartość kary niedopasowania masek.

Miara podobieństwa obrazów oraz kara gładkości przyjmują postać znaną z literatury, zdefiniowaną wzorami 11 i 13, opisaną odpowiednio w rozdziałach 1.8.3.1 oraz 1.8.3.2.

2.4.1 Kara niedopasowania masek

W celu poprawienia dokładności wyznaczania przemieszczeń i odkształceń przy użyciu algorytmu elastycznego dopasowania obrazów w ramach niniejszej pracy opracowano nowy składnik funkcji kosztu nazwany karą niedopasowania masek. Składnik ten pozwala na wykorzystanie informacji uzyskanej w procesie segmentacji obrazów echokardiograficznych.

Wartość kary niedopasowania masek została zdefiniowana jako suma kwadratów różnic (SSD) wartości pikseli maski obrazu dopasowywanego, poddanej procesowi transformacji i interpolacji oraz maski obrazu docelowego:

$$P_m = \frac{\sum_{i=1}^{ixmax} \sum_{j=1}^{iymax} (m_1(i,j) - m_2(i,j))^2}{ixmax \cdot iymax} \quad 22$$

gdzie:

$ixmax$, $iymax$ – liczba pikseli w maskach, odpowiednio w osi x i y ,

m_1 – maska obrazu dopasowywanego, po poddaniu procesom transformacji i interpolacji,

m_2 – maska obrazu docelowego.

Waga kary niedopasowania masek została zdefiniowana jako iloczyn eksperymentalnie dobranego współczynnika (k_m) (patrz rozdział 4) oraz ilorazu sumy kwadratów różnic wartości

intensywności pikseli wszystkich par sąsiadujących obrazów z sekwencji oraz sumy kwadratów różnic wartości intensywności pikseli wszystkich par sąsiadujących masek z sekwencji.

Waga kary niedopasowania masek jest opisana wzorem:

$$\omega_m = k_m \cdot \frac{\sum_{k=1}^{n_i-1} \sum_{i=1}^{ixmax} \sum_{j=1}^{iymax} (i_k(i,j) - i_{k+1}(i,j))^2}{\sum_{k=1}^{n_i-1} \sum_{i=1}^{ixmax} \sum_{j=1}^{iymax} (m_k(i,j) - m_{k+1}(i,j))^2} \quad 23$$

gdzie:

k_m – współczynnik wagowy kary niedopasowania masek,

n_i – liczba obrazów w sekwencji echokardiograficznej,

i_k – k-ty obraz z sekwencji,

m_k – maska, uzyskana dzięki segmentacji k-tego obrazu sekwencji,

$ixmax, iymax$ – wymiar pojedynczego obrazu w pikselach, odpowiednio w kierunkach x i y.

Formuła wagi kary niedopasowania masek wynika z założenia o istnieniu korelacji pomiędzy rozkładami różnic intensywności pikseli sąsiednich klatek a różnicami pomiędzy maskami im odpowiadającymi. Założenie to jest spełnione w sytuacji, w której stosowane maski cechują się wysoką dokładnością. W przypadku, gdy zastosowane maski cechują się niską dokładnością lub obecnością znaczących miejscowych błędów segmentacji, zależność ta zostaje zaburzona, przez zwiększenie różnic pomiędzy maskami. Dzięki umieszczeniu sumy kwadratów różnic w maskach w mianowniku wagi kary niedopasowania masek, wartość wagi zmniejsza się znacząco w sytuacji, gdy zastosowane maski cechują się niską dokładnością. Zabezpiecza to przed zwiększeniem wartości błędów wyznaczania przemieszczeń i odkształceń, wynikającym z zastosowania masek niskiej jakości. Dodatkowo, zastosowanie w wadze informacji o różnicach w wartościach intensywności pikseli obrazów ułatwia dobór wartości współczynnika k_m , poprzez normalizację w stosunku do rozkładu różnic intensywności pikseli obrazów.

2.5 Optymalizacja

W pracy została wykorzystana implementacja metody L-BFGS, opisanej w rozdziale 1.8.4, autorstwa D. Kroona [80]. Tabela 1 zawiera wartości parametrów, warunkujących zakończenie działania algorytmu optymalizacji.

Tabela 1 Wartości parametrów, warunkujących zakończenie działania procesu optymalizacji.

Parametr	Wartość
Maksymalna liczba iteracji	60
Maksymalna liczba wyznaczeń wartości funkcji kosztu	1000
Minimalna zmiana wartości współrzędnych węzłów	0,0001
Minimalna zmiana wartości funkcji kosztu	0,0002

2.6 Wyznaczanie przemieszczeń i odkształceń

2.6.1 Punkty charakterystyczne

Choć technicznie możliwe jest wyznaczanie przemieszczeń i odkształceń mięśnia sercowego w postaci pól ciągłych, miarą powszechnie stosowaną w praktyce klinicznej są odkształcenia mięśnia sercowego wzdłuż wybranych linii (patrz rozdział 1.5.2). W tym celu wyznaczane są przemieszczenia punktów przynależnych do danych linii, przy czym istotnym elementem doboru punktów charakterystycznych jest ich powiązanie z podziałem mięśnia sercowego na segmenty (np. AHA-17) tak, aby możliwe było wyznaczenie odkształceń w segmentach.

W wykorzystywanych w pracy zestawach danych, dla których dostępne są dane referencyjne dotyczące przemieszczeń obiektu, jest ona zapisana w postaci położenia punktów referencyjnych. Są to punkty materialne, których położenie w kolejnych klatkach sekwencji obrazowej jest znane. W celu ułatwienia porównania uzyskanych wyników z informacją referencyjną, te właśnie punkty są wykorzystywane jako punkty charakterystyczne do wyznaczania odkształceń.

2.6.2 Wyznaczanie przemieszczeń

Wyznaczanie przemieszczeń pomiędzy dwiema kolejnymi klatkami sekwencji odbywa się poprzez porównanie współrzędnych punktów referencyjnych sprzed transformacji obrazu dopasowywanego, ze współrzędnymi po transformacji, przy użyciu siatki krzywych B-sklejanych, uzyskanej w procesie optymalizacji.

Do wykonania estymacji przemieszczeń w cyklu pracy serca, konieczna jest znajomość położenia punktów charakterystycznych w kolejnych klatkach sekwencji. Są one wyznaczane w tzw.

procesie akumulacji przemieszczeń. Akumulacja przemieszczeń jest procesem iteracyjnym realizowanym poprzez transformację współrzędnych punktów charakterystycznych przez siatki uzyskane dla następujących po sobie par klatek, co można opisać wzorem:

$$(\varphi_{i,j})_k = T_k((\varphi_{i,j})_{k-1}) \quad 24$$

gdzie:

$\varphi_{i,j}$ – punkt charakterystyczny o współrzędnych początkowych i,j ,

$(\varphi_{i,j})_k$ – położenie punktu charakterystycznego o współrzędnych początkowych i,j wyznaczone w klatce k ,

T_k – siatka krzywych B-sklejanych służąca do transformacji pomiędzy klatkami $k-1$ i k ($k \in \{2, \dots, n\}$, gdzie n – całkowita liczba klatek w sekwencji).

Przemieszczenia punktów charakterystycznych pomiędzy klatkami mogą być następnie wyznaczone w następujący sposób:

$$(\Delta\varphi_{i,j})_{k,l} = (\varphi_{i,j})_k - (\varphi_{i,j})_l \quad 25$$

gdzie:

$(\Delta\varphi_{i,j})_{k,l}$ – przemieszczenie punktu charakterystycznego, o współrzędnych początkowych i, j , pomiędzy klatkami k i l .

2.6.3 Wyznaczanie odkształceń

Informacje o przemieszczeniach, uzyskane w sposób, opisany w rozdziale 2.6.2 są wykorzystywane do wyznaczania odkształceń mięśnia sercowego. Odkształcenia są wyznaczone w segmentach mięśnia lewej komory, zgodnie z podziałem AHA-17 [18] oraz globalnie.

Krzywe zmian wartości odkształcenia segmentów w czasie są wyznaczone zgodnie z rekomendacjami z [49], jako procentowa zmiana długości segmentu, przy czym za długość segmentu przyjmowana jest długość krzywej, łączącej punkty charakterystyczne, położone wzdłuż linii środkowej (patrz Rysunek 4). Odkształcenie j -tego segmentu w i -tej klatce sekwencji echokardiograficznej jest opisane wzorem:

$$\varepsilon_j(i) = \frac{L_j(i) - L_j(1)}{L_j(1)} \quad 26$$

gdzie:

ε_j – krzywa odkształceń (wyrażona w procentach), w czasie, w j-tym segmencie,

i – indeks klatki,

$L_j(i)$ – długość wycinka linii środkowej, odpowiadającego segmentowi j w klatce i ,

$L_j(1)$ – długość wycinka linii środkowej, odpowiadającego segmentowi j w klatce końcowo – rozkurczowej.

Krzywe globalne zmian wartości odkształcenia w czasie są wyznaczane jako procentowa zmiana długości całego mięśnia sercowego, przy czym za długość mięśnia sercowego przyjmowana jest długość krzywej, łączącej punkty charakterystyczne, położone wzdłuż linii środkowej. Odkształcenie globalne jest wyznaczone analogicznie jak odkształcenie w segmentach (wzór 26).

3 Walidacja opracowanej metody

3.1 Dane walidacyjne


Do oceny dokładności działania algorytmu i określenia czynników na nią wpływających w pracy wykorzystane zostały cztery zestawy danych:

- dane syntetyczne, przedstawiające fantom lewej komory serca,
- dane z obrazowania fantomu lewej komory serca,
- dane semi-syntetyczne,
- dane kliniczne.

3.1.1 Dane syntetyczne

Jednym z zestawów danych, wykorzystanych w pracy, są dane syntetyczne, symulujące sekwencję obrazów ultrasonograficznych fantomu lewej komory serca zarejestrowanych w trakcie jednego cyklu pracy serca. Dane te zostały wygenerowane w Zakładzie Inżynierii Biomedycznej na Wydziale Mechatroniki Politechniki Warszawskiej [81]. Do wygenerowania danych posłużył model numeryczny materialnego fantomu (Rysunek 11). Fantom miał kształt elipsoidy, o długości w fazie skurczu, wynoszącej 80 mm, grubości ściany w fazie skurczu, równej 15 mm i pojemności komory w fazie skurczu, wynoszącej 52 ml. Jako model materiału wykorzystano materiał o charakterze izotropowym i hipersprężystym. W pracy wykorzystane zostały zarówno obrazy, przedstawiające fantom o jednorodnych właściwościach mechanicznych, jak i fantom zawierający obszary o podwyższonej sztywności, imitujące fragmenty mięśnia sercowego o obniżonej kurczliwości.

Symulacja mechaniczna została przeprowadzona przy wykorzystaniu metody elementów skończonych (MES). Odkształcenie modelu, symulujące odkształcenie mięśnia sercowego w cyklu pracy, było wymuszane poprzez przyłożenie wewnątrz modelu ciśnienia, o maksymalnej wartości 36 kPa. Ciśnienie w komorze fantomu było zmieniane stopniowo, zgodnie z krzywą, która pozwalała na uzyskanie zmian objętości modelu, zbliżonych do zmian objętości mięśnia sercowego podczas cyklu pracy [82].



Rysunek 11 Źródło: [83] Widok przekroju modelu numerycznego fantomu lewej komory serca, poszczególne kolory oznaczają wartości składowej tensora odkształceń w kierunku osi długiej

Symulacja procesu akwizycji danych ultrasonograficznych modelu została wykonana przy użyciu oprogramowania FIELD II [84], [85]. Ustawienia symulacji były dobrane w taki sposób, aby efekt odwzorowywał wykorzystanie komercyjnego urządzenia Sonix Touch RP (Ultrasonix Medical Corp., Richmond BS, Kanada) z głowicą sektorową SA4 2/24. Płaszczyzna obrazowania znajdowała się 40 mm od podstawy modelu (w stanie nieodkształconym), zaś symulacja skanowania była wykonana z parametrami: częstotliwość wzbudzenia: 2,8 MHz, szerokość sektora: 60°, liczba linii: 109, częstotliwość próbkowania: 80 MHz, ogniskowanie na głębokości: 9,5 cm, długość linii: 14 cm. Obrazy były generowane z częstotliwością 50 klatek na sekundę. Uzyskane dane były następnie poddane demodulacji kwadraturowej, wyznaczeniu obwiedni oraz dwuwymiarowej interpolacji liniowej, co pozwoliło na uzyskanie obrazu o rozdzielczości przestrzennej 0,16 x 0,23 mm oraz rozmiarze 600x600 pikseli.

W pracy wykorzystane zostały dane w widoku osi krótkiej. W danych wyodrębnionych zostało 288 punktów charakterystycznych. Średnia wartość bezwzględna przemieszczenia punktu charakterystycznego w trakcie całego cyklu, zarówno w kierunku x, jak i y wyniosła 2,5 mm.

3.1.1.1 Maski

W pracy z danymi syntetycznymi zostały wykorzystane następujące typy masek:

- maski referencyjne, dokładnie odzwierciedlające położenie i kształt fantomu,
- maski uzyskane przy użyciu segmentacji obrazów echograficznych metodą aktywnego konturu,

- maski uzyskane poprzez deformacje masek, pochodzących z segmentacji metodą aktywnego konturu, mające na celu odzwierciedlenie niedoskonałości masek obserwowanych w praktyce klinicznej, otrzymywanych przy segmentacji obrazów echokardiograficznych [86]. Maski tego typu posłużyły do zbadania wpływu różnych typów błędów segmentacji na dokładność wyznaczania przemieszczeń i odkształceń przy użyciu opracowanej metody.

3.1.1.1.1 Maski referencyjne

Maski referencyjne zostały wygenerowane poprzez poprowadzenie łamanych przez węzły siatki MES (punkty referencyjne), odpowiadające odpowiednio endokardium i epikardium. Otrzymane łamane posłużyły do uzyskania binarnych masek, w których wartość 1 odpowiada materiałowi fantomu lewej komory serca a wartość 0 otoczeniu.

3.1.1.1.2 Maski pochodzące z segmentacji

Segmentacja danych została wykonana przy użyciu algorytmu aktywnego konturu w implementacji Dirk-Jana Kroona [87]. Kontury wewnętrzny i zewnętrzny były wyznaczane oddzielnie. Kontury początkowe, dla pierwszej klatki danych były definiowane ręcznie, zaś kontur początkowy dla segmentacji wszystkich kolejnych klatek stanowiły kontury klatki poprzedzającej. Tabela 2 zawiera parametry procesu segmentacji, które zostały wyznaczone eksperymentalnie, oddzielnie dla endokardium (konturu wewnętrznego) i epikardium (konturu zewnętrznego). Tak samo jak w przypadku konturów referencyjnych, informacje pochodzące z segmentacji zostały wykorzystane do wygenerowania binarnych masek.

Tabela 2 Parametry algorytmu aktywnego konturu, wykorzystanego do segmentacji danych syntetycznych, przedstawiających fantom lewej komory serca

	Endokardium	Epikardium
<i>Parametry ogólne</i>		
Liczba punktów konturu	200	200
Timestep	1	1
Liczba iteracji	200	200
<i>Parametry dotyczące energii konturu i sił zewnętrznych</i>		
Sigma wykorzystywana do liczenia pochodnych obrazu	6	8
Współczynnik przyciągania do linii	-0,01	-0,04
Współczynnik przyciągania do krawędzi	2	2
Współczynnik przyciągania do punktów końcowych linii oraz wierzchołków	0	0
Sigma wykorzystywana do wyznaczania gradientu energii obrazu	15	5
<i>Parametry Gradient Vector Flow (GVF)</i>		
Relacja pomiędzy wektorem szumu i wektorem krawędzi	0,02	0,02
Liczba iteracji GVF	0	0
Parametr sigma wykorzystywany do wyznaczenia wartości laplasjanu w GVF	1	1
<i>Parametry modelu konturu</i>		
Wartość wagi energii odporności na rozciąganie	0,8	0,8
Wartość wagi energii odporności na zginanie	0,8	0,8
Wartość siły rozciągającej model	0,001	0,1
Wartość wagi sił zewnętrznych	4	4

3.1.1.1.3 Maski poddane deformacji

Dane syntetyczne, symulujące obraz ultrasonograficzny fantomu lewej komory serca, cechują się brakiem artefaktów, powstających przy obrazowaniu ultrasonograficznym w warunkach klinicznych, a prezentowany obiekt ma znacząco uproszczony kształt. Powoduje to, że segmentacja tych danych jest łatwiejsza od segmentacji danych klinicznych, a co za tym idzie, uzyskane kontury odzwierciedlają kształt obiektu z dokładnością, trudną do osiągnięcia w zastosowaniach klinicznych. W związku z tym zaproponowany został szereg metod

deformacji masek, mających na celu pogorszenie ich jakości tak, aby otrzymać stopień niedopasowania konturu do obiektu, zbliżony do algorytmów opisanych w literaturze [14], [88], działających na danych klinicznych. Zastosowanie takiego podejścia pozwala na ocenę wpływu błędów segmentacji o zróżnicowanym charakterze i natężeniu, na efekt działania opracowanej metody wyznaczania przemieszczeń i odkształceń w danych echokardiograficznych, przy wykorzystaniu algorytmu elastycznego dopasowania obrazów. Choć rodzaje deformacji masek zostały dobrane w sposób arbitralny, w procesie ich wyboru były brane pod uwagę informacje z badań prowadzonych na danych klinicznych [56], [89]. Poniżej wyszczególnione zostały wszystkie typy deformacji masek, wykorzystane w pracy.

Typ A

Deformacja każdej klatki w sekwencji masek za pomocą transformacji obrazu, opartej na krzywych B-sklejanych, przy użyciu indywidualnej siatki deformującej, wygenerowanej dla każdej klatki poprzez dodanie do każdej współrzędnej każdego węzła siatki równomiernie rozłożonych węzłów, o odległości między węzłami wynoszącej 43 piksele, wartości wylosowanej z rozkładu jednostajnego ciągłego o przedziale $\langle -a, a \rangle$. W pracy użytych zostało 6 zestawów zdeformowanych w ten sposób masek, przy czym parametr a przyjmował w nich odpowiednio wartości 5%, 15%, 25%, 30%, 35% i 40% odległości pomiędzy węzłami niezdeformowanej siatki.

Typ B

7 wariantów dylacji/erozji masek z wykorzystaniem kwadratowego elementu strukturalnego:

Wariant B1a

Dylacja masek przy zachowaniu stałego rozmiaru elementu strukturalnego dla każdej z klatek sekwencji danych. Wykorzystane zostały 3 zestawy takich masek, wygenerowanych przy użyciu elementu strukturalnego o wymiarach 10x10, 15x15 i 20x20 pikseli.

Wariant B1b

Erozja masek przy zachowaniu stałego rozmiaru elementu strukturalnego dla każdej z klatek sekwencji danych. Wykorzystane zostały 3 zestawy takich masek, wygenerowanych przy użyciu elementu strukturalnego o wymiarach 10x10, 15x15 i 20x20 pikseli.

Wariant B2

Dylacja/erozja masek, przy użyciu elementu strukturalnego o zmiennej wielkości, gdzie dla każdej z klatek wybrana została losowa wielkość tego elementu, z przedziału $\{-a, \dots, a\}$. W zależności od znaku wylosowanego parametru przeprowadzana była erozja lub dylacja danej klatki (erozja przy wartościach ujemnych, dylacja przy wartościach dodatnich). Wykorzystane zostały 4 zestawy masek, zdeformowanych w ten sposób, z wartością parametru a równą odpowiednio 4, 6, 8 i 10 pikseli.

Wariant B3a

Dylacja masek przy użyciu elementu strukturalnego o zmiennej wielkości, gdzie dla każdej z klatek wybierana była losowa wartość z przedziału $\{1, \dots, a\}$, odpowiadająca wielkości elementu strukturalnego. Wykorzystane zostały 3 zestawy masek, zdeformowanych w ten sposób, przy wykorzystaniu parametru a o wartościach odpowiednio: 20, 30 i 50 pikseli.

Wariant B3b

Erozja masek przy użyciu elementu strukturalnego o zmiennej wielkości, gdzie dla każdej z klatek wybierana była losowa wartość z przedziału $\{1, \dots, a\}$, odpowiadająca wielkości elementu strukturalnego. Wykorzystane zostały 4 zestawy masek uzyskanych w ten sposób, przy wykorzystaniu parametru a o wartościach odpowiednio 10, 20, 30 i 50 pikseli.

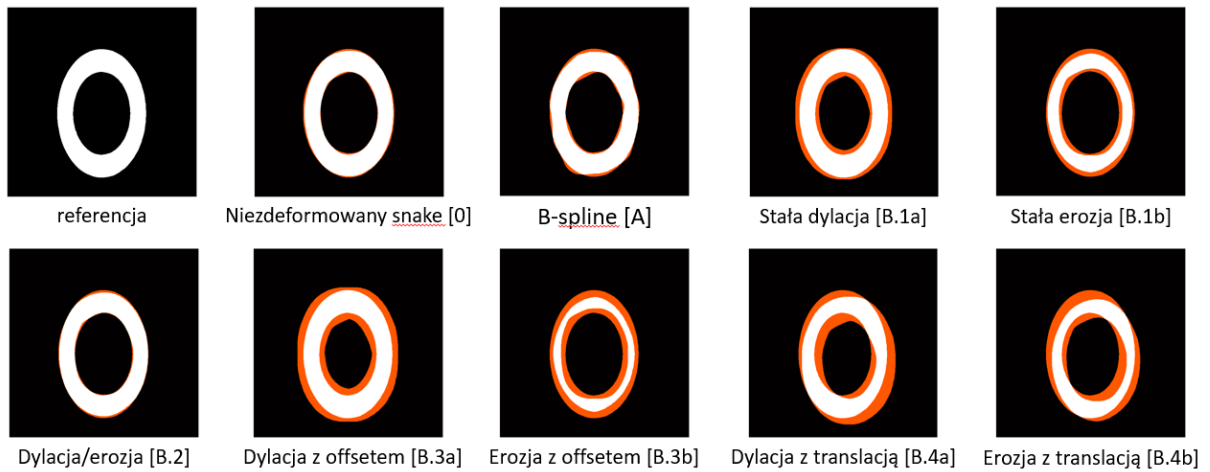
Wariant B4a

Dylacja masek przy użyciu elementu strukturalnego o stałym rozmiarze we wszystkich klatkach (10x10 pikseli), połączona ze sztywną translacją masek, zarówno w osi x , jak i y . Wykorzystane zostały 2 zestawy takich masek, z wartościami przemieszczeń równymi 10 i 20 pikseli.

Wariant B4b

Erozja masek przy użyciu elementu strukturalnego o stałej wielkości we wszystkich klatkach (10x10 pikseli), połączona ze sztywną translacją masek, zarówno w osi x , jak i y . Wykorzystane zostały 2 zestawy takich masek, z wartościami przemieszczeń, równymi 10 i 20 pikseli.

Rysunek 12 pokazuje przykłady różnic pomiędzy maską zdeformowaną a maską referencyjną w wykorzystanych zestawach masek.



Rysunek 12 Przykłady masek zdeformowanych przy użyciu każdej z zastosowanych metod. Kolorem czerwonym oznaczone zostały różnice pomiędzy maskami zdeformowanymi a maską referencyjną

Do oceny stopnia deformacji masek posłużył współczynnik Dice'a (równanie 2).

W poniższej tabeli zamieszczone zostały wartości współczynnika Dice'a wszystkich wykorzystanych wariantów masek, w stosunku do maski referencyjnej. Tabela 3 zawiera średnią wartość współczynnika Dice'a w sekwencji obrazów, jej medianę, wartości minimalną i maksymalną, uzyskaną dla pary obrazów w sekwencji oraz odchylenie standardowe współczynnika Dice'a w sekwencji, co ma na celu weryfikację stopnia zróżnicowania wartości współczynnika w poszczególnych klatkach sekwencji.

Tabela 3 Wartości współczynnika Dice'a wykorzystanych masek zdeformowanych

Wer.	Maska	Średni współczynnik Dice'a	min	max	mediana	std
0	Niezdeformowany snake	0,955	0,946	0,965	0,954	0,005
A	B-spline 0,05	0,955	0,945	0,965	0,954	0,005
	B-spline 0,15	0,950	0,935	0,963	0,949	0,007
	B-spline 0,25	0,942	0,917	0,961	0,943	0,010
	B-spline 0,3	0,933	0,896	0,958	0,934	0,012
	B-spline 0,35	0,929	0,908	0,956	0,928	0,013
	B-spline 0,4	0,923	0,894	0,956	0,924	0,013
B.1a	Stała dylacja 10	0,897	0,890	0,903	0,897	0,003
	Stała dylacja 15	0,855	0,847	0,868	0,847	0,006
	Stała dylacja 20	0,816	0,805	0,837	0,812	0,010
B.1b	Stała erozja 10	0,904	0,881	0,946	0,891	0,022
	Stała erozja 15	0,833	0,799	0,898	0,814	0,033
	Stała erozja 20	0,752	0,703	0,843	0,725	0,047
B.2	Dylacja/erozja 4	0,952	0,926	0,970	0,952	0,009
	Dylacja/erozja 6	0,952	0,936	0,970	0,953	0,007
	Dylacja/erozja 8	0,952	0,933	0,965	0,954	0,007
	Dylacja/erozja 10	0,951	0,927	0,971	0,950	0,009
B.3a	Dylacja z offsetem 20	0,890	0,797	0,958	0,889	0,046
	Dylacja z offsetem 30	0,839	0,740	0,956	0,835	0,065
	Dylacja z offsetem 50	0,786	0,625	0,961	0,754	0,107
B.3b	Erozja z offsetem 10	0,936	0,869	0,970	0,949	0,029
	Erozja z offsetem 20	0,875	0,711	0,970	0,877	0,068
	Erozja z offsetem 30	0,787	0,451	0,968	0,817	0,146
	Erozja z offsetem 50	0,570	0,015	0,969	0,626	0,320
B.4a	Translacja10 dylacja10	0,847	0,837	0,869	0,841	0,011
	Translacja20 dylacja10	0,714	0,687	0,770	0,698	0,027
B.4b	Translacja10 erozja10	0,832	0,808	0,878	0,818	0,023
	Translacja20 erozja10	0,667	0,625	0,752	0,642	0,042


3.1.2 Dane pochodzące z obrazowania fantomu materialnego

Kolejnym zestawem danych, wykorzystanych w pracy, był zestaw danych ultrasonograficznych pochodzących z obrazowania fantomu lewej komory serca. Dane referencyjne zostały uzyskane poprzez nałożenie na obraz punktów referencyjnych, odpowiadającym położeniom węzłów siatki MES w modelu numerycznym fantomu. Dane zostały przygotowane przez dr inż. Szymona Cygana w Zakładzie Inżynierii Biomedycznej na Wydziale Mechatroniki Politechniki Warszawskiej [83].

Przygotowanie danych przebiegało dwuetapowo. Pierwszym etapem była akwizycja obrazów ultrasonograficznych oraz danych sonomikrometrycznych fizycznego, elipsoidalnego fantomu lewej komory serca, wykonanego z kriożelu PVA. Akwizycja została wykonana na stanowisku, na którym zmiana objętości fantomu, odpowiadająca zmianie objętości lewej komory serca w cyklu pracy, była wymuszana przez ciśnienie wody wtłaczanej do jego wnętrza. Obrazy echokardiograficzne zostały zarejestrowane w dwóch widokach: w widoku osi krótkiej (SAX) i w widoku osi długiej (LAX). Do walidacji modelu numerycznego, użytego do generacji danych referencyjnych, posłużyły pomiary sonomikrometryczne. Zostały one wykonane przy użyciu trzech czujników, umieszczonych na ścianie fantomu. Pozwoliło to na pomiar zmiany grubości oraz długości ściany fantomu w pojedynczym cyklu pracy.

Drugim etapem było pozyskanie danych referencyjnych, poprzez symulację numeryczną fizycznego fantomu. Parametry modelu materiału zostały skalibrowane w taki sposób, aby jego właściwości, m.in. współczynnik Poissona, odpowiadały właściwościom kriożelu PVA, z którego został wykonany fizyczny fantom. Model MES fantomu lewej komory serca został poddany wymuszeniu, identycznemu z wymuszeniem zastosowanym w fizycznym stanowisku. Dane o przemieszczeniach poszczególnych punktów modelu numerycznego zostały przeniesione do układu współrzędnych danych ultrasonograficznych, zaś wykonane następnie operacje translacji i interpolacji sekwencji czasowej, oraz kalibracja mechaniczna modelu materiału fantomu pozwoliły na połączenie danych numerycznych i sekwencji ultrasonograficznej. W ten sposób uzyskana została sekwencja danych ultrasonograficznych fantomu lewej komory serca z danymi referencyjnymi cechującymi się wysoką rozdzielczością i dokładnością, dającymi dokładną informację o przemieszczeniach i odkształceniach fantomu.

Rysunek 13 pokazuje przykładową klatkę, pochodzącą z danych z obrazowania fantomu lewej komory serca, z zaznaczonymi punktami referencyjnymi. Średnia wartość bezwzględna przemieszczenia punktów w trakcie cyklu, zarówno w kierunku x, jak i y wynosiła 4,2 mm.




Rysunek 13 Przykładowa klatka danych z obrazowania fantomu, z referencją numeryczną, z zaznaczonymi punktami referencyjnymi

3.1.2.1 Maski

W pracy z danymi z obrazowania fantomu z referencją numeryczną wykorzystane zostały dwa zestawy masek: maski referencyjne oraz maski uzyskane w wyniku segmentacji z zastosowaniem metody aktywnego konturu.

3.1.2.1.1 Maski referencyjne


Maski referencyjne zostały wygenerowane poprzez poprowadzenie łamanych przez węzły siatki MES (punkty referencyjne), odpowiadające krawędziom wewnętrznej i zewnętrznej fantomu. Otrzymane łamane posłużyły do uzyskania binarnych masek, w których wartość 1 odpowiada materiałowi fantomu a 0 – otoczeniu. Rysunek 14 przedstawia przykładową klatkę z opisanej sekwencji, z nałożoną odpowiadającą jej maską referencyjną.



Rysunek 14 Klatka z sekwencji pochodzącej z obrazowania fantomu lewej komory serca, z nałożoną odpowiadającą jej maską referencyjną

3.1.2.1.2 Maski pochodzące z segmentacji

Segmentacja danych została wykonana w taki sam sposób, jak segmentacja danych syntetycznych, opisana w rozdziale 3.1.1.1.2, z wykorzystaniem tych samych wartości parametrów. Rysunek 15 przedstawia przykładową klatkę z opisanej sekwencji, z nałożoną odpowiadającą jej maską, pochodzącą z segmentacji metodą aktywnego konturu.

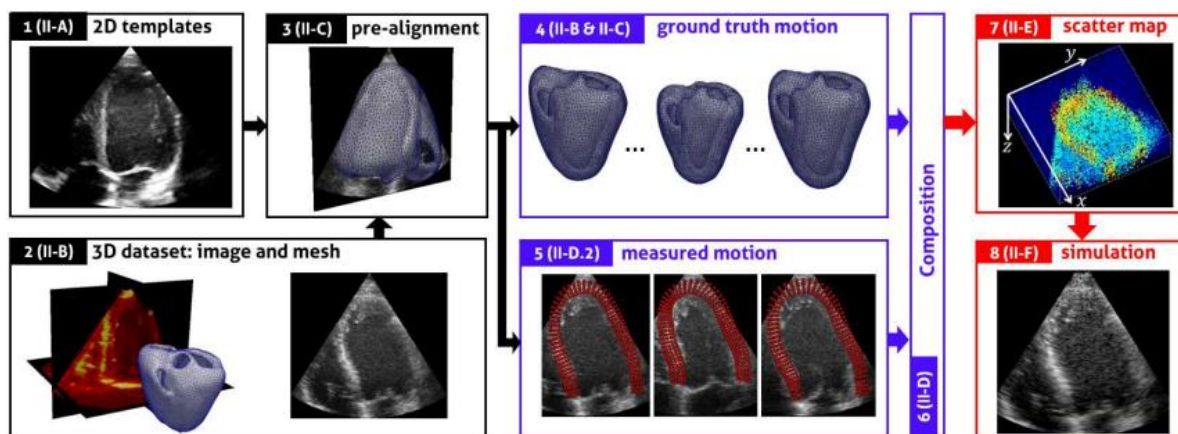


Rysunek 15 Klatka z sekwencji pochodzącej z obrazowania fantomu lewej komory serca, z nałożoną odpowiadającą jej maską z segmentacji metodą aktywnego konturu.


3.1.3 Dane semi-syntetyczne

W pracy zostały również wykorzystane dane syntetyczne, utworzone z użyciem danych klinicznych, wygenerowane na uniwersytecie w Leuven [90] i udostępnione w formie otwartej bazy danych [91]. Dane zostały wygenerowane na podstawie obrazów, pochodzących z urządzeń 7 producentów aparatury ultrasonograficznej (Siemens, Samsung, Philips, Hitachi, Esaote, Toshiba i GE), w 3 widokach w osi długiej: 2-, 3- i 4-komorowym. Symulacja przebiegała poprzez nałożenie na obraz elektromechanicznego modelu mięśnia sercowego o anatomicznym kształcie, dopasowanie geometrii, wyodrębnienie z modelu zestawu punktów referencyjnych, położonych w płaszczyźnie obrazu a następnie numeryczną symulację, pozwalającą na wyznaczenie ruchu modelu elektromechanicznego (Rysunek 16). Do symulacji wykorzystanych zostało 5 wariantów ruchu mięśnia sercowego, odpowiadających następującym stanom klinicznym: zdrowy, z zamkniętą gałęzią międzykomorową przednią lewej tętnicy wieńcowej (w wariancie bliższym i dalszym), z zamkniętą prawą tętnicą wieńcową i z zamkniętą gałęzią okalającą lewej tętnicy wieńcowej.

Rysunek 17 pokazuje przykładowe klatki z sekwencji danych, naśladujących dane, pochodzące z urządzeń poszczególnym producentów, w widoku czterokomorowym.



Rysunek 16 Źródło: [90] Przebieg procesu modelowania danych semi-syntetycznych



Rysunek 17 Przykładowe klatki z sekwencji, naśladujących dane, pochodzące z urządzeń różnych producentów, w widoku czterekomorowym

Wszystkie zestawy danych zawierają dane o położeniu punktów referencyjnych i o podziale na segmenty, zgodnie z AHA-17.

Dzięki użyciu danych obrazowych zarejestrowanych klinicznie oraz realistycznego modelu ruchu, dane te wykazują wysoki realizm, przy jednoczesnej dostępności dokładnej, wiarygodnej referencji.

Ze względu na sposób generacji danych, są one w pracy określane jako dane semi-syntetyczne.

3.1.3.1 Maski

W pracy z danymi semi-syntetycznymi wykorzystane zostały dwa rodzaje masek: maski referencyjne oraz maski uzyskane przy użyciu segmentacji metodą aktywnego konturu.

3.1.3.1.1 Maski referencyjne

Maski referencyjne, analogicznie jak w przypadku danych syntetycznych oraz danych z obrazowania fantomu lewej komory serca, zostały wygenerowane poprzez poprowadzenie łamanych przez punkty referencyjne, odpowiadające epikardium oraz endokardium. W wyniku tej operacji powstały maski, dokładnie odzwierciedlające położenie lewej komory serca w danych referencyjnych. Rysunek 18 przedstawia przykładową klatkę z jednej z sekwencji, wraz z odpowiadającą jej maską referencyjną.



Rysunek 18 Klatka z sekwencji naśladowej dane pochodzące z urządzenia firmy TOSHIBA, w widoku czterekomorowym, z nałożoną odpowiadającą jej maską referencyjną

3.1.3.1.2 Maski pochodzące z segmentacji


Opisane powyżej dane semi-syntetyczne stanowią poważne wyzwanie dla algorytmów segmentacji. Wyniki działania dostępnych implementacji, w tym implementacji Dirk-Jana Kroona [87], wykorzystanej w tej pracy do segmentacji, opisanej w rozdziałach 3.1.1.1.2 oraz 3.1.2.1.2 nie dawały zadowalających efektów. Uzyskanie masek dla wybranych sekwencji danych było możliwe dzięki współpracy z firmą PMOD Technologies LLC (Szwajcaria) [92]. Maski dla sekwencji, naśladowujących dane pochodzące z urządzeń firm GE, ESAOTE oraz TOSHIBA, w widokach 3- i 4-komorowych (łącznie 30 sekwencji) zostały wygenerowane przy użyciu wariantu algorytmu aktywnego konturu, zaimplementowanego w oprogramowaniu PMOD, przez specjalistę zatrudnionego w firmie. Rysunek 19 przedstawia przykładową klatkę z jednej z sekwencji, wraz z odpowiadającą jej maską, wygenerowaną przy użyciu oprogramowania PMOD. Maski uzyskane w ten sposób, poza ścianami lewej komory serca obejmują również obszar zastawek.




Rysunek 19 Klatka z sekwencji naśladowującej dane pochodzące z urządzenia firmy TOSHIBA, w widoku czterekomorowym, z nałożoną odpowiadającą jej maską wygenerowaną przy użyciu oprogramowania PMOD

3.1.4 Dane kliniczne

W pracy wykorzystany został zestaw danych klinicznych z projektu CAMUS [14]. Składają się na niego sekwencje echokardiograficzne, pochodzące z badań 450 pacjentów. Dane są dostępne w widokach 2- i 4-komorowym w osi długiej. Do danych echokardiograficznych są dołączone maski z segmentacji wykonanej ręcznie przez lekarzy kardiologów, dla klatek sekwencji, zawierających zapis etapów końcowo-skurczowego oraz końcowo-rozkurczowego, z oznaczonymi obszarami tkanki lewej komory serca, wnętrza lewej komory serca oraz lewego przedsionka. Rysunek 20 oraz Rysunek 21 przedstawiają odpowiednio przykłady pochodzących ze zbioru obrazów, oznaczonych jako obrazy dobrej i złej jakości, wraz z odpowiadającymi im maskami referencyjnymi, wyznaczonymi ręcznie przez lekarzy specjalistów.



Rysunek 20 Przykład danych klinicznych z projektu CAMUS, oznaczonych jako dane dobrej jakości, po lewej stronie obraz B-mode, końcowo-rozkurczowy, po prawej wynik segmentacji obrazu, wykonanej ręcznie przez specjalistę




Rysunek 21 Przykład danych klinicznych z projektu CAMUS, oznaczonych jako dane złej jakości, po lewej stronie obraz B-mode, końcowo-rozkurczowy, po prawej wynik segmentacji obrazu, wykonanej ręcznie przez specjalistę

3.1.4.1 Maski

Maski wygenerowane przez specjalistów, udostępnione wraz z danymi klinicznymi, są dostępne jedynie dla dwóch klatek sekwencji echokardiograficznej, odpowiadających fazom końcowo-skurczowej oraz końcowo-rozkurczowej cyklu pracy serca. Do działania zaproponowanego algorytmu niezbędne są maski odpowiadające wszystkim klatkom sekwencji echokardiograficznej, dlatego też konieczne było przeprowadzenie procesu segmentacji danych. Ze względu na dostępność masek wygenerowanych przez ekspertów dla części klatek

sekwencji oraz stosunkowo dużą liczbę sekwencji w zbiorze danych, pozwalającą na efektywne zastosowanie metod uczenia maszynowego, segmentacja została przeprowadzona przy użyciu konwolucyjnej sieci neuronowej, zaimplementowanej w oprogramowaniu PMOD [92]. Proces uczenia i segmentacji był prowadzony oddzielnie dla sekwencji w widokach dwu- i czterokomorowym. Hiperparametry algorytmu uczenia zostały dobrane eksperymentalnie. Rysunek 22 przedstawia przykładowe klatki danych klinicznych, z nałożonymi odpowiadającymi im maskami.



Rysunek 22 Dane kliniczne z nałożonymi maskami, uzyskanymi przy użyciu konwolucyjnej sieci neuronowej. Po lewej stronie klatka danych, oznaczonych jako dane dobrej jakości, po prawej stronie klatka danych oznaczonych jako dane złej jakości.

3.2 Metody i miary oceny dokładności estymacji przemieszczeń i odkształceń

3.2.1 Ocena dokładności estymacji przemieszczeń i odkształceń w danych z dostępną referencją numeryczną

W zestawach danych, w których dostępne są dane referencyjne, dotyczące wartości przemieszczeń, ocena wyników odbyła się poprzez porównanie wartości przemieszczeń i odkształceń obiektu, wyznaczonych przy wykorzystaniu algorytmu elastycznego dopasowania obrazów, z przemieszczeniami i odkształceniami referencyjnymi.

Przemieszczenia

Przy ocenie dokładności wyznaczania przemieszczeń, pod uwagę brana była średnia wartość średniego błędu wyznaczania przemieszczenia we wszystkich punktach charakterystycznych w kierunkach x i y w poszczególnych klatkach, opisana wzorem:

$$\frac{\sum_{i=1}^n \sum_{j=1}^k |\hat{w}_{ij} - w_{ij}|}{n \cdot k} \quad 27$$

gdzie:

n – liczba klatek sekwencji obrazowej,

k – liczba punktów charakterystycznych w klatce,

\hat{w}_{ij} – estymowane położenie j-tego punktu charakterystycznego w i-tej klatce sekwencji, wyznaczone na podstawie skumulowanych estymacji przemieszczeń z klatek poprzedzających,

w_{ij} – rzeczywiste położenie j-tego punktu charakterystycznego w i-tej klatce sekwencji.

Kierunki x i y odpowiadają układowi współrzędnych obrazu i siatki punktów kontrolnych, przedstawionemu na rysunku 9.

Odształcenia

Ocena jakości wyznaczenia odształcenia segmentów lewej komory mięśnia sercowego (lub jej modeli) odbyła się poprzez porównanie wartości odształceń wyznaczonych przy wykorzystaniu opracowanego algorytmu estymacji odształceń w poszczególnych segmentach, we wszystkich klatkach sekwencji, z wartościami referencyjnymi. Jako miara jakości wyznaczania odształceń przyjęty został średni błąd bezwzględny (mean absolute error – MAE) wyznaczenia odształcenia we wszystkich klatkach dla danego segmentu.

3.2.2 Ocena działania algorytmu z użyciem danych klinicznych

Dane kliniczne z projektu CAMUS nie zawierają informacji referencyjnej, dotyczącej przemieszczeń i odształceń mięśnia sercowego, dlatego dokonanie oceny jakości wyników działania algorytmu przy użyciu metryk wykorzystywanych w pozostałych przypadkach nie jest możliwe. Jedyną informacją referencyjną zawartą w zestawie są maski, określające obszary mięśnia lewej komory serca, wnętrza lewej komory serca oraz lewego przedsionka serca, wyznaczone przez specjalistów dla faz końcowo-skurczowej i końcowo-rozkurczowej cyklu

pracy serca. Jako że niniejsza praca skupia się na przemieszczeniach i odkształceniach tkanki lewej komory mięśnia sercowego, do oceny wyników działania algorytmu wykorzystane zostały jedynie maski odpowiadające tej części serca.

W celu wykonania oceny wyników działania opracowanego algorytmu, maska wyznaczona przez specjalistę dla fazy końcowo-rozkurczowej była poddawana transformacjom przy użyciu kolejno wszystkich siatek punktów kontrolnych, odpowiadających za dopasowanie do siebie kolejnych klatek sekwencji. W związku z binarnym charakterem masek, zastosowana została interpolacja przy użyciu metody najbliższego sąsiada. Uzyskana w tym procesie maska odkształcona, odpowiadająca klatce, obrazującej fazę końcowo-skurczową pracy serca, była następnie porównywana z maską referencyjną, wyznaczoną przez specjalistę, przy wykorzystaniu współczynnika Dice'a. Wartość współczynnika Dice'a pomiędzy maską odkształconą, a maską referencyjną stanowi miarę, wykorzystaną do porównania działania wariantów algorytmu z karą niedopasowania masek, z karą gładkości, z dwiema funkcjami kar oraz bez żadnej funkcji kary.

4 Dobór wartości hiperparametrów algorytmu

Wartości wag poszczególnych elementów funkcji kosztu są czynnikiem istotnie wpływającym na efekty działania algorytmu. Możliwości praktycznego wykorzystania metody powiązane są z ustaleniem, jakie wartości wag pozwalają na uzyskanie najlepszych efektów w zakresie wyznaczania przemieszczeń oraz czy i jak bardzo wartości te zmieniają się w zależności od jakości i cech przetwarzanych danych. Cechy te związane mogą być ze sposobem akwizycji obrazów, parametrami urządzenia ultrasonograficznego, jak również z cechami obrazowanego obiektu. W związku z tym proces analizy i doboru wag stanowi samodzielny problem badawczy, którego rozwiązanie zostało podzielone na dwie części:

- badanie przeprowadzone przy użyciu danych syntetycznych, przedstawiających fantomy jednorodny i niejednorodny oraz danych semi-syntetycznych z maskami referencyjnymi, pozwalające na zbadanie stopnia zróżnicowania wartości optymalnych wag funkcji kosztu algorytmu dopasowania obrazów, dla różnych zestawów danych,
- badanie przeprowadzone przy użyciu danych syntetycznych, w którym maski referencyjne zostały poddane celowej deformacji (patrz rozdział 3.1.1.1.3), mające na celu ustalenie wpływu jakości masek na efekt działania algorytmu oraz zależności pomiędzy optymalnymi wartościami wag, a jakością wykorzystanych masek.

Wyznacznikiem jakości uzyskanych wyników była suma średnich wartości błędu wyznaczenia skumulowanych przemieszczeń wyznaczonych dla przemieszczeń w kierunku x i y zgodnie z równaniem 27 (rozdział 3.2.1).

4.1 Wpływ rodzaju danych obrazowych

W badaniu wpływu rodzaju danych obrazowych na optymalne wartości hiperparametrów algorytmu, wykorzystanych zostało:

- 5 zestawów danych syntetycznych, przedstawiających jednorodny fantom lewej komory serca w widoku osi krótkiej (SAX), różniących się od siebie rozmieszczeniem elementów rozpraszających, wykorzystywanych w generowaniu syntetycznego obrazu ultrasonograficznego,
- 1 zestaw danych syntetycznych, przedstawiających fantom lewej komory serca, zawierający wtrącenie, cechujące się podwyższoną sztywnością,

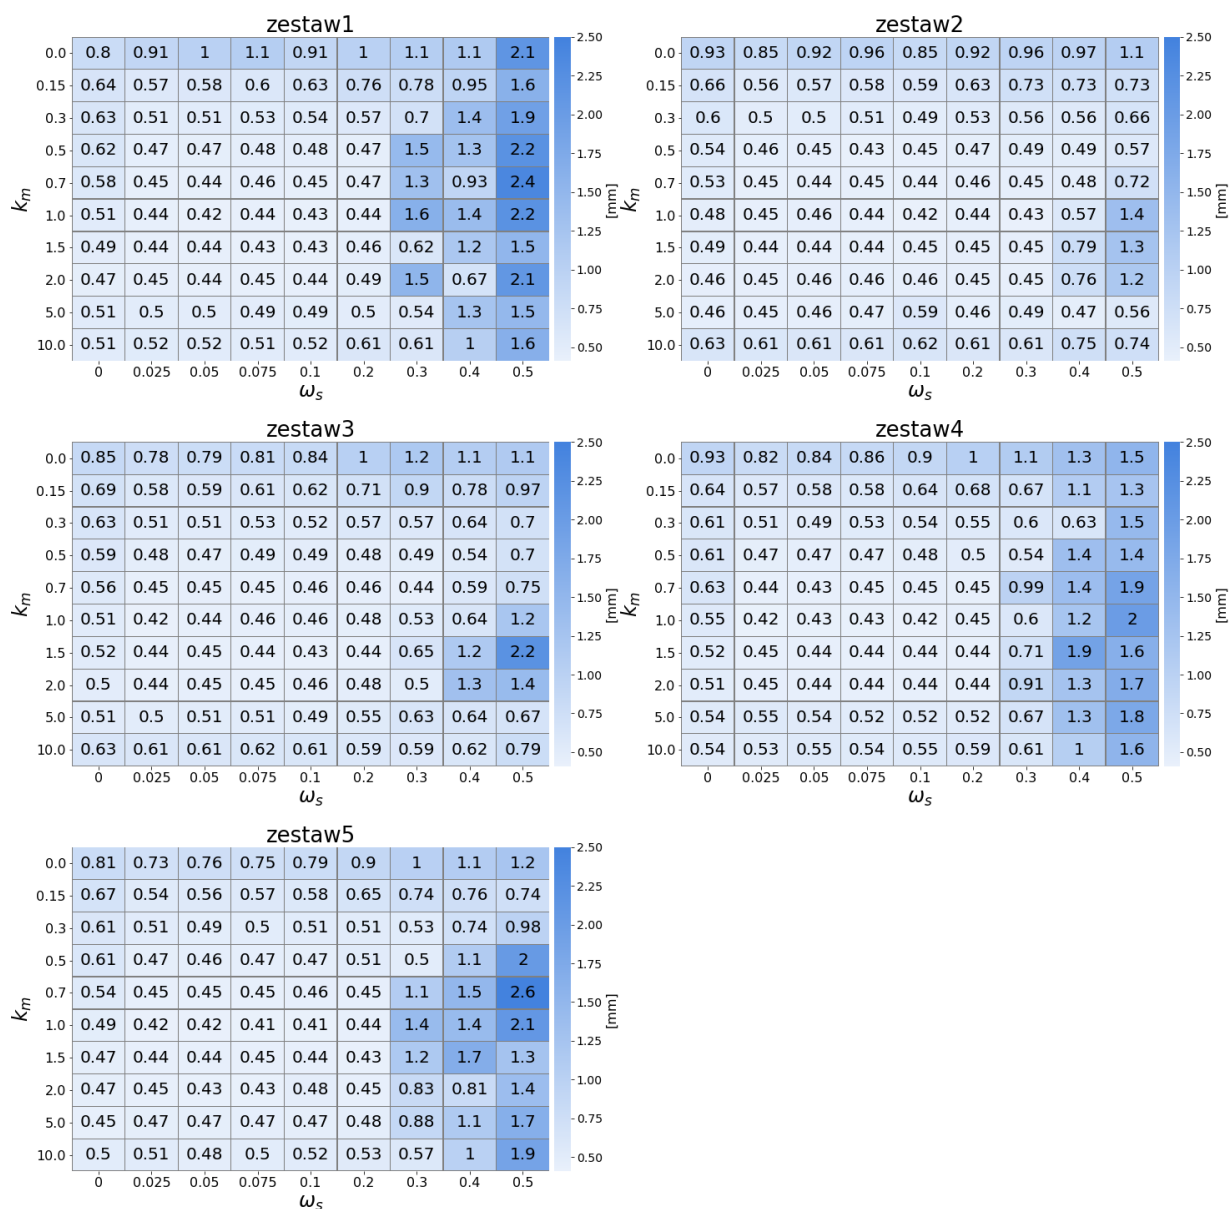
- 1 zestaw danych semi-syntetycznych (wariant imitujący dane, z obrazowania zdrowego serca, pochodzące z urządzenia firmy GE z bazy [91]).

We wszystkich przypadkach wykorzystane zostały maski referencyjne. Badanie zostało przeprowadzone poprzez wyznaczenie przemieszczeń w badanych zestawach danych, przy wykorzystaniu opracowanego algorytmu estymacji przemieszczeń z kombinacjami wartości współczynnika wagowego kary niedopasowania masek ze zbioru {0; 0,15; 0,3; 0,5; 0,7; 1; 1,5; 2; 5; 10} oraz wartości wagi kary gładkości ze zbioru {0; 0,025; 0,05; 0,075; 0,1; 0,2; 0,3; 0,4; 0,5}. Wartości te zostały dobrane na podstawie wyników wcześniejszych prac badawczych [46], [81], [86].

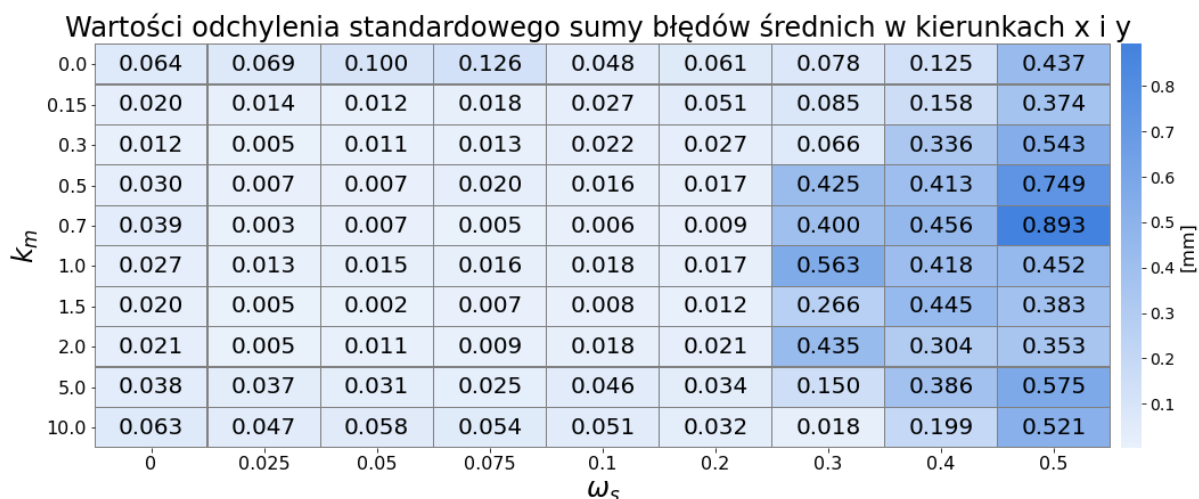
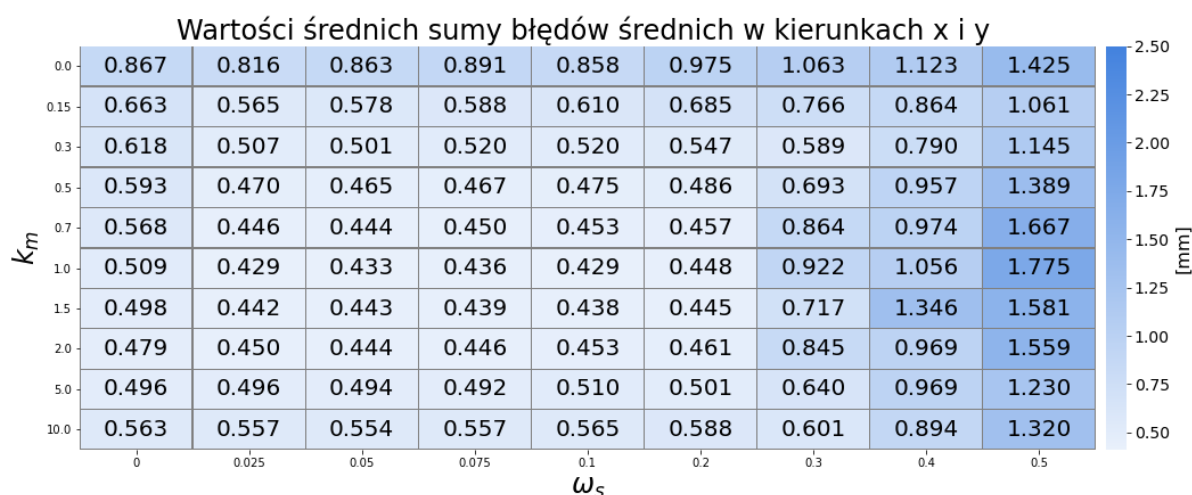
4.1.1 Dane syntetyczne, fantom jednorodny

Badanie zostało przeprowadzone na 5 zestawach danych syntetycznych, przedstawiających jednorodny fantom lewej komory serca. We wszystkich zestawach danych, obiekt stanowił model fantomu, o identycznym kształcie i wymiarach, odkształcany w jednakowy sposób. Jedynym czynnikiem, modyfikowanym w procesie generacji danych, było rozmieszczenie elementów rozpraszających, służących do wygenerowania syntetycznego obrazu ultrasonograficznego – czego skutkiem były różnice w przestrzennym rozkładzie spekli na obrazach.

Sumy wartości średniego błędu wyznaczania przemieszczeń w kierunku x i średniego błędu wyznaczania przemieszczeń w kierunku y w punktach charakterystycznych, w każdym z badanych zestawów danych, w zależności od wartości wagi funkcji kary gładkości oraz współczynnika wagowego kary niedopasowania masek zostały przedstawione na rysunku 23. Rysunek 24 przedstawia średnią wartość tej metryki w [mm], we wszystkich pięciu badanych zestawach danych oraz wartość odchylenia standardowego.



Rysunek 23 Wartości sumy średniego błędu w kierunkach x i y w 5-ciu zestawach danych syntetycznych, przedstawiających fantom jednorodny lewej komory serca, dla kombinacji wybranych wartości współczynnika wagowego kary niedopasowania masek (k_m) oraz wagi kary gładkości (ω_s).



Rysunek 24 Wartości średnich (wykres górny) oraz odchylenia standardowego (wykres dolny) sumy błędów średnich w kierunkach x i y z pięciu zestawów danych syntetycznych fantomu jednorodnego lewej komory serca, dla kombinacji wybranych wartości współczynnika wagowego kary niedopasowania masek (k_m) oraz wagi kary gładkości (ω_s).

Rysunek 23 pokazuje, że różnice w obrazach, wywołane zmienionym ułożeniem elementów rozpraszających, wpływają na efekty działania algorytmu i wyniki uzyskiwane przy różnych zestawieniach wag. Różnice te są szczególnie widoczne w przypadku wykorzystania wartości wagi kary gładkości, wyższych lub równych 0,3. Wykorzystanie wag kary gładkości o wartościach niższych niż 0,3 skutkuje znacznie bardziej powtarzalnymi wynikami i niższymi wartościami błędów.

Najniższa średnia wartość sumy średnich błędów wyznaczania przemieszczeń w kierunkach x i y została uzyskana przy wykorzystaniu współczynnika wagowego kary niedopasowania masek, wynoszącego 1 i wagi kary gładkości, wynoszącej 0,1. Wartości błędu, wyższe od

wartości minimalnej o mniej niż 10% były uzyskiwane przy wykorzystaniu kombinacji współczynnika wagowego kary niedopasowania masek z przedziału $\langle 0,7; 2,0 \rangle$ oraz wagi kary gładkości z przedziału $\langle 0,025; 0,2 \rangle$. Odchylenie standardowe wartości sumy średnich błędów wyznaczania przemieszczeń w kierunkach x i y również przyjmuje najniższe wartości przy wykorzystaniu tych zestawów wag. Oznacza to, że są to zestawy wag, dla których wartości średnich błędów wyznaczania przemieszczeń w kierunkach x i y w 5 zestawach danych cechują się najmniejszą zmiennością.

W przypadku wykorzystania algorytmu nieuwzględniającego informacji z segmentacji (współczynnik wagowy kary niedopasowania masek wynoszący 0), najlepszy wynik został uzyskany dla wagi kary gładkości o wartości 0,025, a wartość błędu była niemal dwukrotnie wyższa od uzyskanego minimum.

W przypadku niewykorzystania kary gładkości (waga kary gładkości wynosząca zero), najlepszy wynik został uzyskany dla współczynnika wagowego kary niedopasowania masek o wartości 2, a wartość błędu w tym przypadku była wyższa od uzyskanego minimum o niespełna 12%.

4.1.2 Dane syntetyczne, fantom z wtrąceniem

Badanie na danych syntetycznych, przedstawiających fantom z wtrąceniem o podwyższonej sztywności zostało przeprowadzone na jednym zestawie danych, w widoku osi krótkiej (SAX).



Rysunek 25 Wartości sumy średniego błędu w kierunkach x i y w danych syntetycznych, przedstawiających fantom lewej komory serca z wtrąceniem o podwyższonej sztywności, dla kombinacji wartości współczynnika wagowego kary niedopasowania masek (k_m) oraz wagi kary gładkości (ω_s).

Rysunek 25 pokazuje zestawienie wartości sumy średniego błędu wyznaczania przemieszczeń, w kierunkach x i y w zestawie danych syntetycznych, przedstawiających fantom lewej komory serca z wtrąceniem o podwyższonej sztywności, przy zastosowaniu kombinacji wartości wag kary gładkości oraz współczynnika wagowego kary niedopasowania masek. Spośród badanych zestawów wartości parametrów, na uzyskanie najniższej wartości prezentowanej miary błędu pozwoliło zastosowanie wagi kary gładkości wynoszącej 0,025 oraz współczynnika wagowego kary niedopasowania masek wynoszącego 0,7. Na uzyskanie wartości błędu, odbiegającej od minimum o nie więcej niż 10%, pozwoliło wykorzystanie wartości wagi kary gładkości z zakresu $\langle 0,025; 0,075 \rangle$, w połączeniu z wartościami współczynnika wagowego kary niedopasowania masek z zakresu $\langle 0,15; 2 \rangle$, jak również część kombinacji spoza tego zakresu.

W przypadku niewykorzystania kary niedopasowania masek (współczynnik wagowy kary niedopasowania masek, wynoszący 0), najlepszy wynik został uzyskany dla wagi kary gładkości o wartości 0,05, a uzyskana wartość błędu była wyższa od minimum o 20%.

W przypadku niewykorzystania kary gładkości (waga kary gładkości wynosząca 0), najlepszy wynik został uzyskany przy wykorzystaniu współczynnika wagowego kary niedopasowania masek o wartości 2, a wartość błędu w tym przypadku była wyższa od minimum o 8%.

4.1.3 Dane semi-syntetyczne

Badanie wpływu wartości wag funkcji kar na wyniki uzyskiwane na danych semi-syntetycznych, zostało przeprowadzone z wykorzystaniem sekwencji imitującej dane pochodzące od zdrowego pacjenta, uzyskane przy użyciu urządzenia firmy GE. Rysunek 26 pokazuje wartości sumy średniego błędu wyznaczania przemieszczeń w kierunkach x i y (w [mm]) w tych danych, dla kombinacji wartości współczynnika wagowego kary niedopasowania masek oraz wagi kary gładkości.



Rysunek 26 Wartości sumy średniego błędu w kierunkach x i y w danych realistycznych danych syntetycznych, imitujących sekwencję danych echokardiograficzną pacjenta zdrowego, uzyskaną przy użyciu urządzenia firmy GE, dla kombinacji wartości współczynnika wagowego kary niedopasowania masek (k_m) oraz wagi kary gładkości (ω_s).

Spośród badanych kombinacji wartości wag, najlepszy wynik został uzyskany przy wykorzystaniu połączenia wartości wagi kary gładkości, wynoszącej 0,3 oraz wartości współczynnika wagowego kary niedopasowania masek, wynoszącej 0,15.

W przypadku tego zestawu danych zróżnicowanie wyników działania algorytmu w zależności od wartości wag funkcji kar było niewielkie. Z wyjątkiem sytuacji, w której obie wartości wag

wynosiły 0 oraz zestawienia wartości wagi kary gładkości równej 0, oraz wartości współczynnika wagowego kary niedopasowania masek, równego 0,15, wszystkie kombinacje pozwoliły na uzyskanie wyników gorszych od minimum o nie więcej niż 2%.

4.1.4 Podsumowanie

Wyniki badań, opisanych w rozdziałach 4.1.1, 4.1.2 oraz 4.1.3 pokazały, że w sytuacji, w której w algorytmie opisanym w pracy wykorzystywane są maski referencyjne, zakresy wartości wag funkcji kar, pozwalające na uzyskanie wyników bliskich optimum są szerokie.

Badanie na 5 zestawach danych syntetycznych, różniących się rozmieszczeniem elementów rozpraszających pokazało, że dla szerokiego zakresu wag funkcji kar, uzyskane wartości błędów pozostają na stabilnym, niskim poziomie, pomimo zmian struktury specklowej na obrazie. Również w badaniu z wykorzystaniem danych syntetycznych, przedstawiających fantom lewej komory serca, z wtrąceniem o podwyższonej sztywności, zakresy wartości wag funkcji kar, pozwalających na uzyskanie najlepszych wyników były szerokie i jednocześnie zbliżone do analogicznych zakresów dla danych przedstawiających fantom jednorodny. Wskazuje to, że jednorazowa kalibracja parametrów dla danych, których akwizycja/ generacja przebiegała w zbliżony sposób, jest wystarczająca do uzyskania powtarzalnej dokładności wyznaczania przemieszczeń.

Różnice w charakterystykach zależności wartości sumy średnich błędów wyznaczenia przemieszczeń w kierunkach x i y od wartości wag funkcji kar w badaniu, przeprowadzonym na danych semi-syntetycznych sugeruje, że w przypadku znaczących różnic w procesie generowania/ akwizycji danych, kalibracja wartości wag funkcji kar jest wskazana. Jednocześnie we wszystkich badanych przypadkach zakresy wartości wag funkcji kar, pozwalające na osiągnięcie wyników zbliżonych do optymalnych są szerokie i obejmują wartości wagi kary gładkości z zakresu $\langle 0,025; 0,075 \rangle$, w połączeniu z wartościami współczynnika wagowego kary niedopasowania masek z zakresu $\langle 0,15; 2 \rangle$, co sugeruje, że wartości parametrów, mieszczące się w tych zakresach, powinny być w pierwszej kolejności brane pod uwagę w dalszych badaniach oraz przy kalibracji parametrów w dalszych zastosowaniach algorytmu.

4.2 Wpływ błędów segmentacji


Ze względu na obecność struktury speklowej, segmentacja obrazów echokardiograficznych pomimo postępu w aparaturze i metodach analizy obrazu nadal stanowi wyzwanie [93]. W związku z tym konieczna jest weryfikacja, jak dokładność segmentacji wpływa na efekty działania algorytmu dopasowania obrazów, wykorzystującego dane o maskach, uzyskanych w procesie segmentacji.

W tym celu przeprowadzone zostało badanie, mające na celu ustalenie, jak różne rodzaje i stopnie deformacji maski referencyjnej oddziałują na dokładność estymacji przemieszczeń i odkształceń oraz jaki wpływ na wyniki mają w takiej sytuacji wartości wag funkcji kary niedopasowania masek. Ze względu na dostępność dokładnych, wiarygodnych danych referencyjnych, pozwalających na precyzyjną ocenę jakości dopasowania, badanie zostało przeprowadzone przy wykorzystaniu danych syntetycznych fantomu lewej komory serca.


W badaniu wykorzystane zostały maski referencyjne, maski pochodzące z segmentacji oraz maski zdeformowane, opisane szczegółowo w rozdziale 3.1.1.1.

Działanie algorytmu dopasowania obrazów, w którym wykorzystane zostały opisane powyżej maski o zróżnicowanej dokładności, zostało przetestowane przy wadze kary gładkości równej 0,05, w czterech wariantach wartości współczynnika wagowego kary niedopasowania masek: {0,15; 0,3; 0,5; 1}.


Rysunek 27, Rysunek 28, Rysunek 29 oraz Rysunek 30 przedstawiają uzyskane wartości sum średnich błędów wyznaczania przemieszczeń w kierunkach x i y. Na wykresach, czarna pozioma linia wskazuje wartość błędu uzyskaną bez wykorzystania informacji o masce, która stanowi wartość odniesienia, służącą do oceny działania algorytmu z wykorzystaniem różnych rodzajów masek.




Rysunek 27 Wartości sumy średniego błędu w kierunkach x i y w danych syntetycznych, przedstawiających fantom jednorodny lewej komory serca, uzyskane przy użyciu zdeformowanych w różny sposób masek (patrz sekcja 3.1.1.1.3), przy wartości wagi kary gładkości, wynoszącej 0,05 i wartości współczynnika wagowego kary niedopasowania masek wynoszącej 1.



Rysunek 28 Wartości sumy średniego błędu w kierunkach x i y w danych syntetycznych, przedstawiających fantom jednorodny lewej komory serca, uzyskane przy użyciu zdeformowanych masek (patrz sekcja 3.1.1.1.3), przy wartości wagi kary gładkości, wynoszącej 0,05 i wartości współczynnika wagowego kary niedopasowania masek wynoszącej 0,5.



Rysunek 29 Wartości sumy średniego błędu w kierunkach x i y w danych syntetycznych, przedstawiających fantom jednorodny lewej komory serca, uzyskane przy użyciu zdeformowanych masek (patrz sekcja 3.1.1.1.3), przy wartości wagi kary gładkości, wynoszącej 0,05 i wartości współczynnika wagowego kary niedopasowania masek wynoszącej 0,3.



Rysunek 30 Wartości sumy średniego błędu w kierunkach x i y w danych syntetycznych, przedstawiających fantom jednorodny lewej komory serca, uzyskane przy użyciu zdeformowanych masek (patrz sekcja 3.1.1.1.3), przy wartości wagi kary gładkości, wynoszącej 0,05 i wartości współczynnika wagowego kary niedopasowania masek wynoszącej 0,15.

Przy wykorzystaniu współczynnika wagowego kary niedopasowania masek o wartości 1, użycie maski referencyjnej pozwala na uzyskanie wartości sumy średniego błędu wyznaczania przemieszczeń w kierunkach x i y, niższej o 57% od wartości uzyskanej bez wykorzystania

kary niedopasowania masek. Wyniki lepsze niż w sytuacji, w której kara niedopasowania masek nie została wykorzystana, zostały uzyskane w 18 z 28 przypadków, w tym w 8 przypadkach o więcej niż 40%. Wyniki gorsze niż bez wykorzystania kary niedopasowania masek zostały uzyskane w 10 przypadkach – przy wszystkich maskach deformowanych metodą erozji z offsetem oraz dylacji z offsetem, oraz w trzech przypadkach masek deformowanych przy użyciu krzywych B-sklejanych. W najgorszym przypadku uzyskany wynik był o ponad 70% gorszy od wyniku uzyskanego bez użycia kary niedopasowania masek.

Wykorzystanie współczynnika wagowego kary niedopasowania masek o wartości 0,5 z maską referencyjną pozwala na uzyskanie wartości sumy średniego błędu wyznaczania przemieszczeń w kierunkach x i y, niższej o 50% od wartości uzyskanej bez wykorzystania kary niedopasowania masek. Przy takiej wartości współczynnika wagowego, wyniki lepsze niż w sytuacji, w której kara niedopasowania masek nie została wykorzystana, zostały uzyskane jeszcze w 18 przypadkach, w tym w 11 przypadkach o więcej niż 40%. Wyniki gorsze niż bez wykorzystania kary niedopasowania masek zostały uzyskane w 10 przypadkach – przy wszystkich maskach deformowanych metodą erozji z offsetem oraz dylacji z offsetem, oraz w trzech przypadkach masek deformowanych przy użyciu krzywych B-sklejanych. W najgorszym przypadku uzyskany wynik był o około 35% gorszy od wyniku uzyskanego bez użycia kary niedopasowania masek.

Wykorzystanie współczynnika wagowego kary niedopasowania masek o wartości 0,3 z maską referencyjną pozwala na uzyskanie, wartości sumy średniego błędu wyznaczania przemieszczeń w kierunkach x i y, niższej o 41% od wartości uzyskanej bez wykorzystania kary niedopasowania masek. Wyniki lepsze niż w sytuacji, w której kara niedopasowania masek nie została wykorzystana, zostały uzyskane jeszcze w 18 przypadkach, w żadnym z tych przypadków poprawa nie była wyższa niż 40%, zaś w 11 przypadkach przekroczyła 30%. Wyniki gorsze niż bez wykorzystania kary niedopasowania masek zostały uzyskane w 10 przypadkach – przy wszystkich maskach deformowanych metodą erozji z offsetem oraz dylacji z offsetem, oraz w trzech przypadkach masek deformowanych przy użyciu krzywych B-sklejanych. W najgorszym przypadku uzyskany wynik był o 20% gorszy od wyniku uzyskanego bez użycia kary niedopasowania masek.

Wykorzystanie współczynnika wagowego kary niedopasowania masek o wartości 0,15 z maską referencyjną pozwala na uzyskanie, wartości sumy średniego błędu wyznaczania przemieszczeń w kierunkach x i y, niższej o 31% od wartości uzyskanej bez wykorzystania kary niedopasowania masek. Wyniki lepsze niż w sytuacji, w której kara niedopasowania

masek nie została wykorzystana, zostały uzyskane jeszcze w 15 przypadkach, w żadnym z tych przypadków poprawa nie była wyższa niż 30%, zaś w 6 przypadkach przekroczyła 20%. Wyniki gorsze niż bez wykorzystania kary niedopasowania masek zostały uzyskane w 13 przypadkach – przy trzech przypadkach masek deformowanych metodą erozji z offsetem, trzech przypadkach masek, deformowanych metodą dylacji z offsetem, w pięciu przypadkach masek deformowanych przy użyciu krzywych B-sklejanych oraz w dwóch przypadkach dylacji/erozji masek. W najgorszym przypadku uzyskany wynik był o 15% gorszy od wyniku uzyskanego bez użycia kary niedopasowania masek.

Uzyskane wyniki wskazują, że użycie wysokich wartości współczynnika wagowego kary niedopasowania masek pozwala na uzyskanie niższych wartości sumy średniego błędu wyznaczania przemieszczeń w kierunkach x i y w przypadku, gdy dostępne są maski, cechujące się wysoką dokładnością oraz maski, których deformacja ma stały charakter (niezmienny w całej sekwencji obrazów). Zastosowanie tak wysokich wartości współczynnika wagowego niesie jednak za sobą wysokie ryzyko znacznego podwyższenia błędu wyznaczania przemieszczeń w sytuacji, w której niedoskonałości procesu segmentacji są źródłem poważnych odstępstw od rzeczywistego kształtu mięśnia sercowego, a charakter tych odstępstw nie jest stały, lecz zmienia się w kolejnych klatkach.

Wykorzystanie niższych wartości współczynnika wagowego kary niedopasowania masek zmniejsza ryzyko uzyskania wysokich wartości błędu wyznaczania przemieszczeń, nie daje jednak szansy na uzyskanie wyników tak dobrych jak wykorzystanie wysokich wartości wagi kary niedopasowania masek, w sytuacji, kiedy dostępne są maski wysokiej jakości. Sugeruje to, że kluczowym elementem doboru wartości współczynnika wagowego kary niedopasowania masek powinna być wiedza o dokładności stosowanej metody segmentacji danych echokardiograficznych.

5 Wyniki walidacji algorytmu

Efekty działania zaproponowanego algorytmu zostały zbadane na trzech zestawach danych:

- dane z obrazowania fantomu lewej komory serca z referencją numeryczną (patrz rozdział 3.1.2),
- dane semi-syntetyczne (patrz rozdział 3.1.3),
- dane kliniczne (patrz rozdział 3.1.4).

W rozdziale tym nie zostały uwzględnione dane syntetyczne, przedstawiające fantom lewej komory serca. Wpływ na to miał ich bardzo uproszczony charakter oraz fakt, że działanie zaproponowanego algorytmu na tych danych zostało przetestowane przy doborze hiperparametrów opracowanej metody (rozdział 4).

W badaniu przeprowadzonym z wykorzystaniem danych z obrazowania fantomu lewej komory serca, porównywane były efekty działania zaproponowanego algorytmu, łączącego w funkcji kosztu dwie funkcje kary: karę gładkości oraz karę niedopasowania masek oraz algorytmu, wykorzystującego jedynie karę gładkości, stanowiącego punkt odniesienia, jako rozwiązanie, opisywane w literaturze. W pozostałych badaniach porównywane było działanie czterech wariantów algorytmu elastycznego dopasowania obrazów: wariantu bez funkcji kar, wariantu z samą karą gładkości, stanowiącego główny punkt odniesienia, wariantu z samą karą niedopasowania masek oraz wariantu z dwiema funkcjami kary. Takie zestawienie miało na celu porównanie proponowanego w pracy rozwiązania z rozwiązaniem referencyjnym (wariant z karą gładkości), jak również obserwację wpływu poszczególnych funkcji kar, oraz ich połączenia na efekty wyznaczania przemieszczeń i odkształceń przy wykorzystaniu elastycznego dopasowania obrazów.

5.1 Dane z obrazowania fantomu z referencją numeryczną

W badaniu wykorzystane zostały dwa rodzaje masek: maski referencyjne, wygenerowane poprzez poprowadzenie łamanej przez punkty referencyjne, odpowiadające wewnętrznej i zewnętrznej krawędzi fantomu, oraz maski wygenerowane przy użyciu metody aktywnego konturu, opisane w rozdziale 3.1.2.1.

W ramach badania porównane zostały wyniki działania algorytmu elastycznego dopasowania obrazów z zastosowaniem kary niedopasowania masek oraz bez jej zastosowania.

W związku z tym, że jakość wyznaczenia masek metodą aktywnego konturu jest w tym zestawie danych bardzo wysoka, w wariancie algorytmu, z zastosowaniem kary niedopasowania masek, dla obu rodzajów masek zastosowany został współczynnik wagowy kary niedopasowania masek o wartości 1. Wartość wagi kary gładkości we wszystkich badaniach wynosiła 0,05.

5.1.1 Błędy wyznaczania przemieszczeń w danych z obrazowania fantomu lewej komory serca, z referencją numeryczną

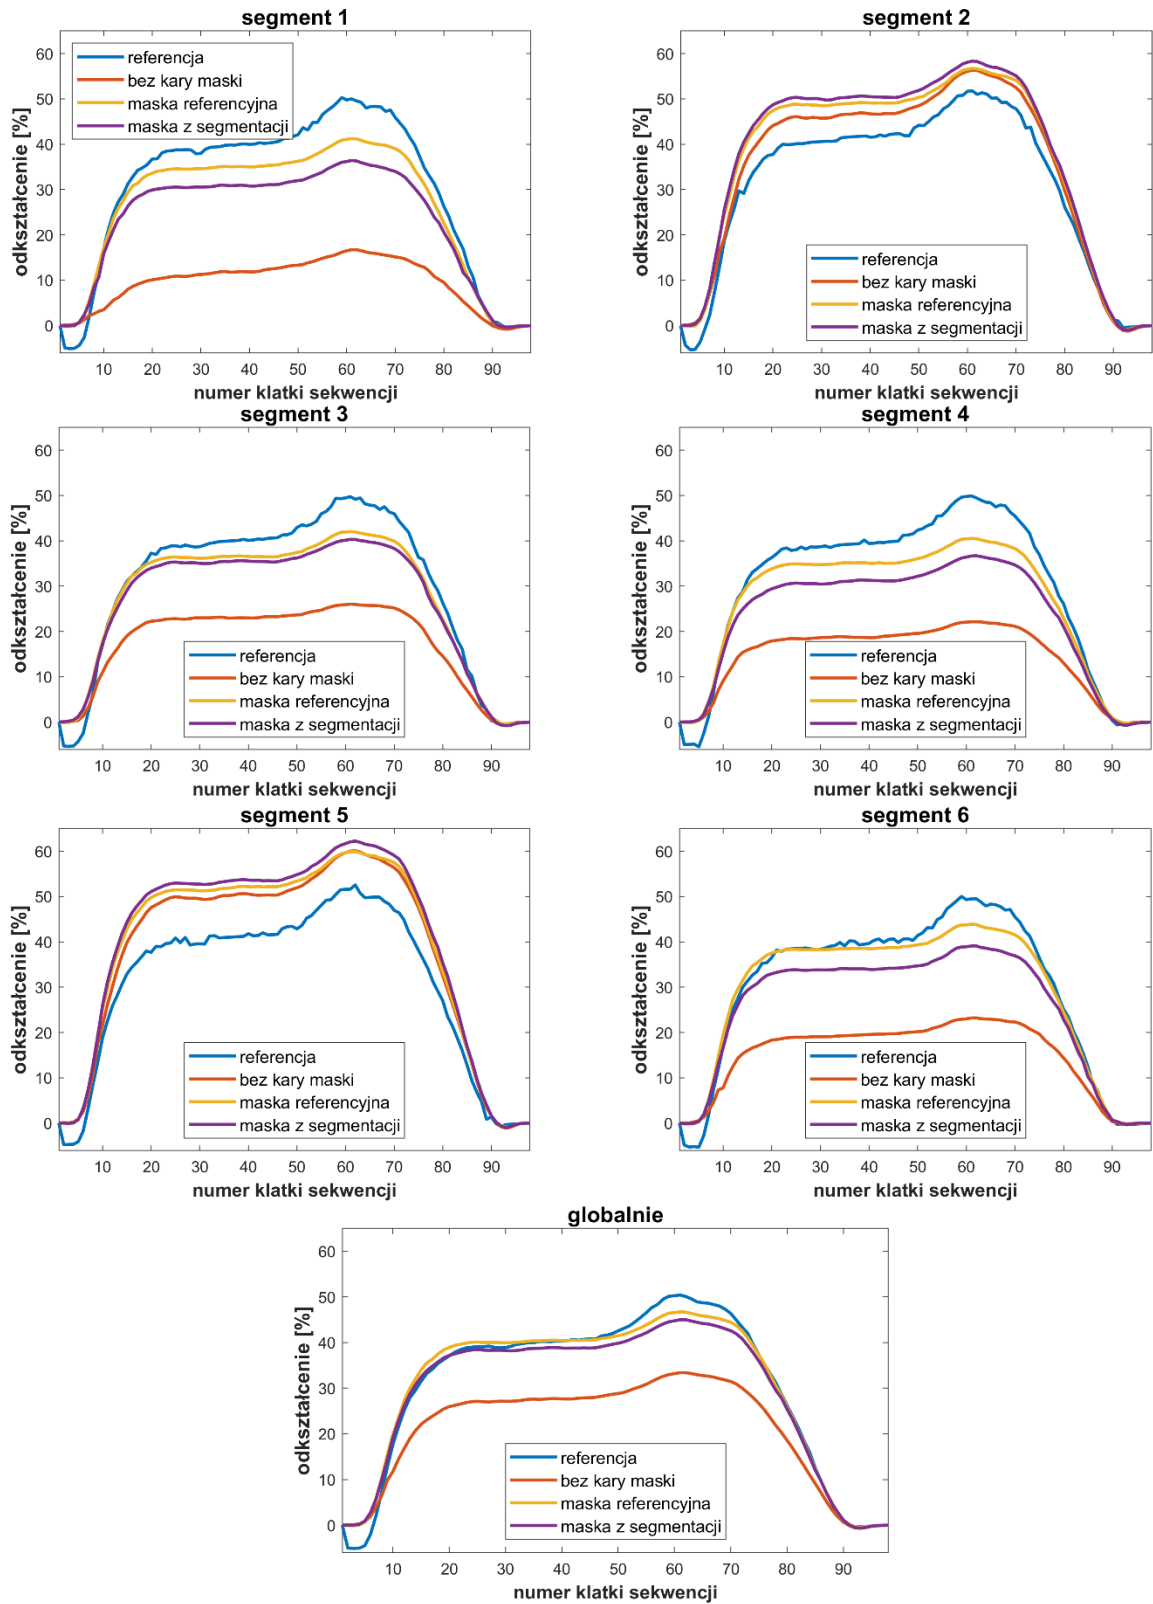
Tabela 4 zawiera wartości średnich błędów wyznaczania przemieszczeń, uzyskane przy użyciu zaproponowanego algorytmu, wykorzystującego karę niedopasowania masek oraz algorytmu niewykorzystującego tej kary, stanowiącego metodę referencyjną. Zastosowanie zaproponowanej w niniejszej pracy kary niedopasowania masek z maską uzyskaną metodą aktywnego konturu, pozwala na trzykrotne zmniejszenie średniej wartości błędu wyznaczania przemieszczeń w kierunku x i zmniejszenie średniej wartości błędu wyznaczania przemieszczeń w kierunku y o kilkanaście procent w stosunku do metody niewykorzystującej kary niedopasowania masek. Zastosowanie maski referencyjnej powoduje zmniejszenie średniej wartości błędu wyznaczania przemieszczeń w kierunku x ponad czterokrotnie, zaś średniej wartości wyznaczania błędu przemieszczeń w kierunku y o około 25%.

Tabela 4 Wartości średnich błędów wyznaczania przemieszczeń, z wykorzystaniem opisywanego algorytmu na danych rzeczywistych fantomu z referencją numeryczną

Użyta maska	Średnia wartość błędu w kierunku x [m]	Średnia wartość błędu w kierunku y [m]
Bez maski	0,003	0,000843
Maska referencyjna	0,000699	0,000637
Maska uzyskana metodą aktywnego konturu	0,001	0,000716

5.1.2 Błędy wyznaczania odkształceń w danych z obrazowania fantomu lewej komory serca, z referencją numeryczną

Rysunek 31 zawiera wykresy, na których pokazane są wartości odkształcenia globalnego oraz odkształceń w segmentach, w kolejnych klatkach sekwencji obrazowej, wyznaczone przy użyciu metody elastycznego dopasowania obrazów z i bez wykorzystania kary niedopasowania masek, jak również krzywe referencyjne. Na wykresach widoczne są wyraźne różnice pomiędzy przebiegami odkształceń uzyskanymi przy użyciu metody elastycznego dopasowania obrazów, a referencją, szczególnie w przypadku segmentów 1, 3, 4 i 6 oraz krzywej globalnej. Największe rozbieżności w stosunku do krzywych referencyjnych są obserwowane w przypadku algorytmu bez zastosowania kary niedopasowania masek, zaś najmniejsze przy zastosowaniu algorytmu z karą niedopasowania masek, w którym zastosowana została maska referencyjna.



Rysunek 31 Krzywe odkształceń w danych z obrazowania fantomu, z referencją numeryczną. Poszczególne wykresy dotyczą poszczególnych segmentów oraz odkształceń globalnych. Wykresy przedstawiają referencyjne wartości odkształceń, zestawione z wartościami uzyskanymi przy wykorzystaniu algorytmu bez kary maski, algorytmu wykorzystującego karę maski z maskami referencyjnymi oraz algorytmu wykorzystującego karę maski z maskami z segmentacji.

Tabela 5 zawiera wartości średniego błędu bezwzględnego (MAE) wyznaczania odkształceń fantomu w całym cyklu dla trzech wariantów algorytmu elastycznego dopasowania obrazów: bez wykorzystania kary niedopasowania masek, z wykorzystaniem maski referencyjnej oraz z wykorzystaniem maski uzyskanej przy użyciu segmentacji metodą aktywnego konturu. Najwyższe wartości średniego błędu bezwzględnego w segmentach 1, 3, 4, 6 oraz wartości globalnej są uzyskiwane przy wykorzystaniu algorytmu bez kary niedopasowania masek, przy czym najwyższa różnica, notowana w segmencie pierwszym, wynosi ponad 21 punktów procentowych. Zastosowanie algorytmu z karą niedopasowania masek, z wykorzystaniem masek referencyjnych, zmniejsza wartości średniego błędu bezwzględnego wyznaczania odkształceń w segmentach 1, 3, 4, 6 oraz globalnie odpowiednio o około 17, 10, 12, 13 i 8 punktów procentowych w stosunku do wyników metody referencyjnej, w której stosowana jest jedynie kara gładkości i zwiększa je w segmentach 2 i 5 o odpowiednio około 2 i 1 punkt procentowy. Zastosowanie algorytmu z wykorzystaniem maski, uzyskanej poprzez segmentację metodą aktywnego konturu zmniejsza wartości średniego błędu bezwzględnego wyznaczania odkształceń w segmentach 1, 3, 4, 5 oraz globalnie odpowiednio o około 14, 9, 9, 11 i 8 punktów procentowych w stosunku do wyników algorytmu bez kary niedopasowania masek i zwiększa je w segmentach 2 i 5 o odpowiednio około 3 i 2 punkty procentowe.

Tabela 5 Średni błąd bezwzględny (MAE) wyznaczania odkształceń w czasie całego cyklu odkształcenia fantomu, w segmentach oraz globalnie (wariant bez maski – wartość uzyskana przy użyciu wariantu algorytmu, nie wykorzystującego masek, wariant z maskami referencyjnymi – wartość uzyskana przy użyciu algorytmu, wykorzystującego maski, z maskami referencyjnymi, wariant z maskami z segmentacji – wartość uzyskana przy użyciu algorytmu, wykorzystującego maski, z maskami z segmentacji)

	MAE, wariant bez maski [p.p.]	MAE, wariant z maskami referencyjnymi [p.p.]	MAE, wariant z maskami z segmentacji [p.p.]
Segment 1	21,18	4,25	7,23
Segment 2	4,01	5,67	6,69
Segment 3	13,27	3,34	4,25
Segment 4	15,98	4,04	6,87
Segment 5	6,75	7,93	9,15
Segment 6	15,42	2,08	4,82
Globalne	9,86	1,44	2,00

Tabela 6 zawiera wartości maksymalnego odkształcenia fantomu w cyklu, uzyskane przy wykorzystaniu trzech wariantów algorytmu elastycznego dopasowania obrazów, zestawione z wartościami referencyjnymi.

Tabela 6 Wartości maksymalnego odkształcenia fantomu w cyklu odkształcenia, w segmentach oraz globalnie

	Odkształcenie referencyjne [%]	Odkształcenie bez kary niedopasowania masek [%]	Odkształcenie z maską referencyjną [%]	Odkształcenie z maską z segmentacji [%]
Segment 1	50,0054	16,7396	41,2448	36,4138
Segment 2	51,7698	56,3643	56,7410	58,3486
Segment 3	49,7417	26,0457	42,0286	40,3174
Segment 4	49,9134	22,1485	40,5310	36,6583
Segment 5	51,6435	60,0159	59,8987	62,0772
Segment 6	49,4793	23,2049	43,8721	39,0901
Globalne	50,4203	33,4187	46,7246	45,0083

W segmentach 1, 3, 4, 6 oraz globalnie, największe błędy estymacji wartości szczytowej wystąpiły dla metody bez kary niedopasowania masek. W segmencie pierwszym w wariacie bez kary niedopasowania masek różnica wyniosła około 33 punkty procentowe, w wariacie z karą niedopasowania masek z maską z segmentacji około 14 punktów procentowych, a z maską referencyjną około 9 punktów procentowych. W segmencie trzecim różnica w stosunku do referencji wyniosła około 24 punkty procentowe dla wariantu bez kary niedopasowania masek, około 9 punktów procentowych dla wariantu z maską z segmentacji i około 8 punktów procentowych dla wariantu z maską referencyjną. W segmencie czwartym różnica ta wyniosła około 28 punktów procentowych w wariacie bez kary niedopasowania masek, około 13 punktów procentowych w wariacie z karą niedopasowania masek, z maską z segmentacji i około 9 punktów procentowych w wariacie z maską referencyjną. W segmencie szóstym różnica w zestawieniu z referencją wyniosła około 26 punktów procentowych w wariacie bez kary niedopasowania masek, około 10 punktów procentowych w wariacie z maską z segmentacji i około 6 punktów procentowych w wariacie z maską referencyjną.

W przypadku segmentów 2 i 5 największe różnice pomiędzy wartością referencyjną maksymalnego odkształcenia, a wartością wyznaczoną przy wykorzystaniu metody elastycznego dopasowania obrazów wystąpiły dla metody z karą niedopasowania masek, z użyciem maski uzyskanej poprzez segmentację metodą aktywnego konturu. Różnice te wyniosły odpowiednio około 7 i 10 punktów procentowych, w obu przypadkach był to wynik o około 2 punkty procentowe gorszy od wyników uzyskanych przy użyciu metody bez kary niedopasowania masek oraz metody z maską referencyjną.

5.1.3 Podsumowanie

Zarówno wartości błędów wyznaczania przemieszczeń, jak i wartości wyznaczonych odkształceń wskazują, że zastosowanie kary niedopasowania masek ma pozytywny wpływ na działanie algorytmu estymacji przemieszczeń i odkształceń. Oba rodzaje zastosowanych masek powodowały znaczną poprawę wyników, w stosunku do efektów uzyskanych przy użyciu algorytmu bez kary niedopasowania masek. Zastosowanie maski referencyjnej pozwala na uzyskanie lepszych efektów niż zastosowanie maski uzyskanej przy użyciu segmentacji metodą aktywnego konturu, jednak różnica w wynikach nie jest znacząca, co może wynikać m.in. z wysokiej jakości zastosowanych masek pochodzących z segmentacji metodą aktywnego konturu.

5.2 Dane semi-syntetyczne

W badaniu na danych semi-syntetycznych wykorzystane zostały dwa rodzaje masek: maski referencyjne oraz maski wygenerowane przy użyciu metody aktywnego konturu, zaimplementowanej w komercyjnym oprogramowaniu PMOD.

W ramach badania przetestowane zostało działanie algorytmu elastycznego dopasowania obrazów z kombinacjami wagi kary gładkości o wartościach 0 oraz 0,05 i współczynnika wagowego kary niedopasowania masek o wartościach 0 oraz 1, dobrane na podstawie wcześniejszych badań, opisanych w rozdziale 4.

Jako że maski wygenerowane przy użyciu metody aktywnego konturu są dostępne jedynie dla części danych z zestawu (patrz rozdział 3.1.3.1.2), wyniki eksperymentów przeprowadzonych z wykorzystaniem masek referencyjnych zostały zaprezentowane w dwóch wariantach: na pełnym zestawie danych oraz na danych, dla których dostępne są maski, pochodzące z segmentacji. Dzięki temu możliwe jest zarówno spojrzenie na wyniki działania wyznaczania przemieszczeń i odkształceń w pełnym zbiorze danych, jak również porównanie wyników,

uzyskanych przy wykorzystaniu masek referencyjnych z wynikami uzyskanymi przy wykorzystaniu masek z segmentacji.

Ze względu na znaczącą liczbę sekwencji, na których przeprowadzone zostało badanie (105 sekwencji w pełnym zestawie i 30 sekwencji, dla których dostępne są maski z segmentacji przy użyciu metody aktywnego konturu) wyniki są zaprezentowane w postaci wykresów pudełkowych oraz wartości wybranych parametrów statystycznych wartości błędów wyznaczania przemieszczeń i odkształceń.


5.2.1 Błędy wyznaczania przemieszczeń w danych semi-syntetycznych

5.2.1.1 Maski referencyjne


Pełny zestaw semi-syntetycznych danych obrazowych

Pełne zestawienia wartości średniego błędu wyznaczania przemieszczeń w kierunku x w danych semi-syntetycznych, z maską referencyjną są umieszczone w tabeli 18 w dodatku A, zaś w kierunku y w tabeli 19 w dodatku A.

Rysunek 32 oraz Rysunek 33 przedstawiają wykresy pudełkowe wartości średniego błędu wyznaczania przemieszczeń odpowiednio w kierunku x oraz w kierunku y , w zależności od zastosowanych wartości wag kar gładkości i maski. Wartości średniej, mediany oraz pierwszego i trzeciego kwartyla zostały dodatkowo umieszczone w tabeli 7 oraz tabeli 8.



Rysunek 32 Wykres pudełkowy wartości błędów wyznaczania przemieszczeń w kierunku x w badaniu z użyciem danych semi-syntetycznych i masek referencyjnych



Rysunek 33 Wykres pudełkowy wartości błędów wyznaczania przemieszczeń w kierunku y w badaniu z użyciem danych semi-syntetycznych i masek referencyjnych

Tabela 7 Parametry statystyczne wartości błędów wyznaczania przemieszczeń w kierunku x w badaniu z użyciem danych semi-syntetycznych i masek referencyjnych (Rysunek 32)

Wartości wag	Średnia [m]	Mediana [m]	1. kwartył [m]	3. kwartył [m]
$\omega_s = 0, k_m = 0$	0,000734	0,000634	0,000530	0,000800
$\omega_s = 0, k_m = 1$	0,000641	0,000612	0,000530	0,000708
$\omega_s = 0,05, k_m = 0$	0,000649	0,000617	0,000532	0,000718
$\omega_s = 0,05, k_m = 1$	0,000642	0,000612	0,000530	0,000707

Tabela 8 Parametry statystyczne wartości błędów wyznaczania przemieszczeń w kierunku y w badaniu z użyciem danych semi-syntetycznych i masek referencyjnych (Rysunek 33)

Wartości wag	Średnia [m]	Mediana [m]	1. kwartył [m]	3. kwartył [m]
$\omega_s = 0, k_m = 0$	0,000639	0,000504	0,000457	0,000669
$\omega_s = 0, k_m = 1$	0,000525	0,000501	0,000450	0,000601
$\omega_s = 0,05, k_m = 0$	0,000534	0,000505	0,000453	0,000604
$\omega_s = 0,05, k_m = 1$	0,000525	0,000501	0,000450	0,000601

Zarówno w przypadku wartości błędu wyznaczania przemieszczeń w kierunku x, jak i w kierunku y, najgorsze wyniki zostały osiągnięte w wariancie, w którym nie została wykorzystana żadna funkcja kary (obie wagi równe 0).

Wartość średnia błędu wyznaczania przemieszczeń w kierunku x była w wariancie bez funkcji kar wyższa o około 13% od wartości uzyskanych w wariantach, w których zastosowana była kara niedopasowania masek oraz o około 12% wyższa niż w wariancie, w którym została zastosowana jedynie kara gładkości. Wartość mediany była w wariancie bez funkcji kar wyższa niż w pozostałych o około 3%. Różnice w wartości pierwszego kwartyla w żadnym z wariantów nie przekraczały 0,5%. Wartość trzeciego kwartyla w wariancie bez funkcji kar wyższa o około 12% niż w wariantach z karą niedopasowania masek i o około 10% wyższa niż w wariancie z samą karą gładkości.


Wartość średnia błędu wyznaczania przemieszczeń w kierunku y była w wariancie bez funkcji kar wyższa o około 18% niż w wariantach z karą niedopasowania masek i o około 16% wyższa niż w wariancie z samą karą gładkości. Różnice w wartościach mediany w poszczególnych wariantach nie przekraczały 1%, zaś w wartościach pierwszego kwartyla nie przekraczały 2%. Wartość trzeciego kwartyla błędu wyznaczania przemieszczeń w kierunku y była w wariancie bez funkcji kar wyższa o około 10% niż w pozostałych wariantach.

Znaczne różnice w wartościach mediany i trzeciego kwartyla pomiędzy wariantem bez funkcji kar i pozostałymi wariantami wskazują, że zastosowanie którejkolwiek z kar powoduje zmniejszenie liczby obserwacji, cechujących się wysoką wartością błędu wyznaczania przemieszczeń. Jednocześnie zastosowanie którejkolwiek z kar lub zestawienia dwóch z nich poprawia wyniki wyznaczania przemieszczeń w zbliżonym stopniu – w żadnym z 4 wyznaczonych parametrów, różnica pomiędzy wariantami z zastosowaniem różnych kar nie przekracza 1,7% - co wskazuje, że w przypadku badanego zestawu danych wystarczające jest zastosowanie jednej z dwóch funkcji kary.


Podzbiór semi-syntetycznych danych obrazowych, dla których dostępne są maski z segmentacji metodą aktywnego konturu

W związku z tym, że maski pochodzące z segmentacji metodą aktywnego konturu są dostępne jedynie dla części semi-syntetycznych danych obrazowych, w kolejnej sekcji zamieszczone są wyniki uzyskane przy wykorzystaniu masek referencyjnych dla tej części zbioru. Jako że efektywność działania algorytmu jest różna w zależności od danych – w szczególności w zależności od producenta urządzenia, wykorzystanego do obrazowania, jest to konieczne do rzetelnej oceny różnicy w działaniu algorytmu z maską referencyjną oraz z maską pochodzącą z segmentacji, co pozwala wnioskować o wpływie jakości zastosowanej maski na efekty działania algorytmu.

Rysunek 34 oraz Rysunek 35 przedstawiają wykresy pudełkowe wartości średniego błędu wyznaczania przemieszczeń odpowiednio w kierunku x i y, w zależności od zastosowanych wartości wag kar gładkości i maski. Wartości średniej, mediany oraz pierwszego i trzeciego kwartyla zostały dodatkowo umieszczone w tabeli 9 oraz 10.



Rysunek 34 Wykres pudełkowy wartości błędu wyznaczania przemieszczeń w kierunku x w badaniu z użyciem danych semi-syntetycznych i masek referencyjnych, gdzie uwzględnione zostały jedynie te zestawy danych, dla których dostępne są maski z segmentacji metodą aktywnego konturu.



Rysunek 35 Wykres pudełkowy wartości błędu wyznaczania przemieszczeń w kierunku y w badaniu z użyciem danych semi-syntetycznych i masek referencyjnych, gdzie uwzględnione zostały jedynie te zestawy danych, dla których dostępne są maski z segmentacji metodą aktywnego konturu.

Tabela 9 Parametry statystyczne wartości błędu wyznaczania przemieszczeń w kierunku x w badaniu z użyciem danych semi-syntetycznych i masek referencyjnych, gdzie uwzględnione zostały jedynie te zestawy danych, dla których dostępne są maski z segmentacji metodą aktywnego konturu.

Wartości wag	Średnia [m]	Mediana [m]	1. kwartyl [m]	3. kwartyl [m]
$\omega_s = 0, k_m = 0$	0,000660	0,000650	0,000540	0,000760
$\omega_s = 0, k_m = 1$	0,000642	0,000663	0,000538	0,000707
$\omega_s = 0,05, k_m = 0$	0,000643	0,000663	0,000539	0,000714
$\omega_s = 0,05, k_m = 1$	0,000641	0,000667	0,000538	0,000708


Tabela 10 Parametry statystyczne wartości błędu wyznaczania przemieszczeń w kierunku y w badaniu z użyciem danych semi-syntetycznych i masek referencyjnych, gdzie uwzględnione zostały jedynie te zestawy danych, dla których dostępne są maski z segmentacji metodą aktywnego konturu.

Wartości wag	Średnia [m]	Mediana [m]	1. kwartyl [m]	3. kwartyl [m]
$\omega_s = 0, \omega_k = 0$	0,000566	0,000544	0,000457	0,000650
$\omega_s = 0, \omega_k = 1$	0,000533	0,000531	0,000462	0,000602
$\omega_s = 0,05, \omega_k = 0$	0,000534	0,000531	0,000464	0,000602
$\omega_s = 0,05, \omega_k = 1$	0,000533	0,000531	0,000462	0,000600


W przypadku zestawu semi-syntetycznych danych obrazowych, ograniczonego do sekwencji, dla których dostępne są maski z segmentacji metodą aktywnych konturów, różnice w wartościach błędów wyznaczania przemieszczeń przez algorytm, wykorzystujący rozważane warianty wartości wag są znacznie mniejsze niż w przypadku pełnego zestawu. Szczególnie małe różnice są obserwowane w błędach wyznaczania przemieszczeń w kierunku x , gdzie różnica wartości średnich pomiędzy sytuacją, w której nie została zastosowana żadna z funkcji kar, a pozostałymi przypadkami wynosi jedynie około 3% na korzyść wariantu z karami, różnica wartości trzeciego kwartyla około 7% na korzyść wariantu z karami zaś różnica wartości mediany około 2% na korzyść wariantu bez kar. W przypadku błędów wyznaczania przemieszczeń w kierunku y , różnice pomiędzy sytuacją, w której nie została zastosowana żadna z funkcji kar, a pozostałymi przypadkami są bardziej zauważalne i wynoszą około 6% na korzyść wariantu z karami dla mediany, około 7% na korzyść wariantu z karami dla trzeciego kwartyla oraz około 6% na korzyść wariantu z karami dla średniej. Różnice pomiędzy wariantami, w których zastosowana została kara niedopasowania masek, kara gładkości oraz obie kary jednocześnie, w przypadku żadnego z parametrów nie przekraczają 1%.

5.2.1.2 Maski z segmentacji metodą aktywnych konturów

Rysunek 36 oraz Rysunek 37 przedstawiają wykresy pudełkowe wartości średniego błędu wyznaczania przemieszczeń, odpowiednio w kierunku x i y, przy użyciu masek z segmentacji, w zależności od zastosowanych wartości wag kar gładkości i maski. Wartości średniej, mediany oraz pierwszego i czwartego kwartyla zostały dodatkowo umieszczone w tabelach 11 oraz 12.



Rysunek 36 Wykres pudełkowy wartości błęd wyznaczania przemieszczeń w kierunku x w badaniu z użyciem danych semi-syntetycznych i masek z segmentacji metodą aktywnego konturu.



Rysunek 37 Wykres pudełkowy wartości błęd wyznaczania przemieszczeń w kierunku y w badaniu z użyciem danych semi-syntetycznych i masek z segmentacji metodą aktywnego konturu.

Tabela 11 Parametry statystyczne wartości błędu wyznaczania przemieszczeń w kierunku x w badaniu z użyciem danych semi-syntetycznych i masek z segmentacji metodą aktywnego konturu

Wartości wag	Średnia [m]	Mediana [m]	1. kwartyl [m]	3. kwartyl [m]
$\omega_s = 0, k_m = 0$	0,000660	0,000650	0,000540	0,000760
$\omega_s = 0, k_m = 1$	0,000640	0,000669	0,000537	0,000705
$\omega_s = 0,05, k_m = 0$	0,000643	0,000663	0,000539	0,000714
$\omega_s = 0,05, k_m = 1$	0,000641	0,000666	0,000537	0,000708

Tabela 12 Parametry statystyczne wartości błędu wyznaczania przemieszczeń w kierunku y w badaniu z użyciem danych semi-syntetycznych i masek z segmentacji metodą aktywnego konturu

Wartości wag	Średnia [m]	Mediana [m]	1. kwartyl [m]	3. kwartyl [m]
$\omega_s = 0, k_m = 0$	0,000566	0,000544	0,000457	0,000650
$\omega_s = 0, k_m = 1$	0,000534	0,000531	0,000466	0,000601
$\omega_s = 0,05, k_m = 0$	0,000534	0,000531	0,000464	0,000602
$\omega_s = 0,05, k_m = 1$	0,000532	0,000531	0,000462	0,000597

Efekty działania algorytmu z maską pochodzącą z segmentacji metodą aktywnego konturu, są bardzo zbliżone do efektów uzyskanych przy wykorzystaniu maski referencyjnej – różnice pomiędzy wynikami uzyskanymi przy użyciu tych dwóch typów masek nie przekraczają 1%. Pokazuje to, że w tym zestawie danych, użycie masek z segmentacji daje efekty bardzo zbliżone do efektów zastosowania masek referencyjnych.

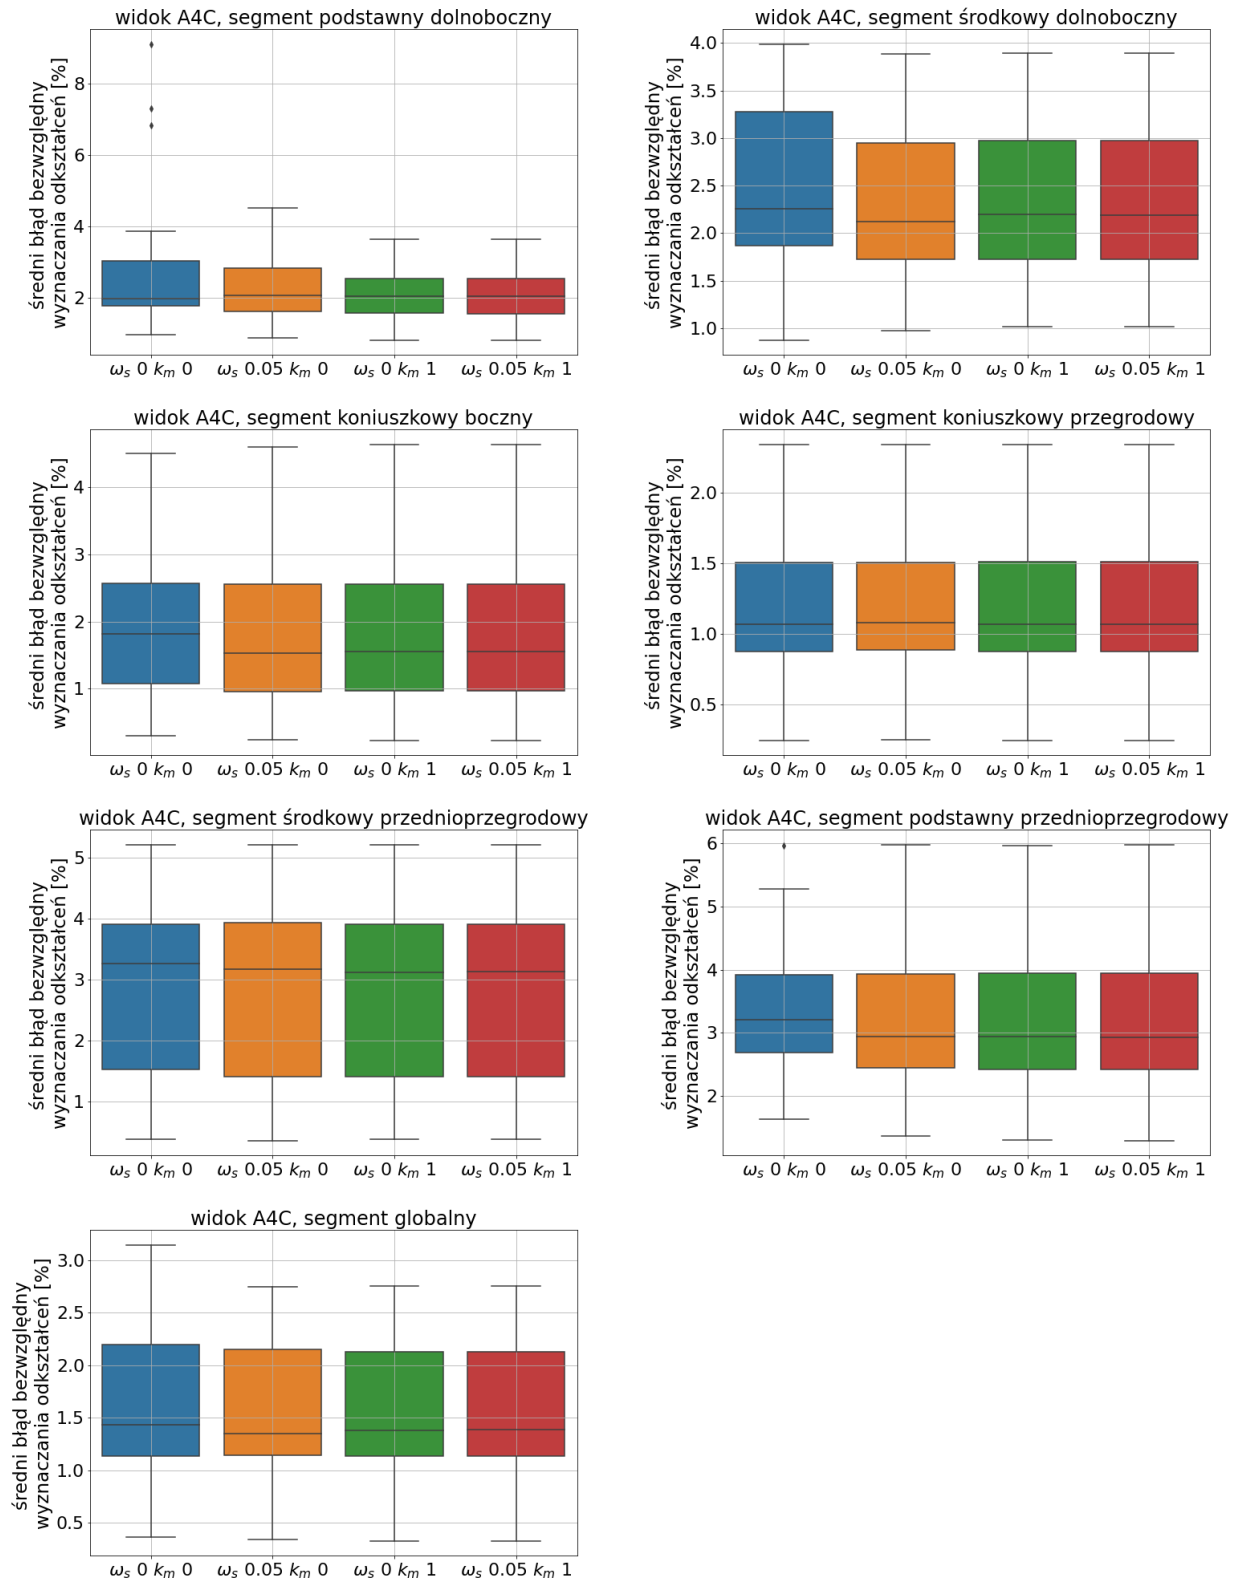
5.2.2 Błędy wyznaczania odkształceń w danych semi-syntetycznych

5.2.2.1 Maski referencyjne

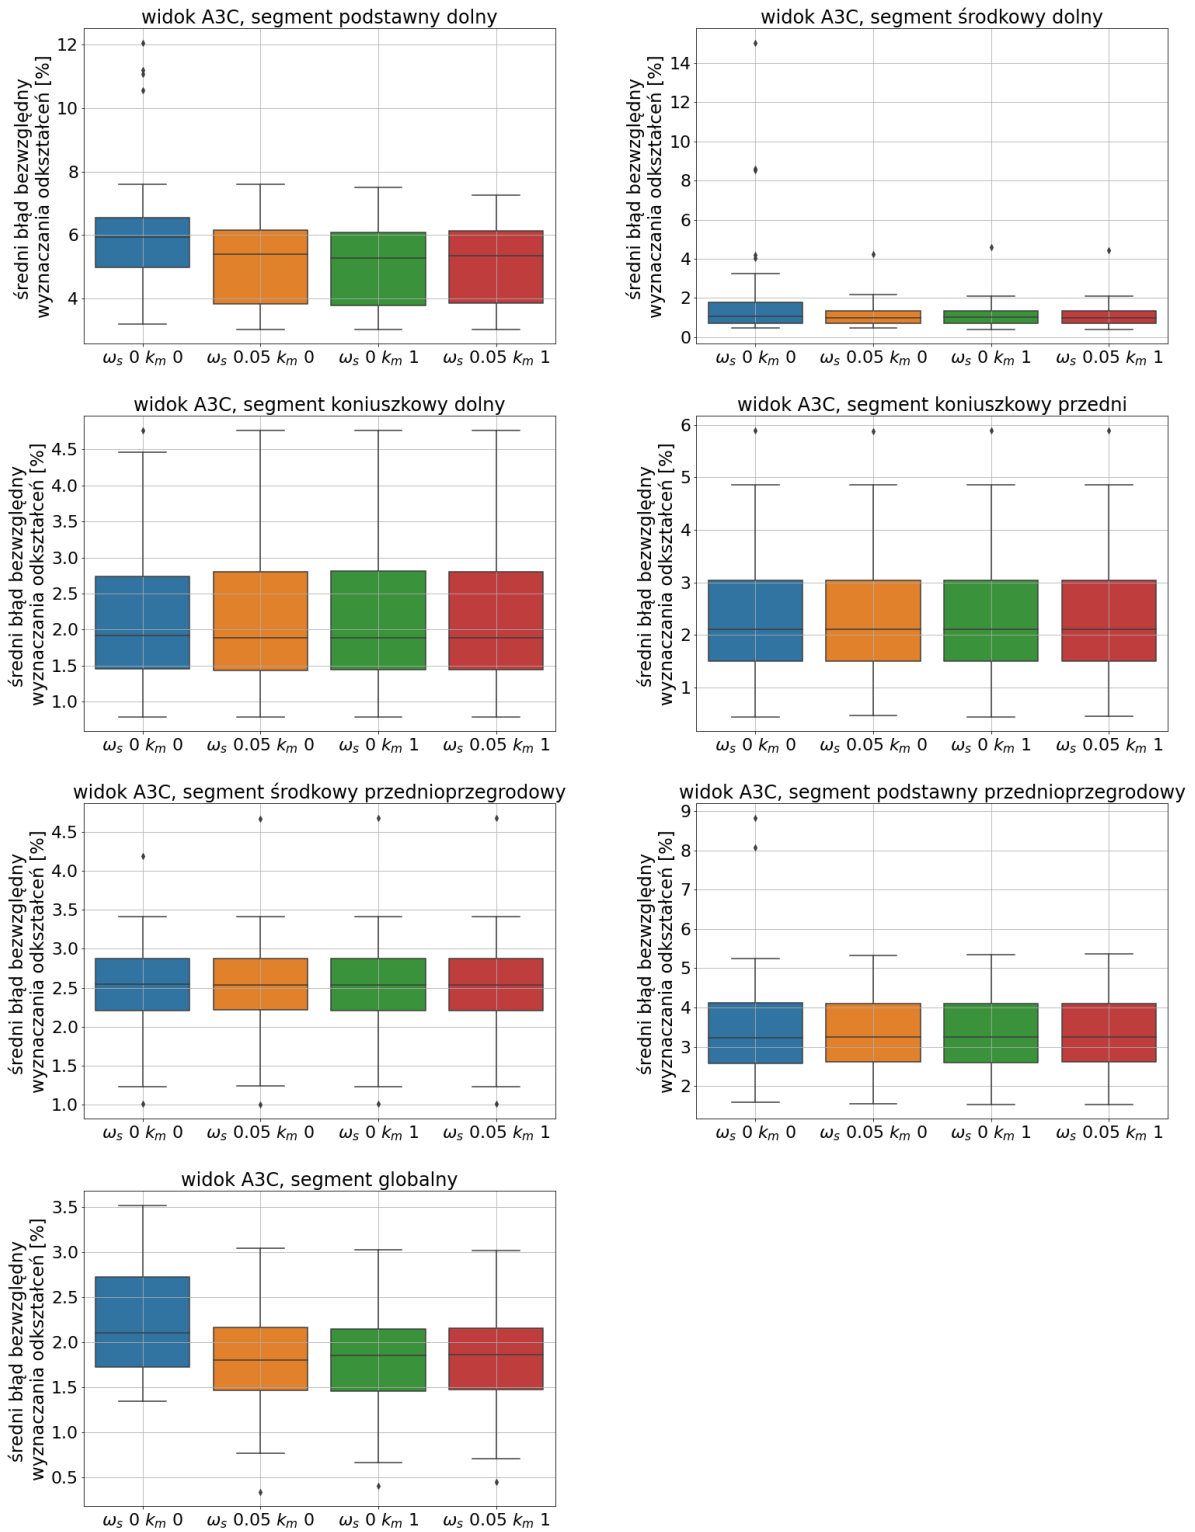
Zestawienie błędów wyznaczania odkształceń, uzyskanych przy wykorzystaniu danych z maskami referencyjnymi zostało przedstawione w dwóch wariantach: zestawienie błędów na pełnym zestawie danych oraz zestawienie błędów w sekwencjach, dla których dostępne są dane z segmentacji metodą aktywnego konturu, ograniczającym się do danych symulujących obrazy, uzyskane przy użyciu urządzeń GE, ESAOTE i TOSHIBA w widokach 3- i 4-komorowym.

Pełny zestaw danych

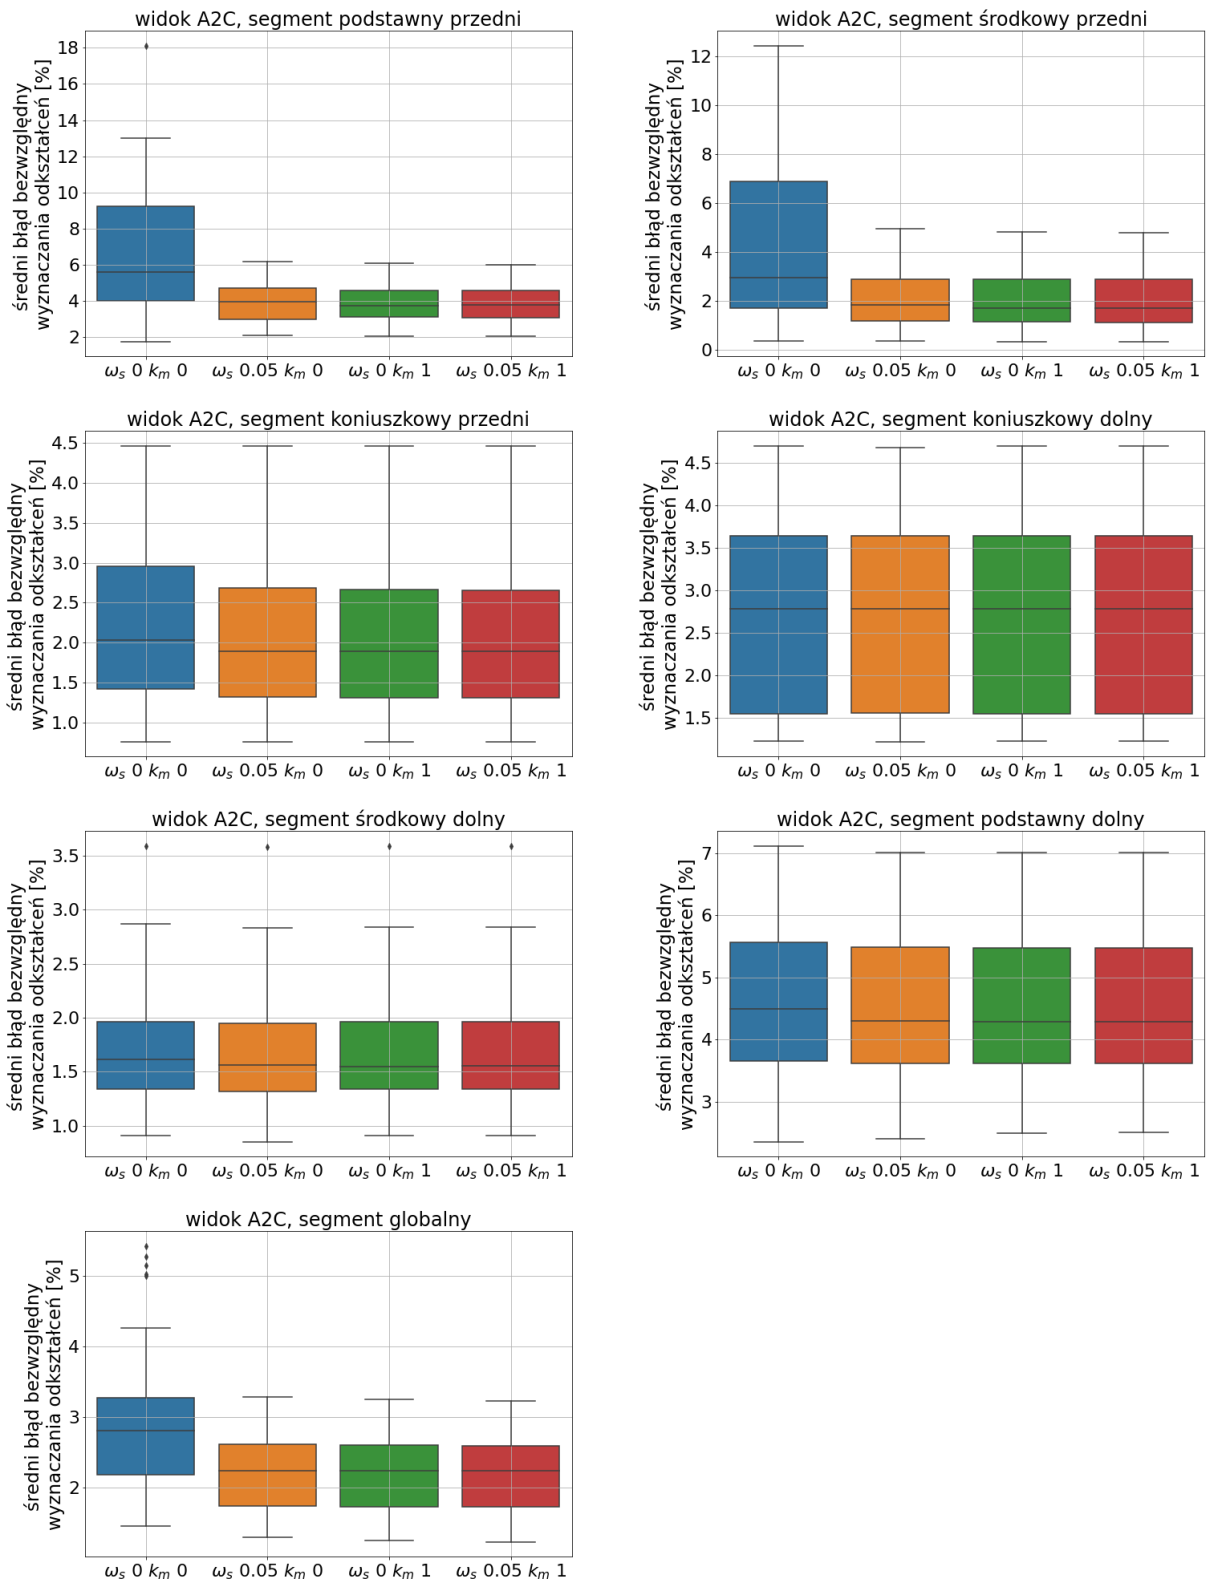
Rysunek 38, Rysunek 39 oraz Rysunek 40 przedstawiają wykresy pudełkowe wartości średniego błędu wyznaczania odkształceń w segmentach, odpowiednio w ramach widoków 4-, 3- i 2-komorowych, w zależności od zastosowanych wartości wagi kary gładkości i współczynnika wagowego kary niedopasowania masek. Wartości średniej, mediany oraz pierwszego i czwartego kwartyła zostały dodatkowo umieszczone w tabeli 20 w dodatku A.



Rysunek 38 Wykresy pudełkowe wartości błędu wyznaczania odkształceń w segmentach w badaniu na danych semi-syntetycznych w widoku czterokomorowym, z maską referencyjną.



Rysunek 39 Wykresy pudełkowe wartości błędu wyznaczania odkształceń w segmentach w badaniu z użyciem danych semi-syntetycznych w widoku trzykomorowym i masek referencyjnych.



Rysunek 40 Wykresy pudełkowe wartości błędu wyznaczania odkształceń w segmentach w badaniu z użyciem danych semi-syntetycznych w widoku dwukomorowym i masek referencyjnych.

Widok czterokomorowy

W widoku czterokomorowym różnice pomiędzy wariantami, w których była użyta kara niedopasowania masek nie przekraczały 5%. Największe różnice można zaobserwować pomiędzy wariantem, w którym nie została zastosowana żadna funkcja kary, a pozostałymi, szczególnie w segmentach podstawnym dolnobocznym oraz środkowym dolnobocznym.

W segmencie podstawnym dolnobocznym najniższa wartość średniego błędu została osiągnięta w dwóch wariantach, w których wykorzystana była kara niedopasowania masek, wykorzystanie jedynie kary gładkości spowodowało uzyskanie wartości średniej wyższej o około 5%, zaś niewykorzystanie żadnej funkcji kary – o ponad 20%. Najniższa wartość mediany błędu została osiągnięta w wariacie bez funkcji kar, zaś najwyższa w wariacie z samą karą gładkości, przy czym różnica nie przekroczyła 1%. Najniższe wartości pierwszego kwartyla zostały osiągnięte przy wykorzystaniu dwóch wariantów z karą niedopasowania masek, wariant z samą karą gładkości dał wynik gorszy o około 4%, a wariant bez funkcji kar o 12%. Sytuacja wyglądała podobnie w przypadku trzeciego kwartyla: warianty z karą niedopasowania masek dały wynik lepszy o 10% od wariantu z karą gładkości i o 16% od wariantu bez kar.

W segmencie środkowym dolnobocznym różnice w wartości średniego błędu wyznaczania odkształceń pomiędzy trzema wariantami, gdzie zastosowana była jakakolwiek funkcja kary, nie przekroczyły 1%, zaś wariant bez funkcji kar osiągnął wynik gorszy o około 6%. Najniższa wartość mediany błędu wyznaczania odkształceń została osiągnięta przy wykorzystaniu wariantów z karą niedopasowania masek, wariant z samą karą gładkości dał wynik o 6% gorszy, zaś wariant bez funkcji kar o 3% gorszy. Różnice w wartości pierwszego kwartyla błędu wyznaczania odkształceń w trzech wariantach, w których użyta została jakakolwiek kara niedopasowania masek, nie przekroczyły 1%, zaś wariant bez kary niedopasowania masek był od nich gorszy o około 8%. Wartość trzeciego kwartyla w wariacie bez funkcji kar osiągnął wynik gorszy niż w pozostałych wariantach o około 10%.

W segmencie koniuszkowym bocznym różnice w wartościach średniej, mediany, pierwszego i trzeciego kwartyla pomiędzy wariantami, w których użyta została jakakolwiek funkcja kary, nie przekraczały 1%. Wariant bez funkcji kary osiągnął wyższe wartości średniej, mediany i pierwszego kwartyla, o odpowiednio 5, 15 i 10%, oraz zbliżoną wartość trzeciego kwartyla.

W segmencie koniuszkowym przegrodowym wszystkie warianty osiągnęły bardzo zbliżone wyniki, w żadnym z parametrów nie odnotowano różnic, przekraczających 1%.

W segmencie środkowym przednioprzegrodowym różnice pomiędzy wariantami w wartościach średniej i trzeciego kwartyla nie przekroczyły 1%. Wartości mediany i pierwszego kwartyla w wariacie bez funkcji kar były gorsze od pozostałych o odpowiednio około 4% i 8%.

W segmencie podstawnym przednioprzegrodowym warianty, w których wykorzystana została którakolwiek z rozważanych funkcji kary osiągnęły wyniki nie różniące się od siebie o więcej niż 1%. Wariant bez funkcji kary dał wynik gorszy niż pozostałe w przypadku średniej, mediany, i pierwszego kwartyla, a różnice wyniosły odpowiednio 6%, 9% i 9%.

Globalnie, warianty, w których zastosowana została jakakolwiek funkcja kary, osiągnęły wartość średnią błędu wyznaczania odkształceń niższą o około 4% niż wariant bez funkcji kar. Najniższa wartość mediany globalnego błędu wyznaczania odkształceń została osiągnięta w wariacie, w którym zastosowana została jedynie kara gładkości i była ona niższa niż w wariantach z karą niedopasowania masek o około 3% i o około 6% niższa niż w wariacie bez funkcji kar. Różnice w wartości pierwszego kwartyla nie przekroczyły 1%. Wariant bez funkcji kary osiągnął wartość trzeciego kwartyla wyższą od pozostałych o około 3%.

W widoku czterokomorowym wyraźnie gorsze wyniki od pozostałych dał wariant bez funkcji kar. Dwa warianty, w których zastosowana została kara niedopasowania masek, dały niemal identyczne wyniki, natomiast wariant, w którym została wykorzystana jedynie kara gładkości, stanowiący główny punkt odniesienia, dał wyniki nieco od nich odbiegające - w większości przypadków były to różnice na korzyść wariantów z karą niedopasowania masek, jednak różnice były stosunkowo niewielkie i w żadnym z przypadków nie przekroczyły 5%.

Widok trzykomorowy

W widoku trzykomorowym, w segmencie podstawnym dolnym różnice w wartościach średniej, mediany, pierwszego i trzeciego kwartyla błędu wyznaczania odkształceń w wariantach, w których została zastosowana jakakolwiek funkcja kary, nie różnią się od siebie o więcej niż 2%. W wyniku zastosowania wariantu bez funkcji kar uzyskane zostały wartości tych parametrów, gorsze odpowiednio o około 18, 10, 23 i 6%.

W segmencie środkowym dolnym, w wariacie, w którym nie została zastosowana żadna funkcja kary, średnia wartość błędu wyznaczania odkształceń była niemal dwukrotnie wyższa niż w pozostałych wariantach, zaś wartość mediany była w tym wariacie wyższa o około 5%. Wartość pierwszego kwartyla była zbliżona w wariantach bez kar oraz z samą karą gładkości

i niższa niż w wariantach z karą niedopasowania masek o około 33%. Wartość trzeciego kwartyła była najwyższa w wariancie bez funkcji kar, pozostałe warianty pozwoliły na osiągnięcie wyniku lepszego o około 24%.

W segmentach koniuszkowym dolnym, koniuszkowym przednim oraz środkowym przednioprzegrodowym różnice pomiędzy poszczególnymi wariantami były niewielkie i w żadnym przypadku nie przekroczyły 3%.

W segmencie podstawnym przednioprzegrodowym wartość średnia błędu wyznaczania odkształceń w wariancie bez funkcji kar była wyższa o około 6% niż w pozostałych wariantach. Wartości pozostałych parametrów nie różniły się pomiędzy wariantami o więcej niż 2%.

Globalnie, wariant, w którym nie została wykorzystana żadna funkcja kary dał wartość średniego błędu wyznaczania odkształceń, gorszą o około 19% od pozostałych wariantów. Najniższa wartość mediany została osiągnięta przy wykorzystaniu wariantu z samą karą gładkości, warianty z karą niedopasowania masek dały wynik gorszy o 3%, zaś wariant bez funkcji kar o 14%. Wartości pierwszego i trzeciego kwartyła były bardzo zbliżone we wszystkich wariantach, w których zostały zastosowane funkcje kary, zaś wariant bez funkcji kar był gorszy odpowiednio o 15 i 21%.

W widoku trzykomorowym, od pozostałych wariantów wyraźnie odstawał wariant, w którym nie została zastosowana żadna funkcja kary. Pozostałe warianty dawały zbliżone wyniki. Wyjątkiem był pierwszy kwartył w segmencie środkowym dolnym, gdzie wariant z samą karą gładkości był o jedną trzecią lepszy od wariantów z karą niedopasowania masek – jednak wartości pierwszego kwartyła błędu wyznaczania odkształceń w tym segmencie były generalnie bardzo niskie – różnica bezwzględna wartości pierwszego kwartyła pomiędzy wariantem z karą gładkości i wariantami z karą niedopasowania masek wyniosła około 0,25 punktu procentowego.

Widok dwukomorowy

W widoku dwukomorowym w segmencie podstawnym przednim, wartości średniej, mediany, pierwszego i trzeciego kwartyła błędu wyznaczania odkształceń w trzech wariantach z funkcjami kary była niższa o odpowiednio około 40%, 30%, 20% i 50% niż w wariancie bez funkcji kar.

W segmencie środkowym przednim wariant bez funkcji kar dał wyniki wyraźnie gorsze niż pozostałe warianty, wartości średniej, mediany, pierwszego i trzeciego kwartyla były w tym wariantcie niższe odpowiednio o około 50%, 40%, 30% i 60%.

W segmencie koniuszkowym przednim osiągnięta przy użyciu wariantu bez funkcji kar wartość średnia błędu wyznaczania odkształceń jest wyższa o około 7% niż w pozostałych wariantach zaś wartości mediany, pierwszego i trzeciego kwartyla w tym wariantcie są wyższe niż w pozostałych o odpowiednio 7%, 8% i 10%.

W segmencie koniuszkowym dolnym wszystkie warianty pozwalają na osiągnięcie zbliżonych wyników, różnice pomiędzy nimi nie przekraczają 1%.

W segmencie środkowym dolnym, różnice pomiędzy wariantami są widoczne jedynie w wartościach średniej i mediany błędu wyznaczania odkształceń, które w wariantcie bez funkcji kar są wyższe niż w pozostałych wariantach o odpowiednio około 2% i 4%.

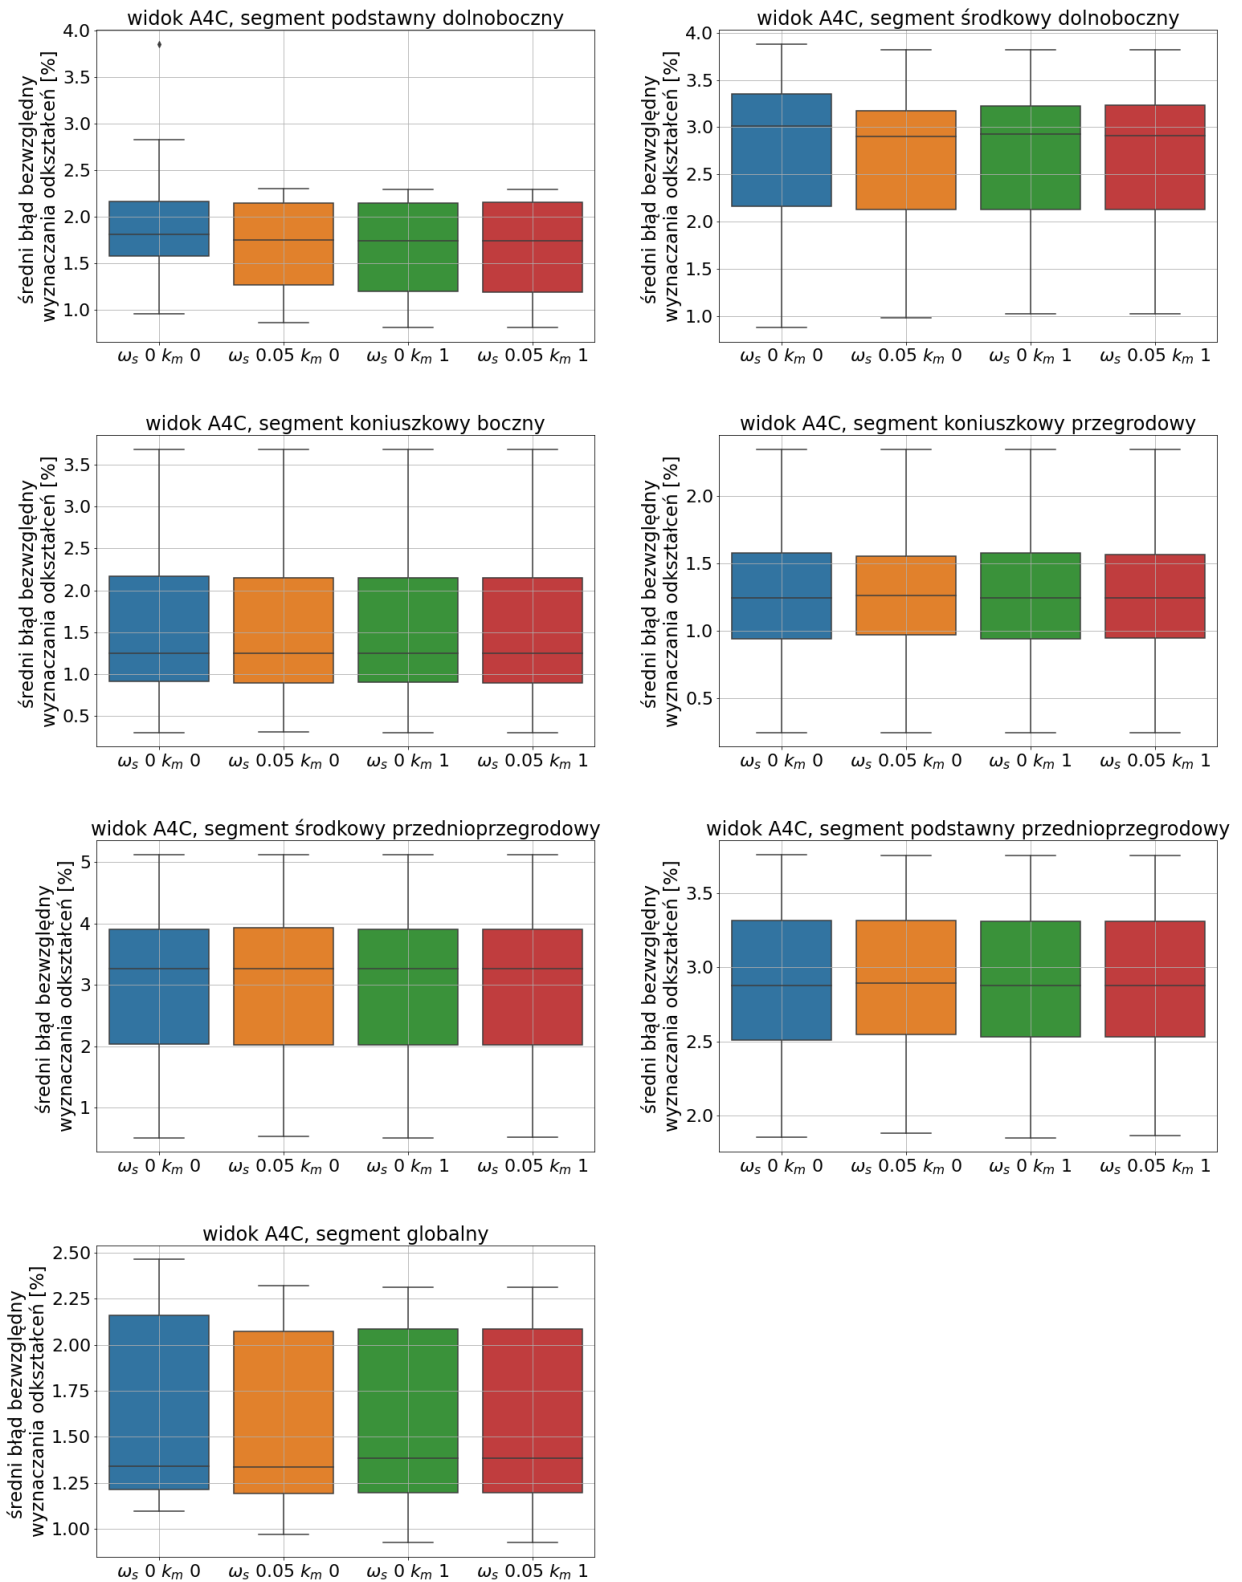
W segmencie podstawnym dolnym różnice wyższe niż 2% są odnotowywane jedynie pomiędzy wariantem bez funkcji kar, a pozostałymi, w wartościach średniej oraz mediany i wynoszą odpowiednio około 2% i 5%.

Globalnie, różnice pomiędzy poszczególnymi wariantami, które wykorzystują funkcje kar, nie przekraczają 1,5%. Od pozostałych wariantów wyraźnie odstaje wariant bez funkcji kar, w którym wartość średnia błędu jest wyższa o ponad 25%, zaś mediana, pierwszy i trzeci kwartyl o około 20%.

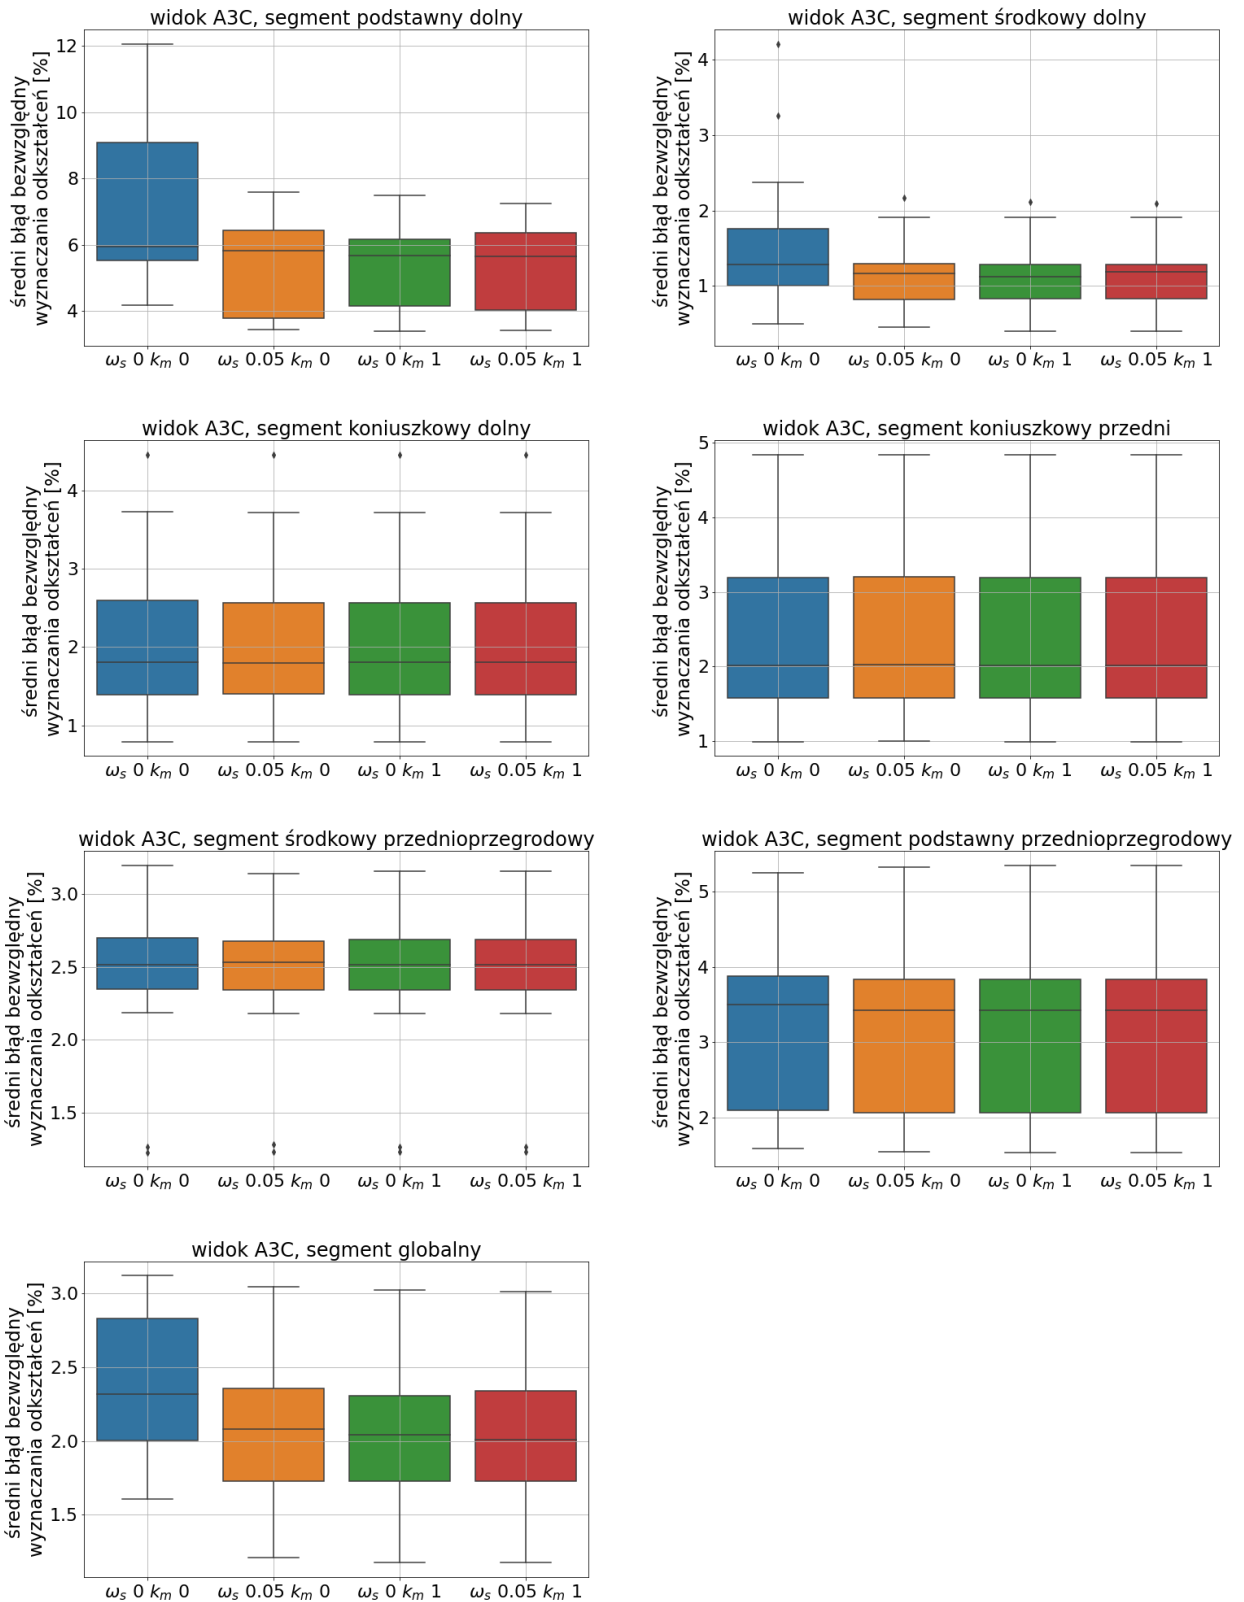
W widoku dwukomorowym warianty, w których zostały wykorzystane funkcje kary cechują się wyższym podobieństwem niż w przypadku widoków trzy- i czterokomorowego, zaś wariant bez funkcji kary daje w większości segmentów, jak również globalnie, wyniki wyraźnie gorsze od pozostałych wariantów.

Podzbiór semi-syntetycznych danych obrazowych, dla których dostępne są maski z segmentacji metodą aktywnego konturu

Rysunek 41 oraz Rysunek 42 przedstawiają wykresy pudełkowe wartości średniego błędu wyznaczania odkształceń w segmentach, odpowiednio w widokach 4- i 3-komorowych, z podziałem na warianty zastosowanych wartości wagi kary gładkości i współczynnika wagowego kary niedopasowania masek. Wartości średniej, mediany oraz pierwszego i czwartego kwartyla zostały dodatkowo umieszczone w tabeli 21 w dodatku A.



Rysunek 41 Wykresy pudełkowe wartości błędu wyznaczania odkształceń w segmentach w badaniu z użyciem danych semi-syntetycznych w widoku A4C i masek referencyjnych, dla których są dostępne maski z segmentacji metodą aktywnego konturu.



Rysunek 42 Wykresy pudełkowe wartości błędu wyznaczania odkształceń w segmentach w badaniu z użyciem danych semi-syntetycznych w widoku trzykomorowym i masek referencyjnych, dla których są dostępne maski z segmentacji metodą aktywnego konturu.

Widok czterokomorowy

W widoku czterokomorowym, w segmencie podstawnym dolnobocznym, wartość średnia błędu wyznaczania odkształceń w wariantach, wykorzystujących funkcje kary jest niższa niż w wariacie bez funkcji kar o ponad 10%, zaś wartość mediany o około 3%. Najniższa wartość pierwszego kwartyla błędu wyznaczania odkształceń występuje w dwóch wariantach, w których wykorzystana została kara niedopasowania masek i jest ona niższa od wartości osiąganey przy użyciu wariantu z samą karą gładkości o około 6%, i o około 24% niższa niż przy użyciu wariantu bez funkcji kar. Wszystkie warianty osiągają zbliżoną wartość trzeciego kwartyla błędu wyznaczania odkształceń – różnice między nimi nie przekraczają 1%.

W segmencie środkowym dolnobocznym wartość średnia błędu wyznaczania odkształceń w wariacie bez funkcji kar jest wyższa niż w pozostałych o około 4%, mediana o około 3%, zaś pierwszy kwartyl o około 1%. Wartość trzeciego kwartyla jest najniższa w wariacie z samą karą gładkości, warianty z karą niedopasowania masek dają wartość trzeciego kwartyla błędu wyznaczania odkształceń wyższą o około 2%, zaś wariant bez funkcji kar o około 5%.

W segmentach koniuszkowym bocznym, koniuszkowym przegrodowym, środkowym przednioprzegrodowym oraz podstawnym przednioprzegrodowym, różnice w wartościach badanych parametrów pomiędzy poszczególnymi wariantami nie przekraczają 2%.

Globalnie, wartość średnia błędu wyznaczania odkształceń w wariacie bez funkcji kar jest wyższa o około 3% niż w pozostałych wariantach. Najniższa wartość mediany jest osiągnana w wariacie bez funkcji kar oraz w wariacie z samą karą gładkości – wartości mediany osiągnane w wariantach z karą niedopasowania masek są wyższe o około 3%. Wartości pierwszego i trzeciego kwartyla są w wariacie bez funkcji kar wyższe niż w pozostałych o odpowiednio około 2% i 4%.

Widok trzykomorowy

W widoku trzykomorowym, w segmencie podstawnym dolnym, w trzech wariantach z funkcjami kar, wartość średnia błędu wyznaczania odkształceń była niższa niż w wariacie bez funkcji kar o około 25%. Najniższa wartość mediany została osiągnięta w wariantach z karą niedopasowania masek – w wariacie z samą karą gładkości wartość mediany jest wyższa o około 3%, zaś w wariacie bez funkcji kar o około 5%. Najniższa wartość pierwszego kwartyla została osiągnięta w wariacie z samą karą gładkości – warianty z karą niedopasowania masek dały wartości wyższe o około 6%, zaś wariant bez funkcji kar – o około

30%. Najniższa wartość trzeciego kwartyła została osiągnięta w wariancie z samą karą niedopasowania masek – warianty z karą gładkości dały wartości wyższe o około 3%, zaś wariant bez funkcji kar – o ponad 30%.

W segmencie środkowym dolnym, w trzech wariantach z funkcjami kar, wartość średnia błędu wyznaczania odkształceń była niższa niż w wariancie bez funkcji kar o około 28%. Najniższa wartość mediany została osiągnięta w wariancie z samą karą niedopasowania masek, wariant z samą karą gładkości dał wartość mediany wyższą o około 3%, wariant z dwiema karami – o około 5%, zaś wariant bez funkcji kar o około 13%. Najniższa wartość pierwszego kwartyła została osiągnięta w wariancie z samą karą gładkości, warianty z karą niedopasowania masek dały wynik gorszy o około 1%, zaś wariant bez funkcji kar o około 18%. Wartość trzeciego kwartyła była zbliżona we wszystkich trzech wariantach, w których zastosowane zostały funkcje kary, zaś wariant bez funkcji kar dał wynik wyższy o około 27%.

W segmentach koniuszkowym dolnym, koniuszkowym przednim, środkowym przednioprzegrodowym oraz podstawnym przednioprzegrodowym różnice pomiędzy poszczególnymi wariantami w żadnym z badanych parametrów nie przekroczyła 2%.

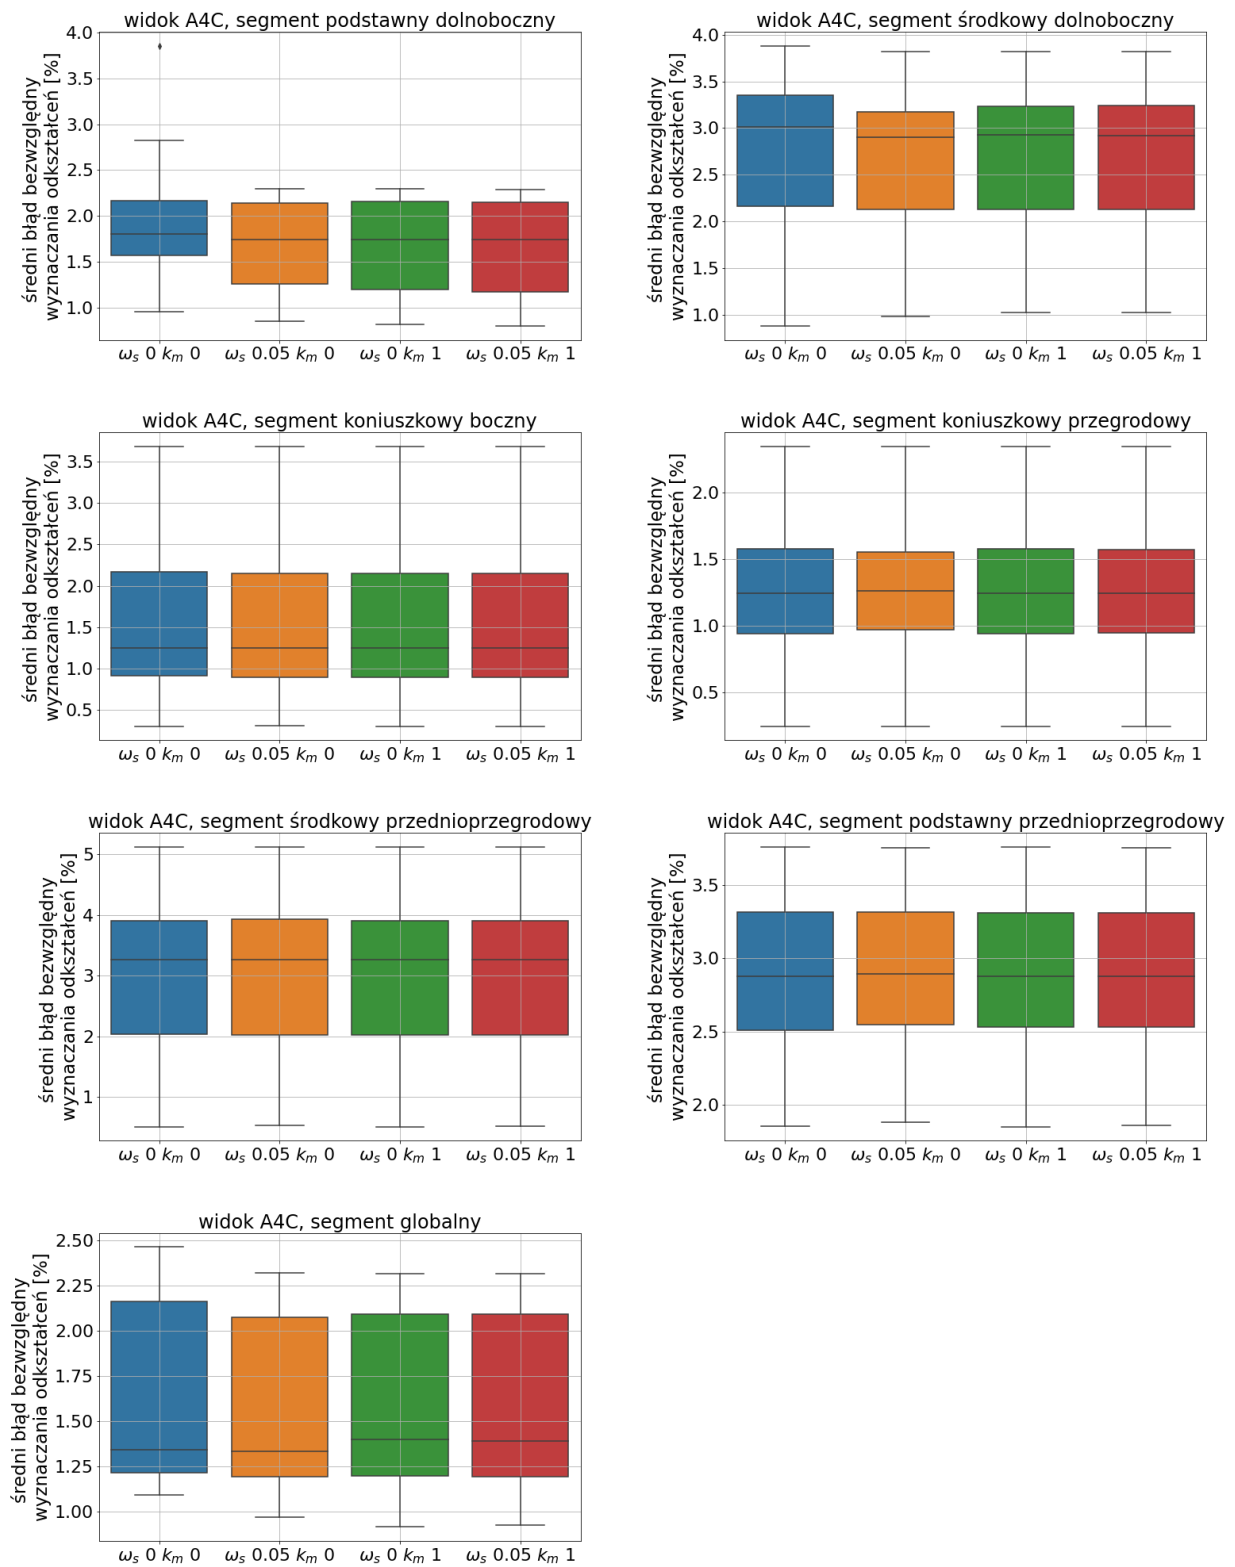
Globalnie, średnia wartość błędu wyznaczania odkształceń w trzech wariantach z funkcjami kary jest niższa niż w wariancie bez funkcji kar o około 15%. Najniższa wartość mediany jest uzyskiwana w wariancie z dwiema funkcjami kary, warianty z samą karą niedopasowania masek, samą karą gładkości oraz bez funkcji kar osiągają wynik wyższy o odpowiednio 2%, 4% i 13%. Wartości pierwszego i trzeciego kwartyła są w wariantach z funkcjami kary niższe niż w wariancie bez funkcji kar o odpowiednio 14% i 17%.

Podsumowanie

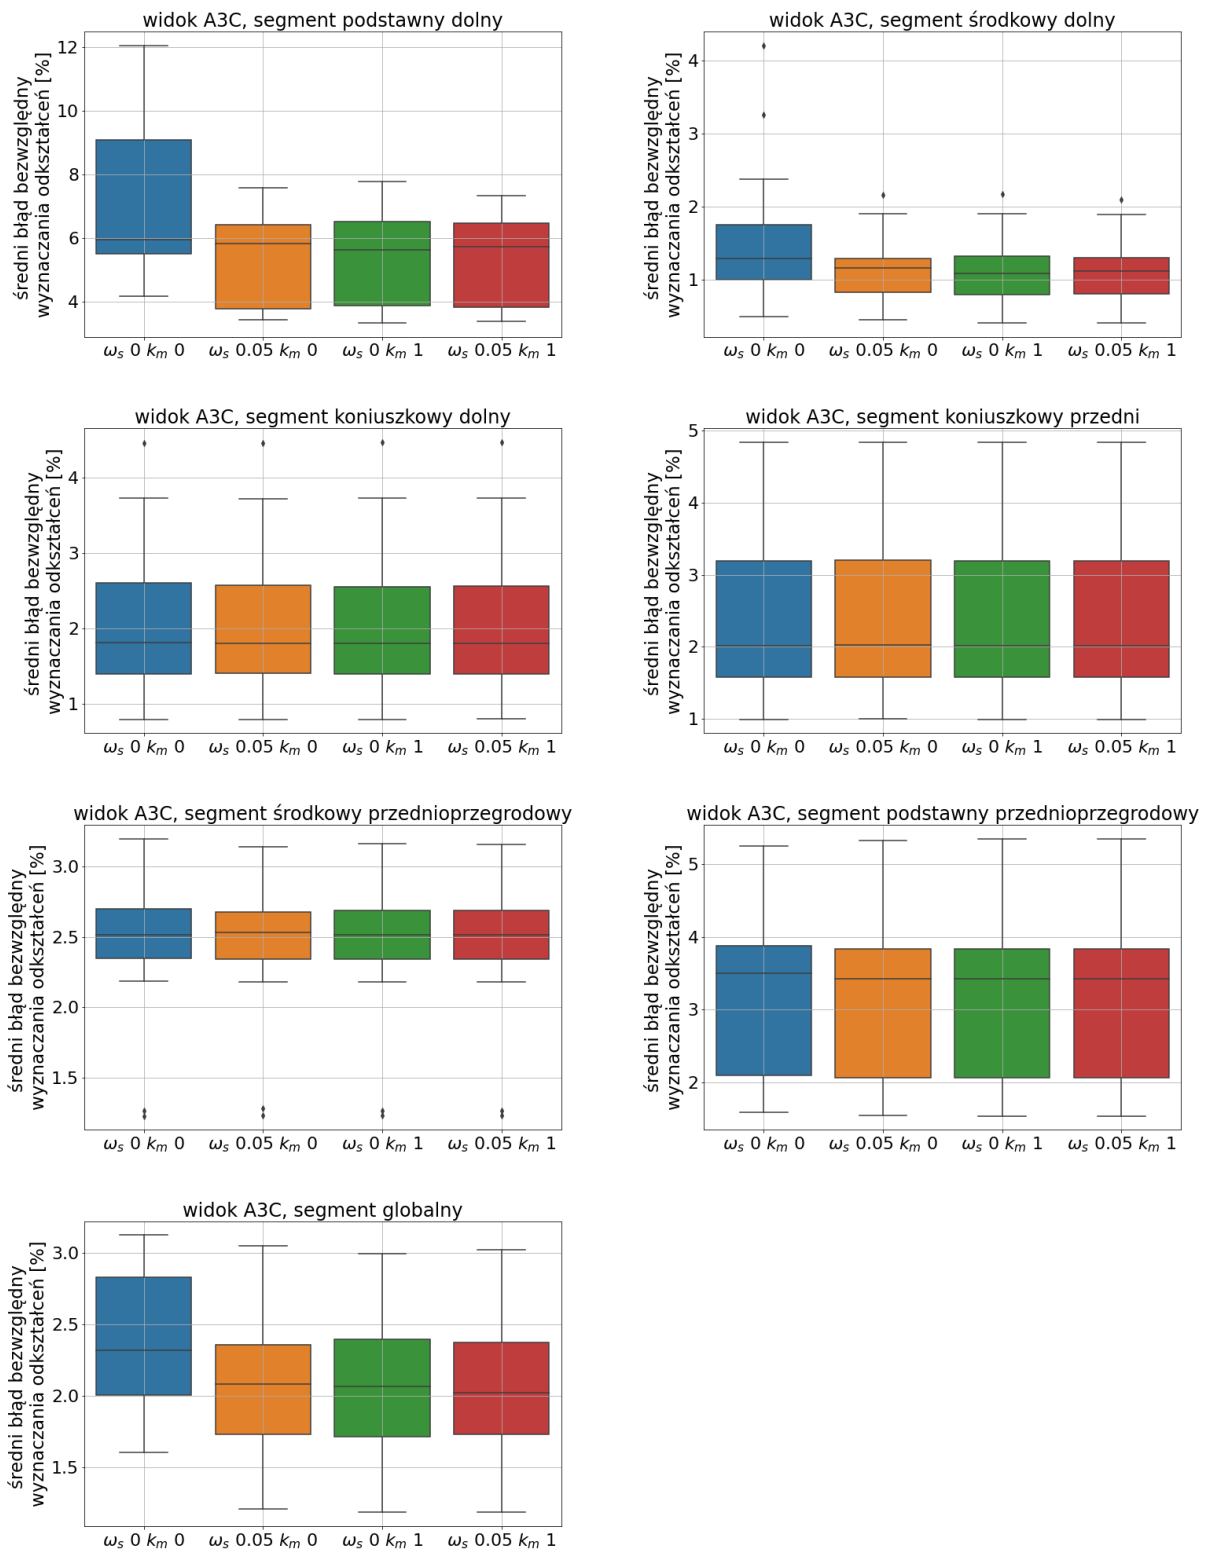
Zarówno w widoku trzy- jak i czterokomorowym, widoczne są wyraźne różnice pomiędzy wartościami odkształceń wyznaczanymi przez algorytm niewykorzystujący funkcji kar a wartościami wyznaczanymi przez pozostałe warianty algorytmu. W przytłaczającej większości przypadków są to różnice na korzyść wariantów, wykorzystujących funkcje kar. Różnice w wartościach błędu wyznaczania odkształceń, uzyskanych przy wykorzystaniu algorytmu z karą gładkości, stanowiącego referencję, algorytmu z karą niedopasowania masek i algorytmu z obiema funkcjami kary jednocześnie są nieznaczne i wynoszą maksymalnie 6%. W większości przypadków nie przekraczają zaś 1%.

5.2.2.2 Maski z segmentacji metodą aktywnych konturów

Rysunek 43 oraz Rysunek 44 przedstawiają wykresy pudełkowe wartości średniego błędu wyznaczania odkształceń w segmentach, odpowiednio w widokach 4- i 3-komorowych, z podziałem na warianty zastosowanych wartości wagi kary gładkości i współczynnika wagowego kary niedopasowania masek. Wartości średniej, mediany oraz pierwszego i czwartego kwartyla zostały dodatkowo umieszczone w tabeli 22 w dodatku A.



Rysunek 43 Wykresy pudełkowe wartości błędu wyznaczania odkształceń w segmentach w badaniu z użyciem danych semi-syntetycznych w widoku czterokomorowym i masek z segmentacji metodą aktywnego konturu.



Rysunek 44 Wykresy pudełkowe wartości błęd wyznaczania odkształceń w segmentach w badaniu z użyciem danych semi-syntetycznych w widoku trzykomorowym i masek z segmentacji metodą aktywnego konturu.

Widok czterokomorowy

W widoku czterokomorowym, w segmencie podstawnym dolnobocznym wartość średnia błędu wyznaczania odkształceń w wariancie bez funkcji kar była wyższa niż w pozostałych wariantach o około 14%, a wartość mediany o około 4%. Wartość pierwszego kwartyla była najniższa w wariancie z dwiema funkcjami kary, przy czym wariant z samą karą niedopasowania masek pozwolił na uzyskanie wyniku gorszego o 2%, wariant z samą karą gładkości o 7% a wariant bez funkcji kar o 25%. Wartości trzeciego kwartyla były we wszystkich wariantach bardzo zbliżone – różnice nie przekroczyły 1%.

W segmencie środkowym dolnobocznym wariant bez funkcji kar osiągnął wartość średnią błędu wyznaczania odkształceń wyższą o 4% od pozostałych wariantów. Wartość mediany była w wariancie bez funkcji kar wyższa o około 3% a wartość pierwszego kwartyla - o około 1%. Najniższa wartość trzeciego kwartyla została osiągnięta przy wykorzystaniu wariantu z samą karą gładkości i była o odpowiednio 2% i 5% niższa niż przy wariantach z karą niedopasowania masek i wariancie bez funkcji kar.

W segmentach koniuszkowym bocznym, koniuszkowym przegrodowym, środkowym przednioprzegrodowym oraz podstawnym przednioprzegrodowym różnice w wartościach żadnego z parametrów nie przekroczyły 2%.

Globalnie, wariant bez funkcji kar osiągnął wartość średnią błędu wyznaczania odkształceń wyższą o około 3% od pozostałych. Najniższa wartość mediany błędu wyznaczania odkształceń została osiągnięta w wariancie bez kary niedopasowania masek oraz w wariancie z samą karą gładkości – w wariantach z karą niedopasowania masek osiągnięta wartość była o około 4% wyższa. Różnice w wartości pierwszego kwartyla pomiędzy wariantami były nieznaczne – wariant bez funkcji kar dał wynik gorszy od pozostałych o około 1%. Wartość trzeciego kwartyla była w wariancie bez funkcji kar wyższa o około 4% niż w pozostałych.

Widok trzykomorowy

W widoku trzykomorowym, w segmencie podstawnym dolnym, w wariancie bez funkcji kar, wartość średnia błędu wyznaczania odkształceń była wyższa o około 24% niż w pozostałych wariantach. Najniższa wartość mediany została osiągnięta przy wykorzystaniu wariantu z samą karą niedopasowania masek, wariant z samą karą gładkości dał wynik gorszy o około 2%, wariant z dwiema funkcjami kary o około 3%, zaś wariant bez funkcji kar o około 5%. Wartości

pierwszego i trzeciego kwartyła błędu wyznaczania odkształceń były w trzech wariantach z funkcjami kary niższe o około 30% niż w wariancie bez funkcji kar.

W segmencie środkowym dolnym, wartość średnia błędu wyznaczania odkształceń w trzech wariantach, w których zastosowane zostały funkcje kary, była niższa o około 28% niż w wariancie bez funkcji kar. Najniższa wartość mediany została osiągnięta przy wykorzystaniu wariantu z samą karą niedopasowania masek, wartość osiągnięta przy użyciu wariantu z dwiema funkcjami kary była wyższa o około 3%, wariantu z samą karą gładkości o około 5%, zaś wariantu bez funkcji kar o około 16%. Najniższe wartości pierwszego kwartyła zostały osiągnięte przy wykorzystaniu wariantów z karą niedopasowania masek – wariant z samą karą gładkości dał wynik gorszy o około 2%, zaś wariant bez funkcji kar o około 20%. Wartość trzeciego kwartyła była w wariantach z funkcjami kar niższa o około 25% niż w wariancie bez funkcji kar.

W segmentach koniuszkowym dolnym, koniuszkowym przednim, środkowym przednioprzegrodowym oraz podstawnym przednioprzegrodowym różnice w wartości żadnego parametru pomiędzy wariantami nie przekroczyły 2%.

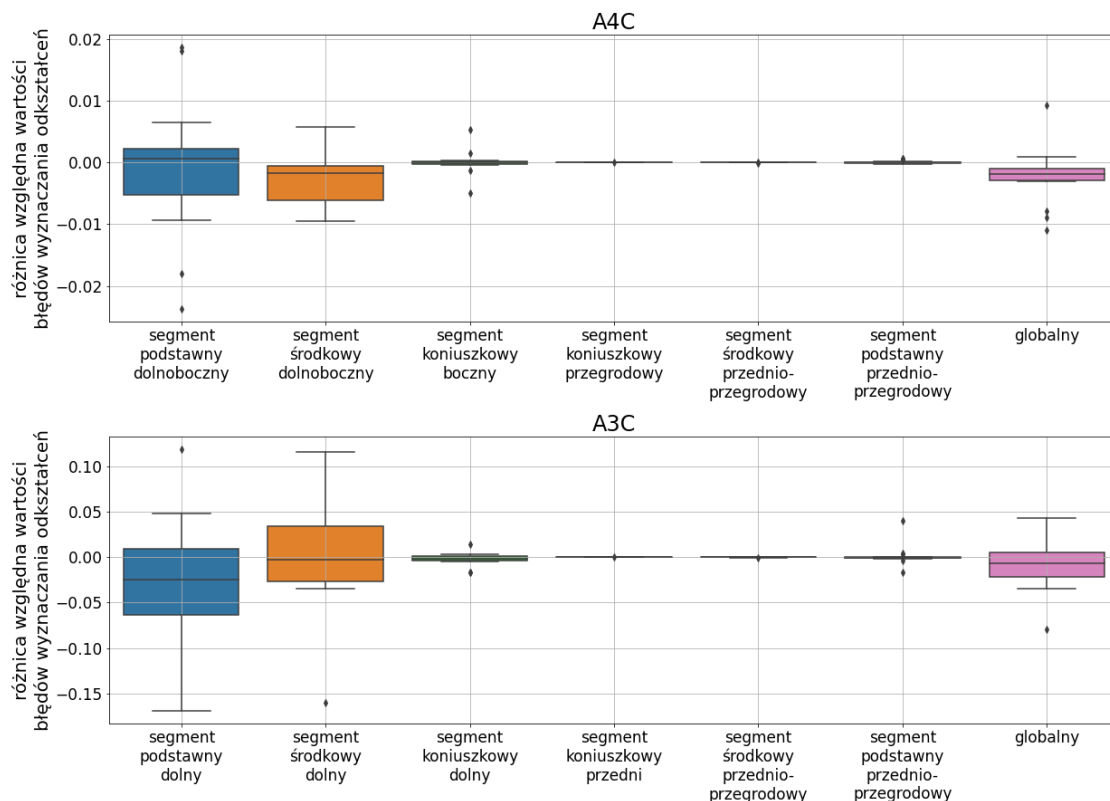
Globalnie, wartość średnia błędu wyznaczania odkształceń w trzech wariantach, w których zastosowane zostały funkcje kary była niższa o około 15% niż w wariancie bez funkcji kar. Najniższa wartość mediany została osiągnięta w wariancie z dwiema funkcjami kary i była ona niższa o około 2% niż w wariantach z samą karą gładkości i samą karą niedopasowania masek oraz o około 13% niższa niż w wariancie bez funkcji kar. Wartość pierwszego kwartyła była w wariantach z funkcjami kar niższa o około 14% niż w wariancie bez funkcji kar, zaś wartość trzeciego kwartyła o około 16%.

Podsumowanie

Największe różnice w dokładności wyznaczania odkształceń zostały odnotowane pomiędzy wariantem algorytmu, w którym nie zostały wykorzystane funkcje kar, a pozostałymi wariantami. W zdecydowanej większości przypadków były to różnice na niekorzyść wariantu bez funkcji kar, a maksymalna zaobserwowana różnica wartości parametru wyniosła 30%. Różnice pomiędzy poszczególnymi wariantami, wykorzystującymi funkcje kar były znacznie mniejsze – w większości przypadków nie przekroczyły 1%, zaś maksymalna różnica pomiędzy parametrami wyniosła 7%.

5.2.2.3 Porównanie wyników uzyskanych przy użyciu masek referencyjnych i masek z segmentacji

Porównanie dokładności wyznaczania odkształceń, przy wykorzystaniu do obliczeń masek referencyjnych oraz masek z segmentacji metodą aktywnego konturu, zostało wykonane poprzez obliczenie względnej różnicy w wartości średniego błędu wyznaczania odkształceń w każdej sekwencji, w której dostępne były oba rodzaje masek. Wartość ta była wyznaczana jako różnica średniego błędu wyznaczania odkształceń, uzyskanego przy wykorzystaniu masek referencyjnych oraz średniego błędu wyznaczania odkształceń, uzyskanego przy wykorzystaniu masek z segmentacji, podzielona przez wartość średniego błędu wyznaczania odkształceń, uzyskaną przy wykorzystaniu masek referencyjnych. Zaprezentowane porównanie dotyczy wariantu algorytmu, w którym wartość współczynnika wagowego kary niedopasowania masek wynosi 1, zaś wartość wagi kary gładkości wynosi 0, a więc wariantu, w którym została zastosowana wyłącznie kara niedopasowania masek, której wpływ na wyniki wyznaczania odkształceń podlega analizie. Rysunek 45 pokazuje wykresy pudełkowe, agregujące uzyskane wyniki.



Rysunek 45 Wykresy pudełkowe różnic w wartościach średniego błędu wyznaczania odkształceń uzyskanych przy wykorzystaniu maski referencyjnej oraz maski, uzyskanej w wyniku segmentacji metodą aktywnego konturu, w danych semi-syntetycznych

Widok czterokomorowy

Różnice w dokładności wyznaczania odkształceń przy wykorzystaniu masek referencyjnych oraz masek z segmentacji metodą aktywnego konturu w widoku czterokomorowym są widoczne w segmentach podstawnym dolnobocznym i środkowym dolnobocznym oraz w ujęciu globalnym.

W segmencie podstawnym dolnobocznym, mediana różnicy względnej błędu wyznaczania odkształceń była dodatnia i wynosiła 0,065%, co oznacza, że w ponad połowie przypadków wynik uzyskany przy użyciu maski z segmentacji był lepszy od wyniku uzyskanego przy użyciu maski referencyjnej. W sekwencji, w której wystąpiła największa różnica wyników, na korzyść masek referencyjnych, wynosiła ona 1,9%, zaś jednej czwartej sekwencji różnica na korzyść masek referencyjnych przekraczała 0,22%. W sekwencji, w której wystąpiła największa różnica wyników, na korzyść masek referencyjnych, wynosiła ona 2,4%. W jednej czwartej sekwencji różnica na korzyść masek referencyjnych przekraczała 0,53%.

W segmencie środkowym dolnobocznym, w ponad 80% przypadków, wynik uzyskany przy użyciu maski referencyjnej był lepszy od wyniku uzyskanego przy użyciu maski z segmentacji metodą aktywnego konturu. W sekwencji, w której przewaga masek referencyjnych była największa, różnica w wynikach wyniosła około 1%.

Globalnie, w około 87% przypadków wynik uzyskany przy użyciu maski referencyjnej był lepszy od wyniku uzyskanego przy użyciu maski z segmentacji metodą aktywnego konturu, zaś największa różnica na korzyść wariantu z maskami referencyjnymi wyniosła około 1,1%.

W pozostałych segmentach różnice pomiędzy wynikami uzyskanymi przy wykorzystaniu dwóch zestawów masek były minimalne.

Widok trzykomorowy

W widoku trzykomorowym, różnice w dokładności wyznaczania odkształceń przy wykorzystaniu masek referencyjnych oraz masek z segmentacji metodą aktywnego konturu są widoczne w trzech przypadkach: w segmencie podstawnym dolnym, w segmencie środkowym dolnym oraz w ujęciu globalnym.

W segmencie podstawnym dolnym w ponad połowie przypadków wynik uzyskany przy użyciu masek referencyjnych był lepszy niż wynik uzyskany przy użyciu masek z segmentacji. W sekwencji, w której wystąpiła największa różnica na korzyść masek referencyjnych, wyniosła ona 16,9%. W jednej czwartej sekwencji różnica na korzyść masek referencyjnych

przekroczyła 6,3%. W sekwencji, w której wystąpiła największa różnica na korzyść masek z segmentacji, wyniosła ona 11,9%. W jednej czwartej sekwencji różnica na korzyść masek segmentacji przekroczyła około 1%.

W segmencie podstawnym dolnym, w około połowie przypadków, wynik uzyskany przy użyciu masek referencyjnych był lepszy niż wynik uzyskany przy użyciu masek z segmentacji. W sekwencji, w której wystąpiła największa różnica na korzyść masek referencyjnych, wyniosła ona 16,1%. W jednej czwartej sekwencji różnica na korzyść masek referencyjnych przekroczyła 2,6%. W sekwencji, w której wystąpiła największa różnica na korzyść masek z segmentacji, wyniosła ona 11,6%. W jednej czwartej sekwencji różnica na korzyść masek segmentacji przekroczyła 3,4%.

Globalnie, w ponad połowie przypadków wynik uzyskany przy użyciu maski referencyjnej był lepszy od wyniku uzyskanego przy użyciu maski z segmentacji metodą aktywnego konturu, zaś największa różnica na korzyść wariantu z maskami referencyjnymi wyniosła 8%. W jednej czwartej sekwencji różnica na korzyść masek referencyjnych przekroczyła 2,2%. W sekwencji, w której wystąpiła największa różnica na korzyść masek z segmentacji, wyniosła ona 4,3%. W jednej czwartej sekwencji różnica na korzyść masek segmentacji przekroczyła 0,5%.

W pozostałych segmentach różnice pomiędzy wynikami uzyskanymi przy wykorzystaniu dwóch zestawów masek, poza nielicznymi obserwacjami odstającymi, były minimalne.

Podsumowanie

Tam, gdzie wystąpiły wyraźne różnice w wynikach działania algorytmu z wykorzystaniem masek referencyjnych i masek z segmentacji, były to w większości różnice na korzyść masek referencyjnych. Skala różnic była jednak nieznaczna - w najgorszym przypadku było to kilkanaście procent, a w zdecydowanej większości przypadków poniżej 5%.


5.3 Dane kliniczne

W badaniu działania zaproponowanego algorytmu na danych klinicznych, wykorzystane zostały maski wygenerowane przy użyciu metody, wykorzystującej konwolucyjne sieci neuronowe, dostępnej w komercyjnym oprogramowaniu PMOD. Proces uczenia został przeprowadzony z wykorzystaniem masek dla klatek odpowiadających etapom końcowo-skurczowemu i końcowo-rozkurczowemu cyklu pracy serca, przygotowanych przez ekspertów, udostępnionych razem z danymi obrazowymi (rozdział 3.1.4).

Wyniki działania algorytmu dla sekwencji w widoku dwukomorowym i czterekomorowym zostały zaprezentowane oddzielnie. Metodologia, zastosowana w ramach badania, została opisana w rozdziale 3.2.2. Wyższe wartości współczynnika Dice'a oznaczają większe podobieństwo masek, a co za tym idzie lepszy wynik dopasowania.

Rysunek 46 oraz Rysunek 47 pokazują wykresy pudełkowe wartości współczynnika Dice'a pomiędzy maską poddaną transformacjom i maską referencyjną, odpowiednio w sekwencjach dwu- i czterekomorowych, zaś dokładne wartości średniej, mediany, pierwszego kwartyła oraz trzeciego kwartyła są zawarte w tabelach 13 oraz 14.

W związku z tym, że jakość masek uzyskanych dla danych klinicznych nie jest tak wysoka, jak w pozostałych przypadkach, w tym badaniu zastosowana została niższa wartość współczynnika wagowego kary niedopasowania masek, wynosząca 0,3.



Rysunek 46 Wykresy pudełkowe współczynnika Dice'a pomiędzy maską wynikową i referencyjną dla 4 kombinacji wartości wagi kary gładkości i współczynnika wagowego kary niedopasowania masek, na danych w widoku dwukomorowym



Rysunek 47 Wykresy pudełkowe współczynnika Dice'a pomiędzy maską wynikową i referencyjną dla 4 kombinacji wartości wagi kary gładkości i współczynnika wagowego kary niedopasowania masek, na danych w widoku czterokomorowym

Tabela 13 Wartości średniej, mediany, pierwszego i trzeciego kwartyła wartości współczynnika Dice'a masek poddanych transformacjom i referencyjnych w widoku dwukomorowym.

Wartości wag	średnia	mediana	1. kwartył	3. kwartył
$\omega_s = 0, k_m = 0$	0,825	0,833	0,797	0,863
$\omega_s = 0, k_m = 0,3$	0,852	0,861	0,832	0,887
$\omega_s = 0,05, k_m = 0$	0,816	0,826	0,784	0,859
$\omega_s = 0,05, k_m = 0,3$	0,840	0,850	0,816	0,878

Tabela 14 Wartości średniej, mediany, pierwszego i trzeciego kwartyła wartości współczynnika Dice'a masek poddanych transformacjom i referencyjnych w widoku czterokomorowym.

Wartości wag	średnia	mediana	1. kwartył	3. kwartył
$\omega_s = 0, k_m = 0$	0,806	0,829	0,785	0,859
$\omega_s = 0, k_m = 0,3$	0,828	0,855	0,816	0,878
$\omega_s = 0,05, k_m = 0$	0,789	0,815	0,763	0,848
$\omega_s = 0,05, k_m = 0,3$	0,816	0,841	0,800	0,869

Wyższe wartości współczynnika Dice'a wskazują na większe podobieństwo pomiędzy maskami – zatem wysokie wartości współczynnika oznaczają lepszy efekt działania algorytmu elastycznego dopasowania obrazów. Wartości te, zarówno w widoku dwu- jak i czterokomorowym są wyraźnie wyższe w wariantach, w których użyta została kara niedopasowania masek.

W wariancie dwukomorowym zastosowanie samej kary niedopasowania masek spowodowało wzrost średniej, mediany i trzeciego kwartyła współczynnika Dice'a o około 3%, zaś pierwszego kwartyła o około 4%. Zastosowanie kary niedopasowania masek w połączeniu z karą gładkości skutkowało podwyższeniem wszystkich przedstawionych parametrów, w stosunku do wariantu bez funkcji kar, o około 2%. Zastosowanie jedynie kary gładkości spowodowało obniżenie wartości średniej i mediany współczynnika Dice'a o około 1%, pierwszego kwartyła o około 2%, a trzeciego kwartyła o około 0,5% w stosunku do wariantu, w którym nie została zastosowana żadna funkcja kary. Liczba obserwacji, w których wartość współczynnika Dice'a była niższa niż 0,7 wynosi 13 w wariancie, w którym nie zostały zastosowane funkcje kary, 7 w wariancie, gdzie została zastosowana jedynie kara niedopasowania masek, 25 w wariancie, w którym zastosowana została jedynie kara gładkości i 13 w wariancie, w którym zostały zastosowane obie funkcje kary.

W wariancie czterokomorowym zastosowanie jedynie kary niedopasowania masek spowodowało podwyższenie średniej i mediany współczynnika Dice'a o około 3%, pierwszego kwartyła o około 4%, zaś trzeciego kwartyła o około 2% w stosunku do wariantu bez funkcji kar. Zastosowanie kary niedopasowania masek w połączeniu z karą gładkości spowodowało podwyższenie średniej, mediany i trzeciego kwartyła współczynnika Dice'a o około 1%, zaś pierwszego kwartyła o około 2% w stosunku do wyników uzyskanych przy użyciu wariantu bez funkcji kar. Zastosowanie jedynie kary gładkości spowodowało obniżenie wartości średniej i mediany współczynnika Dice'a o około 2%, pierwszego kwartyła o około 3%, a trzeciego kwartyła o około 1%. Liczba obserwacji w widoku czterokomorowym, w których wartość współczynnika Dice'a była niższa niż 0,7 wynosi 37 w wariancie, w którym nie zostały zastosowane funkcje kary, 27 w wariancie, gdzie została zastosowana jedynie kara niedopasowania masek, 62 w wariancie, w którym zastosowana została jedynie kara gładkości i 34 w wariancie, w którym zostały zastosowane obie funkcje kary.

5.3.1 Podsumowanie

W badaniu na danych klinicznych najlepsze wyniki zostały uzyskane przy wykorzystaniu wariantu algorytmu z karą niedopasowania masek, bez kary gładkości. Wyniki działania algorytmu z dwiema funkcjami kar były jedynie nieznacznie gorsze niż wariant z samą karą niedopasowania masek. Wariant z samą karą gładkości dał wyniki gorsze niż wariant bez funkcji kar. Wskazuje to, że w przypadku badanego zestawu danych, zaproponowana w pracy kara niedopasowania masek poprawia efekty działania algorytmu elastycznego dopasowania obrazów a jej zastosowanie daje lepsze rezultaty, niż zastosowanie kary gładkości.

5.4 Czas wykonania algorytmu

Istotnym zagadnieniem, dotyczącym algorytmów, wykorzystywanych w praktyce klinicznej jest czas ich wykonania. Tabela 15 zawiera średnie czasy wykonania algorytmu elastycznego dopasowania obrazów, na pełnej sekwencji danych, w trzech wariantach: z zastosowaniem jedynie kary niedopasowania masek, z zastosowaniem jedynie kary gładkości oraz z zastosowaniem obu kar, na komputerze PC, z 6-rdzeniowym procesorem Intel Core i-7, o częstotliwości taktowania 2,6 GHz i 16 GB pamięci fizycznej RAM. Tabela 16 zawiera wartości średniej liczby iteracji algorytmu optymalizacji, niezbędnych do dopasowania dwóch klatek sekwencji echokardiograficznej w każdym z wariantów, zaś Tabela 17 średni czas trwania pojedynczej iteracji algorytmu optymalizacji.

Tabela 15 Średni czas wykonania algorytmu elastycznego dopasowania obrazów na pełnej sekwencji danych

	Algorytm z karą niedopasowania masek	Algorytm z karą gładkości	Algorytm z dwiema karami
Dane z obrazowania fantomu lewej komory serca	1862 s	2631 s	1834 s
Dane semi-syntetyczne	723 s	1233 s	750 s
Dane kliniczne	964 s	1373 s	891 s

Tabela 16 Średnia liczba iteracji algorytmu optymalizacji, przypadających na parę klatek sekwencji echokardiograficznej

	Algorytm z karą niedopasowania masek	Algorytm z karą gładkości	Algorytm z dwiema karami
Dane z obrazowania fantomu lewej komory serca	7,1	8,1	4,9
Dane semi-syntetyczne	5,1	6,7	3,5
Dane kliniczne	7,7	8,4	4,9

Tabela 17 Średni czas trwania iteracji algorytmu optymalizacji

	Algorytm z karą niedopasowania masek	Algorytm z karą gładkości	Algorytm z dwiema karami
Dane z obrazowania fantomu lewej komory serca	2,71 s	3,36 s	3,85 s
Dane semi-syntetyczne	2,49 s	3,33 s	3,76 s
Dane kliniczne	6,32 s	8,02 s	9,18 s

Różnice w czasie wykonania algorytmów, różniących się składowymi funkcjami kosztu wynikają z różnic w złożoności obliczeniowej poszczególnych funkcji kar, jak również z różnic w liczbie iteracji algorytmu optymalizacji, niezbędnych do dopasowania pary obrazów. Średni czas trwania pojedynczej iteracji algorytmu optymalizacji na wszystkich badanych typach danych jest najkrótszy w przypadku algorytmu, wykorzystującego jedynie karę niedopasowania masek i najdłuższy w przypadku algorytmu, wykorzystującego obie funkcje kary. Średnia liczba iteracji algorytmu optymalizacji, niezbędnych do dopasowania dwóch klatek sekwencji jest dla wszystkich typów danych najniższa dla algorytmu z dwiema funkcjami kary i najwyższa dla algorytmu z karą gładkości. Kombinacja tych dwóch czynników powoduje, że czas wykonania algorytmu elastycznego dopasowania obrazów dla pełnej sekwencji danych jest zbliżony dla

algorytmu wykorzystującego jedynie karę niedopasowania masek i dla algorytmu wykorzystującego obie funkcje kar i znacząco dłuższy dla algorytmu, wykorzystującego jedynie karę gładkości, stanowiącego metodę referencyjną.

Czas wykonania algorytmu, wykorzystującego jedynie karę niedopasowania masek był w przeprowadzonych badaniach krótszy od czasu wykonania algorytmu wykorzystującego jedynie karę gładkości o 29% dla danych z obrazowania fantomu lewej komory serca, o 41% dla danych semi-syntetycznych i o 30% dla danych klinicznych. Czas wykonania algorytmu, wykorzystującego zarówno karę niedopasowania masek, jak i karę gładkości, był w przeprowadzonych badaniach krótszy od czasu wykonania algorytmu wykorzystującego jedynie karę gładkości o 30% dla danych z obrazowania fantomu lewej komory serca, o 39% dla danych semi-syntetycznych i o 35% dla danych klinicznych.

5.5 Dyskusja

Badanie zmienności optymalnych wartości wag funkcji kar pokazało, że zakresy wartości wag, pozwalających na otrzymanie wartości błędów wyznaczania przemieszczeń, zbliżonych do uzyskiwanego minimum, są szerokie i relatywnie niezmiennie w przypadku zestawów danych, których akwizycja przebiegała w zbliżonych warunkach – co sugeruje, że w przypadku takich danych, jednorazowa kalibracja jest wystarczająca. Jednocześnie dane pochodzące z różnych zestawów wykazywały różnice w charakterystyce zależności wartości sumy średnich błędów wyznaczania przemieszczeń od wartości wag funkcji kar, co sugeruje, że w przypadku znaczących różnic w procesie akwizycji danych, kalibracja wartości wag jest wskazana.

Badanie wpływu jakości masek pochodzących z segmentacji, na działanie całego algorytmu wykazało, że wykorzystanie masek niskiej jakości powoduje obniżenie dokładności wyznaczania przemieszczeń przy użyciu proponowanego algorytmu. Badanie pokazało, że najwyższy negatywny wpływ na działanie algorytmu mają błędy segmentacji, cechujące się losowością i zmiennością w kolejnych klatkach sekwencji, takie jak wybrzuszenia czy wklęsnięcia, pojawiające się w różnych miejscach różnych klatek, czy obejmowanie przez maski obszaru większego lub mniejszego niż obszar mięśnia lewej komory serca, przy zmiennej objętości obszaru niezgodności. Jednocześnie niedokładności segmentacji, powtarzające się w kolejnych klatkach, takie jak stałe oznaczanie przez algorytm segmentacji większego lub mniejszego obszaru nie powodują znacznego pogorszenia wyników wyznaczania przemieszczeń. Negatywny wpływ błędów segmentacji na działanie algorytmu spada wraz ze zmniejszaniem wagi kary niedopasowania masek. Jednocześnie jednak zmniejszanie wagi kary

niedopasowania masek powoduje obniżenie dokładności wyznaczania przemieszczeń tam, gdzie błędy segmentacji są mniejsze lub bardziej powtarzalne. Pokazuje to, że świadomość sposobu działania wykorzystanego algorytmu segmentacji i rodzajów błędów segmentacji, występujących w zastosowanych maskach ma kluczowe znaczenie dla decyzji o zastosowaniu kary niedopasowania masek oraz wyboru wartości wagi tej kary.

Wykorzystanie kary niedopasowania masek w przypadku danych z obrazowania fantomu z referencją numeryczną, dało poprawę wyników wyznaczania zarówno przemieszczeń, jak i odkształceń, w stosunku do sytuacji, w której wykorzystany został wariant algorytmu z samą karą gładkości, zarówno w przypadku zastosowania masek referencyjnych, jak i masek z segmentacji metodą aktywnego konturu.

W danych semi-syntetycznych różnice pomiędzy wariantem algorytmu, gdzie została zastosowana jedynie kara gładkości, a wariantami z karą niedopasowania masek oraz z dwiema karami, były nieznaczne. Jednocześnie wszystkie warianty z funkcjami kar dały wyniki znacznie lepsze, niż wariant, w którym nie została zastosowana żadna funkcja kary.

W badaniu wykonanym przy użyciu danych klinicznych najlepsze wyniki zostały uzyskane przy zastosowaniu kary niedopasowania masek, bez kary gładkości. Najgorsze dopasowanie masek poddanych transformacji i masek referencyjnych zostało uzyskane przy wykorzystaniu kary gładkości bez kary niedopasowania masek.

Wykorzystanie kary niedopasowania masek skraca czas wykonania algorytmu elastycznego dopasowania obrazów. Czas wykonywania obliczeń, przy wariacie algorytmu, wykorzystującym jedynie karę niedopasowania masek, był o od 29% do 41% krótszy, niż przy wariacie algorytmu, wykorzystującym karę gładkości, zaś przy wariacie algorytmu, wykorzystującym dwie funkcje kary, był o od 30% do 39% krótszy niż przy wykorzystaniu jedynie kary gładkości.

6 Podsumowanie

Celem, zrealizowanym w ramach pracy było zaproponowanie nowej wersji algorytmu elastycznego dopasowania obrazów, wykorzystującej informacje z segmentacji do zwiększenia dokładności wyznaczania przemieszczeń i odkształceń mięśnia sercowego na podstawie dwuwymiarowych danych echokardiograficznych, oraz walidacja jej działania.

Algorytm elastycznego dopasowania obrazów polega na przekształceniu geometrycznym jednego z dwóch obrazów w taki sposób, aby zminimalizować wartość funkcji kosztu, składającej się z miary podobieństwa obrazów oraz, opcjonalnie, funkcji kar. Funkcją kary stosowaną typowo w tego typu rozwiązaniach jest kara gładkości, której celem jest wymuszenie regularyzacji transformacji. W ramach pracy opracowana została nowa funkcja kary, której zastosowanie pozwala na włączenie do algorytmu elastycznego dopasowania obrazów informacji z segmentacji, jako dodatkowej informacji, pozwalającej na uzyskanie zwiększonej dokładności wyznaczania przemieszczeń i odkształceń mięśnia sercowego. Proponowana funkcja kary - kara niedopasowania masek, wykorzystuje różnice w binarnych maskach obrazów. Jest to nowy, nie opisywany dotychczas w literaturze sposób włączenia informacji z segmentacji do algorytmu elastycznego dopasowania obrazów. Nowa funkcja kary została wprowadzona do algorytmu z wagą, której formuła, poza dobraćanym eksperymentalnie współczynnikiem, wykorzystuje iloraz sumy kwadratów różnic wartości intensywności pikseli wszystkich par sąsiadujących obrazów z sekwencji oraz sumy kwadratów różnic wartości intensywności pikseli wszystkich par sąsiadujących masek z sekwencji. Rozwiązanie to ułatwia dobór wartości hiperparametrów algorytmu, a co za tym idzie aplikację rozwiązania do różnorodnych zestawów danych obrazowych, jak również zmniejsza podatność metody na błędy wynikające z wykorzystania masek, cechujących się znaczącymi błędami.

Istotnym czynnikiem w działaniu algorytmu elastycznego dopasowania obrazów są wartości wag funkcji kar, wchodzących w skład funkcji kosztu. W ramach pracy zbadana została zmienność optymalnych wartości wag funkcji kar algorytmu przy zróżnicowanych danych wejściowych. Do tego celu wykorzystane zostały dwa zestawy danych: dane syntetyczne, przedstawiające fantom lewej komory serca oraz dane semi-syntetyczne. Przeprowadzone badanie wykazało, że zakresy wartości wag funkcji kar, pozwalające na uzyskanie wyników zbliżonych do optimum są szerokie. W przypadku danych, pochodzących z jednego zestawu, a więc cechujących się zbliżonym sposobem generacji, zakresy te pokrywają się w znacznym stopniu, jednak pomiędzy danymi syntetycznymi i danymi semi-syntetycznymi, których proces

generacji przebiegał inaczej, występują rozbieżności. Fakty te wskazują, że w przypadku danych o zbliżonych właściwościach, wystarczająca jest jednorazowa kalibracja hiperparametrów, a ze względu na szeroki zakres wartości wag funkcji kar, pozwalający na uzyskanie efektów zbliżonych do optimum, wysoka precyzja procesu kalibracji nie jest konieczna do uzyskania wyników wyznaczania przemieszczeń i odkształceń, cechujących się wysoką dokładnością.

Ze względu na fakt, że wykorzystywane w zaproponowanej metodzie maski z segmentacji mogą cechować się zróżnicowaną dokładnością i błędami, algorytm został zbadany pod kątem wrażliwości na dokładność zastosowanych masek. W tym celu porównane zostały efekty działania algorytmu, uzyskane przy wykorzystaniu sztucznie zdeformowanych masek, różniących się dokładnością oraz charakterem występujących niedoskonałości. Badanie to wykazało, że błędy segmentacji, skutkujące poważnymi odstępstwami od rzeczywistego kształtu mięśnia sercowego, których charakter nie jest stały, lecz zmienia się w kolejnych klatkach, wpływają negatywnie na efekty wyznaczania przemieszczeń i odkształceń przy wykorzystaniu opracowanego algorytmu i mogą powodować uzyskiwanie wyników gorszych niż przy użyciu metody referencyjnej, nie wykorzystującej danych z segmentacji. Błędy segmentacji, których charakter jest stały na przestrzeni całego zbioru danych, takie jak systematyczne oznaczanie obszaru mniejszego lub większego od rzeczywistego obszaru mięśnia sercowego nie powodują tak znaczącego obniżenia dokładności działania zaproponowanej metody. Wskazuje to, że świadomość ograniczeń wykorzystanej metody segmentacji danych ma kluczowe znaczenie przy podejmowaniu decyzji o zastosowaniu zaproponowanego w pracy algorytmu.

Dokładność wyznaczania przemieszczeń i odkształceń przy zastosowaniu zaproponowanego rozwiązania została zbadana przy wykorzystaniu danych z obrazowania fantomu lewej komory serca, danych syntetycznych, bazujących na danych klinicznych oraz danych klinicznych. Uzyskane wyniki zostały porównane z wynikami uzyskanymi przy użyciu klasycznej wersji algorytmu, niewykorzystującej informacji z segmentacji.

Przeprowadzone badania wskazują, że zastosowanie kary niedopasowania masek, pozwala na uzyskanie wyników lepszych bądź porównywalnych do wyników uzyskanych przy zastosowaniu metody referencyjnej z karą gładkości. Dotyczy to również badań z użyciem danych z obrazowania fantomu lewej komory serca oraz danych semi-syntetycznych, w których zostały wykorzystane maski, uzyskane przy użyciu segmentacji metodą aktywnego konturu. Wskazuje to, że dokładność masek, wygenerowanych przy użyciu powszechnie stosowanych

metod segmentacji może być wystarczająca do zastosowania zaproponowanej metody z pozytywnym efektem. Badanie przeprowadzone z wykorzystaniem danych klinicznych również wykazało, że zaproponowana metoda poprawia dokładność działania algorytmu elastycznego dopasowania obrazów w porównaniu z wersją algorytmu, niewykorzystującą kary niedopasowania masek.

Czas wykonywania obliczeń przy zastosowaniu zaproponowanego rozwiązania jest istotnie (od 30% do 39%) krótszy niż czas wykonywania obliczeń przy zastosowaniu standardowego algorytmu jedynie z karą gładkości. Stanowi to ważny atut opisywanego algorytmu, zwiększający jego użyteczność oraz rozszerzający możliwości jego stosowania w systemach cechujących się ograniczoną mocą obliczeniową np. w systemach mobilnych.

Na dalszym etapie prac możliwe jest rozszerzenie algorytmu tak, aby umożliwiał również wyznaczanie przemieszczeń i odkształceń w danych trójwymiarowych, które zyskują coraz większą popularność w diagnostyce kardiologicznej. W celu dalszej walidacji proponowanego rozwiązania należy przeprowadzić badania kliniczne w tym badania porównawcze z algorytmami stosowanymi komercyjnie.

7 Bibliografia

- [1] J. Liu *i in.*, „Contemporary Role of Echocardiography for Clinical Decision Making in Patients During and After Cancer Therapy”, *JACC Cardiovasc. Imaging*, t. 11, nr 8, s. 1122–1131, sie. 2018, doi: 10.1016/j.jcmg.2018.03.025.
- [2] F. Bursi *i in.*, „Prognostic utility of quantitative offline 2D-echocardiography in hospitalized patients with COVID-19 disease”, *Echocardiography*, t. 37, nr 12, s. 2029–2039, grudz. 2020, doi: 10.1111/echo.14869.
- [3] A. Gallard *i in.*, „Echocardiographic view and feature selection for the estimation of the response to CRT”, *PLOS ONE*, t. 16, nr 6, s. e0252857–e0252857, cze. 2021, doi: 10.1371/journal.pone.0252857.
- [4] J. U. Doherty *i in.*, „APPROPRIATE USE CRITERIA 2019 Appropriate Use Criteria for Multimodality Imaging in the Assessment of Cardiac Structure and Function in Nonvalvular Heart Disease Rating Panel Members Appropriate Use Criteria Task Force”, doi: 10.1016/j.jacc.2018.10.038.
- [5] M. Cameli, G. E. Mandoli, C. Sciacaluga, i S. Mondillo, „More than 10 years of speckle tracking echocardiography: Still a novel technique or a definite tool for clinical practice?”, *Echocardiography*, t. 36, nr 5, s. 958–970, 2019, doi: 10.1111/echo.14339.
- [6] J. F. Pombo, B. L. Troy, i R. O. Russell, „Left Ventricular Volumes and Ejection Fraction by Echocardiography”, *Circulation*, t. 43, nr 4, s. 480–490, kwi. 1971, doi: 10.1161/01.CIR.43.4.480.
- [7] R. B. Stamm, B. A. Carabello, D. L. Mayers, i R. P. Martin, „Two-dimensional echocardiographic measurement of left ventricular ejection fraction: Prospective analysis of what constitutes an adequate determination”, *Am. Heart J.*, t. 104, nr 1, s. 136–144, lip. 1982, doi: 10.1016/0002-8703(82)90651-2.
- [8] Y. F. M. Nosir *i in.*, „Accurate Measurement of Left Ventricular Ejection Fraction by Three-dimensional Echocardiography”, *Circulation*, t. 94, nr 3, s. 460–466, sie. 1996, doi: 10.1161/01.CIR.94.3.460.
- [9] E. Kowalczyk, J. D. Kasprzak, P. Wejner-Mik, i P. Lipiec, „Ilościowa ocena funkcji mięśnia sercowego techniką śledzenia markerów akustycznych u pacjenta z akromegalią i chorobą wieńcową”, *Folia Cardiol.*, t. 11, nr 6, Art. nr 6, 2016, doi: 10.5603/FC.2016.0115.
- [10] R. M. Lang *i in.*, „Recommendations for Cardiac Chamber Quantification by Echocardiography in Adults: An Update from the American Society of Echocardiography and the European Association of Cardiovascular Imaging”, *Eur. Heart J. - Cardiovasc. Imaging*, t. 16, nr 3, s. 233–271, mar. 2015, doi: 10.1093/ehjci/jev014.
- [11] B. Heyde *i in.*, „Elastic Image Registration to Quantify 3-D Regional Myocardial Deformation from Volumetric Ultrasound: Experimental Validation in an Animal Model”, *Ultrasound Med. Biol.*, t. 39, nr 9, s. 1688–1697, wrz. 2013, doi: 10.1016/j.ultrasmedbio.2013.02.463.
- [12] B. Chakraborty, Z. Liu, B. Heyde, J. Luo, i J. D’hooge, „2D RF-based non-rigid image registration for cardiac motion estimation: Comparison against block matching”, w *2016 IEEE International Ultrasonics Symposium (IUS)*, wrz. 2016, s. 1–4. doi: 10.1109/ULTSYM.2016.7728621.
- [13] A. Nowicki, *Wstęp do ultrasonografii Podstawy fizyczne i instrumentacja*. Warszawa: Medipage, 2003.
- [14] S. Leclerc *i in.*, „Deep Learning for Segmentation Using an Open Large-Scale Dataset in 2D Echocardiography”, *IEEE Trans. Med. Imaging*, t. 38, nr 9, s. 2198–2210, wrz. 2019, doi: 10.1109/TMI.2019.2900516.

- [15] S. Pradeep i P. Nirmaladevi, „A Review on Speckle Noise Reduction Techniques in Ultrasound Medical images based on Spatial Domain, Transform Domain and CNN Methods”, *IOP Conf. Ser. Mater. Sci. Eng.*, t. 1055, nr 1, s. 012116, luty 2021, doi: 10.1088/1757-899X/1055/1/012116.
- [16] Q. Zhang, H. Han, C. Ji, J. Yu, Y. Wang, i W. Wang, „Gabor-based anisotropic diffusion for speckle noise reduction in medical ultrasonography”, *JOSA A*, t. 31, nr 6, s. 1273–1283, cze. 2014, doi: 10.1364/JOSAA.31.001273.
- [17] C. Mitchell *i in.*, „Guidelines for Performing a Comprehensive Transthoracic Echocardiographic Examination in Adults: Recommendations from the American Society of Echocardiography”, *J. Am. Soc. Echocardiogr.*, t. 32, nr 1, s. 1–64, sty. 2019, doi: 10.1016/j.echo.2018.06.004.
- [18] M. D. Cerqueira *i in.*, „Standardized Myocardial Segmentation and Nomenclature for Tomographic Imaging of the Heart”, *Circulation*, t. 105, nr 4, s. 539–542, sty. 2002, doi: 10.1161/hc0402.102975.
- [19] J. D. Kasprzak, W. Braksator, A. Gackowski, P. Hoffman, M. Plewka, i E. P. i A. Szyszka, „Polskojęzyczne nazewnictwo echokardiograficzne; rekomendacje Sekcji Echokardiografii Polskiego Towarzystwa Kardiologicznego”, *Folia Cardiol.*, t. 12, nr 3, Art. nr 3, 2005.
- [20] A. Jurado-Román *i in.*, „Superiority of wall motion score index over left ventricle ejection fraction in predicting cardiovascular events after an acute myocardial infarction”, *Eur. Heart J. Acute Cardiovasc. Care*, t. 8, nr 1, s. 78–85, luty 2019, doi: 10.1177/2048872616674464.
- [21] K. Jensen-Urstad *i in.*, „Comparison of Different Echocardiographic Methods With Radionuclide Imaging for Measuring Left Ventricular Ejection Fraction During Acute Myocardial Infarction Treated by Thrombolytic Therapy”, *Am. J. Cardiol.*, t. 81, nr 5, s. 538–544, mar. 1998, doi: 10.1016/S0002-9149(97)00964-8.
- [22] C. Eek *i in.*, „Strain Echocardiography and Wall Motion Score Index Predicts Final Infarct Size in Patients With Non–ST-Segment–Elevation Myocardial Infarction”, *Circ. Cardiovasc. Imaging*, t. 3, nr 2, s. 187–194, mar. 2010, doi: 10.1161/CIRCIMAGING.109.910521.
- [23] C. Y. Ho i S. D. Solomon, „A Clinician’s Guide to Tissue Doppler Imaging”, *Circulation*, t. 113, nr 10, s. e396–e398, mar. 2006, doi: 10.1161/CIRCULATIONAHA.105.579268.
- [24] J. Goresan, V. K. Gulati, W. A. Mandarino, i W. E. Katz, „Color-coded measures of myocardial velocity throughout the cardiac cycle by tissue Doppler imaging to quantify regional left ventricular function”, *Am. Heart J.*, t. 131, nr 6, s. 1203–1213, cze. 1996, doi: 10.1016/S0002-8703(96)90097-6.
- [25] C.-M. Yu, J. E. Sanderson, T. H. Marwick, i J. K. Oh, „Tissue Doppler Imaging: A New Prognosticator for Cardiovascular Diseases”, *J. Am. Coll. Cardiol.*, t. 49, nr 19, s. 1903–1914, maj 2007, doi: 10.1016/j.jacc.2007.01.078.
- [26] K. K. Kadappu i L. Thomas, „Tissue Doppler Imaging in Echocardiography: Value and Limitations”, *Heart Lung Circ.*, t. 24, nr 3, s. 224–233, mar. 2015, doi: 10.1016/j.hlc.2014.10.003.
- [27] O. A. Smiseth, H. Torp, A. Opdahl, K. H. Haugaa, i S. Urheim, „Myocardial strain imaging: how useful is it in clinical decision making?”, *Eur. Heart J.*, t. 37, nr 15, s. 1196–1207, kwi. 2016, doi: 10.1093/eurheartj/ehv529.
- [28] E. Potter i T. H. Marwick, „Assessment of Left Ventricular Function by Echocardiography”, *JACC Cardiovasc. Imaging*, t. 11, nr 2_Part_1, s. 260–274, luty 2018, doi: 10.1016/j.jcmg.2017.11.017.

- [29] Fabiani, I., Pugliese, N. R., Santini, V., Conte, L., & Di Bello, V., „Speckle-tracking imaging, principles and clinical applications: A review for clinical cardiologists”, w *Echocardiography in Heart Failure and Cardiac Electrophysiology*, 2016, s. 85–114.
- [30] S. Mondillo i in., „Speckle-Tracking Echocardiography”, *J. Ultrasound Med.*, t. 30, nr 1, s. 71–83, 2011, doi: 10.7863/jum.2011.30.1.71.
- [31] B. Heyde, O. Mirea, i J. D’hooge, „Cardiac Strain and Strain Rate Imaging”, w *Ultrasound Elastography for Biomedical Applications and Medicine*, John Wiley & Sons, Ltd, 2018, s. 143–160. doi: 10.1002/9781119021520.ch11.
- [32] E. D. Angelini i O. Gerard, „Review of Myocardial Motion Estimation Methods from Optical Flow Tracking on Ultrasound Data”, w *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, sie. 2006, s. 1537–1540. doi: 10.1109/IEMBS.2006.259640.
- [33] J. L. Barron, D. J. Fleet, i S. S. Beauchemin, „Performance of optical flow techniques”, *Int. J. Comput. Vis.*, t. 12, nr 1, s. 43–77, luty 1994, doi: 10.1007/BF01420984.
- [34] M. Alessandrini, H. Liebgott, D. Barbosa, i O. Bernard, „Monogenic Phase Based Optical Flow Computation for Myocardial Motion Analysis in 3D Echocardiography”, w *Statistical Atlases and Computational Models of the Heart. Imaging and Modelling Challenges*, O. Camara, T. Mansi, M. Pop, K. Rhode, M. Sermesant, i A. Young, Red., w *Lecture Notes in Computer Science*. Berlin, Heidelberg: Springer, 2013, s. 159–168. doi: 10.1007/978-3-642-36961-2_19.
- [35] D. Boukerroui, J. A. Noble, i M. Brady, „Velocity Estimation in Ultrasound Images: A Block Matching Approach”, w *Information Processing in Medical Imaging*, C. Taylor i J. A. Noble, Red., w *Lecture Notes in Computer Science*. Berlin, Heidelberg: Springer, 2003, s. 586–598. doi: 10.1007/978-3-540-45087-0_49.
- [36] L. Tautz, A. Hennemuth, i H.-O. Peitgen, „Quadrature Filter Based Motion Analysis for 3D Ultrasound Sequences”, w *Statistical Atlases and Computational Models of the Heart. Imaging and Modelling Challenges*, O. Camara, T. Mansi, M. Pop, K. Rhode, M. Sermesant, i A. Young, Red., w *Lecture Notes in Computer Science*. Berlin, Heidelberg: Springer, 2013, s. 169–177. doi: 10.1007/978-3-642-36961-2_20.
- [37] B. K. P. Horn i B. G. Schunck, „Determining optical flow”, *Artif. Intell.*, t. 17, nr 1, s. 185–203, sie. 1981, doi: 10.1016/0004-3702(81)90024-2.
- [38] B. D. Lucas, B. D. Lucas, i T. Kanade, „An iterative image registration technique with an application to stereo vision”, *IJCAI81*, s. 674–679, 1981.
- [39] P. Baraldi, A. Sarti, C. Lamberti, A. Prandini, i F. Sgallari, „Evaluation of differential optical flow techniques on synthesized echo images”, *IEEE Trans. Biomed. Eng.*, t. 43, nr 3, s. 259–272, mar. 1996, doi: 10.1109/10.486283.
- [40] Y. Chunke, K. Terada, i S. Oe, „Motion analysis of echocardiograph using optical flow method”, w *1996 IEEE International Conference on Systems, Man and Cybernetics. Information Intelligence and Systems (Cat. No.96CH35929)*, paź. 1996, s. 672–677 t.1. doi: 10.1109/ICSMC.1996.569875.
- [41] C. Lamberti, A. Sarti, i F. Bertucci, „Topology of optical flow in 3D echocardiography”, w *Computers in Cardiology 1997*, wrz. 1997, s. 227–230. doi: 10.1109/CIC.1997.647872.
- [42] B. H. Amundsen i in., „Noninvasive Myocardial Strain Measurement by Speckle Tracking Echocardiography”, *J. Am. Coll. Cardiol.*, t. 47, nr 4, s. 789–793, luty 2006, doi: 10.1016/j.jacc.2005.10.040.
- [43] F. Sun, X.-J. Wang, Q. Wu, G.-H. Yao, i Y. Zhang, „Measurement of left ventricular torsion using block-matching-based speckle tracking for two-dimensional echocardiography”, *J. Electron. Imaging*, t. 22, nr 1, s. 013010, sty. 2013, doi: 10.1117/1.JEI.22.1.013010.

- [44] L. S. Fixsen *i in.*, „Echocardiographic Assessment of Left Bundle Branch–Related Strain Dyssynchrony: A Comparison With Tagged MRI”, *Ultrasound Med. Biol.*, t. 45, nr 8, s. 2063–2074, sie. 2019, doi: 10.1016/j.ultrasmedbio.2019.03.012.
- [45] C. Wang, Y. Shi, i J. Ji, „Application of block matching method-based Echocardiography combined with serum NT-PROBNP level detection in the early prediction of PDA in premature infants”, *Pak. J. Med. Sci.*, t. 37, nr 6, s. 1657–1661, 2021, doi: 10.12669/pjms.37.6-WIT.4864.
- [46] A. Wilczewska, S. Cygan, i J. Żmigrodzki, „Displacement Field Estimation for Echocardiography Strain Imaging Using B-Spline Based Elastic Image Registration—Synthetic Data Study”, w *Recent Global Research and Education: Technological Challenges*, R. Jabłoński i R. Szewczyk, Red., w *Advances in Intelligent Systems and Computing*. Cham: Springer International Publishing, 2017, s. 309–315. doi: 10.1007/978-3-319-46490-9_42.
- [47] F. P. M. Oliveira i J. M. R. S. Tavares, „Medical image registration: a review”, *Comput. Methods Biomech. Biomed. Engin.*, t. 17, nr 2, s. 73–93, sty. 2014, doi: 10.1080/10255842.2012.670855.
- [48] M. J. Ledesma-Carbayo *i in.*, „Spatio-temporal nonrigid registration for ultrasound cardiac motion estimation”, *IEEE Trans. Med. Imaging*, t. 24, nr 9, s. 1113–1126, wrz. 2005, doi: 10.1109/TMI.2005.852050.
- [49] J.-U. Voigt *i in.*, „Definitions for a common standard for 2D speckle tracking echocardiography: consensus document of the EACVI/ASE/Industry Task Force to standardize deformation imaging”, *Eur. Heart J. - Cardiovasc. Imaging*, t. 16, nr 1, s. 1–11, sty. 2015, doi: 10.1093/ehjci/jeu184.
- [50] S. Kłysz, *Podstawy wytrzymałości materiałów*. Warszawa: Wydawnictwo Instytutu Technicznego Wojsk Lotniczych, 2015.
- [51] T. Varghese i J. Ophir, „A theoretical framework for performance characterization of elastography: the strain filter”, *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, t. 44, nr 1, s. 164–172, sty. 1997, doi: 10.1109/58.585212.
- [52] H. Blessberger i T. Binder, „Two dimensional speckle tracking echocardiography: basic principles”, *Heart*, t. 96, nr 9, s. 716–722, maj 2010, doi: 10.1136/hrt.2007.141002.
- [53] R. R. Shamir, Y. Duchin, J. Kim, G. Sapiro, i N. Harel, „Continuous Dice Coefficient: a Method for Evaluating Probabilistic Segmentations”. arXiv, 26 czerwiec 2019. doi: 10.48550/arXiv.1906.11031.
- [54] B. Guindon i Y. Zhang, „Application of the Dice Coefficient to Accuracy Assessment of Object-Based Image Classification”, *Can. J. Remote Sens.*, t. 43, nr 1, s. 48–61, sty. 2017, doi: 10.1080/07038992.2017.1259557.
- [55] M. Haidekker, *Advanced Biomedical Image Analysis*. John Wiley & Sons, 2010.
- [56] M. Marsousi, J. Alirezaie, A. Ahmadian, i A. Kocharian, „Segmenting Echocardiography Images using B-Spline Snake and Active Ellipse Model”, w *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, sie. 2010, s. 8. doi: 10.1109/IEMBS.2010.5626094.
- [57] V.-T. Pham i T.-T. Tran, „Active contour model and nonlinear shape priors with application to left ventricle segmentation in cardiac MR images”, *Optik*, t. 127, nr 3, s. 991–1002, luty 2016, doi: 10.1016/j.ijleo.2015.10.162.
- [58] O. Oktay *i in.*, „Anatomically Constrained Neural Networks (ACNNs): Application to Cardiac Image Enhancement and Segmentation”, *IEEE Trans. Med. Imaging*, t. 37, nr 2, s. 384–395, luty 2018, doi: 10.1109/TMI.2017.2743464.
- [59] A. Shalhaf, H. Behnam, Z. Alizade-Sani, i M. Shojaifard, „Left ventricle wall motion quantification from echocardiographic images by non-rigid image registration”, *Int. J.*

- Comput. Assist. Radiol. Surg.*, t. 7, nr 5, s. 769–783, wrz. 2012, doi: 10.1007/s11548-012-0786-2.
- [60] A. Shalhaf, H. Behnam, Z. Alizade-Sani, i M. Shojaifard, „Automatic Classification of Left Ventricular Regional Wall Motion Abnormalities in Echocardiography Images Using Nonrigid Image Registration”, *J. Digit. Imaging*, t. 26, nr 5, s. 909–919, paź. 2013, doi: 10.1007/s10278-012-9543-x.
- [61] J. Kybic i M. Unser, „Fast parametric elastic image registration”, *IEEE Trans. Image Process.*, t. 12, nr 11, s. 1427–1442, lis. 2003, doi: 10.1109/TIP.2003.813139.
- [62] D. Rueckert, L. I. Sonoda, C. Hayes, D. L. G. Hill, M. O. Leach, i D. J. Hawkes, „Nonrigid registration using free-form deformations: application to breast MR images”, *IEEE Trans. Med. Imaging*, t. 18, nr 8, s. 712–721, sie. 1999, doi: 10.1109/42.796284.
- [63] N. L. Sicotte, R. P. Woods, i J. C. Mazziotta, „Automated image registration using a 105 parameter non-linear model”, *NeuroImage*, t. 3 Supplement, nr 3, s. S123, 1996, doi: 10.1016/S1053-8119(96)80125-X.
- [64] S. J. Kiebel, J. Ashburner, J.-B. Poline, i K. J. Friston, „MRI and PET Coregistration—A Cross Validation of Statistical Parametric Mapping and Automated Image Registration”, *NeuroImage*, t. 5, nr 4, s. 271–279, maj 1997, doi: 10.1006/nimg.1997.0265.
- [65] Y. Amit, „A Nonlinear Variational Problem for Image Matching”, *SIAM J. Sci. Comput.*, t. 15, nr 1, s. 207–224, sty. 1994, doi: 10.1137/0915014.
- [66] B. Heyde *i in.*, „Regional cardiac motion and strain estimation in three-dimensional echocardiography: a validation study in thick-walled univentricular phantoms”, *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, t. 59, nr 4, s. 668–682, kwi. 2012, doi: 10.1109/TUFFC.2012.2245.
- [67] M. Unser, A. Aldroubi, i M. Eden, „B-spline signal processing. I. Theory”, *IEEE Trans. Signal Process.*, t. 41, nr 2, s. 821–833, luty 1993, doi: 10.1109/78.193220.
- [68] C. Studholme, D. L. G. Hill, i D. J. Hawkes, „Automated three-dimensional registration of magnetic resonance and positron emission tomography brain images by multiresolution optimization of voxel similarity measures”, *Med. Phys.*, t. 24, nr 1, s. 25–35, 1997, doi: 10.1118/1.598130.
- [69] T. Rohlfing, C. R. Maurer, D. A. Bluemke, i M. A. Jacobs, „Volume-preserving nonrigid registration of MR breast images using free-form deformation with an incompressibility constraint”, *IEEE Trans. Med. Imaging*, t. 22, nr 6, s. 730–741, cze. 2003, doi: 10.1109/TMI.2003.814791.
- [70] R. H. Byrd, P. Lu, J. Nocedal, i C. Zhu, „A Limited Memory Algorithm for Bound Constrained Optimization”, *SIAM J. Sci. Comput.*, t. 16, nr 5, s. 1190–1208, wrz. 1995, doi: 10.1137/0916069.
- [71] C. Lu *i in.*, „An integrated approach to segmentation and nonrigid registration for application in image-guided pelvic radiotherapy”, *Med. Image Anal.*, t. 15, nr 5, s. 772–785, paź. 2011, doi: 10.1016/j.media.2011.05.010.
- [72] M. S. Elmahdy, J. M. Wolterink, H. Sokooti, I. Išgum, i M. Staring, „Adversarial Optimization for Joint Registration and Segmentation in Prostate CT Radiotherapy”, zaprezentowano na *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Springer, paź. 2019, s. 366–374. doi: 10.1007/978-3-030-32226-7_41.
- [73] N. Parajuli *i in.*, „Sparsity and Biomechanics Inspired Integration of Shape and Speckle Tracking for Cardiac Deformation Analysis”, w *Functional Imaging and Modeling of the Heart*, Springer, Cham, cze. 2015, s. 57–64. doi: 10.1007/978-3-319-20309-6_7.
- [74] N. Parajuli *i in.*, „Integrated Dynamic Shape Tracking and RF Speckle Tracking for Cardiac Motion Analysis”, w *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016*, S. Ourselin, L. Joskowicz, M. R. Sabuncu, G. Unal, i W.

- Wells, Red., w *Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2016, s. 431–438. doi: 10.1007/978-3-319-46720-7_50.
- [75] C. B. Compas *i in.*, „Radial basis functions for combining shape and speckle tracking in 4D echocardiography”, *IEEE Trans. Med. Imaging*, t. 33, nr 6, s. 1275–1289, 2014, doi: 10.1109/TMI.2014.2308894.
- [76] C. B. Compas *i in.*, „Comparing shape tracking, speckle tracking, and a combined method for deformation analysis in echocardiography”, zaprezentowano na Proceedings - 2011 1st IEEE International Conference on Healthcare Informatics, Imaging and Systems Biology, HISB 2011, 2011, s. 120–125. doi: 10.1109/HISB.2011.16.
- [77] D. Mahapatra i Y. Sun, „Integrating Segmentation Information for Improved MRF-Based Elastic Image Registration”, *IEEE Trans. IMAGE Process.*, t. 21, nr 1, 2012, doi: 10.1109/TIP.2011.2162738.
- [78] S. Lee, G. Wolberg, K.-Y. Chwa, i S. Y. Shin, „Image metamorphosis with scattered feature constraints”, *IEEE Trans. Vis. Comput. Graph.*, t. 2, nr 4, s. 337–354, grudz. 1996, doi: 10.1109/2945.556502.
- [79] R. Keys, „Cubic convolution interpolation for digital image processing”, *IEEE Trans. Acoust. Speech Signal Process.*, t. 29, nr 6, s. 1153–1160, grudz. 1981, doi: 10.1109/TASSP.1981.1163711.
- [80] „FMINLBFGS: Fast Limited Memory Optimizer”. Dostęp: 25 czerwiec 2022. [Online]. Dostępne na: <https://www.mathworks.com/matlabcentral/fileexchange/23245-fminlbfgs-fast-limited-memory-optimizer>
- [81] J. Żmigrodzki, S. Cygan, A. Wilczewska, i K. Kałużyński, „Quantitative Assessment of the Effect of the Out-of-Plane Movement of the Homogenous Ellipsoidal Model of the Left Ventricle on the Deformation Measures Estimated Using 2-D Speckle Tracking—An In-Silico Study”, *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, t. 65, nr 10, s. 1789–1803, paź. 2018, doi: 10.1109/TUFFC.2018.2856127.
- [82] B. Lesniak-Plewinska *i in.*, „A Dual-Chamber, Thick-Walled Cardiac Phantom for Use in Cardiac Motion and Deformation Imaging by Ultrasound”, *Ultrasound Med. Biol.*, t. 36, nr 7, s. 1145–1156, lip. 2010, doi: 10.1016/j.ultrasmedbio.2010.04.008.
- [83] S. Cygan, *Modelowanie numeryczne fantomów serca na potrzeby obrazowania odkształceń w echokardiografii*, 1. wyd. Warszawa: Exit, 2019.
- [84] J. A. Jensen, „FIELD: A Program for Simulating Ultrasound Systems”, w *10th Nordicbaltic Conference on Biomedical Imaging, Vol. 4, Supplement 1, Part 1:351–353*, 1996, s. 351–353.
- [85] J. A. Jensen i N. B. Svendsen, „Calculation of pressure fields from arbitrarily shaped, apodized, and excited ultrasound transducers”, *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, t. 39, nr 2, s. 262–267, mar. 1992, doi: 10.1109/58.139123.
- [86] A. Wilczewska, S. Cygan, i J. Żmigrodzki, „Segmentation Enhanced Elastic Image Registration for 2D Speckle Tracking Echocardiography—Performance Study In Silico”, *Ultrason. Imaging*, t. 44, nr 1, s. 39–54, sty. 2022, doi: 10.1177/01617346211068812.
- [87] „Snake: Active Contour”. Dostęp: 19 styczeń 2022. [Online]. Dostępne na: <https://www.mathworks.com/matlabcentral/fileexchange/28149-snake-active-contour>
- [88] Y. Hu *i in.*, „AIDAN: An Attention-Guided Dual-Path Network for Pediatric Echocardiography Segmentation”, *IEEE Access*, t. 8, s. 29176–29187, 2020, doi: 10.1109/ACCESS.2020.2971383.
- [89] X. Qin, Z. Cong, i B. Fei, „Automatic segmentation of right ventricular ultrasound images using sparse matrix transform and a level set”, *Phys. Med. Biol.*, t. 58, nr 21, s. 7609–7624, lis. 2013, doi: 10.1088/0031-9155/58/21/7609.
- [90] M. Alessandrini *i in.*, „Realistic Vendor-Specific Synthetic Ultrasound Data for Quality Assurance of 2-D Speckle Tracking Echocardiography: Simulation Pipeline and Open

- Access Database”, *IEEE Trans. Ultrason. Ferroelectr. Freq. Control*, t. 65, nr 3, s. 411–422, mar. 2018, doi: 10.1109/TUFFC.2017.2786300.
- [91] „database_2d_simulations_uffc | Obsługiwane przez Box”. Dostęp: 25 czerwiec 2022. [Online]. Dostępne na: <https://kuleuven.app.box.com/s/rpr27o79au2a6twjlg3mhib21rqdi147>
- [92] „PMOD Technologies LLC – PMOD Technologies”. Dostęp: 2 październik 2022. [Online]. Dostępne na: <https://www.pmod.com/web/>
- [93] M. Habijan *i in.*, „Overview of the Whole Heart and Heart Chamber Segmentation Methods”, *Cardiovasc. Eng. Technol.*, t. 11, nr 6, s. 725–747, grudz. 2020, doi: 10.1007/s13239-020-00494-8.

8 Dodatki

8.1 Dodatek A

Tabela 18 Wartości średniego błędu wyznaczania przemieszczeń w kierunku x w badaniu na danych syntetycznych z maską referencyjną

producent	typ danych	widok	$\omega_s = 0$	$\omega_s = 0$	$\omega_s = 0,05$	$\omega_s = 0,05$
			$k_m = 0$	$k_m = 1$	$k_m = 0$	$k_m = 1$
ESAOTE	laddist	A4C	0,000482	0,000475	0,000475	0,000474
		A3C	0,000597	0,000607	0,000604	0,000605
		A2C	0,000556	0,000539	0,000541	0,000539
	ladprox	A4C	0,000375	0,000365	0,000365	0,000365
		A3C	0,000529	0,000530	0,000532	0,000531
		A2C	0,000517	0,000502	0,000504	0,000501
	lcx	A4C	0,000510	0,000518	0,000515	0,000517
		A3C	0,000507	0,000524	0,000519	0,000519
		A2C	0,000527	0,000520	0,000520	0,000519
	normal	A4C	0,000613	0,000603	0,000601	0,000602
		A3C	0,000717	0,000713	0,000718	0,000715
		A2C	0,000658	0,000642	0,000644	0,000643
	rca	A4C	0,000530	0,000525	0,000523	0,000524
		A3C	0,000709	0,000697	0,000701	0,000702
		A2C	0,000751	0,000683	0,000694	0,000687
GE	laddist	A4C	0,000648	0,000663	0,000663	0,000667
		A3C	0,000663	0,000680	0,000678	0,000682
		A2C	0,000972	0,000765	0,000772	0,000763
	ladprox	A4C	0,000482	0,000498	0,000503	0,000499
		A3C	0,000570	0,000594	0,000590	0,000596
		A2C	0,000854	0,000751	0,000754	0,000753
	lcx	A4C	0,000676	0,000668	0,000681	0,000667
		A3C	0,000652	0,000664	0,000663	0,000667
		A2C	0,000690	0,000753	0,000758	0,000744

	normal	A4C	0,000676	0,000668	0,000681	0,000667	
		A3C	0,000652	0,000664	0,000663	0,000667	
		A2C	0,001100	0,000833	0,000827	0,000842	
	rca	A4C	0,000670	0,000697	0,000693	0,000698	
		A3C	0,000856	0,000766	0,000762	0,000757	
		A2C	0,000756	0,000762	0,000782	0,000760	
HITACHI	laddist	A4C	0,000493	0,000496	0,000497	0,000496	
		A3C	0,000694	0,000687	0,000688	0,000687	
		A2C	0,000519	0,000511	0,000508	0,000508	
	ladprox	A4C	0,000371	0,000382	0,000385	0,000381	
		A3C	0,000603	0,000601	0,000600	0,000601	
		A2C	0,000500	0,000492	0,000492	0,000492	
	lcx	A4C	0,000494	0,000483	0,000482	0,000483	
		A3C	0,000672	0,000661	0,000665	0,000661	
		A2C	0,000563	0,000551	0,000551	0,000550	
	normal	A4C	0,000600	0,000612	0,000612	0,000612	
		A3C	0,000828	0,000821	0,000822	0,000820	
		A2C	0,000594	0,000589	0,000589	0,000588	
	rca	A4C	0,000551	0,000559	0,000560	0,000559	
		A3C	0,000804	0,000793	0,000796	0,000793	
		A2C	0,000621	0,000615	0,000617	0,000615	
	PHILIPS	laddist	A4C	0,000484	0,000482	0,000480	0,000482
			A3C	0,000592	0,000584	0,000580	0,000580
			A2C	0,000448	0,000448	0,000451	0,000447
ladprox		A4C	0,000352	0,000355	0,000355	0,000355	
		A3C	0,000544	0,000539	0,000540	0,000539	
		A2C	0,000442	0,000445	0,000448	0,000446	
lcx		A4C	0,000528	0,000512	0,000511	0,000512	
		A3C	0,000566	0,000553	0,000552	0,000556	
		A2C	0,000452	0,000433	0,000434	0,000430	
normal		A4C	0,000600	0,000607	0,000604	0,000606	
		A3C	0,000727	0,000721	0,000721	0,000722	
		A2C	0,000483	0,000474	0,000474	0,000472	

	rca	A4C	0,000536	0,000536	0,000534	0,000536	
		A3C	0,000698	0,000691	0,000689	0,000692	
		A2C	0,000481	0,000463	0,000466	0,000466	
SAMSUNG	laddist	A4C	0,000936	0,000725	0,000734	0,000724	
		A3C	0,001600	0,001100	0,001100	0,001100	
		A2C	0,001400	0,000726	0,000783	0,000707	
	ladprox	A4C	0,001300	0,000605	0,000645	0,000604	
		A3C	0,001100	0,000989	0,000984	0,000992	
		A2C	0,001000	0,000708	0,000740	0,000700	
	lca	A4C	0,002400	0,000595	0,000611	0,000597	
		A3C	0,001500	0,001100	0,001100	0,001100	
		A2C	0,001200	0,000716	0,000851	0,000727	
	normal	A4C	0,001500	0,000897	0,000903	0,000897	
		A3C	0,001500	0,001300	0,001400	0,001300	
		A2C	0,001200	0,000854	0,000898	0,000829	
	rca	A4C	0,001500	0,000751	0,000742	0,000745	
		A3C	0,001800	0,001200	0,001300	0,001200	
		A2C	0,000628	0,000650	0,000740	0,000752	
	SIEMENS	laddist	A4C	0,000710	0,000707	0,000705	0,000707
			A3C	0,000566	0,000565	0,000566	0,000565
			A2C	0,000498	0,000472	0,000472	0,000472
ladprox		A4C	0,000573	0,000564	0,000560	0,000563	
		A3C	0,000520	0,000520	0,000522	0,000520	
		A2C	0,000456	0,000442	0,000442	0,000442	
lca		A4C	0,000643	0,000647	0,000655	0,000651	
		A3C	0,000543	0,000540	0,000538	0,000540	
		A2C	0,000551	0,000526	0,000532	0,000527	
normal		A4C	0,000840	0,000836	0,000835	0,000837	
		A3C	0,000675	0,000673	0,000672	0,000673	
		A2C	0,000585	0,000570	0,000571	0,000569	
rca		A4C	0,000696	0,000692	0,000693	0,000693	
		A3C	0,000643	0,000641	0,000639	0,000641	
		A2C	0,000624	0,000589	0,000593	0,000591	

TOSHIBA	laddist	A4C	0,000589	0,000560	0,000560	0,000560
		A3C	0,000800	0,000762	0,000781	0,000781
		A2C	0,000697	0,000588	0,000595	0,000588
	ladprox	A4C	0,000460	0,000421	0,000422	0,000421
		A3C	0,000773	0,000700	0,000709	0,000698
		A2C	0,000689	0,000556	0,000559	0,000564
	lcx	A4C	0,000516	0,000530	0,000530	0,000530
		A3C	0,000805	0,000709	0,000716	0,000710
		A2C	0,000743	0,000631	0,000628	0,000637
	normal	A4C	0,000718	0,000692	0,000692	0,000692
		A3C	0,001000	0,000940	0,000919	0,000917
		A2C	0,000824	0,000662	0,000677	0,000665
	rca	A4C	0,000623	0,000598	0,000598	0,000598
		A3C	0,000921	0,000853	0,000863	0,000846
		A2C	0,000865	0,000684	0,000698	0,000681

Tabela 19 Wartości średniego błędu wyznaczania przemieszczeń w kierunku w badaniu na danych syntetycznych z maską referencyjną

producent	typ danych	widok	$\omega_s = 0$	$\omega_s = 0$	$\omega_s = 0,05$	$\omega_s = 0,05$
			$k_m = 0$	$k_m = 1$	$k_m = 0$	$k_m = 1$
ESAOTE	laddist	A4C	0,000441	0,000442	0,000442	0,000442
		A3C	0,000445	0,000443	0,000446	0,000442
		A2C	0,000455	0,000452	0,000460	0,000453
	ladprox	A4C	0,000404	0,000405	0,000404	0,000405
		A3C	0,000436	0,000432	0,000435	0,000432
		A2C	0,000428	0,000424	0,000428	0,000423
	lcx	A4C	0,000520	0,000515	0,000514	0,000514
		A3C	0,000504	0,000509	0,000518	0,000513
		A2C	0,000529	0,000514	0,000519	0,000515
	normal	A4C	0,000499	0,000500	0,000498	0,000499
		A3C	0,000477	0,000479	0,000483	0,000479
		A2C	0,000468	0,000446	0,000451	0,000447

	rca	A4C	0,000509	0,000508	0,000507	0,000508	
		A3C	0,000429	0,000427	0,000432	0,000429	
		A2C	0,000455	0,000422	0,000427	0,000422	
GE	laddist	A4C	0,000550	0,000535	0,000536	0,000535	
		A3C	0,000734	0,000610	0,000618	0,000612	
		A2C	0,000789	0,000632	0,000661	0,000634	
	ladprox	A4C	0,000539	0,000502	0,000505	0,000502	
		A3C	0,000656	0,000588	0,000592	0,000590	
		A2C	0,000609	0,000565	0,000586	0,000569	
	lca	A4C	0,000665	0,000631	0,000629	0,000631	
		A3C	0,000778	0,000596	0,000604	0,000597	
		A2C	0,000916	0,000665	0,000677	0,000664	
	normal	A4C	0,000665	0,000631	0,000629	0,000631	
		A3C	0,000778	0,000596	0,000604	0,000597	
		A2C	0,000858	0,000660	0,000659	0,000658	
	rca	A4C	0,000669	0,000617	0,000616	0,000616	
		A3C	0,000733	0,000626	0,000630	0,000623	
		A2C	0,001200	0,000644	0,000652	0,000643	
	HITACHI	laddist	A4C	0,000460	0,000460	0,000458	0,000461
			A3C	0,000435	0,000433	0,000432	0,000433
			A2C	0,000510	0,000510	0,000508	0,000508
ladprox		A4C	0,000382	0,000381	0,000379	0,000381	
		A3C	0,000425	0,000420	0,000420	0,000420	
		A2C	0,000469	0,000467	0,000467	0,000467	
lca		A4C	0,000548	0,000553	0,000551	0,000553	
		A3C	0,000418	0,000415	0,000413	0,000415	
		A2C	0,000507	0,000497	0,000497	0,000497	
normal		A4C	0,000495	0,000495	0,000493	0,000495	
		A3C	0,000458	0,000454	0,000453	0,000454	
		A2C	0,000492	0,000487	0,000486	0,000487	
rca		A4C	0,000490	0,000491	0,000489	0,000491	
		A3C	0,000426	0,000424	0,000422	0,000424	
		A2C	0,000467	0,000461	0,000459	0,000461	

PHILIPS	laddist	A4C	0,000377	0,000378	0,000377	0,000378
		A3C	0,000473	0,000472	0,000474	0,000471
		A2C	0,000447	0,000441	0,000445	0,000441
	ladprox	A4C	0,000353	0,000354	0,000353	0,000354
		A3C	0,000461	0,000448	0,000453	0,000444
		A2C	0,000401	0,000392	0,000394	0,000392
	lcx	A4C	0,000464	0,000450	0,000448	0,000450
		A3C	0,000461	0,000461	0,000465	0,000462
		A2C	0,000472	0,000466	0,000467	0,000465
	normal	A4C	0,000430	0,000430	0,000428	0,000431
		A3C	0,000501	0,000501	0,000506	0,000501
		A2C	0,000471	0,000467	0,000471	0,000466
	rca	A4C	0,000441	0,000438	0,000436	0,000438
		A3C	0,000469	0,000466	0,000469	0,000466
		A2C	0,000457	0,000447	0,000453	0,000453
SAMSUNG	laddist	A4C	0,000654	0,000566	0,000556	0,000567
		A3C	0,001200	0,000685	0,000697	0,000673
		A2C	0,001200	0,000726	0,000885	0,000725
	ladprox	A4C	0,000495	0,000500	0,000496	0,000501
		A3C	0,000958	0,000699	0,000754	0,000697
		A2C	0,001000	0,000655	0,000820	0,000651
	lcx	A4C	0,000606	0,000709	0,000724	0,000710
		A3C	0,001500	0,000600	0,000601	0,000606
		A2C	0,001700	0,000742	0,000948	0,000744
	normal	A4C	0,000769	0,000629	0,000619	0,000630
		A3C	0,001700	0,000744	0,000730	0,000731
		A2C	0,001400	0,000740	0,000869	0,000735
	rca	A4C	0,000744	0,000660	0,000666	0,000659
		A3C	0,001900	0,000635	0,000628	0,000650
		A2C	0,001400	0,000733	0,000733	0,000726
SIEMENS	laddist	A4C	0,000479	0,000478	0,000484	0,000480
		A3C	0,000485	0,000483	0,000485	0,000483
		A2C	0,000470	0,000451	0,000457	0,000451

	ladprox	A4C	0,000426	0,000425	0,000429	0,000426
		A3C	0,000456	0,000452	0,000456	0,000442
		A2C	0,000425	0,000417	0,000420	0,000417
	lcx	A4C	0,000563	0,000559	0,000568	0,000562
		A3C	0,000480	0,000479	0,000482	0,000479
		A2C	0,000488	0,000451	0,000455	0,000451
	normal	A4C	0,000522	0,000521	0,000526	0,000524
		A3C	0,000524	0,000521	0,000524	0,000522
		A2C	0,000453	0,000438	0,000440	0,000438
	rca	A4C	0,000530	0,000529	0,000533	0,000532
		A3C	0,000488	0,000487	0,000490	0,000487
		A2C	0,000452	0,000434	0,000436	0,000434
TOSHIBA	laddist	A4C	0,000434	0,000457	0,000457	0,000457
		A3C	0,000623	0,000606	0,000607	0,000608
		A2C	0,001100	0,000589	0,000595	0,000588
	ladprox	A4C	0,000412	0,000419	0,000419	0,000419
		A3C	0,000631	0,000565	0,000571	0,000563
		A2C	0,001000	0,000530	0,000532	0,000527
	lcx	A4C	0,000563	0,000548	0,000546	0,000548
		A3C	0,000580	0,000594	0,000586	0,000589
		A2C	0,001200	0,000618	0,000623	0,000619
	normal	A4C	0,000508	0,000515	0,000516	0,000515
		A3C	0,000699	0,000647	0,000639	0,000645
		A2C	0,000953	0,000614	0,000613	0,000612
	rca	A4C	0,000529	0,000526	0,000527	0,000527
		A3C	0,000633	0,000604	0,000595	0,000601
		A2C	0,000942	0,000601	0,000603	0,000601

Tabela 20 Parametry statystyczne wartości błędu wyznaczania odkształceń w badaniu na danych semi-syntetycznych z maską referencyjną

Widok	segment	Wartości wag	średnia	mediana	1. kwartył	3. kwartył
A2C	Podstawny przedni	$\omega_s = 0, k_m = 0$	6,655	5,589	4,001	9,246
		$\omega_s = 0, k_m = 1$	3,864	3,745	3,104	4,570
		$\omega_s = 0,05, k_m = 0$	3,923	3,940	2,998	4,707
		$\omega_s = 0,05, k_m = 1$	3,850	3,766	3,062	4,590
	Środkowy przedni	$\omega_s = 0, k_m = 0$	4,360	2,966	1,696	6,891
		$\omega_s = 0, k_m = 1$	2,047	1,703	1,133	2,889
		$\omega_s = 0,05, k_m = 0$	2,075	1,832	1,185	2,898
		$\omega_s = 0,05, k_m = 1$	2,054	1,705	1,123	2,884
	Koniuszkowy przedni	$\omega_s = 0, k_m = 0$	2,203	2,033	1,419	2,955
		$\omega_s = 0, k_m = 1$	2,056	1,894	1,312	2,663
		$\omega_s = 0,05, k_m = 0$	2,060	1,891	1,317	2,679
		$\omega_s = 0,05, k_m = 1$	2,056	1,894	1,305	2,654
	Koniuszkowy dolny	$\omega_s = 0, k_m = 0$	2,702	2,778	1,540	3,637
		$\omega_s = 0, k_m = 1$	2,703	2,778	1,540	3,637
		$\omega_s = 0,05, k_m = 0$	2,716	2,779	1,551	3,638
		$\omega_s = 0,05, k_m = 1$	2,704	2,778	1,541	3,635
	Środkowy dolny	$\omega_s = 0, k_m = 0$	1,722	1,615	1,339	1,964
		$\omega_s = 0, k_m = 1$	1,690	1,550	1,337	1,963

		$\omega_s = 0,05, k_m = 0$	1,682	1,562	1,319	1,951
		$\omega_s = 0,05, k_m = 1$	1,690	1,554	1,337	1,962
	Podstawny dolny	$\omega_s = 0, k_m = 0$	4,525	4,490	3,650	5,559
		$\omega_s = 0, k_m = 1$	4,439	4,281	3,618	5,477
		$\omega_s = 0,05, k_m = 0$	4,433	4,296	3,620	5,482
		$\omega_s = 0,05, k_m = 1$	4,439	4,280	3,618	5,476
	Globalny	$\omega_s = 0, k_m = 0$	2,988	2,804	2,184	3,278
		$\omega_s = 0, k_m = 1$	2,192	2,244	1,729	2,600
		$\omega_s = 0,05, k_m = 0$	2,213	2,238	1,741	2,612
		$\omega_s = 0,05, k_m = 1$	2,188	2,245	1,726	2,594
A3C	Podstawny dolny	$\omega_s = 0, k_m = 0$	6,121	5,928	4,991	6,557
		$\omega_s = 0, k_m = 1$	4,968	5,272	3,776	6,073
		$\omega_s = 0,05, k_m = 0$	5,058	5,392	3,832	6,166
		$\omega_s = 0,05, k_m = 1$	5,039	5,338	3,852	6,133
	Środkowy dolny	$\omega_s = 0, k_m = 0$	2,126	1,059	0,723	1,757
		$\omega_s = 0, k_m = 1$	1,131	1,005	0,968	1,333
		$\omega_s = 0,05, k_m = 0$	1,130	0,985	0,710	1,313

		$\omega_s = 0,05, k_m = 1$	1,131	0,993	0,965	1,358
	Konuszkowy dolny	$\omega_s = 0, k_m = 0$	2,220	1,914	1,453	2,739
		$\omega_s = 0, k_m = 1$	2,198	1,883	1,443	2,808
		$\omega_s = 0,05, k_m = 0$	2,196	1,884	1,437	2,799
		$\omega_s = 0,05, k_m = 1$	2,197	1,883	1,443	2,806
	Konuszkowy przedni	$\omega_s = 0, k_m = 0$	2,426	2,109	1,510	3,045
		$\omega_s = 0, k_m = 1$	2,426	2,109	1,509	3,042
		$\omega_s = 0,05, k_m = 0$	2,418	2,108	1,510	3,038
		$\omega_s = 0,05, k_m = 1$	2,425	2,109	1,509	3,042
	Środkowy przednioprzegrodowy	$\omega_s = 0, k_m = 0$	2,482	2,548	2,209	2,877
		$\omega_s = 0, k_m = 1$	2,488	2,531	2,208	2,872
		$\omega_s = 0,05, k_m = 0$	2,483	2,531	2,211	2,872
		$\omega_s = 0,05, k_m = 1$	2,488	2,531	2,208	2,873
	Podstawny przednioprzegrodowy	$\omega_s = 0, k_m = 0$	3,536	3,222	2,573	4,110
		$\omega_s = 0, k_m = 1$	3,322	3,242	2,607	4,097
		$\omega_s = 0,05, k_m = 0$	3,318	3,254	2,615	4,102
		$\omega_s = 0,05, k_m = 1$	3,322	3,244	2,610	4,097
	Globalny	$\omega_s = 0, k_m = 0$	2,242	2,103	1,728	2,724
		$\omega_s = 0, k_m = 1$	1,808	1,856	1,459	2,148
		$\omega_s = 0,05, k_m = 0$	1,821	1,806	1,463	2,166
		$\omega_s = 0,05, k_m = 1$	1,815	1,863	1,474	2,154
A4C		$\omega_s = 0, k_m = 0$	2,677	1,970	1,763	3,032

Podstawny dolnoboczny	$\omega_s = 0, k_m = 1$	2,092	2,046	1,554	2,532
	$\omega_s = 0,05, k_m = 0$	2,193	2,054	1,607	2,813
	$\omega_s = 0,05, k_m = 1$	2,091	2,029	1,550	2,529
Środkowy dolnoboczny	$\omega_s = 0, k_m = 0$	2,474	2,259	1,871	3,280
	$\omega_s = 0, k_m = 1$	2,319	2,194	1,729	2,975
	$\omega_s = 0,05, k_m = 0$	2,310	2,122	1,725	2,947
	$\omega_s = 0,05, k_m = 1$	2,319	2,193	1,729	2,973
Koniuszkowy boczny	$\omega_s = 0, k_m = 0$	1,916	1,823	1,078	2,566
	$\omega_s = 0, k_m = 1$	1,825	1,550	0,968	2,564
	$\omega_s = 0,05, k_m = 0$	1,822	1,536	0,963	2,560
	$\omega_s = 0,05, k_m = 1$	1,825	1,550	0,966	2,563
Koniuszkowy przegrodowy	$\omega_s = 0, k_m = 0$	1,166	1,072	0,875	1,509
	$\omega_s = 0, k_m = 1$	1,165	1,072	0,875	1,512
	$\omega_s = 0,05, k_m = 0$	1,159	1,080	0,888	1,508
	$\omega_s = 0,05, k_m = 1$	1,163	1,072	0,876	1,512
Środkowy przednioprzegrodowy	$\omega_s = 0, k_m = 0$	2,859	3,268	1,530	3,905
	$\omega_s = 0, k_m = 1$	2,843	3,122	1,409	3,905
	$\omega_s = 0,05, k_m = 0$	2,856	3,166	1,410	3,928
	$\omega_s = 0,05, k_m = 1$	2,846	3,128	1,409	3,908
Podstawny przednioprzegrodowy	$\omega_s = 0, k_m = 0$	3,351	3,213	2,685	3,918
	$\omega_s = 0, k_m = 1$	3,155	2,937	2,417	3,940
	$\omega_s = 0,05, k_m = 0$	3,163	2,938	2,446	3,929

		$\omega_s = 0,05, k_m = 1$	3,155	2,931	2,425	3,940
	Globalny	$\omega_s = 0, k_m = 0$	1,614	1,431	1,136	2,199
		$\omega_s = 0, k_m = 1$	1,548	1,383	1,135	2,128
		$\omega_s = 0,05, k_m = 0$	1,556	1,347	1,139	2,155
		$\omega_s = 0,05, k_m = 1$	1,549	1,385	1,136	2,131

Tabela 21 Parametry statystyczne wartości błędu wyznaczania odkształceń w badaniu na danych semi-syntetycznych z maską referencyjną, dla których jest dostępna maska z segmentacji metodą aktywnego konturu.

widok	segment	Wartości wag	średnia	mediana	1. kwartyl	3. kwartyl
A3C	Podstawny dolny	$\omega_s = 0, k_m = 0$	7,209	5,947	5,519	9,085
		$\omega_s = 0, k_m = 1$	5,337	5,681	4,139	6,168
		$\omega_s = 0,05, k_m = 0$	5,428	5,824	3,784	6,433
		$\omega_s = 0,05, k_m = 1$	5,362	5,656	4,024	6,351
	Środkowy dolny	$\omega_s = 0, k_m = 0$	1,596	1,288	1,003	1,757
		$\omega_s = 0, k_m = 1$	1,145	1,126	0,834	1,283
		$\omega_s = 0,05, k_m = 0$	1,163	1,165	0,822	1,290
		$\omega_s = 0,05, k_m = 1$	1,152	1,184	0,829	1,289
	Konuszkowy dolny	$\omega_s = 0, k_m = 0$	2,077	1,806	1,395	2,601
		$\omega_s = 0, k_m = 1$	2,073	1,805	1,392	2,564
		$\omega_s = 0,05, k_m = 0$	2,071	1,797	1,402	2,565
		$\omega_s = 0,05, k_m = 1$	2,072	1,804	1,393	2,569

	Koniuszkowy przedni	$\omega_s = 0, k_m = 0$	2,359	2,018	1,582	3,197
		$\omega_s = 0, k_m = 1$	2,359	2,017	1,581	3,197
		$\omega_s = 0,05, k_m = 0$	2,361	2,027	1,581	3,201
		$\omega_s = 0,05, k_m = 1$	2,358	2,017	1,581	3,195
	Środkowy przednioprzegrodowy	$\omega_s = 0, k_m = 0$	2,431	2,515	2,345	2,700
		$\omega_s = 0, k_m = 1$	2,425	2,515	2,344	2,687
		$\omega_s = 0,05, k_m = 0$	2,423	2,530	2,340	2,679
		$\omega_s = 0,05, k_m = 1$	2,425	2,516	2,344	2,687
	Podstawny przednioprzegrodowy	$\omega_s = 0, k_m = 0$	3,126	3,498	2,102	3,882
		$\omega_s = 0, k_m = 1$	3,121	3,426	2,065	3,833
		$\omega_s = 0,05, k_m = 0$	3,120	3,427	2,068	3,840
		$\omega_s = 0,05, k_m = 1$	3,122	3,426	2,065	3,837
	Globalny	$\omega_s = 0, k_m = 0$	2,370	2,319	2,006	2,830
		$\omega_s = 0, k_m = 1$	2,007	2,045	1,726	2,306
		$\omega_s = 0,05, k_m = 0$	2,035	2,082	1,727	2,358
		$\omega_s = 0,05, k_m = 1$	2,011	2,007	1,728	2,340
A4C	Podstawny dolnoboczny	$\omega_s = 0, k_m = 0$	1,943	1,807	1,574	2,165
		$\omega_s = 0, k_m = 1$	1,674	1,743	1,198	2,148
		$\omega_s = 0,05, k_m = 0$	1,687	1,746	1,261	2,144
		$\omega_s = 0,05, k_m = 1$	1,687	1,744	1,186	2,153
	Środkowy dolnoboczny	$\omega_s = 0, k_m = 0$	2,739	3,010	2,158	3,355
		$\omega_s = 0, k_m = 1$	2,625	2,924	2,129	3,227

		$\omega_s = 0,05, k_m = 0$	2,617	2,906	2,129	3,174
		$\omega_s = 0,05, k_m = 1$	2,625	2,914	2,128	3,233
	Konuszkowy boczny	$\omega_s = 0, k_m = 0$	1,552	1,246	0,912	2,169
		$\omega_s = 0, k_m = 1$	1,546	1,249	0,898	2,149
		$\omega_s = 0,05, k_m = 0$	1,544	1,246	0,894	2,149
		$\omega_s = 0,05, k_m = 1$	1,546	1,249	0,897	2,150
	Konuszkowy przegrodowy	$\omega_s = 0, k_m = 0$	1,265	1,244	0,943	1,574
		$\omega_s = 0, k_m = 1$	1,265	1,244	0,943	1,574
		$\omega_s = 0,05, k_m = 0$	1,265	1,261	0,970	1,553
		$\omega_s = 0,05, k_m = 1$	1,264	1,244	0,946	1,566
	Środkowy przednioprzegrodowy	$\omega_s = 0, k_m = 0$	2,894	3,268	2,029	3,905
		$\omega_s = 0, k_m = 1$	2,893	3,268	2,027	3,905
		$\omega_s = 0,05, k_m = 0$	2,910	3,269	2,028	3,928
		$\omega_s = 0,05, k_m = 1$	2,896	3,268	2,027	3,908
	Podstawny przednioprzegrodowy	$\omega_s = 0, k_m = 0$	2,894	2,878	2,512	3,316
		$\omega_s = 0, k_m = 1$	2,881	2,877	2,531	3,310
		$\omega_s = 0,05, k_m = 0$	2,893	2,897	2,546	3,315
		$\omega_s = 0,05, k_m = 1$	2,884	2,880	2,533	3,311
	Globalny	$\omega_s = 0, k_m = 0$	1,631	1,340	1,213	2,162
		$\omega_s = 0, k_m = 1$	1,586	1,383	1,194	2,087
		$\omega_s = 0,05, k_m = 0$	1,586	1,333	1,192	2,075

		$\omega_s = 0,05, k_m = 1$	1,587	1,385	1,195	2,088
--	--	----------------------------	-------	-------	-------	-------

Tabela 22 Parametry statystyczne wartości błędu wyznaczania odkształceń w badaniu na danych semi-syntetycznych z maską z segmentacji metodą aktywnego konturu.

widok	segment	Wartości wag	średnia	mediana	1. kwartyl	3. kwartyl	
A3C	Podstawny dolny	$\omega_s = 0, k_m = 0$	7,209	5,947	5,519	9,085	
		$\omega_s = 0, k_m = 1$	5,488	5,633	3,884	6,531	
		$\omega_s = 0,05, k_m = 0$	5,428	5,824	3,784	6,433	
		$\omega_s = 0,05, k_m = 1$	5,407	5,746	3,838	6,481	
	Środkowy dolny	$\omega_s = 0, k_m = 0$	1,596	1,288	1,003	1,757	
		$\omega_s = 0, k_m = 1$	1,147	1,086	0,798	1,326	
		$\omega_s = 0,05, k_m = 0$	1,163	1,165	0,822	1,290	
		$\omega_s = 0,05, k_m = 1$	1,143	1,114	0,804	1,301	
	Konuszkowy dolny	$\omega_s = 0, k_m = 0$	2,077	1,806	1,395	2,601	
		$\omega_s = 0, k_m = 1$	2,075	1,802	1,395	2,551	
		$\omega_s = 0,05, k_m = 0$	2,071	1,797	1,402	2,565	
		$\omega_s = 0,05, k_m = 1$	2,073	1,803	1,392	2,559	
	Konuszkowy przedni	$\omega_s = 0, k_m = 0$	2,359	2,018	1,582	3,197	
		$\omega_s = 0, k_m = 1$	2,359	2,017	1,581	3,196	
		$\omega_s = 0,05, k_m = 0$	2,361	2,027	1,581	3,201	
		$\omega_s = 0,05, k_m = 1$	2,359	2,017	1,582	3,196	
			$\omega_s = 0, k_m = 0$	2,431	2,515	2,345	2,700

	Środkowy przednioprzegrodowy	$\omega_s = 0, k_m = 1$	2,425	2,515	2,344	2,687	
		$\omega_s = 0,05, k_m = 0$	2,423	2,530	2,340	2,679	
		$\omega_s = 0,05, k_m = 1$	2,425	2,515	2,344	2,687	
	Podstawny przednioprzegrodowy	$\omega_s = 0, k_m = 0$	3,126	3,498	2,102	3,882	
		$\omega_s = 0, k_m = 1$	3,116	3,431	2,067	3,841	
		$\omega_s = 0,05, k_m = 0$	3,120	3,427	2,068	3,840	
		$\omega_s = 0,05, k_m = 1$	3,119	3,427	2,065	3,837	
	Globalny	$\omega_s = 0, k_m = 0$	2,370	2,319	2,006	2,830	
		$\omega_s = 0, k_m = 1$	2,024	2,066	1,714	2,394	
		$\omega_s = 0,05, k_m = 0$	2,035	2,082	1,727	2,358	
		$\omega_s = 0,05, k_m = 1$	2,013	2,023	1,729	2,371	
	A4C	Podstawny dolnoboczny	$\omega_s = 0, k_m = 0$	1,943	1,807	1,574	2,165
			$\omega_s = 0, k_m = 1$	1,677	1,743	1,198	2,157
$\omega_s = 0,05, k_m = 0$			1,687	1,746	1,261	2,144	
$\omega_s = 0,05, k_m = 1$			1,669	1,741	1,174	2,154	
Środkowy dolnoboczny		$\omega_s = 0, k_m = 0$	2,739	3,010	2,158	3,355	
		$\omega_s = 0, k_m = 1$	2,631	2,925	2,130	3,231	
		$\omega_s = 0,05, k_m = 0$	2,617	2,906	2,129	3,174	
		$\omega_s = 0,05, k_m = 1$	2,630	2,920	2,127	3,244	
Koniuszkowy boczny		$\omega_s = 0, k_m = 0$	1,552	1,246	0,912	2,169	
		$\omega_s = 0, k_m = 1$	1,546	1,248	0,896	2,149	
		$\omega_s = 0,05, k_m = 0$	1,544	1,246	0,894	2,149	

		$\omega_s = 0,05, k_m = 1$	1,546	1,249	0,896	2,150
Koniuszkowy przegrodowy		$\omega_s = 0, k_m = 0$	1,265	1,244	0,943	1,574
		$\omega_s = 0, k_m = 1$	1,265	1,244	0,943	1,574
		$\omega_s = 0,05, k_m = 0$	1,265	1,261	0,970	1,553
		$\omega_s = 0,05, k_m = 1$	1,264	1,244	0,947	1,568
Środkowy przednioprzegrodowy		$\omega_s = 0, k_m = 0$	2,894	3,268	2,029	3,905
		$\omega_s = 0, k_m = 1$	2,893	3,268	2,027	3,905
		$\omega_s = 0,05, k_m = 0$	2,910	3,269	2,028	3,928
		$\omega_s = 0,05, k_m = 1$	2,897	3,268	2,028	3,910
Podstawny przednioprzegrodowy		$\omega_s = 0, k_m = 0$	2,892	2,878	2,512	3,316
		$\omega_s = 0, k_m = 1$	2,881	2,877	2,530	3,310
		$\omega_s = 0,05, k_m = 0$	2,893	2,897	2,546	3,315
		$\omega_s = 0,05, k_m = 1$	2,884	2,881	2,533	3,311
Globalny		$\omega_s = 0, k_m = 0$	1,631	1,340	1,213	2,162
		$\omega_s = 0, k_m = 1$	1,589	1,398	1,196	2,092
		$\omega_s = 0,05, k_m = 0$	1,586	1,333	1,192	2,075
		$\omega_s = 0,05, k_m = 1$	1,589	1,390	1,195	2,091