

**Sebastian BUDZAN**

44-100 GLIWICE, UL. AKADEMICKA 16 (POLITECHNIKA ŚLĄSKA W GLIWICACH, INSTYTUT AUTOMATYKI)

**Algorytmy przetwarzania nieregularnych obrazów 3D****mgr inż. Sebastian BUDZAN**

W 2002 roku ukończył studia na Wydziale Automatyki, Elektroniki i Informatyki Politechniki Śląskiej w Gliwicach uzyskując tytuł magistra inżyniera specjalności Systemy Pomiarowe w Instytucie Automatyki. Od 2002 roku jest doktorantem w Instytucie Automatyki Politechniki Śląskiej w Zakładzie Systemów Pomiarowych. Jego zainteresowania naukowe skupiają się w głównej mierze wokół wykorzystania aparatury pomiarowej dla celów pozyskiwania informacji 3D o obiektach rzeczywistych, oprogramowania stosowanego w przetwarzaniu obrazów 3D.



e-mail: sebastian.budzan@polsl.pl

**Streszczenie**

W artykule prezentuje się modyfikacje algorytmów stosowanych w przetwarzaniu danych 3D. W pierwszej kolejności omówiono algorytm filtracji nieregularnych danych pomiarowych 3D, zwanych obrazem 3D. Źródłem szumu pomiarowego w skanerach 3D są najczęściej elementy optyczne skanera. Szum ten ma najczęściej charakter odrębnych grup punktów o wysokiej amplitudzie, jak również pojedynczych punktów o niskiej amplitudzie. Główna idea stosowanego algorytmu polega na maksymalizacji dystansu – odległości w przestrzeni  $x,y,z$  pomiędzy danymi pomiarowymi – najbliższymi sąsiadami znajdującymi się w bieżącym oknie pomiarowym. Do tego celu wykorzystuje się estymację funkcji gęstości, która wyliczana jest dla każdego punktu pomiarowego z bieżącego okna w przestrzeni 3D. Kolejną zaprezentowaną modyfikacją jest poprawa algorytmu decymacji zbioru punktów. Modyfikacja skupia się na wprowadzeniu *a priori* wartości stopnia decymacji określającego liczbę usuniętych punktów ze zbioru.

**Słowa kluczowe:** algorytmy przetwarzania 3D, filtracja, decymacja**Irregularly-sampled 3D image processing algorithms****Abstract**

In the paper some modification of 3D processing algorithms has been presented. At first effective and robust noise reduction in three dimensional measurement data algorithm has been presented. Often the noise source are optical elements from the 3D scanner. This noise commonly is the separate groups of points with high amplitude or single points with low amplitude. Main idea of applied algorithm depends on maximize distance – distance between points in three dimensional space – nearest neighbours in sliding 3D window. The proposed filter class is based on the nonparametric estimation of the density probability function in a sliding filter window. Next the modification of decimation algorithm has been presented. Main idea of proposed algorithm depends on adding a priori decimation level – number of the data points, which must be deleted from the dataset.

**Keywords:** 3D processing algorithms, noise reduction, decimation**1. Wstęp**

Rozwój technik akwizycji obrazów 3D jak również zastosowania praktyczne zwiększyły zainteresowanie technikami przetwarzania takich obrazów. Szerokie zastosowania skanerów 3D powodują potrzebę poszukiwania nowych rozwiązań, mających na celu optymalizację procesów zarówno pozyskiwania danych, jak również analizy tych danych w ściśle określonym celu, tj. począwszy od inżynierii odwrotnej, zarówno w układach przemysłowych, medycynie jak i architekturze, a kończąc na

generowaniu modeli obiektów 3D dla zastosowań multimedialnych. Narzędziem akwizycji danych 3D wykorzystanym w opisanych badaniach był skaner zaliczany do bezdotykowych systemów pomiaru kształtu opierającego się na metodzie projekcji strukturalnego światła białego [1]. Skaner wykorzystuje jedną z wielu optycznych metod stosowanych w pomiarach kształtu obiektów rzeczywistych. Zastosowanie tej techniki znacznie przyspiesza proces akwizycji danych 3D w stosunku do metod wykorzystujących światło lasera. Przewaga ta wynika z faktu generowania prążków na całej widocznej dla detektora powierzchni obiektu, a nie jak przy pomiarze punktowym, bądź liniowym z wykorzystaniem promienia światła pochodzącego z lasera.

Obraz 3D jest zbiorem punktów pomiarowych, z których każdy opisany jest przez trzy współrzędne  $[x,y,z]$  zwany również w literaturze chmurą punktów. Zbiór punktów pozyskany z wykorzystaniem techniki światła strukturyzowanego posiada kilka negatywnych cech, które powodują konieczność stosowania metod przetwarzania wstępnego. Do tych cech należy zaliczyć nieodpowiednio wyliczone punkty, szumy pomiarowe, czy też znaczną liczbę samych danych w zbiorze – obrazie 3D. Nieodpowiednio wyliczone punkty powstają wskutek niedokładności metod numerycznych, których zadaniem jest konwersja obrazu prążkowego na określone wartości współrzędnych  $[x,y,z]$ . Szum pomiarowy spowodowany jest najczęściej przez chwilową zmianę warunków w ośrodku pomiarowym, w którym umieszczony jest obiekt rzeczywisty, np. wprowadzenie dodatkowego źródła światła, zakłócającego odbiór obrazów prążkowych przez detektor. Zmiana warunków powoduje powstawanie w zbiorze właściwym grup błędnych punktów. Natomiast znacząca liczba zmierzonych punktów ma bezpośredni wpływ w głównej mierze na szybkość dalszych procesów przetwarzania, jak również na jakość rezultatów dalszej analizy. Zmniejszenie rozmiaru zbioru niesie ze sobą ryzyko utraty ważnych informacji dotyczących rzeczywistego obiektu, jednocześnie pozostawienie zbioru w oryginalnym rozmiarze często może powodować trudności w zarządzaniu takim zbiorem za pomocą odpowiednich narzędzi programistycznych. Z tego względu przed przystąpieniem do dalszej analizy należy ocenić stosunek rozmiaru zbioru punktów do jakości.

Zaprezentowane powyżej negatywne cechy tak pozyskanych obrazów 3D mają bezpośredni wpływ na zmianę wyników analizy na dalszym etapie. Z tego względu stosuje się algorytmy redukcji szumów pomiarowych, jak również decymacji zbioru punktów.


**2. Redukcja szumów pomiarowych**

Głównym celem redukcji szumów poprzez metody filtracji oraz wygładzania zbioru danych jest poprawa jego jakości, a tym samym wydobycie szeregu informacji ważnych z punktu widzenia użytkownika, np. krawędzi obiektów, powierzchni, tekstury. Filtry 3D definiuje się jako operator przekształcający zbiór oryginalny w zbiór wynikowy według znanej funkcji  $f$  [2]:

$$b(x, y, z) = f(a(x, y, z)) \quad (1)$$

Wiele filtrów operujących na zbiorach 3D analogicznie do filtrów obrazów barwnych 2D wykorzystuje zależność tzw. sąsiedztwa – każdy punkt zbioru jest modyfikowany z wykorzystaniem informacji o punktach najbliższych. Dla zbiorów danych regularnych punkty te wyznaczone są na podstawie tzw. maski, np.:  $3 \times 3 \times 3$ , natomiast dla zbiorów danych

nieregularnych na podstawie sfery, której centrum znajduje się w punkcie aktualnie analizowanym.



Rys.1. Algorytm filtracji dla danych nieregularnych  
Fig.1. Noise reduction algorithm for irregularly data

Wokół punktu centralnego powstaje sfera o promieniu  $R$ . Na nową wartość punktu centralnego mają wpływ tylko punkty znajdujące się wewnątrz sfery.

Procedury filtracji dzieli się na dwie klasy: liniowe oraz nieliniowe. Efektywniejszą poprawę jakości obrazów 3D uzyskuje się za pomocą filtrów nieliniowych, głównie dzięki mniejszemu zniekształcaniu krawędzi obiektów, jak również większej redukcji szumu impulsowego. Z tego względu swoją uwagę autor skupił na metodach filtracji nieliniowej. Dokonano analizy m.in. metod opartych na medianie wektorowej, jak również wykorzystujących obliczanie dystansu Hausdorffa [1,3], czy też filtrów dolnoprzepustowych [4]. Metody te powodują redukcję głównie szumu impulsowego o wysokiej amplitudzie – w obrazie 3D są to grupy punktów znacznie oddalone od głównego obiektu. Natomiast w przypadku szumu o małej amplitudzie wykorzystuje się metody wygładzania, np. oparte na dopasowaniu płaszczyzny zbioru punktów. Inną grupą metod filtracji są metody operujące na siatce-powierzchni [5, 6, 7] utworzonej z wykorzystaniem procedury triangulacji zbioru punktów 3D, w przeciwieństwie do metod operujących bezpośrednio na punktach zbioru.

Najpopularniejszą grupą stosowanych procedur nieliniowych są filtry oparte na medianie, głównie ze względu na efektywną redukcję szumu impulsowego. Filtry te należą do klasy opartej na statystykach porządkowych, tzw. order statistics. Do statystyk tych zalicza się marginal ordering, conditional ordering, partial ordering oraz reduced ordering [8]. Statystyki te mogą być stosowane do szeregowania dowolnych sygnałów wielowymiarowych. Jednakże, schemat szeregowania, który jest atrakcyjny dla potrzeb przetwarzania zbiorów danych 2D oraz 3D, powinien spełniać pewne kryteria, z których najważniejsze jest następujące: schemat szeregowania powinien uwzględniać typ wielowymiarowych danych. Z tego względu powinien uwzględniać ważne informacje jednakowo dla wszystkich wartości wektora opisującego punkt w zbiorze danych. Algorytmy oparte na medianie charakteryzują się dobrą efektywnością oraz niską złożonością obliczeniową, dzięki czemu ich zastosowanie dla danych trójwymiarowych jest możliwe.

Inne podejście do redukcji szumu opiera się na wycieceniu dystansu Hausdorffa [3]. Metoda ta opiera się na podziale zbioru punktów na homogeniczne podzbiory, które oddalone są od siebie o odległość Hausdorffa. Metoda ta efektywnie usuwa grupy punktów znacznie oddalone od zbioru głównego, jak również pojedyncze punkty znajdujące się w małej odległości od zbioru głównego.

## 2.1. Filtracja nieparametryczna

Omówione filtry nieliniowe, jak również inne w dobrym stopniu redukują szum ze zbioru punktów 3D, jednakże nie usuwają go bez szkody dla samych danych. Następuje efekt rozmycia objawiający się uszkodzeniami ważnych szczegółów, t.j. krawędzi obiektów. Naturalnym jest poszukiwanie innych metod, algorytmów pozwalających zwiększyć efektywność

redukcji szumów pomiarowych. Uwzględniając charakter szumów pomiarowych w zbiorach danych 3D – szumy impulsowe o wysokiej amplitudzie, jak również szumy o małej amplitudzie autor zaproponował wykorzystanie estymacji nieparametrycznej [9], która w powiązaniu z adaptacyjnym współczynnikiem wygładzania funkcji gęstości pozwala na efektywną redukcję szumów, jednocześnie pełniąc funkcję filtra wygładzającego. Estymator Parzena funkcji gęstości prawdopodobieństwa z funkcją jądra w postaci funkcji Gaussa opisany jest następującym równaniem

$$p_N(\mathbf{x}, h) = \frac{1}{N(h\sqrt{2\pi})^m} \sum_{i=1}^N \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}_i\|^2}{2h^2}\right) \quad (2)$$

gdzie  $N$  oznacza liczbę danych objętych oknem pomiarowym (dla 3D – sferą),  $h$  jest aktualnym współczynnikiem wygładzającym,  $m$  określa wymiar danych (dla danych 3D,  $m=3$ ),  $\|\cdot\|$  określa dystans pomiędzy punktami  $\mathbf{x}$  oraz  $\mathbf{x}_i$  w przestrzeni 3D obliczany jako pierwiastek sumy kwadratów współrzędnych  $[x,y,z]$ .

Stosowane współczynniki wygładzania wyznaczone są adaptacyjnie w każdym oknie pomiarowym niezależnie, lub przyjmują stałą wartość liczbową dla wszystkich kolejnych okien pomiarowych. Współczynniki opisane są następującymi równaniami

$$h = C \sqrt{\frac{1}{mN} \sum_{i=1}^N \|x_i^* - x_i\|^2} \quad (3)$$

$$h = C \sigma N^{-\frac{1}{m+4}} \quad (4)$$

gdzie  $C$  jest współczynnikiem kształtu,  $m$  określa wymiar danych (dla 3D,  $m=3$ ),  $N$  oznacza liczbę danych objętych oknem pomiarowym,  $x_j^*$  określa punkt, którego odległość do punktu centralnego jest minimalna spośród wszystkich punktów w danym oknie pomiarowym,  $x_i$  jest punktem centralnym,  $\sigma$  jest odchyleniem standardowym.

## 2.2. Proponowana modyfikacja

Biorąc pod uwagę okno filtracji  $W$  zawierające  $N$  punktów  $\{x_1, \dots, x_N\}$  definiuje się funkcję podobieństwa  $\mu: [0, \infty) \rightarrow \mathfrak{R}$  spełniającą następujące warunki  $\mu(0) = 1$ ,  $\mu(\infty) = 0$ . Podobieństwo pomiędzy punktami o identycznych wartościach powinno wynosić 1, natomiast o wartościach znacznie różniących się, podobieństwo dąży do 0. Definiuje się skumulowaną sumę podobieństw  $M$  pomiędzy punktem centralnym okna filtracji, a wszystkimi pozostałymi w oknie filtracji. Dla punktu centralnego funkcja ta zdefiniowana jest poprzez  $M_1$ , dla pozostałych punktów przez  $M_k$ .

$$M_1 = \sum_{j=2}^N \mu(x_i, x_j), \quad (5)$$

$$M_k = \sum_{j=2, j \neq k}^N \mu(x_k, x_j), \quad k > 1$$

Taka postać funkcji (5) oznacza pominięcie podczas sumowania funkcji podobieństw sąsiadów punktu  $x_1$  funkcji podobieństwa pomiędzy  $x_k$ , a  $x_1$ . Postępowanie takie podyktowane jest założeniem *a priori*, że punkt  $x_1$  jest obciążony szumem.

Takie działanie pociąga za sobą również zmniejszenie nakładów obliczeniowych. Punkt centralny  $x_1$  w oknie filtracji  $W$  jest zastępowany przez jeden z sąsiednich punktów tylko w przypadku, gdy  $M_1 < M_k$ ,  $k = 2, \dots, N$ . Funkcje  $\mu$  w równaniu (5) obliczane są na podstawie estymatora Parzena funkcji gęstości prawdopodobieństwa opisanego równaniem (2). Większa wartość funkcji podobieństwa  $M$  punktu oznacza większe podobieństwo punktu w stosunku do jego sąsiadów, stąd naturalnym staje się stwierdzenie: punkt centralny okna filtracji  $x_1$  jest zastępowany przez ten punkt sąsiedni, który posiada maksymalną wartość funkcji podobieństwa, jednocześnie większą od funkcji podobieństwa punktu centralnego. Wprowadzona w ten sposób modyfikacja umożliwia poprawę efektywności redukcji szumu poprzez zmniejszenie nakładów obliczeniowych, jak również poprawę jakości obrazów 3D.

### 3. Decymacja zbioru punktów 3D

Drugą grupą omawianych algorytmów przetwarzania obrazów 3D jest decymacja, tzw. upraszczanie obrazów 3D. Autor prezentuje możliwości stosowania tej grupy metod do generowania poziomów dokładności (ang. Level of Detail), które stosowane są dla celów optymalizacji procesu dalszego przetwarzania obrazów 3D. Algorytm sprawdza dystans pomiędzy kolejnymi punktami pomiarowymi znajdującymi się w badanym oknie pomiarowym. W wyniku jego działania uzyskuje się zmniejszenie procentowe liczby punktów pomiarowych w obrazie oraz zwiększenie regularności występowania punktów.

Rozmiar pozyskanych danych, obok szumu pomiarowego jest czynnikiem w znacznym stopniu wpływającym na procedury dalszej analizy. Proces powodujący zmniejszenie rozmiaru zbioru punktów, czyli decymacja zbioru jest procesem *stratnym*. Konsekwencją stosowania decymacji jest utrata części informacji dotyczącej obiektów w zbiorze punktów, np. krawędzie obiektów. Z tego względu powstało dotychczas wiele rozwiązań, które skupiają się na zmniejszeniu ingerencji w zbiór punktów, jednakże ich głównym celem jest zmniejszenie zbioru punktów powodujące znaczne zmniejszenie nakładów obliczeniowych podczas dalszej analizy.

Sitnik [1] zaproponował metodę homogeniczną oraz adaptacyjną upraszczania zbioru punktów. Metoda homogeniczna polega na usuwaniu punktów zbioru, których dystans do punktu centralnego sfery jest mniejszy od zadanego progu  $d_h$ . W pierwszej kolejności wszystkie punkty zbioru oznaczone są jako nieobliczone. Kolejno wybiera się nieobliczony punkt  $p_c$ , dla którego szukane są punkty nieobliczone o dystansie mniejszym niż  $d_h$ . Dla każdego z tych punktów szukane są kolejne punkty nieobliczone, tym razem o dystansie nie mniejszym niż  $2 \cdot d_h$ . Jeżeli takie punkty nie istnieją w zbiorze punktów wówczas punkt  $p_c$  jest zaznaczany jako skończony. Ostatnim krokiem algorytmu jest usunięcie zaznaczonych punktów.

Innym podejściem jest podział przestrzeni na jednakowe komórki – sześciiany [10]. Wyniki tej metody są bardzo podobne do wyników metody homogenicznej. Dla każdej komórki oblicza się średnią z punktów znajdujących się w komórce, a następnie usuwa się wszystkie punkty i zastępuje przez jeden punkt. Metoda ta jednak wprowadza do zbioru punktów nowy punkt. Modyfikacją tej metody jest wybór nie punktu wynikającego z uśredniania punktów należących do komórki, a punktu znajdującego się najbliżej punktu średniego. Ten punkt wówczas traktowany jest jako reprezentant wszystkich punktów należących do komórki.

Powyższe metody decymacji zbioru punktów pomimo wielu posiadanych zalet, m.in. niskie nakłady obliczeniowe, uwzględnianie informacji lokalnej o kształcie obiektów w przypadku metod adaptacyjnych, nie pozwalają na zadanie wartości tzw. stopnia decymacji, który został wprowadzony przez autora. Stopień decymacji definiuje procentowo liczbę punktów


zbioru, która powinna zostać usunięta ze zbioru, np.  $S$  na poziomie 70% równoważny jest usunięciu ze zbioru wejściowego 70% punktów. Algorytm wykorzystujący stopień decymacji opiera się na zasadzie upraszczania homogenicznego, jednakże redukcja punktów zbioru w danym oknie pomiarowym następuje po uwzględnieniu stopnia decymacji, jak również liczby dotychczas usuniętych punktów zbioru. W efekcie uzyskuje się kontrolę nad globalną decymacją zbioru. Wprowadzenie stopnia decymacji umożliwia kontrolę nad rozdzielczością zbioru punktów, konsekwencją czego jest możliwość generowania podzbiorów zbioru wejściowego o różnej wartości  $S$ . W zależności od wymagań dalszej analizy użytkownik decyduje w jakim stopniu zbiór wejściowy powinien zostać uproszczony.

### 4. Przykładowe rezultaty


Badaniom pod kątem redukcji szumu poddano obrazy 3D zarówno rzeczywiste pozyskane za pomocą skanera światła strukturyzowanego, jak również obrazy wygenerowane programowo – szum pomiarowy dla tych obrazów również został wygenerowany programowo. Wprowadzono ustawiany manualnie, jak i adaptacyjnie współczynnik wygładzania  $h$ . Porównano osiągnięte wyniki z omawianymi metodami.

Na rys.2 prezentuje się rzeczywisty obraz 3D przed (rys.2a) i po redukcji szumu pomiarowego (rys.2b). Dla tego obrazu zastosowano adaptacyjny współczynnik wygładzania. Redukcji uległy głównie grupy punktów znajdujące się w znacznej odległości od obiektu głównego. Jednakże uzyskano również poprawę jakości obiektu poprzez usunięcie pojedynczych błędnych punktów stanowiących szum pomiarowy.

a)



b)

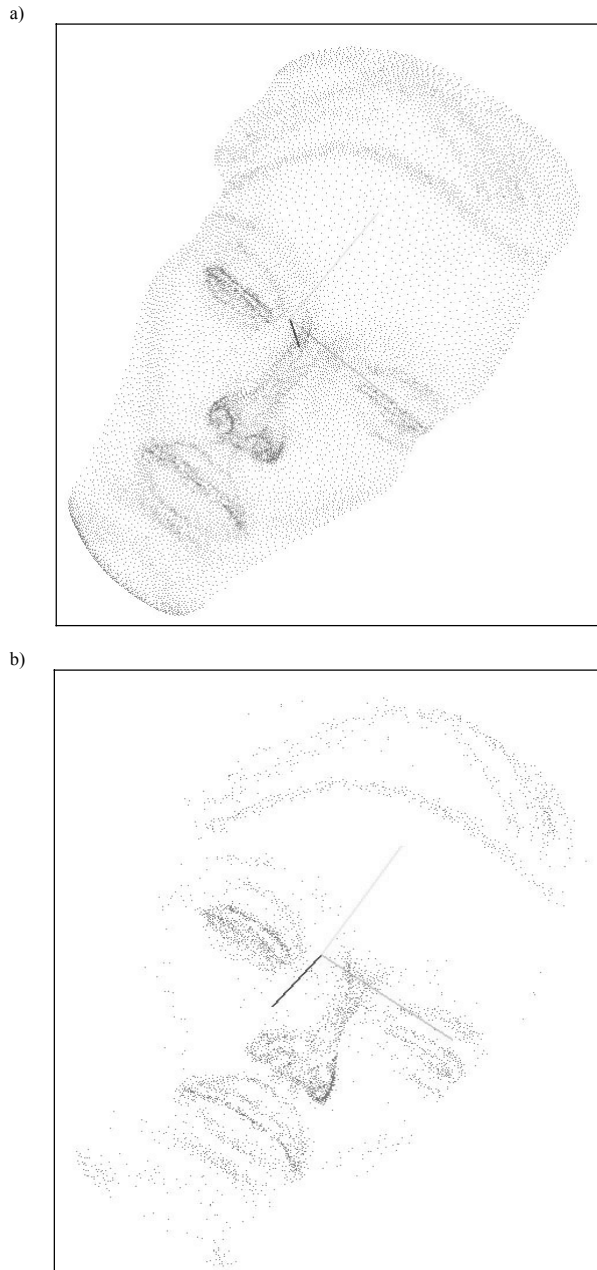


Rys.2. Redukcja szumu pomiarowego. (a) – obraz oryginalny – 41938 punktów, (b) – obraz po filtracji – 35067 punktów

Fig.2. Noise reduction algorithm. (a) – original image – 41938 points, (b) – image after filtration – 35067 points

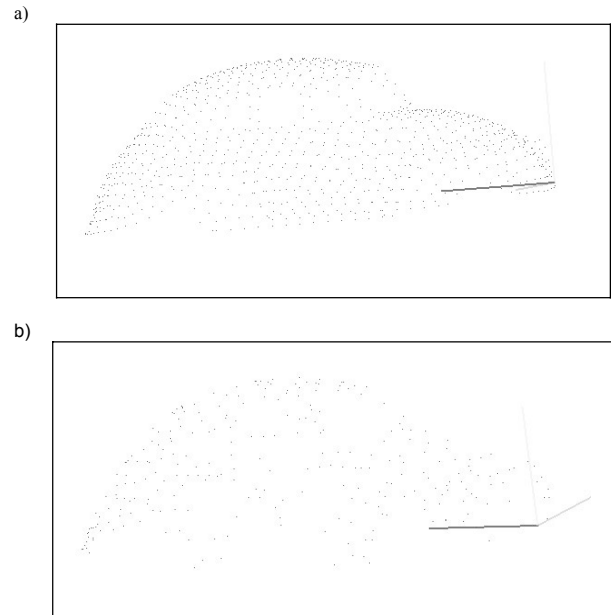
Badania w zakresie decymacji obrazów 3D wykonano na rzeczywistych obrazach. Wprowadzenie stopnia decymacji nie

powoduje pogorszenia jakości decymacji, jednocześnie umożliwiając kontrolę nad stopniem upraszczania. W metodzie homogenicznej [1], jak i innych omówionych istnieje możliwość określenia stopnia decymacji, jednakże jest to możliwe dopiero po zakończeniu procesu. Rys.3. prezentuje obraz 3D poddany upraszczaniu ze stopniem decymacji  $S$  wynoszącym 35%. Zaproponowana modyfikacja znalazła zastosowanie podczas badań autora poruszających problematykę detekcji powierzchni parametrycznych ze zbioru punktów 3D. Klasa powierzchni została ograniczona do tzw. prymitywów (płaszczyzna, kula, sfera, walec). Z tego względu podczas analizy nie wymaga się korzystania z całego dostępnego zbioru punktów, a jedynie ze zbioru poddanego decymacji.



Rys.3. Decymacja obrazu 3D. (a) oryginalny obraz – 15011 punktów, (b) – obraz po decymacji – 10755 punktów  
Fig.3. 3D image decimation. (a) – original image – 15011 points, (b) – image after decimation – 10755 points

Rys. 4b. prezentuje wynik upraszczania ze stopniem decymacji  $S$  wynoszącym 28%. Taka wartość stopnia decymacji dla obiektu z rys.4a. powoduje utratę informacji o kształcie obiektu, jak również wprowadza znaczącą nieregularność punktów.



Rys.4. Decymacja obrazu 3D. (a) oryginalny obraz – 988 punktów, (b) – obraz po decymacji – 270 punktów  
Fig.4. 3D image decimation. (a) – original image – 988 points, (b) – image after decimation – 270 points

## 5. Podsumowanie

W artykule zaprezentowano dwie grupy algorytmów przetwarzania obrazów 3D. Omówiono szczegółowo istniejące rozwiązania w zakresie redukcji szumów pomiarowych, jak również decymacji obrazów 3D. Zaproponowane rozwiązania wprowadziły poprawę jakości efektów działania metod przetwarzania obrazów 3D, nie tylko poprzez poprawę jakości obrazu wynikowego, ale również poprzez zmniejszenie nakładów obliczeniowych. W rozdziale 4 zaprezentowano przykładowe obrazy 3D po zastosowaniu wymienionych modyfikacji, jak również zaprezentowano efekty nieodpowiedniego doboru stopnia decymacji dla metod upraszczania obrazów 3D.

## 6. Literatura

- [1] R. Sitnik: A Fully automatic 3D shape measurement system with data export for engineering and multimedia systems. Politechnika Warszawska, Warszawa, 2002
- [2] N. Nikolaidis, I.Pitas: 3-D image processing algorithms. John Wiley & Sons, Inc. 2001
- [3] G. Rote: Computing the minimum hausdorff distance between two point sets on a line under translation. Information Processing Letters 38(1991), 123-127, 1991
- [4] L. Linsen: point cloud representation. Tech. Rep. 2001-3. Universitaet Karlsruhe, 2001
- [5] B. Menderos, L. Velho, L.H. de Figueiredo: Smooth surface reconstruction from noisy clouds. Journal of the Brazilian Computing Society 2004
- [6] P. Perona, J. Malik: Scale-space and edge detection using anisotropic diffusion. IEEE Trans. on Pattern Analysis and Machine Intelligence, vol.12, no. 9, pp. 629-639, 1990
- [7] M. Alexa, J. Behr, D. Cohen-Or, S. Fleishman, C.T. Silva: Point set surfaces. IEEE Visualization 2001, 21-28, 2001
- [8] S. Budzan: On the nonparametric noise reduction in color images. Zeszyty Naukowe Politechniki Śląskiej, seria: Automatyka z.138, Gliwice, 2003
- [9] B.W. Silverman: Density Estimation for Statistics and Data Analysis. Chapman and Hall, London, 1986
- [10] J. Rossignac, P. Borrel: Multiresolution 3D approximations for rendering complex scenes. Modeling in Computer Graphics: Methods and Applications, 1993