

Łukasz Jopek*, Laurent Babout**, Marcin Janaszewski*, Michał Postolski*

Nowa metoda segmentacji obrazów stopów tytanowych wykonanych za pomocą tomografii rentgenowskiej, wykorzystująca transformatę *contourlet*


1. Wprowadzenie

Stopy tytanowe o strukturze krystalicznej [1, 2] znajdują szerokie zastosowanie w przemyśle, na przykład energetycznym, czy w aeronautyce, jak również technice biomedycznej. Zawdzięczają to swoim unikatowym właściwościom, takim jak wysoka odporność na odkształcenia mechaniczne czy korozję, którą łączą się ze stosunkowo niską gęstością. Własności te są ściśle związane z budową wewnętrzną tego materiału, dlatego bardzo istotne jest jej poznanie. Szczególnie ważne wydaje się poznanie zależności między propagacją pęknięcia wewnątrz materiału z jego wewnętrzną strukturą. Niniejsze badania prowadzone są przy wykorzystaniu Europejskiego synchrotronu (*European Synchrotron Radiation Facility* – ESRF), dzięki któremu możliwe stało się uzyskanie obrazów techniką mikrotomografii rentgenowskiej. Oryginalnie obrazy są trójwymiarowe, lecz w artykule skupiono się na obrazach dwuwymiarowych, gdyż są prostsze w analizie. Wynika to też z faktu, iż wiele metod przetwarzania obrazów opracowanych zostało właśnie dla obrazów 2D. W badaniach wykorzystano też dwuwymiarowe obrazy uzyskane za pomocą mikroskopu optycznego, dlatego iż technika ta pozwala na uzyskanie obrazów mikrostruktur o wyższym kontraście i mniejszej zawartości szumów niż w przypadku tomografii rentgenowskiej. Niestety obrazy uzyskane za pomocą mikroskopu pozwalają uzyskać tylko obraz powierzchni zewnętrznych materiału. Zatem ostatecznie należy skupić się na trudniejszych, lecz pozwalających zbadać strukturę wewnętrzną, trójwymiarowych obrazach tomograficznych. Na obu typach obrazów można wyróżnić, w zasadzie dwa typy struktur: kolonie α -płatków (kolonie α -lamellar) oraz β -ziarna (β -grain); β -ziarna (rys. 1) mogą być scharakteryzowane jako pojedyncze krzywe, często o zmiennym kierunku, o stosunkowo dużej grubości. W przypadku obrazów optycznych są z reguły jaśniejsze od innych elementów

* Katedra Informatyki Stosowanej Politechniki Łódzkiej, Katedra Systemów Ekspertowych i Sztucznej Inteligencji Wyższej Szkoły Informatyki w Łodzi

** Katedra Informatyki Stosowanej Politechniki Łódzkiej

mikrostruktury, a w przypadku obrazów tomograficznych zazwyczaj są ciemniejsze, często praktycznie czarne. Kolonie α -płatków (rys. 1) mogą być opisane jako obszary zawierające grupy linii (krzywych), mających orientację kierunkową. Każda kolonia α -płatków zawiera grupy linii o podobnej orientacji kierunkowej, choć rozrzut kierunku w jednej kolonii może dochodzić nawet do kilkunastu stopni. Oprócz tego, kolonie α -płatków mogą być charakteryzowane za pomocą rozrzutu jasności linii i „tła” (obszaru pomiędzy liniami). Rozrzut ten może być albo mały, i wtedy linie oraz tło mają podobną jasność (gdyż rozważane są obrazy w skali szarości), albo duży, i wtedy linie i tło znacznie różnią się od siebie jasnością. Linie mogą być zarówno jaśniejsze, jak i ciemniejsze od tła. Zatem kolonie α -płatków podlegają segmentacji względem dwóch kryteriów: orientacji kierunkowej oraz rozrzutu jasności. Problem segmentacji kolonii α -płatków na podstawie rozrzutu jasności pikseli został już rozwiązany w [3], dzięki wykorzystaniu parametru obrazu, jakim jest wariancja lokalnego histogramu. Trudniejszym zadaniem jest segmentacja kolonii α -płatków pod względem ich orientacji kierunkowej.



Rys. 1. Przykład obrazów stopów tytanowych – obraz uzyskany za pomocą tomografii rentgenowskiej

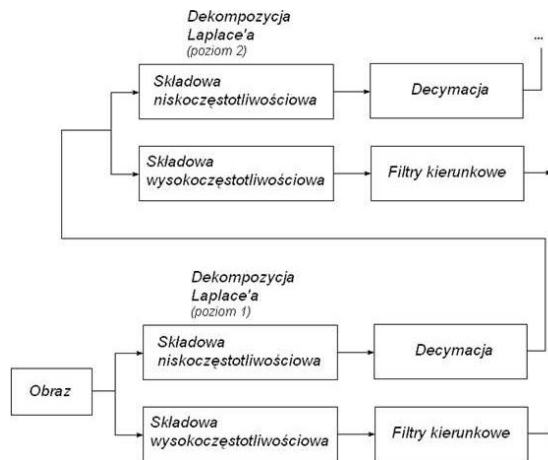
Pierwszą zaproponowaną metodą była metoda wykorzystująca transformatę falkową [3], a ściślej dekompozycję falkową, ponieważ poszczególne komponenty takiej dekompozycji wrażliwe były na różne składowe kierunkowe obrazu. W ten sposób uzyskać można było podział obrazu na dwie klasy kierunkowe: poziomą i pionową. W przypadku obrazów optycznych uzyskano stosunkową dobrą separację kolonii o orientacji zbliżonej do poziomej i pionowej. W przypadku obrazów tomograficznych podział ten realizowany był dużo

gorzej, zarówno czułość metody, rozumiana jako zdolność do wykrywania kierunkowości obiektów na obrazie, jak i selektywność rozumiana jako przypisanie obiektowi jednego kierunku, zgodnej z jego rzeczywistą orientacją – były niewystarczające. Drugim problemem było to, że dwa możliwe do wykrycia kierunki są liczbą niewystarczającą. Kolejne rozwiązanie opierało się na wykorzystaniu macierzy zdarzeń [4] i macierzy pasm [4]. Metody te teoretycznie pozwalały na wykrywanie obiektów o czterech kierunkach (0, 45, 90 i 135 stopni). Selektywność metody była lepsza niż w poprzednim wypadku, czułość także, co widoczne było w szczególności w przypadku obrazów tomograficznych, jednak w dalszym ciągu były niewystarczające. Nadal nie wszystkie kolonie widoczne na obrazie były separowane, część kolonii było identyfikowanych błędnie. Inne podejście do problemu zostało zaproponowane w [5]. Wprawdzie rozważane tam materiały, a co za tym idzie, także ich obrazy, różniły się od zaprezentowanych w niniejszym artykule, to jednak stopień podobieństwa był dosyć wysoki. Zaproponowana tam metoda wykorzystywała gradient jasności pikseli. Pozwalało to na pomiar lokalnego kierunku struktur tworzących teksturę obrazu. Wykorzystując ten fakt, opracowano [6] algorytm segmentacji dla rozważanych tutaj obrazów. Do przypisania pikseli do konkretnych klas wykorzystywany był klasyfikator k -NN. Zbiór uczący tworzony był automatycznie, za pomocą algorytmu grupowania k -średnich. Uzyskane wyniki okazały się być najlepsze spośród wszystkich, przytaczanych wcześniej metod. Jednak, w dalszym ciągu nie wszystkie kolonie były identyfikowane poprawnie. Nadal część z nich przypisywana była do niewłaściwych klas lub kształt wykrytych koloni nie był zgodny z rzeczywistością. Problemy dotyczyły zwłaszcza obrazów 3D. Problemem w dalszym ciągu są czułość i selektywność detektora kierunku. Względnie wysoką czułość uzyskano w przypadku wykorzystania dekompozycji falkowej, choć tu problemem okazała się niewystarczająca selektywność. Problem ten rozwiązuje dekompozycja typu *contourlet* [7–9]. Jest to metoda, w której dekompozycja ma o wiele więcej komponentów niż w przypadku standardowego schematu dekompozycji falkowej, co, jak się okazuje, rozwiązuje problem selektywności, przy utrzymaniu wysokiej czułości. Artykuł prezentuje metodę służącą do segmentacji obrazów stopów tytanowych, wykorzystującą w roli detektora kierunku dekompozycję *contourlet*. W rozdziale drugim przedstawiono ideę transformaty *contourlet*, w rozdziale trzecim zaprezentowany został algorytm segmentacji, następny rozdział prezentuje uzyskane wyniki, porównanie z poprzednimi rozwiązaniami oraz dyskusje. Ostatni rozdział to propozycje dalszych badań, w tym budowy algorytmu służącego do segmentacji obrazów 3D.

2. Transformata *contourlet*

Transformata *contourlet* (transformata konturkowa) jest uogólnieniem transformacji falkowej. Zasadniczą różnicą jest algorytm analizy i syntezy sygnału. W klasycznej dwuwymiarowej transformacji falkowej przestrzeń kątowna analizy obrazu jest ograniczona do trzech kierunków (pionowy, poziomy i ukośny). Transformata *contourlet* pozwala na taką parametryzację transformacji, aby na danym poziomie dekompozycji (w danej skali) rozszerzyć rozdzielczość kątowną do $2n$ liczby kierunków analizy, czyli np. pierwszy stopień

dekompozycji oferuje dwa komponenty kierunkowe, na drugim już cztery, na trzecim osiem komponentów, a na czwartych poziomie dekompozycji aż szesnaście. Rozszerzenie przestrzeni dekompozycji o wymiar kąta analizy dało możliwość pełniejszego opisu obiektów w transformowanym obrazie. Transformacja *contourlet* jest złożeniem analizy wielorozdzielczej przy użyciu piramidy Laplace'a (*Laplacian Pyramid Contourlet Transform*) z podziałem na każdym poziomie dekompozycji na poszczególne kierunki analizy z zastosowaniem filtrów kierunkowych lub bazującą na wielorozdzielczej dekompozycji falkowej (*Wavelet Based Contourlet Transform*). Zasadniczo, podobnie jak w przypadku standardowej transformaty falkowej, czy innych metod o nią opartych, jak np. *curvlet* [10] czy *ridgeret* [10, 11], Contourlet wykorzystywany jest do kompresji, odszumiania i poprawy jakości obrazów, w tej pracy jednak dekompozycje tej transformaty wykorzystano w roli detektora kierunku. Niezależnie od tego podziału, istnieje kilka odmian implementacyjnych tej metody [7]. Rysunek 2 ilustruje podstawowy schemat dekompozycji *contourlet*. W niniejszej pracy zastosowano metodę zwaną *Nonsubsampled Contourlet Transform* (NSCT) [7].




Rys. 2. Schemat dekompozycji *counturlet* na bazie piramidy Laplace'a [12]

2.1. *Nonsubsampled Contourlet Transform* (NSCT)

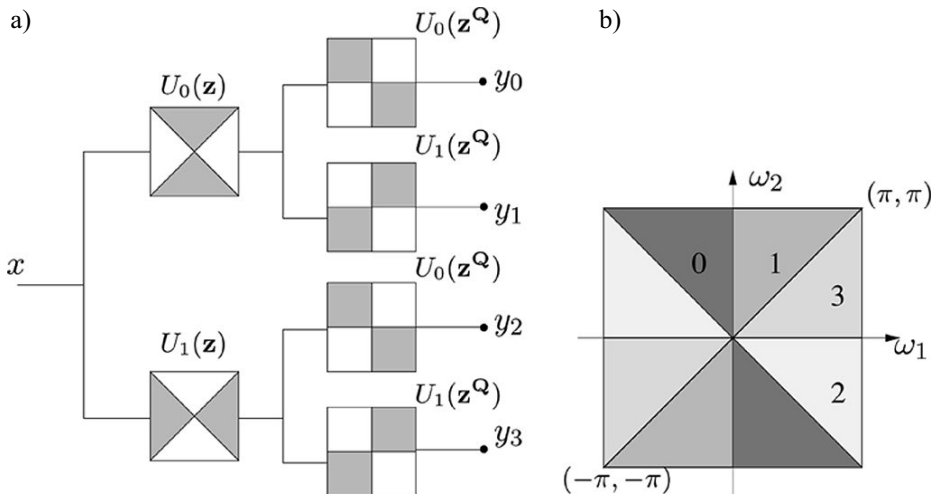
Jak wspomniano w poprzednim rozdziale transformata *contourlet* jest złożeniem analizy wielorozdzielczej przy użyciu piramidy Laplace'a z podziałem na każdym poziomie dekompozycji na poszczególne kierunki analizy z zastosowaniem filtrów kierunkowych.

Zazwyczaj, na każdym poziomie dekompozycji następuje decymacja ciągu próbek, czyli wybieranie co drugiej próbki (długość każdego ciągu zmniejsza się o połowę z dokładnością do jednej próbki ze względu na przypadek nieparzystej liczby próbek wejściowych). Jednak w przypadku NSCT niestosuje się decymacji. Może być to wadą w przypadku np. kompresji obrazów, ale nie stanowi problemu w przypadku zastosowania dekompozycji w roli detektora kierunku, co więcej, może okazać się zaletą, gdyż brak decymacji

oznacza, że podobrazy na każdym poziomie dekompozycji mają takie same rozmiary co obraz wejściowy. Ułatwia to powiązanie pikseli na podobrazach z pikselami obrazu wejściowego. Na potrzeby transformaty opracowano dwuwymiarowe banki filtrów kierunkowych (rys. 3) w celu zapewnienia kierunkowych właściwości transformacji. Obecnie istnieje cały szereg takich banków filtrów [7, 13]. Ideą tego rozwiązania był podział przestrzeni na określoną liczbę części w taki sposób, aby linie podziału znajdowały się w centralnym punkcie i wyznaczały kierunki. Dało to możliwość dyskretyzacji kąta linii podziału i tym samym zaadresowania danego kierunku na płaszczyźnie obrazu. W przypadku niniejszego problemu najbardziej korzystne okazało się zastosowanie *Nonsampled Directional Filter Bank* (NSDFB) [7]. Metoda ta polega na wygenerowaniu pary filtrów U_0 i U_1 , gdzie jeden to filtr dolnoprzepustowy, a drugi jest filtrem górnoprzepustowym. Każda taka para filtrów jest wrażliwa na inny kierunek. Schemat analizy obrazu z wykorzystaniem metody NSDFB przedstawiono na rysunku 4.



Rys. 3. Schemat banku filtrów kierunkowych [9]

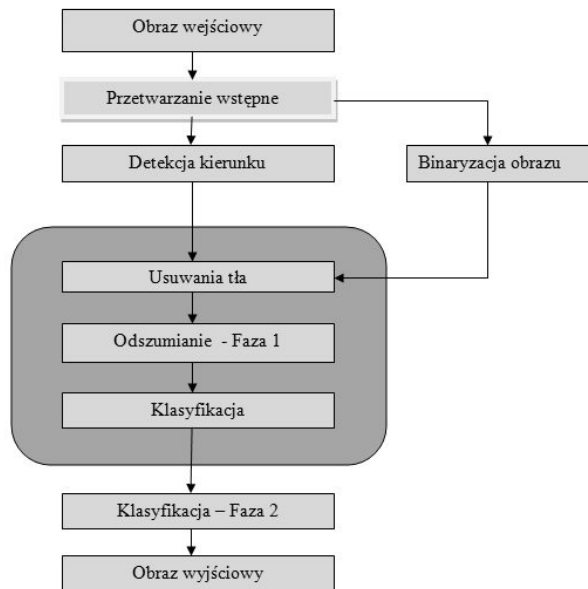


Rys. 4. Schemat dekompozycji obrazu *Directional Filter Bank* (NSDFB) [7]

Jak można zobaczyć na rysunku 4a, na pierwszym poziomie dekompozycji uzyskać można dwa komponenty kierunkowe, na kolejnym już cztery, trzeci poziom oferuje już ich osiem, a czwarty poziom szesnaście. Proces realizowany może być jako splot obrazu z odpowiedzią implusową filtru.

3. Algorytm segmentacji dwuwymiarowych obrazów stopów tytanowych wykonanych techniką tomografii rentgenowskiej, wykorzystujący transformatę *contourlet*

Zadaniem algorytmu jest segmentacja dwuwymiarowych obrazów stopów tytanowych, w której głównym kryterium klasyfikacji piksela do konkretnej klasy jest orientacja kierunkowa jego otoczenia. Jak wspomniano we wstępie, na rozważanych tutaj obrazach wyróżnić można dwa elementy tworzące strukturę materiału: β -ziarna oraz kolonie α -płatków. Segmentacji podlegać będą kolonie α -płatków. W roli detektora kierunku kolonii α -płatków wykorzystana zostanie opisana w poprzednim rozdziale transformata *contourlet*, jednak z uwagi na skomplikowany charakter obrazów algorytm służący do ich segmentacji jest złożony. W tym rozdziale zostaną omówione po kolei wszystkie jego główne elementy, a schemat blokowy przedstawiony został na rysunku 5.



Rys. 5. Schemat algorytmu segmentacji obrazów teksturowanych o charakterze kierunkowym

3.1. Przetwarzanie wstępne

Przetwarzanie wstępne obrazu ma na celu taką jego transformację, żeby stłumić pewne jego cechy, np. szum, a wzmacnić inne, np. kontrast. W przypadku tutaj rozważanych obrazów największym problemem jest wysoki poziom szumów (szczególnie w przypadku obrazów tomograficznych). Zredukowanie poziomu tych szumów można osiągnąć również poprzez zastosowanie algorytmów opartych na transformatach takich jak *wavelet*, *curvelet* czy *contourlet*, z adaptacyjnym doбором progów. W niniejszym algorytmie skorzystano z metody przedstawionej w pracy [7].

3.2. Detekcja kierunku

Proces detekcji kierunku jest sercem proponowanej metody. Proponowana metoda oparta jest na spostrzeżeniu, że każdy spośród filtrów kierunkowych, zawartych w banku filtrów NSDFB, reaguje na konkretne składowe kierunkowe, zawarte na obrazie. Specyfika tych filtrów pozwala na dokładne i selektywne wyznaczanie kierunku struktur zawartych w obrazie. Podstawowa metoda detekcji kierunku może być opisana za pomocą równania (1):

$$P_{i,j} = \arg \max (E_{k_{i,j}}) \quad (1)$$

gdzie:

- $P_{i,j}$ – piksel obrazu wyjściowego o współrzędnych i, j ,
- k – k -ty komponent dekompozycji,
- $E_{k_{i,j}}$ – wartość piksela o współrzędnych i, j w k -tym obrazie dekompozycji.

Ponieważ nie zachodzi tu proces decymacji, zatem dowolny komponent, na dowolnym poziomie dekompozycji ma taki sam rozmiar jak obraz wejściowy. Jest to więc obraz, który powstał w wyniku przefiltrowania obrazu oryginalnego przez szereg filtrów cyfrowych. Proces ten ma służyć wykrywaniu krawędzi o określonym kierunku. Jeśli na obrazie znajduje się taka krawędź, to zostanie ona wykryta w komponentach dekompozycji, które są wrażliwe na podobny kierunek. Najsilniej krawędź będzie widoczna w tym komponencie, który jest najbliższy pod względem wykrywanego kierunku. Etykieta komponentu będzie stanowiła informację o dominującym kierunku w otoczeniu piksela. Otoczenie to związane jest z rozmiarem użytych w dekompozycji filtrów. Wykryta krawędź będzie oznaczona za pomocą pikseli o najwyższych lub najniższych wartościach, piksele związane z kierunkami odleglejszymi od wykrywanego przez komponent będą miały wartości bliższe średniej wartości pikseli na obrazie. Wystarczy zatem znaleźć komponent o wartości maksymalnej (lub minimalnej), aby określić na podstawie etykiety komponentu, jaka jest dominująca kierunkowość jego otoczenia. W pracy zdecydowano się szukać wartości maksymalnej (1), jednak zastąpienie jej wartością minimalną daje taki sam efekt. Krawędź często oznaczona jest też jako krzywa zbudowana z pikseli o wysokich wartościach po jednej jej stronie i niskich po drugiej, można więc badać zamiast pojedynczego piksela, np. odchylenie standardowe pikseli w jego otoczeniu. Komponent, który będzie miał najwyższą jego wartość, będzie komponentem najbliższym pod względem wykrywanego kierunku.

3.3. Usuwanie tła

Dekompozycja *contourlet* potrafi wykryć krawędzie na obrazie. W przypadku kolonii α -płatków, wykrywane są krzywe je tworzące (rys. 1). Jeśli podzielić obraz na dwie klasy: obiekty i tło, to obiektami będą właśnie te krzywe, a tłem pozostałe piksele. Po zastosowaniu metody detekcji kierunku, opisanej w poprzednim rozdziale, obiekty oznaczone będą etykietami odpowiednich komponentów, podczas gdy tło będą stanowić w większości przypadkowe wartości. Ze względu na segmentację obrazów krystalicznych stopów tytanu, interesujące są obiekty, tło zaś nie niesie ze sobą istotnych informacji, można je zatem pominąć, a do klasyfikacji (segmentacji) użyć jedynie pikseli z obiektów. W zaproponowanym algorytmie usuwanie tła przebiega następująco: obraz oryginalny poddawany jest binaryzacji, elementy kolonii α -płatków i tła zostają przydzielone do osobnych klas. Następnie, po dokonaniu detekcji kierunku (na obrazie oryginalnym, nie binarnym) następuje druga faza. Polega na transformacji punktowej obrazu według poniższej reguły (2):

$$P_{i,j} = \begin{cases} In_{i,j} & \text{jeśli } B_{i,j} = 1 \\ 0 & \text{jeśli } B_{i,j} = 0 \end{cases} \quad (2)$$

gdzie:


$P_{i,j}$ – piksel obrazu wyjściowego o współrzędnych i, j ,

$In_{i,j}$ – piksel obrazu wejściowego współrzędnych i, j ,

$B_{i,j}$ – piksel obrazu binarnego o współrzędnych i, j , 1 – obiekt, 0 – tło.

3.4. Odszumianie


Piksele, które zostały zaklasyfikowane jako obiekty (2), mają wartości, będące w istocie kierunkiem struktury elementów kolonii α -płatków. Nie oznacza to jednak, że każdy piksel ma wartość poprawną. Należy przeprowadzić odszumianie obrazu, polegające na usunięciu pikseli o wartościach „niepasujących” do reszty. Idea jest podobna jak w przypadku filtrów medianowych, jednak takie filtry nie mogą być zastosowane z uwagi na specyfikę obrazu. Procesowi poddawane są jedynie piksele obiektów. Dla każdego piksela obiektu tworzony jest histogram z otaczającego go obszaru. Wielkość tego obszaru ustalana jest manualnie. Jest to okno o rozmiarze $W \times W$. W najprostszym przypadku piksel uzyskuje wartość tej klasy, która ma największą ilość przedstawicieli. Rysunek 6 pokazuje przykładowy histogram. Widać, że piksele o wartości 11 wyraźnie dominują nad pozostałymi, zatem badany piksel powinien mieć taką wartość. Eksperymentalnie ustalono, że taka metoda jest wystarczająca.



Rys. 6. Przykład histogramu z wartości pikseli obiektów, dla okna o rozmiarze 25×25 pikseli

3.5. Klasyfikacja – poziom 1

Klasyfikacja ta pod pewnymi względami przypomina odsumianie przedstawione w poprzednim paragrafie. Po odsumieniu obraz zawiera dwa elementy: obiekty będące elementami kolonii α -płatków, z przypisanymi etykietami klas, oraz tło, na które składają wszystkie, pozostałe piksele. Mają one przypisaną wartość zero. Klasyfikacja, w tym wypadku, sprowadza się do przypisania pikseli tła do odpowiednich klas, na podstawie ich otoczenia. Jeżeli dany piksel tła otoczony jest przez elementy (obiekty) tylko jednej klasy, to można przyjąć, że jest on zawarty wewnątrz danej kolonii. Ilustruje to rysunek 7a. Trudniejszym przypadkiem jest sytuacja, gdy piksel tła znajduje się w pobliżu obiektów, należących do różnych klas. Ilustrują to rysunki 7b i 7c. Tutaj można posłużyć się metodą odsumiania z poprzedniego paragrafu, tzn. dany piksel przypisać do najliczniej reprezentowanej klasy. Na rysunku 7d zobaczyć można efekt pracy tej metody.



Rys. 7. Przykłady pikseli tła poddawanych klasyfikacji (zostały oznaczone literą A)

Po klasyfikacji pikseli tła może zdarzyć się sytuacja, gdy wewnątrz danej kolonii pozostaną nadal pojedyncze piksele, niepasujące do reszty, będące pierwotnie elementami obiektów (linii tworzący kolonie). Można je usunąć albo za pomocą filtrów medianowych, albo stosując opisaną już metodę klasyfikacji tła, ale tym razem dla każdego piksela obrazu.


3.6. Odszumianie kontekstowe – klasyfikacja poziom drugi

Obraz uzyskany za pomocą opisanego algorytmu może nadal zawierać elementy niepożądane. Składają się na nie nieusunięte w procesie odszumiania i błędnie zaklasyfikowane piksele oraz elementy poprawnie sklasyfikowane ze względu na przetwarzanie obrazu, ale wymagające dalszej reklasyfikacji z uwagi na wiedzę o materiałach. Na tym etapie pikseli błędnie zaklasyfikowanych jest względnie niewiele, gdyż opisane wcześniej podejście usuwa przeważającą większość błędów. Ich pojawienie się jest związane albo z małą ilością (lub nawet brakiem) elementów tworzących kolonie α -płatków, lub elementy kolonii α -płatków nie mają wyraźniej kierunkowości. Na obrazie tworzą zwykle małe (do kilkudziesięciu pikseli) obszary. Przykład ilustruje rysunek 8, elementy oznaczone literą 'A'. Mogą znaleźć się wewnątrz danej kolonii lub też mogą stykać się z kilkoma naraz. Drugi problem to obszary, które wprawdzie zostały poprawnie sklasyfikowane, ale biorąc pod uwagę wiedzę o materiale, trzeba zmienić ich przynależność. Maksymalny rozmiar takich obszarów ustalany jest na przez eksperta z dziedziny materiałoznawstwa. Przykładem tego jest sytuacja, gdy wewnątrz danej kolonii α -płatków znajduje się inna kolonii α -płatków, ale jej rozmiar jest stosunkowo mały (jednak większy niż elementy związane z szumem). W takiej sytuacji należy postąpić według poniższych zaleceń:

- a) *Jeśli rozmiar kolonii jest niewielki i jej kierunek nie różni się istotnie od otaczającej kolonii, to należy taką kolonię włączyć do kolonii ją otaczającej.*
- b) *Jeśli rozmiar kolonii jest niewielki i jej kierunek różni się istotnie od otaczającej kolonii, to należy taką kolonię uznać za odrębną.*
- c) *Jeśli rozmiar kolonii jest duży, to należy taką kolonię uznać za odrębną.*

Reguły te przypominają reguły tworzące system ekspertowy. Choć w niniejszym rozwiązaniu autorzy nie zdecydowali się na razie na budowę takiego systemu, to w przypadku zwiększenia się liczby reguł rozważana jest taka możliwość. Należy pamiętać, że reguły te są ustalane przez ekspertów w dziedzinie materiałoznawstwa. Niektóre kolonie α -płatków są jednak otoczone przez więcej niż jedną kolonią α -płatków, a ich niewielkie rozmiary mogą wskazywać na potrzebę ich włączenia do kolonii z którymi są połączone. Tutaj zastosowanie znajduje następująca reguła:

- d) *Jeśli rozmiar kolonii jest niewielki oraz styka się z więcej niż jedną kolonią, to należy taką kolonię włączyć do kolonii, z którą jest najbardziej połączona oraz do której jest najbliższa pod względem kierunku.*



Rys. 8. Wynik segmentacji obrazu krystalicznego stopu tytanu. Kolonie oznaczone literą 'A' są zawarte całkowicie w innych koloniach, kolonie oznaczone 'B' są otoczone przez więcej niż jedną kolonię, obszary oznaczone literą 'C' są obszarami tworzonymi przez szum i błędy w klasyfikacji

Przez „najbardziej połączona” autorzy rozumieją największą liczbę pikseli znajdujących się na obwodzie kolonii, połączonych z daną kolonią za pomocą cztero- lub ośmiopołączeniowości. Ostatecznie algorytm klasyfikacji drugiego poziomu można przedstawić następująco:

Krok 0: Inicjalizacja – Współczynniki Thr1 i Thr2.

Krok 1: dokonaj binaryzacji obrazu posegmentowanego dla każdej klasy osobno. Powstaje w tej sposób N obrazów binarnych, gdzie N to liczba klas występujących na obrazie.

Krok 2: dla każdego obrazu wykonaj:

- a) labelizację wszystkich obiektów na obrazie;*
- b) usuń (przypisz do tła) wszystkie obiekty mniejsze niż Thr1;*
- c) jeśli obiekt jest większy od Thr1 i mniejszy niż Thr2, to przypisz do klasy najbardziej połączonej oraz najbliższej pod względem kierunku;*
- d) jeśli obiekt jest większy niż Thr2, to pozostaw bez zmian.*

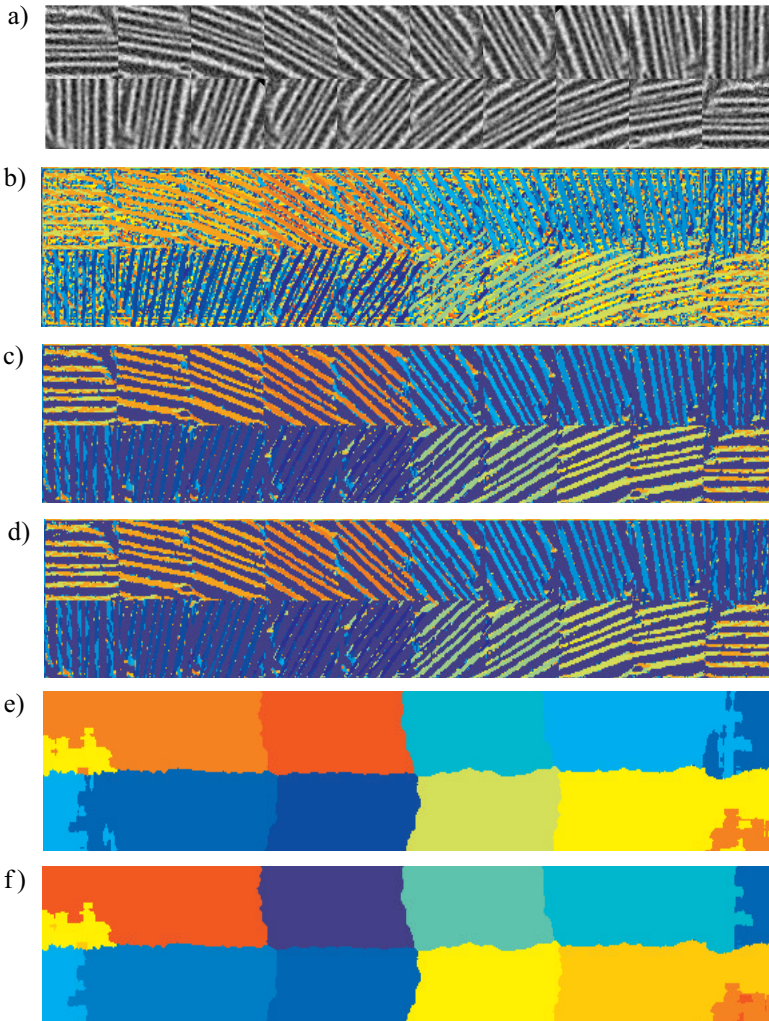
Krok 3: Scal obraz.

Pamiętajmy, że podane reguły mogą ulec zmianie.

4. Wyniki i wnioski

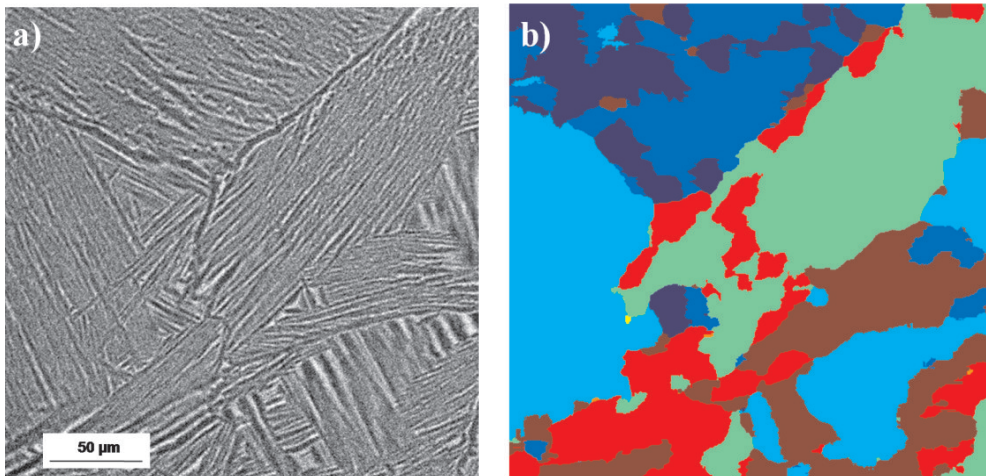
Rysunek 9 pokazuje wyniki pracy algorytmu dla sztucznie wygenerowanej tekstury. Tekstura ta została wygenerowana z użyciem oryginalnej tekstury tomograficznej. Rysunek 9b ukazuje wynik pracy detektora kierunku (1). Widać wyraźnie, że w miejscach występowania linii zaznaczone zostały obiekty o konkretnej orientacji kierunkowej. Pomiedzy nimi

występuje chaotyczne tło. Rysunek 9c ilustruje efekt usunięcia tła (2). Tutaj znaczenie ma rodzaj zastosowanego algorytmu progowania obrazu. Im lepsza metoda tym lepsza separacja pomiędzy obiektami a tłem. Dzięki temu na rysunku 9c piksele znajdujące się na obszarach zajmowanych na obrazie oryginalnym przez obiekty (kolonie α -płatków) zostały przypisane do klasy obiektów, a pozostałe do klasy tła. Rysunek 9d ukazuje efekt odsumiania, opisanego w podrozdziale 3.4. Rysunek 9e pokazuje efekt klasyfikacji pierwszego poziomu, a rysunek 9f efekt klasyfikacji drugiego poziomu.



Rys. 9. Kolejne etapy pracy algorytmu: a) oryginalny obraz; b) obraz po detekcji kierunku za pomocą dekompozycji *contourlet*; c) obraz po usunięciu tła; d) obraz po odsumianiu, e) obraz po klasyfikacji 1 stopnia; f) po klasyfikacji 2 stopnia

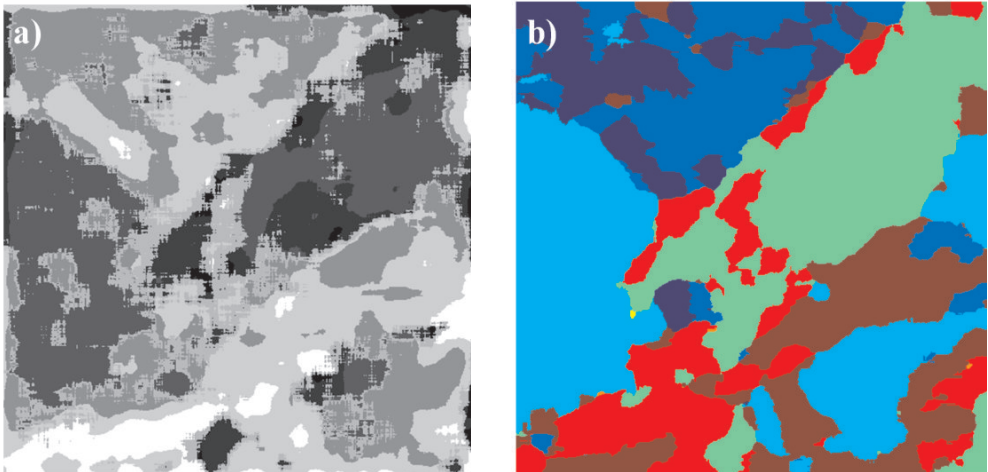
Rysunki 9e i 9f są prawie identyczne, gdyż występują na nich nieliczne elementy wymagające reklasyfikacji. Poszczególne klasy na obrazie są prawidłowo wykrywane. Orientacyjna rozdzielczość kierunkowa algorytmu wynosi 22,5 stopnia. Pewne problemy z dopasowaniem pikseli do klas występują w przypadku elementów o kierunku poziomym i pionowym, co związane jest z faktem, iż dwa różne komponenty dekompozycji NSCT reagują podobnie w przypadku linii poziomych, oraz dwa inne, w przypadku pionowych. Na rzeczywistych obrazach kolonie α -płatków nie składają się jednak z linii idealnie poziomych lub pionowych i skąd problem ten traci na ważności, co ilustruje rysunek 10. Pokazuje on wynik segmentacji obrazu tomograficznego. Pewnym problemem są natomiast kolonie o małych rozmiarach. Jak wspomniano w podrozdziale 3.6, o przydzieleniu kolonii do danej klasy decyduje nie tylko kierunkowość elementów ją tworzących, ale także jej otoczenie. Zasady te tworzone są przez specjalistów w dziedzinie materiałoznawstwa. I tak: wielkość kolonii, która uznawana jest za błąd, ustalona została na poziomie 150 pikseli. Wielkość kolonii, która będzie podlegała ponownej klasyfikacji, ze względu na otoczenie ustalono na 2000 pikseli. Wszystkie kolonie α -płatków zostały wykryte poprawnie.



Rys. 10. Wynik segmentacji obrazu stopu tytanowego wykonanego za pomocą tomografu rendenowskiego: a) obraz oryginalny; b) obraz posegmentowany

Rozdzielczość kierunkowa wynosząca ok. 22,5 stopnia okazuje się być wystarczająca w tym wypadku. Czułość proponowanej metody jest także wystarczająca, obszary o słabo i bardzo słabo zaznaczonej kierunkowości są identyfikowane poprawnie. Problematiczne są obszary pozbawione kierunkowego charakteru. Z jednej strony mogą być powodowane przez błędy w akwizycji obrazu lub specyficzną budową materiału, z drugiej strony mogą to być fragmenty struktur zorientowanych w płaszczyźnie prostopadłej do płaszczyzny obrazu. Oryginalny obraz pochodzący z tomografu ma wymiary $501 \times 501 \times 500$ pikseli. Obrazy wejściowe 2D są tworzone na zasadzie wyboru jednego wycinka o wymiarach $501 \times 501 \times 1$,

w płaszczyźnie XY. Jeśli jakaś kolonia będzie zorientowana w płaszczyźnie np. YZ, to na obrazie-wycinku z płaszczyzny XY będą widoczne jako chaotyczne i przypadkowe struktury. Sytuacje takie zdarzają się jednak stosunkowo rzadko. Analizując obrazy 2D, należy jednak brać pod uwagę ten problem. Do binaryzacji obrazu (usuwanie tła – podrozdz. 3.3) użyty został algorytm Otsu. Rysunek 11 przedstawia porównanie wyników segmentacji obrazu z rysunku 10a za pomocą algorytmu wykorzystującego tradycyjną dekompozycję falkową z falką Haara [3] i algorytmu zaproponowanego w niniejszej publikacji. Metoda zaprezentowana w [3] nie potrafiła dokonać prawidłowej segmentacji obrazów tego typu. Głównym problemem był tutaj sam proces detekcji kierunku, który charakteryzował się słabą czułością i bardzo małą selektywnością – potrafił przypisywać piksele tylko do trzech klas – poziomej, pionowej i bezkierunkowej.



Rys. 11. Wynik segmentacji obrazu stopu tytanowego wykonanego za pomocą tomografu rentgenowskiego: a) algorytm wykorzystujący klasyczną dekompozycję falkową; b) algorytm wykorzystujący dekompozycję *contourlet*

Dodatkowo, metodę cechowała niska czułość i wysoka podatność na szum zawarty na obrazie. Przez to wiele kolonii było identyfikowanych niepoprawnie. Metoda wykorzystująca dekompozycję *contourlet* odznacza się zarówno wysoką czułością, bo potrafi wykryć nawet słabo widoczne struktury tworzące kolonię α -płatków, jak i stosunkowo wysoką selektywnością, bo potrafi dobrze odseparować od siebie kolonie z rozdzielczością kierunkową wynoszącą około 22,5 stopnia. Testy wykonano na komputerze PC o następujących parametrach: procesor Intel i7 2.3 GHz, 12GB RAM, pod kontrolą systemu operacyjnego MS Windows XP 64bit. Algorytm zaimplementowany został w środowisku MATLAB 9. W przypadku tekstury tomograficznej o rozmiarze 501×501 pikseli czas wykonania algorytmu wyniósł średnio ok. 510 s. Wizualna ocena wyników segmentacji obrazów 2D przez

eksperta w dziedzinie wiedzy o materiałach jest dobra. Metoda daje na tyle dokładne wyniki, iż możliwe jest rozpoczęcie badań na właściwościach materiału z użyciem tych wyników.

5. Propozycje dalszych badań

Rozwinięcie proponowanej metody na potrzeby przetwarzania obrazów 3D wydaje się naturalną konsekwencją opisywanego algorytmu. Oryginalne obrazy tomograficzne są także trójwymiarowe. Wszystkie etapy segmentacji mają możliwość rozszerzenia do przestrzeni 3D przez dodanie nowego wymiaru do algorytmu. W przypadku detektora kierunku, jakim jest transformata *contourlet*, nie istnieje prosta możliwość użycia tej metody do segmentacji obrazów 3D, jednakże opracowana została transformata będąca rozszerzeniem *contourlet* pod nazwą *surfacelets* [14, 15]. Wykorzystuje ona banki trójwymiarowych filtrów (*hourglass filter banks*). Rozszerzenie algorytmu do przestrzeni 3D pozwoli na pełną analizę tomograficznych obrazów krystalicznych stopów tytanu.

Podziękowania

Autorzy chcą podziękować Dr J. Bennett z School of Materials, University of Manchester, za wykonanie trójwymiarowych obrazów z próbki tytanu przy wykorzystaniu ID19 beam Line w ESRF.

Autorzy dziękują za wsparcie badań poprzez grant badawczy (6522/B/T02/2011/40).

Referencje

- [1] Babout L., Marrow T.J., M., P., *Sequential x-ray tomography studies of damage assessment*. [w:] Materials Science, 4th Symposium on Process Tomography, Warszawa, Polska, 2006.
- [2] Biroscas S., Buffiere J.Y., Garcia-Pastor F.A., Karadge M., Babout L., Preuss, M., *Three-dimensional characterization of fatigue cracks in Ti-6246 using X-ray tomography and electron backscatter diffraction*. Acta Materialia, 57(19), 2009, 5834–5847.
- [3] Babout L., Jopek Ł., Janaszewski M., Preuss M., J., B., *Towards the texture segmentation of X-ray tomography images of lamellar microstructure in titanium base alloys*, [w:] Piąte międzynarodowe sympozjum tomografii procesowej. Zakopane, Polska, 2008, 168–173.
- [4] Szczypinski P.M., Strzelecki M., Materka A., *MaZda – A software for texture analysis*. [w:] Proc. 2007 International Symposium on Information Technology Convergence, ISITC 2007.
- [5] Jeulin D., Moreaud M., *Segmentation of 2D and 3D textures from estimates of the local orientation*. Image Anal Stereol, 2008, 183–192.
- [6] Jopek Ł., Babout L., Janaszewski M., M., P., *A new method to segment X-ray tomography images of lamellar microstructure in titanium alloys based on gray level gradient*. Automatyka (półrocznik AGH), 2010.
- [7] Arthur L. da Cunha, J.Z., Minh N. Do, *The Nonsampled Contourlet Transform: Theory, Design, and Applications*. IEEE Transactions on Image Processing, 15, October 2006, 3089–3101.
- [8] Duncan D-Y. Po, M.N.D., *Directional Multiscale Modeling of Images using the Contourlet Transform*. IEEE Transactions on Image Processing, 15, June 2006, 1610–1620.

-
- [9] Minh N. Do, M.V., *The Contourlet Transform: An Efficient Directional Multiresolution Image Representation*. IEEE Transactions on Image Processing, 14, December 2005, 2091–2106.
 - [10] Dettori L., Semler L., *A comparison of wavelet, ridgelet, and curvelet-based texture classification algorithms in computed tomography*. Computers in Biology and Medicine, 37(4), 2007, 486–498.
 - [11] Do M.N., M., V., *The finite ridgelet transform for image representation*. IEEE Transactions on Image Processing, 12(1), 2003, 16–28.
 - [12] Przelaskowski A., *Komputerowe wspomaganie obrazowej diagnostyki medycznej*. Warszawa, 2006.
 - [13] Cunha A.L., M.N.D., *On two-channel filter banks with directional vanishing moments*. IEEE Transactions on Image Processing, 16, 2007, 2309–2321.
 - [14] Lu Y.M., M.N.D., *Multidimensional directional filter banks and surfacelets*. IEEE Transactions on Image Processing, 16, 2007, 918–931.
 - [15] Lu Y.M., N.D., *A mapping-based design for nonsubsampling hourglass filter banks in arbitrary dimensions*. IEEE Transactions on Signal Processing, 56, 2008, 1466–1478.