

LESIAK Piotr¹
BOJARCZAK Piotr²

Inteligentne algorytmy analizy ultradźwiękowych obrazów w badaniach bezstykowych złączy szyn metodą TOFD

złącza szynowe,
ultradźwiękowa metoda TOFD
analiza obrazów

Streszczenie

W pracy przedstawiono technologię ultradźwiękowej metody TOFD (ang. *Time-Of-Flight Diffraction*) do badania spawanych i zgrzewanych złączy szyn kolejowych w torze. Omówiono specyfikę uzyskiwanych z takich badań obrazów i algorytmy pozyskiwania informacji o wadach w złączach szyn, traktując te obrazy, jako teksturę. Wykorzystano w tych algorytmach procedurę ekstrakcji wektorów cech dla każdego piksela za pomocą dekompozycji falkowej, następnie zoptymalizowano je stosując analizę głównych składowych PCA (ang. *Principal Component Analysis*). W końcowym etapie klasyfikacji obrazu, jako klasyfikator binarny wad zastosowano metodę SVM (ang. *Support Vector Machines*).

INTELLIGENT ALGORITHMS OF ANALYSIS OF ULTRASONIC IMAGES OF SEAMLESS JOINTS CAPTURED WITH TOFD METHOD

Abstract

The paper presents ultrasonic TOFD method using in diagnostic of welded and flash-welded joints of railway rails. Features of ultrasonic images of seamless joints obtained with the use of TOFD and image processing algorithms using in extraction of flaws from these images have been presented. These algorithms use wavelet transform to extract the feature vector describing flaw zone. Dimension of feature vector is reduced with the use of PCA (*Principal Component Analysis*). At the end of analyzing procedure SVM (*Support Vector Machines*) classifier is used in determination if extracted feature vector corresponds or not to the flaw zone.

1. WSTĘP

W badaniach ultradźwiękowych spoin, coraz częściej stosowana jest metoda TOFD (ang. *Time-Of-Flight Diffraction*) [15]. Wykorzystuje się w niej zjawisko dyfrakcji fali ultradźwiękowej na granicy wady. W efekcie otrzymuje się dość nietypowe obrazy wad, wymagające dodatkowych zabiegów rekonstrukcji i ich oceny.

Naturalnym obiektem stosowania tej metody są złącza zgrzewane i spawane szyn kolejowych. Pierwsze próby wykorzystania metody TOFD do takich badań, podjęto w USA [1]. Na PKP spoiny badane są w sposób tradycyjny (metoda echa lub tandem), defektoskopami szynowymi lub wagonem pomiarowym [16]. Jednak nie zawsze uzyskuje się tu zadowalające wyniki, gdyż w bezpośrednim sąsiedztwie złącza, często występują nierówności powierzchni tocznej główki szyny, co dyskryminuje uzyskanie dobrego kontaktu akustycznego głowic. Ponadto wskazane też byłoby dokładne badanie obszaru bocznych części stopki szyny, gdyż rozwijające się od tych miejsc pęknięcia propagują do pozostałych części szyny, a także badania szyjki i główki szyny z ich bocznej powierzchni [11].

Pomimo poprawy technologii wytwarzania takich spoin, dalej istnieje problem występujących w nich wad, szczególnie na szlakach dawno nie modernizowanych (informacja własna z Centrum Diagnostyki PKP PLK S.A.). Jako przykłady niech posłużą zdjęcia złączy wykonane tej zimy, na jednej z linii obsługiwanej przez Zakład Linii Kolejowych w Skarżysku Kamiennej, rys. 1. Jedynie zgrzew rys. 1a wzbudza wizualne zaufanie, natomiast zewnętrzny wygląd wszystkich spawów rys. 1b, c, d i e wskazuje na domniemane uszkodzenia i potwierdza trudności uzyskania wiarygodnych badań dotychczasowymi metodami. Jednoznaczny przełom w obrębie spoiny, ma też złącze na rys. 1 f.

Dlatego w celu polepszenia badań spoin szyn, autorzy proponują zastosowanie metody TOFD. Metoda ta zapewnia wskazania wysokości, długości i pozycji wad z poziomem dokładności nieosiągalnym dla innych metod ultradźwiękowych. Wymaga ona specjalizowanych skomputeryzowanych defektoskopów ultradźwiękowych wyposażonych w skanery z cyfrowym enkoderem położenia głowic ultradźwiękowych, do ręcznego ich prowadzenia po szynie w obszarze spoiny. Ponadto niezbędna jest akwizycja wyników badań i oprogramowanie zapewniające zobrazowanie wad 2D.


W pracy zaprezentowane zostaną inteligentne algorytmy wykorzystywane do analizy obrazów 2D uzyskanych z badań spoin metodą TOFD, rys. 2, gdyż mają one odmienną strukturę w porównaniu do innych obrazów ultradźwiękowych. Z obserwacji autorów wynika, że badania nad coraz doskonalszymi algorytmami przeznaczonymi dla tej metody,

¹ Piotr Lesiak, Politechnika Radomska, Wydział Transportu i Elektrotechniki, 26-600 Radom, ul. Malczewskiego 29, tel: + 48 48 361-77-09, e-mail: p.lesiak@pr.radom.pl

² Piotr Bojarczak, Politechnika Radomska, Wydział Transportu i Elektrotechniki; 26-600 Radom; ul. Malczewskiego 29, tel: + 48 48 361-77-23, e-mail: bojarczpp@wp.pl

szczególnie szybko się rozwijają w krajach o znaczącym potencjale wydobycia i transferu ropy naftowej, gdzie powszechnie się stosuje kontrolę spoin w rurociągach, czego przykładem mogą być publikacje [2], [6], [7], [19], [22].

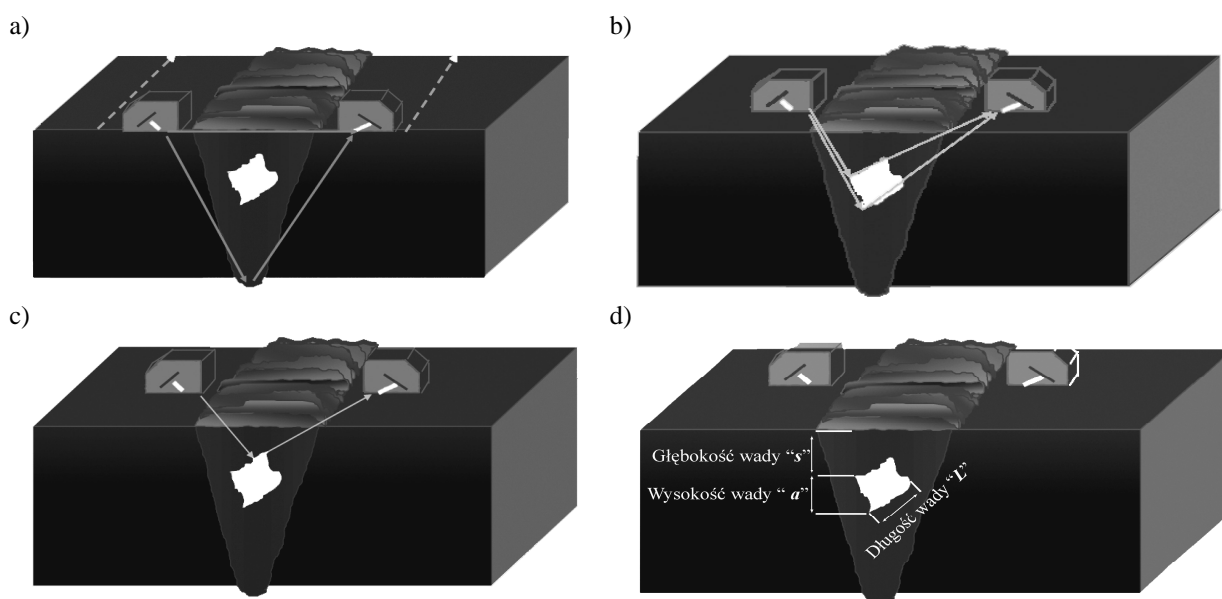
Proces detekcji wad można tu potraktować, jako typowe zadanie segmentacji obrazu na podstawie jego tekstury, lub też, jako proces jej klasyfikacji. W tym drugim przypadku najistotniejszym czynnikiem mającym zasadniczy wpływ na skuteczność całego procesu jest prawidłowy dobór cech tekstury. Ogólnie metody te można podzielić na metody bazujące na statystykach pierwszego rzędu (wartości średnie, entropia) [5] i drugiego rzędu (tak zwane miary Haralicka) [9], metody wykorzystujące przekształcenia falkowe [8] oraz filtry Gabora [3], [12]. Dwie ostatnie metody należą do metod pozwalających na analizę tekstury w wielu skalach (ang. *multi-resolution analysis*).



Rys. 1. Spoiny złączy szyn: a) zgrzew, b), c) d) i e) spawy, f) przełom w obrębie spoiny


2. ULTRADŹWIĘKOWE OBRAZY TOFD ZŁĄCZY SZYN

W technice *TOFD* wykorzystuje się parę głowic umieszczonych po przeciwnych stronach spoiny. Jedna z głowic emituje sygnał ultradźwiękowy, który przechwytywany jest przez drugą głowicę. Jeśli w spoinie nie ma wad odbierane są dwie fale: jedna wędruje tuż pod powierzchnią, druga odbita jest od przeciwległej powierzchni (dna). Wraz ze wskazaniem wady pojawia się dyfrakcja fali ultradźwiękowej, którą wykrywa głowica odbiorcza [17]. Klasyczny przykład badania modelu spoiny i sposobu zwiaryzowania wady, przedstawiono na rys. 2.



Rys. 2. Kolejne fazy badania modelu spoiny z wadą, ultradźwiękową metodą TOFD

Użycie techniki *TOFD* pozwala na bardzo dokładne wymiarowanie pęknięć. W przeciwieństwie do innych technik ultradźwiękowych nie używa ona amplitudy sygnału ultradźwiękowego, w związku z tym nie jest czuła na niekorzystną orientację wady. Zamiast amplitudy w celu ustalenia lokalizacji wskazań używane są sygnały pochodzące od fal dyfrakcyjnych, rys. 3.



Rys. 3. Przykładowe B - skany ultradźwiękowych obrazów *TOFD* spoin szyn z naznaczonymi obszarami wad: a) sposób oceny położenia i rozmiarów wad (jak na rys. 2d) i przykłady obrazów spoin z wadami

3. INTELIGENTNE ALGORYTMY EKSTRAKЦИИ WAD W SPOINACH SZYN

Najistotniejszym czynnikiem, wpływającym na jakość procesu klasyfikacyjnego ultradźwiękowych obrazów *TOFD* tekstur spoin w szynach, jest dobór odpowiedniego klasyfikatora. Podobnie jak przy wyborze metod opisu cech tekstur również tutaj istnieje wiele rodzajów klasyfikatorów np. klasyfikatory statystyczne (k – ang. *Nearest Neighbor*) [4], [18], drzewa decyzyjne [18] oraz klasyfikatory oparte o sieci neuronowe [4]. Autorzy zdecydowali się na klasyfikator neuronowy, ze względu na względną łatwość jego konstrukcji. Wybrano klasyfikator SVM (ang. *Support Vector Machines*), zapewniający maksymalny margines separacji klasyfikowanych grup danych [20], [22].

W algorytmie z [12], [13], zastosowano kilka innowacyjnych procedur takich jak dyskretna transformata falkowa (ang. *Discrete Wavelet Transform – DWT*), analiza tekstury oraz detekcja krawędzi płaskich wad. Podejście to opiera się na rozkładzie obrazu przez pakiety falek, biorąc pod uwagę zawartość jego tekstury na każdym poziomie dekompozycji. Rekonstrukcja obrazu odbywa się poprzez eliminację tekstury i na końcu jego segmentację, wykorzystując algorytm logiki rozmytej (ang. *Fuzzy Sets*). Algorytm ten dostosowany jest do autonomicznego funkcjonowania, bez potrzeby ciągłej interwencji i zapewnia automatyzację detekcji i oceny wad w spoinach, jako istotny etap kompleksowej kontroli *TOFD*.

Korzystając z algorytmu przedstawionego w publikacji [14], rys. 4, najpierw dokonuje się ekstrakcji wektorów cech dla każdego pikselu za pomocą dekompozycji falkowej. Dekompozycja ta realizowana jest w obrębie fragmentu – wycinka obrazu o postaci kwadratu $N \times N$ pixeli, nazywanego dalej ramką (okienkiem). W trakcie całego procesu ramka przesuwana jest piksel po pikselu w obrębie całego analizowanego obrazu. W wyniku tego dla każdego położenia ramki uzyskiwany jest wektor cech skojarzony ze środkowym jej punktem. Wektor ten określany jest w oparciu o transformatę falkową, która jest przekształceniem dekomponującym analizowany przebieg na składowe o skończonej długości, nazywane falkami. W wyniku generowane są współczynniki tej transformaty $W(a,b)$, czyli:

$$W(a,b) = \int_{-\infty}^{\infty} f(t) * \Psi_{a,b}(t) dt \quad (1)$$

gdzie:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (2)$$

jest falką o skali a i przesunięciu równym b . Przekształcenie to jest przekształceniem odwracalnym to znaczy funkcja $f(t)$ może zostać odtworzona na podstawie współczynników $W(a,b)$ oraz funkcji bazowych – falek. W wyniku dekompozycji funkcja $f(t)$ jest dzielona na część $f_0(t)$ zawierającą składowe niskoczęstotliwościowe oraz część $g_0(t)$ zawierającą składowe wysokoczęstotliwościowe. W następnym kroku funkcja $f_0(t)$ może zostać dalej rozłożona na składową niskoczęstotliwościową $f_1(t)$ i składową wysokoczęstotliwościową $g_1(t)$. Proces ten może być kontynuowany do dowolnego poziomu dekompozycji.

W przypadku transformaty falkowej ultradźwiękowego obrazu 2D jest ona wykonywana w dwóch etapach, najpierw dla wierszy a następnie dla kolumn obrazu. W wyniku tego dla każdego poziomu dekompozycji generowane są cztery

sub - obrazy: $f_{LL}(x,y)$, $f_{LH}(x,y)$, $f_{HL}(x,y)$, $f_{HH}(x,y)$ zawierające odpowiednio komponenty niskoczęstotliwościowe,

komponenty wysokoczęstotliwościowe o orientacji poziomej, komponenty wysokoczęstotliwościowe o orientacji pionowej oraz komponenty wysokoczęstotliwościowe o orientacji diagonalnej.

W następnym kroku przeprowadzana jest redukcja wymiaru wektora cech przy pomocy analizy głównych składowych PCA (ang. *Principal Component Analysis*), jako jednej ze statystycznych metod analizy, definiującą liniowe przekształcenie o postaci [10]:

$$\mathbf{y} = \mathbf{W}\mathbf{x} \quad (3)$$

przekształcające dane stochastyczne $\mathbf{x} \in R^N$ w wektor $\mathbf{y} \in R^K$ przy pomocy macierzy $\mathbf{W} \in R^{K \times N}$ w taki sposób, że przestrzeń wyjściowa \mathbf{y} o zredukowanym rozmiarze $K < N$ zachowuje najistotniejsze informacje zawarte w przestrzeni wejściowej \mathbf{x} .

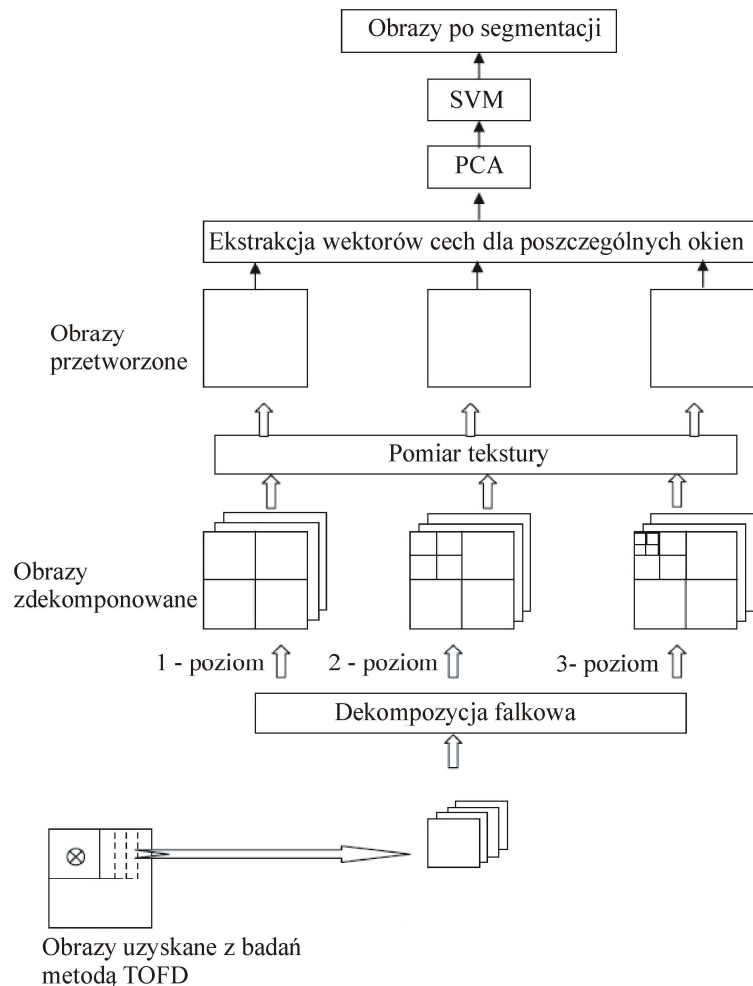
Niech \mathbf{x} będzie dowolnym wektorem o wartości średniej równej zero a $\mathbf{R}_{xx} = E[\mathbf{x}\mathbf{x}^T]$ macierzą korelacji wszystkich wektorów \mathbf{x}_i . Niech ortogonalne wektory własne \mathbf{w}_i (nazywane też wektorami – komponentami głównymi) będą skojarzone z odpowiadającymi im wartościami własnymi μ_i . Rozmieszczając wartości własne w porządku malejącym to znaczy $\mu_1 \geq \mu_2 \geq \dots \geq \mu_N$ macierz korelacji może zostać zrekonstruowana w następujący sposób [10]:

$$\mathbf{R}_{xx} = \sum_{k=1}^N \mu_k \mathbf{w}_k \mathbf{w}_k^T \quad (4)$$

Wkład poszczególnego wektora własnego \mathbf{w}_i w rekonstrukcję macierzy mierzony jest poprzez odpowiadającą mu wartość własną μ_i . Na ogół do rekonstrukcji zachowujących najistotniejsze cechy przestrzeni wejściowej \mathbf{x} wystarczy użyć $K < N$ pierwszych wektorów własnych mających największe wartości własne. Odrzucone wektory własne reprezentują szum występujący w wektorze wejściowym \mathbf{x} . Wówczas rekonstrukcja oryginalnego wektora \mathbf{x} oznaczonego, jako $\hat{\mathbf{x}}$ będzie określona przez:

$$\hat{\mathbf{x}} = \mathbf{W}^T \mathbf{y} \quad \text{gdzie } \mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_K]^T \quad (5)$$

Reasumując, zastosowanie metody PCA redukuje rozmiar wektora wejściowego oraz ogranicza wpływ szumu na proces klasyfikacji.



Rys. 4. Algorytm inteligentnej segmentacji obrazów uzyskanych z ultradźwiękowych badań spin szyn metodą TOFD

W końcowym etapie klasyfikacji obrazu wady, jako klasyfikator binarny zastosowano wspomniany SVM [20]. Działanie sieci neuronowej opartej o SVM przebiega w dwóch etapach. W etapie pierwszym sieć przeprowadza nieliniowe rzutowanie N – wymiarowej przestrzeni wejściowej w K - wymiarową przestrzeń cech. Rzutowanie to jest realizowane z pomocą funkcji $\varphi(\mathbf{x})$. W drugim etapie sieć przeprowadza liniową separację uprzednio rzutowanych danych (występujących w przestrzeni K - wymiarowej). Liniowa separacja danych realizowana jest przy pomocy hiperpłaszczyzny opisanej następującą zależnością:

$$y(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b = \sum_{j=1}^K w_j \varphi_j(\mathbf{x}) + b \quad (6)$$

gdzie: $\varphi(\mathbf{x})$ jest funkcją rzutującą N - wymiarową przestrzeń wejściową w K - wymiarową przestrzeń cech, \mathbf{x} jest wektorem wejściowym podawanym na sieć a \mathbf{w} jest wektorem wag sieci. Jeśli wektor wejściowy \mathbf{x} spełnia zależność $y(\mathbf{x}) > 0$ to należy on do pierwszej klasy, w przeciwnym razie należy do drugiej klasy.

W trakcie procesu uczenia, na sieć podawane są pary wektorów uczących (\mathbf{x}_i, d_i) , gdzie \mathbf{x}_i jest i -tym wektorem wejściowym podawanym na wejście sieci a d_i jest wartością zadaną jak ma pojawić się na wyjściu sieci ($d_i = 1$, gdy wektor wejściowy \mathbf{x}_i należy do pierwszej klasy lub $d_i = -1$, gdy wektor wejściowy \mathbf{x}_i należy do drugiej klasy). Proces uczenia zapewnia maksymalizację odstępów między danymi obu klas położonymi najbliżej siebie. Po zakończeniu procesu uczenia finalna postać hiperpłaszczyzny opisana jest przez:

$$y(\mathbf{x}) = \sum_{i=1}^{N_{SV}} \alpha_i d_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (7)$$

gdzie: N_{SV} jest liczbą tak zwanych wektorów podtrzymujących równą liczbę neuronów ukrytych, α_i – współczynnikami Lagrange'a, $K(\mathbf{x}, \mathbf{x}_i)$ jest funkcją jądra przyjmująca postać liniową wielomianu lub Gaussa, natomiast d_i są wartościami zadanymi opisanymi wcześniej.

W wyniku działania klasyfikatora następuje rozdzielenie zbioru pikseli ultradźwiękowego obrazu na dwie części, czyli znalezienie optymalnej hiperpłaszczyzny, przy możliwie jak największym marginesie separacji. Każdy piksel obrazu musi zostać dobrze sklasyfikowany, czyli znajdować się po właściwej stronie hiperpłaszczyzny i zostać zaliczony do „wady spoiny” lub „nie - do wady”.

Aby sprawdzić skuteczność proponowanych procedur, zastosowano obrazy uzyskane z kontroli spoin szyn, zawierających wady o znanej geometrii. W trakcie badań metodą *TOFD*, wybrano 50 obrazów w strefie uszkodzeń i 50 w zdrowej strefie spoiny. Po wyodrębnieniu wektorów cech dla każdego obrazu przez transformację falkową (algorytm na rys. 4), otrzymano macierz uczącą znanej klasy 100 próbek. Algorytm PCA zredukował rozmiar tej macierzy poprzez zmniejszenie wielkości atrybutów każdego wektora o 50%. Stosując algorytm SVM dla nowej macierzy uczącej, można zauważyć poprawę wyników analizy obrazu, która zależy od następujących czynników:


- rodzaju falki,
- rozmiaru okna (ramki) dekompozycji,
- funkcji jądra (SVM),
- parametru funkcji jądra.

Uzyskane ultradźwiękowe obrazy *TOFD* przedstawione na rys. 5, będące efektem stosowania tego algorytmu, zachęcają do jego zastosowania w kompleksowej kontroli spoin szyn kolejowych. Po wielu testach stwierdzono, że dla obrazów spoin najlepsze wyniki uzyskuje się dla falki Daubechies rzędu 2 do 10 [8], funkcji jądra w postaci wielomianu, jednorodnego wielomianu stopnia 4 do 9 i rozmiaru okna 21. W przykładzie przedstawionym na rys. 5a, optymalne wyniki uzyskano dla falki db2, jednorodnego wielomianu stopnia 6 i rozmiaru okna 21. W celu skorygowania błędnych klasyfikacji wyizolowanych pikseli zastosowano dodatkowo filtr *medianowy* [5], rys. 5d, f, i.

4. WNIOSKI

Autorzy podjęli nowatorską próbę w kraju wykorzystania inteligentnych algorytmów do analizy ultradźwiękowych obrazów wad uzyskanych w technologii *TOFD*, spoin bezстыkowych złączy szynowych. Obrazy te mają zupełnie inną strukturę w porównaniu do obrazów 2D pozyskiwanych z konwencjonalnych zautomatyzowanych badań ultradźwiękowych. Stąd też ekstrakcja z nich charakterystycznych obrazów wad, wymaga ciągu przekształceń matematycznych, co wykazano w pracy. Do zamierzonego celu można tu dotrzeć różnymi ścieżkami, a pokazaną w pracy należy traktować jako jedną z propozycji realizacji zamierzonego celu.

Autorzy mają nadzieję, że w miarę upowszechnienia się technologii *TOFD* badań spoin szyn na szlakach PKP, powstaną w pełni automatyzowane inteligentne algorytmy oceny wad w bezстыkowych złączach, pozwalające na znaczącą poprawę skuteczności ich detekcji i dokładności oceny.



Rys. 5. Ilustracja działania algorytmu inteligentnej segmentacji obrazów uzyskanych w badaniach spoin szyn metodą TOFD: a), d) i g) obraz oryginalny, b), e) i h) odpowiednio obrazy z a), d) i g) po segmentacji, c, f) i i) odpowiednio obrazy z b), e) i h) po filtracji medianowej

5. BIBLIOGRAFIA

- [1] Application of ultrasonic Phased Arrays for rail flaw inspection. U.S. Department of Transportation. Federal Railroad Administration. DOT/FRA/ORD-06/17 July 2006.
- [2] Baskaran G., Balasubramaniam K., Lakshmana Rao C.: Ultrasonic TOFD flaw sizing and imaging in thin plates using Embedded Signal Identification Technique (ESIT). Insight - Non-Destructive Testing and Condition Monitoring (The Journal of The British Institute of Non-Destructive Testing), Vol. 46, No 9, September 2004.
- [3] Bondarova A., Bennamoun M., Latham S.: Optimal Gabor filter for textile flaw detection. Pattern Recognition, Vol. 35, (2973 -2991), December 2002.
- [4] Bishop C.M.: Neural networks for Pattern Recognition, Oxford University Press, 1996
- [5] Bovik A.I.: Handbook of Image and Video Processing. Academic Press 2000.
- [6] C'Shekhar N Shitole, O Zahran and W Al-Nuaimy: Combining fuzzy logic and neural networks in classification of weld defects using ultrasonic time-of-flight diffraction. The 45th Annual British Conference on NDT, Stratford-upon-Avon, UK, September 2006.
- [7] C'Shekhar N. Shitole, O. Zahran and W. Al-Nuaimy: Advanced neural-fuzzy and image processing techniques in the automatic detection and interpretation of weld defects using ultrasonic Time-of-Diffraction. 4th International Conference on NDT, Hellenic Society for NDT, Chania, Crete – Greece, 11-14 October 2007.
- [8] Daubechies I.: Ten lectures on wavelets. SIAM Press, 1988.
- [9] Haralick R.M., Shanmugam K., Dinstein I.: Textural features for image classification. IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-3, n°6, (610 -621) November 1973.
- [10] Haykin S.: Neural Networks a comprehensive foundation. Prentice Hall International Inc 1996.
- [11] Katalog wad w szynach. Kod UIC 712 R. Wydanie IV, luty 2002.
- [12] Kechida A., Draï R., Khelil M.: 2D Gabor Functions and FCMI Algorithm for Flaws Detection in Ultrasonic Images. World Academy of Science, Engineering and Technology 9 (184 – 188), 2005.
- [13] Kechida A, Draï R., Benammar A.: Image Processing and wavelets transform for Sizing of Weld Defects Using Ultrasonic TOFD images. Acoustic'08, Paris, June 29 – July 4, (609 – 614), 2008.
- [14] Kechida A., Draï R., Guessoum A.: Detection Automatique des Defauts Dans des Images Industrielles Ultrasonores en Utilisant les Supports Vectors Machines (SVM). Conférence Internationale sur le Soudage, le CND et l'Industrie des Métaux, IC-WNDT-MI'10, Oran, 27 - 28 Novembre 2010.
- [15] Krishnamurthy C.V., Baskaran G., Balasubramaniam K., Rao C.L.: Development of an advanced ultrasonic TOFD system. Journal of Non-Destructive Testing and Evaluation, Vol. 3, (24-32), 2004.
- [16] Lesiak P.: Mobilna diagnostyka szyn w torze kolejowym. Wyd. Politechniki Radomskiej, seria monografie, nr 116, Radom 2008.

- [17] Mackiewicz S.: Metoda TOFD nowe podejście do ultradźwiękowych badań spoin. *Badania Nieniszczące PTBN*, nr 9, (20 – 23), 1997.
- [18] Mitchell T.: *Machine Learning*. McGraw-Hill , 1997.
- [19] de Moura E. P., Siqueira M. H. S., da Silva R. R., Rebello J. M. A., Calôba L. P.: Welding defect pattern recognition in TOFD signals. Part 1. Linear classifiers. *Insight - Non-Destructive Testing and Condition Monitoring*, Vol. 47, Number 12, 1 December (777 – 782), 2005.
- [20] Schölkopf B., Smola A.: *Learning with Kernels, Support Vector Machines, Regularization, Optimization and Beyond*. MIT Press, 2002.
- [21] Stapor K.: *Automatyczna klasyfikacja obiektów*. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2005.
- [22] Veiga J. L. B. C., de Carvalho A. A., da Silva I. C., Rebello J. M. A.: The use of artificial neural network in the classification of pulse-echo and TOFD Ultra-Sonic signals. *Braz. Soc. Mech. Sci. & Eng.* vol.27 no.4 Rio de Janeiro Oct./Dec. 2005.