

Piotr T. LESIAK, Piotr GOŁĄBEK

POPRAWA ULTRADŹWIĘKOWYCH OBRAZÓW WAD W DZIEDZINIE CZĘSTOTLIWOŚCI NA PRZYKŁADZIE SZYN KOLEJOWYCH


Streszczenie. Artykuł prezentuje rezultaty zastosowania filtrowania w dziedzinie częstotliwości do poprawy typowych ultradźwiękowych obrazów wad powstających w szynach kolejowych. Głównym celem procesu poprawy jest usunięcie z obrazu zakłóceń utrudniających interpretację wady. Zakłócenia wywołane są różnymi przyczynami, np. utratami kontaktu przez głowicę ultradźwiękową, albo fałszywymi echemi ultradźwiękowymi. Problem usunięcia tych zakłóceń sprowadza się do określenia pożądanej częstotliwościowej odpowiedzi filtru. Nieliniowa sieć neuronowa, będąca nieliniowym filtrem adaptacyjnym, może być nauczona na przykładach wad realizowania pożądanej funkcji filtracyjnej.

FREQUENCY DOMAIN ENHANCEMENT OF THE ULTRASONIC IMAGES OF FLAWS APPLIED TO RAILROAD TESTING

Summary. The article presents results of frequency domain filtering of the typical ultrasonic images of flaws collected in the railroad testing. The main goal of the process is getting rid of distortions making difficult the interpretation of flaws. The distortions are caused by different effects, such as ultrasonic probe contact losses or false echos. The problem of filtering out these distortions in frequency domain reduces to the appropriate definition of desired frequency response of the filter. The nonlinear neural network, being in fact a nonlinear adaptive filter, can be taught to perform such filtering with good results.


1. Ultradźwiękowe obrazy wad

W zautomatyzowanych defektoskopowych badaniach ultradźwiękowych obrazy wad prezentowane są najczęściej jako zbiór oczek skaningowej siatki, tzw. zobrazowanie typu C lub D. Obraz taki powstaje w wyniku zastosowania matrycy głowic ultradźwiękowych albo w procesie skanowania (rys.1). Głowica lub zespół głowic porusza się w kierunku x z zadanym krokiem, odpowiadającym przekrojowi A, a następnie zmienia warstwę C i powtórnie porusza się wzdłuż osi x w granicach skrajnych wymiarów płaszczyzny xy . Poziom B sygnału w oczku może być traktowany jako binarny lub skwantowany z określoną rozdzielczością.



Rys. 1. Siatka skaningowa
Fig. 1. Scanning raster

Opisana zasada stosowana jest np. w defektoskopowym wagonie pomiarowym, w którym każdy tok szynowy obserwowany jest przez zespół głowic ultradźwiękowych. Ruchowi skanera odpowiada przemieszczanie się wagonu. Odpowiada to dyskretyzacji obiektu w kierunku poprzecznym do kierunku skanowania. Samo skanowanie realizowane jest poprzez przemieszczanie się wagonu. Ponieważ wagon wyposażony jest w defektoskopy z pomiarami progowymi, uzyskane obrazy mają charakter binarny. Często się zdarza, że obrazy ulegają degradacji wskutek zakłóceń. W rezultacie uzyskany podczas badań kształt wady zawiera oczka nadmiarowe, wynikające z zakłóceń elektrycznych albo błędnych ech ultradźwiękowych, lub też oczka puste, wynikające z przerw w odbiorze fali. Typowe zniekształcone obrazy wad liniowych pokazano na rys.2. Przy ich klasyfikacji istotna jest ich rozległość (długość). Dlatego procedury automatycznej klasyfikacji wymagają wstępnej poprawy obrazów.



Rys. 2. Typowe zniekształcenia obrazów wad rejestrowanych przy badaniu szyn kolejowych: a) nieciągłość wynikająca z szumu dyskretyzacji, b) utrata sprzężenia, c) sytuacja fizycznie niemożliwa – zakłócenia aparatury

Fig. 2. Typical flaw images distortions collected in railroads testing: a) discontinuity caused by discretization noise, b) the lack of coupling, c) physically impossible situation – the aparature functioning distortions

2. Poprawa obrazu w dziedzinie częstotliwości

Podstawą technik filtracji w dziedzinie częstotliwości jest teoria splotu. Jeżeli $g(x,y)$, to obraz uzyskamy ze splotu obrazu wyjściowego $f(x,y)$ i pewnego liniowego operatora $h(x,y)$ (maski filtracyjnej), tzn.:

$$g(x,y) = h(x,y) * f(x,y) \quad (1)$$

to, zgodnie z teorią splotu, obowiązuje również poniższa relacja:

$$G(u, v) = H(u, v)F(u, v) \quad (2)$$

przy czym G , H i F są transformatami Fouriera g , h oraz f . Czyli filtrowaniu za pomocą maski przestrzennej $h(x, y)$ odpowiada zastosowanie filtru częstotliwościowego o transmitancji $H(x, y)$. W typowym zagadnieniu poprawy obrazu $f(x, y)$ jest dane, a celem jest wyznaczenie takiej $H(u, v)$, że obraz $g(x, y)$, uzyskany w wyniku:

$$g(x, y) = \text{Fourier}^{-1}[H(u, v)F(u, v)] \quad (3)$$

wypukła lub osłabia pewne cechy $f(x, y)$. Podstawowym zagadnieniem częstotliwościowych metod poprawy obrazu jest więc dobór funkcji przenoszenia filtru $H(u, v)$.

Metody filtracji częstotliwościowej wymagają zwykle znacznie większego nakładu obliczeniowego w stosunku do filtracji za pomocą masek przestrzennych. Istnieje natomiast cała klasa technik, dla których język metod częstotliwościowych jest podstawowy, a ich realizacja za pomocą filtracji przestrzennej byłaby trudna lub wręcz niemożliwa. Rozpatrywane zagadnienie poprawiania obrazów wad należy do klasy zagadnień określanych nazwą odtwarzanie obrazu [1,2].

Zagadnienie doboru filtru $H(u, v)$ jest tu traktowane analitycznie. Przyjmuje się pewien model zniekształceń obrazu i na jego podstawie, przy znajomości parametrów modelu lub ich estymat, dokonuje się wyznaczenia $H(u, v)$. Jednym z najczęściej używanych modeli jest model liniowy. Przyjmuje się w nim, że zniekształcony obraz $g(x, y)$ powstaje z obrazu oryginalnego $f(x, y)$ w procesie opisanym równaniem:

$$g(x, y) = H[f(x, y)] + \eta(x, y) \quad (4)$$

Występujący w równaniu operator H jest operatorem liniowym i niezmiennym względem translacji przestrzennych, co można zapisać:

$$H[f(x - \alpha, y - \beta)] = g(x - \alpha, y - \beta) \quad (5)$$

tnz. wynik zastosowania operatora w pewnym punkcie zależy tylko od wartości $f(x, y)$ w tym punkcie, a nie od położenia punktu. Występujący w równaniu (4) $\eta(x, y)$ to szum addytywny.

Dla zdyskretyzowanych funkcji $f(x, y)$, $g(x, y)$, a także występują w przetwarzaniu obrazów rastrowych, powyższy model prowadzi do macierzowego równania:

$$\mathbf{g} = \mathbf{H}\mathbf{f} + \boldsymbol{\eta} \quad (6)$$

gdzie \mathbf{f} , \mathbf{g} , $\boldsymbol{\eta}$ to wektory $(MN) \times 1$, powstałe z obrazów $M \times N$ poprzez konkatenację kolejnych wierszy, a \mathbf{H} to macierz $MN \times MN$, którą można traktować jako blokową macierz cyrkularną $M \times M$, w której bloki \mathbf{H}_i o rozmiarze $N \times N$ w jednym wierszu układają się w sekwencję powtarzaną w następnym wierszu z przesunięciem o jedną pozycję. Macierz \mathbf{H}_i sama w sobie jest również cyrkularna i składa się z wierszy zawierających wyrazy z i -tej kolumny odpowiedzi impulsowej operatora H .

Jak widać z równania (6), występuje tu układ równań liniowych, za pomocą którego można wyznaczyć $f(x, y)$. Jest to jednak dla typowych praktycznych przypadków monumentalne zadanie (np. dla $M=N=512$ \mathbf{H} ma rozmiar $262\,144 \times 262\,144$) i dlatego wypracowano uproszczenia tego podejścia, bazujące np. na diagonalizacji macierzy \mathbf{H} . Metoda powyższa zakłada znajomość operatora H , jak i szumu η . W przypadku niepełnej wiedzy oczywiste jest, że da się wyznaczyć jedynie estymatę $\hat{\mathbf{f}}$ macierzy \mathbf{f} . Jednym z podejść do tego zagadnienia, przy nieznanym charakterze szumu η , jest wyznaczenie $\hat{\mathbf{f}}$, tak aby norma „założonego” szumu:

$$\|\boldsymbol{\eta}\|^2 = \|\mathbf{g} - \mathbf{H}\hat{\mathbf{f}}\|^2 \quad (7)$$

była jak najmniejsza. Następuje więc minimalizacja funkcji:

$$J(\hat{\mathbf{f}}) = \|\mathbf{g} - \mathbf{H}\hat{\mathbf{f}}\|^2 \quad (8)$$

Po zastosowaniu warunku zerowania gradientu $\frac{\partial J(\hat{\mathbf{f}})}{\partial \hat{\mathbf{f}}} = 0$ uzyskuje się bezpośrednie wyrażenie na estymatę $\hat{\mathbf{f}}$:

$$\hat{\mathbf{f}} = \mathbf{H}^{-1} \mathbf{g} \quad (9)$$

Po zastosowaniu odpowiednich przekształceń [1] ze wzoru (9) da się wyznaczyć zależność:

$$F(u, v) = \frac{G(u, v)}{H(u, v)}, \quad (10)$$

będącą podstawą techniki zwanej „odwrotne filtrowanie”. F, G oraz H to transformaty Fouriera obrazów $f(x, y)$, $g(x, y)$ oraz operatora H , traktowanego jak funkcja filtrująca.

Inną techniką wyznaczającą estymatę $\hat{\mathbf{f}}$ przy znanym operatorze zniekształcenia H jest tzw. filtr Wienera [3]. Wychodzi on z zagadnienia minimalizacji z ograniczeniami, z funkcją celu zdefiniowaną następująco:

$$J(\hat{\mathbf{f}}) = \|\mathbf{Q}\hat{\mathbf{f}}\|^2 + \alpha(\|\mathbf{g} - \mathbf{H}\hat{\mathbf{f}}\|^2 - \|\boldsymbol{\eta}\|^2) \quad (11)$$

Liniowy operator \mathbf{Q} oraz współczynnik α przed składnikiem reprezentującym ograniczenie minimalizacyjne (redukcja zakładanej normy szumu) są parametrami otwierającymi drogę całej rodzinie technik, w zależności od doboru ich wartości. I tak, filtr Wienera zakłada:

$$\mathbf{Q}^T \mathbf{Q} = \mathbf{R}_f^{-1} \mathbf{R}_\eta \quad (12)$$

gdzie: \mathbf{R}_f to wartość oczekiwana macierzy autokorelacji obrazu $f(x, y)$, a \mathbf{R}_η - wartość oczekiwana macierzy autokorelacji szumu addytywnego η . Dla tak założonego \mathbf{Q} otrzymano:

$$\hat{\mathbf{f}} = (\mathbf{H}^T \mathbf{H} + \gamma \mathbf{R}_f^{-1} \mathbf{R}_\eta)^{-1} \mathbf{H}^T \mathbf{g} \quad (13)$$

z czego można wyznaczyć zależność używającą transformat Fouriera poszczególnych wielkości.

Zakładana we wszystkich tych podejściach znajomość operatora zniekształcenia H w praktyce jest realizowana różnymi sposobami, w zależności od posiadanej wiedzy. Na przykład dla zagadnień takich, jak usuwanie zniekształceń powstałych w wyniku poruszenia kamery w momencie otwarcia migawki, operator H daje się wyznaczyć analitycznie.

3. Sieć neuronowa

Przedstawione metody odtwarzania obrazu opierają się na założeniu o liniowości operatora zniekształcenia H i wykorzystują wiedzę o nim. Zastosowana tu sieć neuronowa dokonuje odwrotnego filtrowania filtrem nieliniowym, wyznaczonym w nadzorowanym procesie adaptacyjnym, wykorzystującym jako przykłady uczące idealne i zniekształcone obrazy wad.

Sieć neuronowa to układ połączonych ze sobą elementarnych jednostek przetwarzających – neuronów, realizujących pewną, generalnie nieliniową funkcję przenoszenia. Transmittancja całej sieci, przy ustalonej strukturze (liczba i rodzaj neuronów i sposób ich połączenia), zależy od zbioru parametrów zwanych wagami. Termin „wagi” najczęściej charakteryzuje połączenia międzyneuronowe, ale w wielu strukturach sieci obejmuje także inne adaptowane parametry. Najważniejsze stwierdzenia dotyczące sieci neuronowej, istotne dla opisanego zastosowania, to:

- Sieć neuronowa stanowi filtr adaptacyjny. Algorytm uczący, stowarzyszony z siecią neuronową, na podstawie informacji dostarczonej w postaci tzw. danych uczących dokonuje adaptacji wag w ten sposób, aby sieć była w stanie realizować odwzorowanie.
- Sieć neuronowa zbudowana z neuronów o nieliniowej funkcji aktywacyjnej jest tzw. uniwersalnym aproksymatorem, tzn. może z dowolną dokładnością aproksymować dowolną funkcję nieliniową [4].
- Algorytmy adaptacji sieci neuronowych, choć określone jako proste algorytmy, o zasięgu lokalnym (działające na poziomie pojedynczego neuronu), oparte są zwykle na bardzo pryncypialnych metodach, takich jak np. metoda najmniejszych kwadratów, będąca realizacją zasady największego prawdopodobieństwa, czy też techniki regularyzacji źle postawionych problemów [5,6].

Spśród wielu możliwych struktur sieci neuronowych do rozwiązania naszego problemu została użyta sieć RBF (Radial Basis Function), zbudowana z neuronów realizujących funkcję Gaussa:

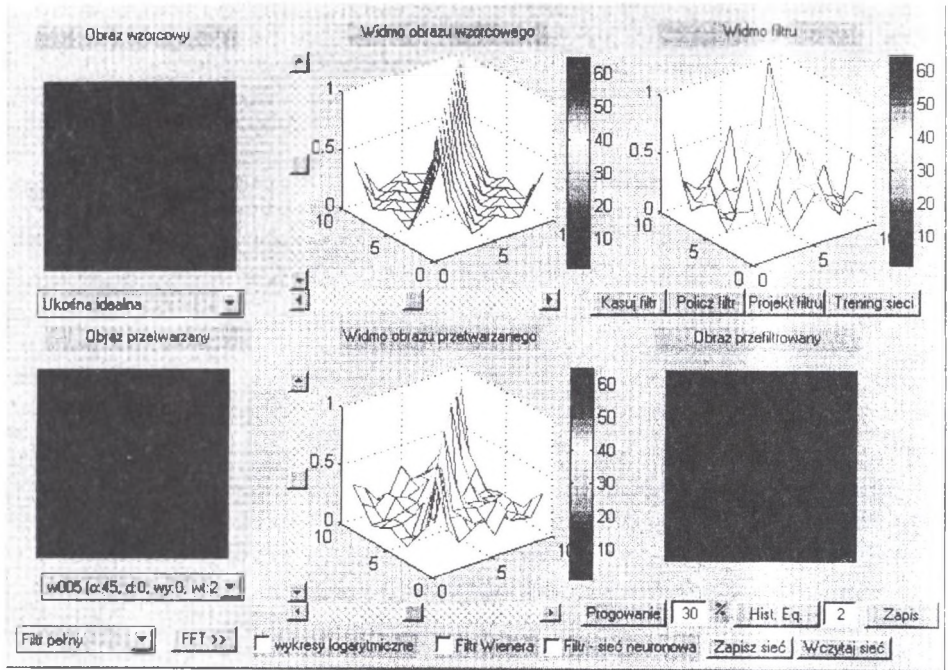
$$\phi_j(x) = e^{-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}} \quad (14)$$

Wykres takiej funkcji stanowi krzywą dzwonową o wierzchołku dla argumentu równego μ_j i rozległości (obszarze oddziaływania) określonej parametrem σ_j . Zbiór takich funkcji stanowi bardzo wygodną bazę dla modelu aproksymacyjnego, jako że funkcje mają zasięg lokalny, umożliwiając dopasowanie się do lokalnych cech aproksymowanej funkcji, a zarazem wyposażone są w mechanizm regularyzacyjny (parametr σ_j), umożliwiając sterowanie stopniem generalizacji oferowanej przez sieć.

4. Symulacje

Jak wspomniano w poprzednim punkcie, treningu sieci dokonywano w tak zwanym trybie nadzorowanym. Nadzorowany proces uczenia polega na podawaniu na wejście sieci pewnych danych, a na wyjście – pożądaných odpowiedzi na podane argumenty. Sieć w procesie uczenia uczy się odwzorowania pomiędzy danymi podawanymi na wejście a danymi wyjściowymi. W najczęściej stosowanym algorytmie uczenia – wstecznej propagacji proces ten ma charakter dopasowania na zasadzie najmniejszych kwadratów.

Idea uczenia nadzorowanego zastosowanego w naszych symulacjach widoczna jest na rys. 3, który przedstawia okno aplikacji napisanej w systemie MATLAB, używanej w symulacjach. Dwa obrazy wad, umieszczone po lewej stronie okna, to obraz wzorcowy i zdekształcony obraz przetwarzany. Tuż za nimi umieszczone są ich widma Fouriera. W ostatniej kolumnie pokazane jest widmo zastosowanego filtra (u góry) oraz obraz odtworzony w wyniku odwrotnej transformaty przefiltrowanego widma obrazu zdekształconego. Widoczna na rysunku sytuacja przedstawia filtrowanie za pomocą filtra o transmitancji policzonej przez podzielenie macierzy widma obrazu wzorcowego przez macierz widma obrazu przetwarzanego. Wynikiem jest więc oczywiście obraz wzorcowy.



Rys. 3. Okno aplikacji w systemie MATLAB używanej do symulacji

Fig. 3. The application developed with MATLAB software, used to perform simulations

Do uczenia sieci używane były widma Fouriera obrazów zniekształconych (dane wejściowe) oraz odpowiadających im obrazów wzorcowych (pożądane wyjście). Sieć w procesie adaptacji uczyła się realizować odwzorowanie przekształcające widmo obrazu zniekształconego w widmo odpowiadające mu obrazu wzorcowego. Wytrenowana sieć reprezentuje filtr o nieliniowej transmitancji. W nawiązaniu do opisanych technik odtwarzania obrazu sieć realizuje filtrację odwrotną z operatorem zniekształcenia H , potraktowanym jako operator nieliniowy. Wiedza o operatrze H nabywana jest w trakcie uczenia sieci.

Sieć neuronowa ma charakter systemu typu „black box”. Realizuje wyuczoną funkcję, ale nie ma prostego mechanizmu przedstawienia wiedzy nabytej przez sieć w trakcie uczenia. Wizualizacja transmitancji realizowanej przez sieć nie wchodzi w rachubę, dlatego że jest to nieliniowa funkcja o wielowymiarowej dziedzinie i zbiorze wartości funkcji. W naszym przypadku, dla przyjętej rozdzielczości widma Fouriera 10×10 , realizowana przez sieć.

Uczenie sieci przeprowadzono na kilkuset przykładach par widm. Do uzyskania danych trenujących wykorzystana została procedura generacji zniekształconych obrazów wad. Procedura ta zaczyna od wady ciągłej o wylosowanej orientacji kątowej – jest to obraz wzorcowy, następnie dodaje z zadanym prawdopodobieństwem zniekształcenia trzech, zilustrowanych na rys. 2, typów – szum dyskretyzacyjny (rys. 2a), ubytki (rys. 2b) oraz szum addytywny (rys. 2c). Obydwa obrazy przekształcone za pomocą transformaty Fouriera stanowią jedną parę trenującą sieci. Sieć była uczona algorytmem realizującym minimalizację kwadratowej funkcji błędu. Do oszacowania jakości filtracji, której wyniki podane są niżej, wygenerowany został alternatywny zestaw 100 par trenujących – z dużym prawdopodobieństwem, żadna z nich nie została użyta do uczenia sieci.

Wyniki pokazane są na rys.4. Dla kilku zniekształconych obrazów przedstawiono wyniki filtracji odwrotnej filtrem liniowym, filtracji przy użyciu filtru Wienera, filtracji wyuczoną siecią neuronową oraz wyjścia sieci neuronowej poddanego progowaniu z progiem równym 50% max. amplitudy. Przedstawiona liniowa filtracja odwrotna została dokonana za pomocą filtru o transmitancji wyliczonej na podstawie widma obrazu wzorcowego i zniekształconego dla jednej pary trenującej (nie pokazanej na rys. 5). Jest to oczywiście podejście naiwne, nie wróżące żadnych efektów dla innych par trenujących, co widać na rysunku. Zaprojektowany filtr o symetrii kołowej miałby większe szanse sukcesu. Filtr Wienera realizowany przez procedurę z pakietu przetwarzania obrazów MATLAB nie realizuje potrzebnych celów. Wyrażnie osłabia pojedyncze wtrącenia odpowiadające szumowi addytywnemu, lecz np. nie uciąga wady. Z kolei sieć neuronowa, złożona z 75 neuronów RBF, bardzo dobrze wywiązuje się z zadania. Widać, że eliminuje pojedyncze wtrącenia, zarówno punktowe, jak i większe, uciąga obraz wady i usuwa zakłócenia o charakterze szumu dyskretyzacyjnego (pierwszy rząd). Prosty zabieg progowania sprowadza obrazy do trybu binarnego, zarazem dodatkowo je ulepsza.

Aby ocenić ilościowo jakość filtracji z użyciem sieci neuronowych, obliczono średni błąd względny procentowy z odchyłką wyznaczoną za pomocą modyfikacji miary Hamminga. Miara Hamminga służy do wyrażenia podobieństwa dwóch wzorców binarnych i zdefiniowana jest jako liczba pozycji bitowych, na których wzorce się różnią. W naszym przypadku tak określona miarę można zastosować tylko do obrazów po progowaniu.

Przed progowaniem można zastosować miarę zmodyfikowaną, która porównuje dwa obrazy A,B na odpowiednich pixelach a_{ij} , b_{ij} sumując wartość bezwzględną różnicy unormowanej (sprowadzonej do zakresu 0..1) jasności pixeli:

$$\Delta(A, B) = \sum_{i,j} |a_{ij} - b_{ij}| \quad (15)$$

Natomiast błąd względny procentowy wyrażony jest wzorem:

$$\delta = \frac{1}{K} \sum_{j=1}^K \frac{\Delta(A_j, B_j)}{N^2} * 100\% \quad (16)$$


przy założeniu K obrazów o rozmiarze N x N.

Wyniki tak wyliczonych błędów filtracji za pomocą sieci neuronowej podane są w tabeli 1. Podane wyniki dotyczą 100 obrazów testowych rozmiaru 10 x 10 pixeli, nie używanych do uczenia sieci.

Tabela 1

Ilościowe oszacowanie jakości filtracji z użyciem sieci neuronowej

Błąd względny procentowy filtracji za pomocą sieci neuronowej dla obrazów przed progowaniem (zmodyfikowana odległość Hamminga)	Błąd względny procentowy filtracji za pomocą sieci neuronowej dla obrazów po progowaniu (klasyczna odległość Hamminga)
0.72%	0.5%



Rys. 4. Wyniki filtracji za pomocą filtru liniowego, filtru Wienera oraz sieci neuronowej
 Fig. 4. The results of filtration with linear inverse filtering, Wiener filter and neural network

5. Konkluzje

Przeprowadzone symulacje wykazały, że sieć neuronowa o relatywnie prostej strukturze i metodologii uczenia bardzo dobrze sobie radzi z problemem poprawiania zniekształconych ultradźwiękowych obrazów wad. Dalsze możliwe zagadnienia symulacyjne to zastosowanie sieci neuronowych do obrazów ze skalą szarości, dostrojenie metodologii uczenia w celu wyznaczenia przez sieć filtru o symetrii kołowej bądź zastosowanie innych struktur sieci.

Literatura

1. Gonzalez R., Woods R.: Digital Image Processing, Addison Wesley 1993.
2. Lim J.: Two dimensional signal processing, Prentice Hall Intl 1996.
3. „MATLAB Image Processing Toolbox User's Guide”, printed documentation, 1997.
4. Hassoun M.: Fundamentals of Artificial Neural Networks, MIT Press 1995.
5. Haykin S.: Neural Networks – A Comprehensive Foundation, Prentice Hall Intl 1998.
6. Bishop C.: Neural Networks for Pattern Recognition, Oxford University Press 1997.

Recenzent: Prof. dr hab. Zygmunt Kleszczewski

Abstract

In the automated ultrasound testing the flaw images are represented mainly as a so-called C- or D-scans. Every cell of scanning raster represents average level of signal in the discretized neighborhood, either binary, or quantized with certain resolution. Oftenly the image is unacceptably distorted. We have rasters with filled cells in the regions, where there was no ultrasound wave propagation, and empty cells, where there were disturbances of wave. Testing the railways gives us the results containing characteristic types of flaw image degenerations.

This article presents the results of applying frequency-domain image enhancement techniques to the ultrasonic images of flaws. After transforming the image into frequency-domain with Fourier transform, we can apply a frequency-domain filter. In the process of filter design we have a few options. We can choose the frequency-space filter symmetry, e.g. circular. We can constrain the portion of frequency information used, e.g. only the magnitude or only the phase. Finally we can decide, what filter design methodology to use, either in determining the desired filter transmittance, as well as in implementing the filter in digital form. The use of adaptive filters is a point of interest here. The inverse Fourier transform brings back cleaned-up image.

The article presents the results of simulations performed with specially developed MATLAB procedures. The images are gotten from routine testing of railways conducted with WAD 2000 testing railway car developed by Politechnika Radomska. The different methodologies of filter design are tested. In the attempt for generalization, the neural network is used as an adaptive filter learning the frequency response, working well with different images.

The process of flaw image enhancement can be treated as a preprocessing phase for the flaw recognition and classification procedure implemented with some kind of classifier - neural, fuzzy-logic or a decision tree.