

KOMPUTEROWE PRZETWARZANIE SYGNAŁÓW ULTRADŹWIĘKOWYCH

Marcin STARNACKI

Przemysłowy Instytut Telekomunikacji S.A.
ul. Poligonowa 30 04-051 Warszawa, fax. 22 813 0205, email: mstarnacki@pit.edu.pl

Streszczenie

Właściwości użytkowe materiałów wykorzystywanych w przemyśle zbrojeniowym ulegają obniżeniu pod wpływem warunków eksploatacji takich jak temperatura, środowisko pracy oraz naprężenia. Zjawisko to określane jest mianem degradacji materiału i spowodowane jest wieloma procesami zachodzącymi w strukturze eksploatowanego materiału. Efektem tego jest konieczność stosowania metod umożliwiających rozpoznanie i ocenę stopnia degradacji materiału w celu jego dalszego bezpiecznego użytkowania. Ważnym elementem podjętego problemu są komputerowe możliwości oceny badanych struktur kompozytów. Wykorzystano w tym celu wybrane metody sztucznej inteligencji. Wyniki pomiarów powstają na podstawie elementów, które poddawane są systematycznej ocenie poprzez badania nieniszczące, w których wiodącą metodą są pomiary ultradźwiękowe. Badaniom poddawano próbki kompozytowe polimerowe.

Słowa kluczowe: ultradźwięki, defektoskopia, sztuczna inteligencja.

COMPUTER ULTRASOUNDS PROCESSING

Summary

As a result of exploitation of materials in industry their properties are reduced. The reason for which it occur are temperature, environment when it works and stress. This situation is called material degradation. As a result of this it is necessary to use method which makes possible detection and assessment degree of material degradation. It is necessary to qualify further abilities of the material to be used safely. The most important part of this problem are computer based abilities assessment examined of composite structures. To achieve this, selected methods of artificial intelligence (AI) were used. The results of measurement are generated on the basis of elements, which are systematically assess in non destructive testing (NDT). In NDT, among others ultrasonic testing methods are used. In testing polymer composite samples were used.

Keywords: ultrasound, defectoscopy, artificial intelligence.

1. WPROWADZENIE

Potrzeba zwiększenia precyzyjności otrzymywanych wyników monitorowania stanu struktury materiałów kompozytowych jest związana przede wszystkim z uwarunkowaniami ekonomicznymi, bezpieczeństwem ludzkim oraz ekologią środowiska naturalnego. W tym celu przeprowadzane jest wiele badań nad rozwojem metod nieniszczących używanych do testowania wykonanych kompozytów, w których najbardziej efektywną są pomiary ultradźwiękowe [2].

Wymagane jest aby badania ultradźwiękami elementów kompozytowych wykonywane były okresowo tak jak to ma miejsce w przemyśle lotniczym oraz wszędzie tam gdzie materiały eksploatowane są w szczególnych warunkach. W przypadku niektórych samolotów pasażerskich w około 25% składają się one z materiałów kompozytowych, których niekontrolowana degradacja mogłaby doprowadzić do katastrofy

w przypadku braku polityki bezpieczeństwa wykonanego produktu.

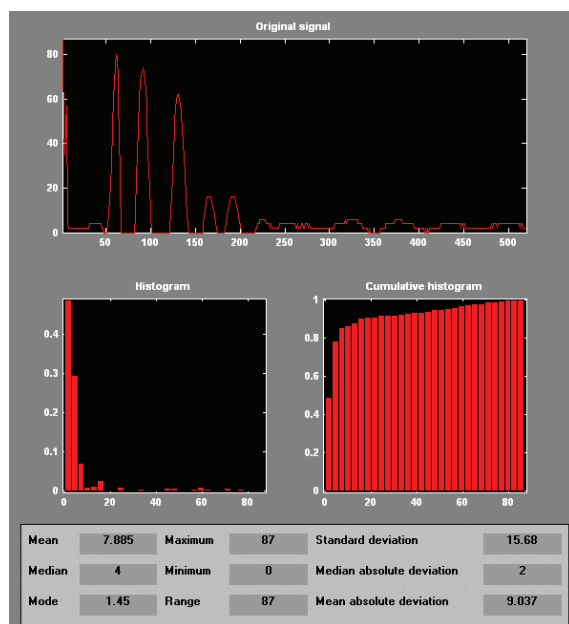
Jednym z najważniejszych etapów badania materiału ultradźwiękami jest późniejsza interpretacja otrzymanych wyników w postaci dyskretnych wartości sygnału dźwiękowego. Sygnały te przesyłane są on-line z głowicy przetwornikowej do komputera i poddawane są przetwarzaniu i wizualizacji. Badanie kompozytów wspieranych przy pomocy opracowanego programu UTracker umożliwia na bieżąco śledzić wady wykryte w materiale od początku jego przechwycenia. Powoduje to szybsze i dokładniejsze wskazanie całego obszaru defektu materiału.

Wykrywane przez program wady są bazą danych dla sztucznej sieci neuronowej, która otrzymuje je w postaci wektorów liczbowych i dokonuje na nich samoorganizacji. Powstają dzięki temu skupiska obiektów w przestrzeni dwuwymiarowej nazywane grupami. Są one charakterystyczne dla poszczególnych grup wad materiałów, które każdy musi określić sam.

Celem niniejszego artykułu jest raport z przeprowadzonych testów rozpoznania poprawności wykrywania wad w wybranych materiałach kompozytowych wspieranych technologiami komputerowymi.

2. ULTRADŹWIĘKI W DEFEKTOSKOPII

Głównym problemem w defektoskopii jest wykrycie lub zlokalizowanie obszarów w testowanym obiekcie. W tym przypadku jest to płytka kompozytu polimerowego. W większości przypadków wady materiału nie są wykrywalne gołym okiem tylko są skumulowane w wewnętrznej strukturze obiektu. W celu oceny jakości struktury materiału możemy wykonać dowolnym narzędziem do przetwarzania obrazów histogram tego obiektu. Wizualnie możemy ocenić różnice w statystycznym rozkładzie składowych otrzymanego sygnału oraz kolejnych sygnałów z przetwornika jak pokazane jest na rys. 1. Jest to najprostszy sposób wykazania nieprawidłowości w materiale.



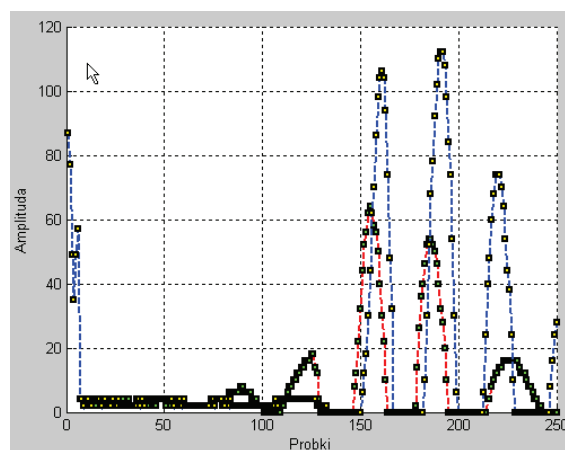
Rys.1. Przebieg sygnału oraz jego histogramy

Ludzkie ucho umożliwia odbieranie dźwięków o częstotliwości 20 – 20 000 Hz. Ultradźwięk jest dźwiękiem [5], którego częstotliwość jest większa niż 20 000 Hz. Ultradźwięk diagnostyczny operuje w zakresie od 1 do 10 MHz. Kierunek w jakim podąża fala ultradźwiękowa jest taki sam jak ruch cząstki. Fale są wytwarzane przez przetwornik ultradźwiękowy. Cechą jaką posiada fala ultradźwiękowa jest przenikania przez dane medium, które jest ograniczone przez właściwości tego medium; te właściwości obejmują gęstość i elastyczność. Określają one impedancję akustyki dla danego medium. Przenikanie fali jest także ograniczone przez częstotliwość przetwornika: wyższe częstotliwości mają krótsze długości fali

oraz mniejsza zdolność penetracji materiału niż niższe częstotliwości.

Ponieważ ultradźwięk napotyka warstwy w materiale o różnej impedancji akustycznej, tak więc prędkość fali przechodzącej przez medium ulega modyfikacji tak że wracające echa są odbierane przez przetwornik w różnych czasach oraz zmiennej intensywności. Komputer odbiera tylko dyskretne dane z każdego wykonanego kroku wysłania fali ultradźwiękowej oraz odebrania echa. Właściwość przenikania fali przez materiał pozwala zbudować diagnostyczny obraz na monitorze.

Problem jaki się pojawia to błędy pomiaru a raczej przesunięcia pozycji prążków wynikające z niedoskonałości głowicy jedno przetwornikowej, która wykonuje ruch w określonym czasie. Może powodować to zmiany pomiaru obszaru martwego oraz przesunięcia względem siebie pomiaru właściwego jak pokazano na rys. 2. Dlatego też opracowano metodę testową śledzenia wybranej próbki będącej elementem piku sygnału. W założeniu metoda ta śledzi położenie próbki w kolejnych sygnałach co umożliwia śledzenie defektu w materiale na bieżąco.



Rys. 2. Widmo przebiegu dwóch sygnałów w kolejnych punktach pomiarowych

3. BADANIE KOMPOZYTÓW


Zwiększone zapotrzebowanie na materiały kompozytowe w przemyśle lotniczym wynika z faktu, że pod wieloma względami przewyższają tradycyjne materiały konstrukcyjne. Wysokie parametry wytrzymałościowe, mała gęstość a co za tym idzie niższa waga w stosunku do tradycyjnych materiałów powoduje tak dużą popularność kompozytów w tym obszarze gospodarki.

Ogólnie kompozytem nazywamy materiał składający się z co najmniej dwóch komponentów o odmiennych właściwościach fizykochemicznych, którego całość zawiera lepsze bądź inne właściwości niż osobno każdy z komponentów. Kompozyt polimerowy badany w tym przypadku składa się z żywicy, która jest bazą dla włókien wzmacniających nadających kompozytowi wytrzymałość i sztywność. Ponieważ składa się

z wielu cienkich warstw połączonych spoiwem nazywany jest laminatem. Można go porównać do naturalnego laminatu jakim jest drzewo.

Pośród różnych metod nieniszczących przeznaczonych do badania kompozytów można wymienić m.in. „Tap test”, „Metoda rezonansowa”, „Metody termowizyjne i interferometryczne” oraz „Metody radiograficzne i ultradźwiękowe”. W przeprowadzonym eksperymencie użyto metody ultradźwiękowej typu A-mode.

Tryb amplitudy (A) wyświetla amplitudy indywidualnych ech jako funkcję dystansu w czasie. Technika ta stosowana jest głównie do badań monolitycznych struktur laminatowych. Jej przeznaczeniem jest głównie wykrywanie wad materiału typu rozwarstwienie, posiadanie ciała obcego oraz porowatość.



Rys. 3. Badanie laminatu techniką A-mode. Głowica badająca laminat bez wad oraz laminat z rozwarstwieniem

Opisana powyżej metoda sprawdza się najlepiej podczas produkcji laminatu kiedy można testować proces spajania warstw w kompozycje. W rozpatywanym przypadku przeprowadzono wiele testów laminatu w punkcie na całej powierzchni jak pokazano na rys. 3. Na podstawie przeprowadzonych testów zebrano dane liczbowe, które poddawane były obróbce gdzie opisane jest to w kolejnych rozdziałach.

4. PORÓWNYWANIE SYGNAŁÓW PRZY POMOCY FALI ELEMENTARNEJ

Na potrzeby przeprowadzenia eksperymentu stworzono program o nazwie USTracker opracowany całkowicie w języku wysokiego poziomu Matlab. Program ten służy do analizy sygnałów ultradźwiękowych oraz powstałych na ich podstawie tzw. falek (ang. wavelet). Falka jest rodzajem fali skończonej [1] lub inaczej funkcją dążącą do zera, która przekształca reprezentację sygnałów nieskończonych na ograniczonych w czasie. Czyli jest swojego rodzaju filtrem. W artykule przedstawiono sposób śledzenia prążka, który jest elementem piksu z wykorzystaniem ciągłej transformaty falkowej (ang. Continuous Wavelet Transform) według funkcji (1).

$$\text{cwt}(S, \text{SCALES}, 'wname') \quad (1)$$

gdzie:

S – sygnał analizowany wektorowy,
 SCALES – skala analizy sygnału,
 wname – skrócona nazwa z rodziny z jakiej pochodzi falka.

Przekształcenie falkowe CWT opiera się na schemacie, w którym falkę podstawową poddaje się skalowaniu i przesuwaniu pozycji wzdłuż badanego sygnału według wzoru (2).


$$C(\text{scale}, \text{position}) = \int_{-\infty}^{\infty} f(t)\psi(\text{scale}, \text{position}, t)dt \quad (2)$$

gdzie:

ψ – falka podstawowa.

Jedną z przyczyn dlaczego wybrano ten rodzaj przekształcenia jest to iż ma ona tę wyższość nad tradycyjną analizą fourierowską, że wyniki analiz podawane są w dziedzinie czasu i częstotliwości, co jest szczególnie przydatne przy analizie sygnałów sporadycznych i nieciągłych.

Falka podstawowa nie jest zawsze sztywno określona, musi jednak spełniać pewne kryteria. Musi mieć m.in. skończoną energię oraz wartość średnią równą zero. Natomiast funkcja skalująca danej falki ma wartość średnią różną od zera. Te wymagania sprawiają, że falka ma postać krótkotrwałej charakterystycznej oscylacji jak na rys.4, stąd wywodzi się jej nazwa. Rozróżniamy wiele typów rodzin falek, które można stosować do analizy sygnałów jednowymiarowych ale także analizy obrazów takich jak dekompozycję oraz kompresje. W przeprowadzonych badaniach poddano transformacji sygnały przy pomocy falek tj. Haar, Daubechies, Coiflets, Morlet oraz Mexican hat. Ich wspólnymi cechami są mianowicie dokładna rekonstrukcja skompresowanego sygnału czy transformacja ciągła. W zależności od użytej falki podstawowej można określić różne cechy sygnału. Falka Mexican hat nadaje się do oceny rozkładu ekstremów sygnału, a falka Morleta do rozkładu amplitud częstotliwości składowych sygnału.




Rys. 4. Falka podstawowa Mexican hat

Posiadanie dodatkowych cech takich jak symetryczność pozwoliło ocenić funkcję falkową Mexican hat jako najlepiej reprezentującą charakter badanych sygnałów.

W eksperymencie na bieżąco kolejne sygnały były poddawane przekształceniom falkowym w skali z przedziału od 1 do 30 według funkcji (1). Jest to przedział wystarczający aby zostały wykryte wszystkie ekstrema sygnału. W wyniku transformaty CWT powstaje widmo parametryczne sygnału stworzone w programie USTracker jak na rys. 5.

Chociaż stworzenie widma współczynników wydaje się trywialne to wstępna interpretacja stawia wiele pytań. Wartości skali w jakiej analizowany jest sygnał określa szerokość falki oraz pozycje na których nastąpi wyliczenie wzajemnej korelacji falki z sygnałem. Mała skala na widmie odzwierciedla lokalne analizy sygnału, natomiast duża skala opisuje globalną analizę.



Rys. 5. Widmo współczynników sygnału dla różnych skal oraz jego wykres oryginalny (kolor zielony) i wykres współczynników dla skali 25 (kolor niebieski)

Nawiązując do rys. 5 na którym przedstawiona została transformata CWT dla sygnału numer 55. Program USTracker ma za zadanie wczytywanie kolejnych sygnałów z bufora oraz przedstawienie ich w postaci graficznej. Operator ma możliwość zweryfikowania widma sygnału widocznego w górnej części rys. 5. Kolor biały jasny oznacza najlepsze dopasowanie falki *Mexican hat* do sygnału czyli posiada najwyższą wartość współczynnika korelacji zawierającej się w przedziale -1 do 1. Korelacja może być dodatnia lub ujemna tak jak przestawia to niebieski wykres na rys. 5. Czerwona pozioma linia informuje, w której skali osiągnięto najlepszą korelację falki i badanego sygnału.


Na dolnej części wykresu na rys. 5 widoczne są dwie pionowe czerwone linie w danych punktach pomiaru. Mają one za zadanie oddzielić strefę martwą sygnału po lewej stronie wykresu oraz zbędne dane, które nie mają znaczenia także w kolejnych pomiarach. Powoduje to oddzielenie zakłóceń jakie wprowadza strefa martwa do naszych obliczeń oraz zmniejszenie wykonywanych operacji obliczeniowych co ma duże znaczenie podczas przesyłu danych w trybie on-line z dużą częstotliwością. W celu śledzenia konkretnego punktu próbki w pikie zaznaczamy na oryginalnym wykresie współrzędne, które są wyświetlane na bieżąco. Następnie uruchamiany jest proces analizy, który rozpoczyna pobieranie kolejnych sygnałów oraz ich porównywanie. Efektem czego jest wyznaczenie przybliżonego położenia próbki we wszystkich sygnałach pochodzących z badanego materiału.

4.1. Gradient generalizacji

Gradientem generalizacji czyli uogólniania można nazwać wzmocnienie pewnej reakcji na dany układ sygnałów wzmacniającej tendencję do takiego samego reagowania na inne układy sygnałów tym bardziej im bardziej są one do siebie podobne. Czyli należałoby znaleźć wzorce w podstawowym sygnale i próbować znaleźć podobne w kolejnych sygnałach.

Szukanie pików odbywa się według następującej procedury. Fragmenty analizowanego sygnału są kolejno skanowane pod kątem wartości współczynnika transformaty CWT. Stała zmiana gradientu oznacza początek pików. Czyli przed osiągnięciem szczytu możemy uznać, że jesteśmy na lewym skrzydle pików. Natomiast poza punktem szczytu wstępnie możemy uznać pomiar za prawe skrzydło pików.

Powyższy słownie opisany algorytm może rozpoznać jako pik pewien fragment analizowanego widma, który pikiem nie jest a tylko częstymi zmianami amplitud. Należy wprowadzić więc warunki przybliżonej ilości liczby próbek na szczycie pików co dałoby podstawy sądzić, że są one pikami. W znalezionym pikach należy znaleźć odwzorowanie szukanej próbki. Nie zawsze jest to pik jeżeli poszukujemy próbki w wadzie materiału. Wynik symulowanej ścieżki szukanej próbki w wadzie pokazano na rys. 6.



Rys. 6. Wykres sygnałów wraz z śledzonym położeniem próbki w defekcie badanego materiału


5. MODEL SZTUCZNEJ SIECI NEURONOWEJ

Generalnie sztuczna sieć neuronowa [6], która ma odzwierciedlać pracę ludzkich neuronów zachowuje się najbardziej szczególnie w dwóch kluczowych przypadkach. Po pierwsze wtedy gdy sieć czerpie wiedzę z wydzielonej części świata, którą mu dostarczamy. Wtedy to następuje etap postrzegania cech, które w jakiś sposób opisują badane środowisko. Następuje formowanie pewnych wag będących wskaźnikami przyswajania wiedzy przez sztuczną sieć neuronową. Po etapie nauki możemy wprowadzić sieć w inne środowisko i kazać jej się adaptować na podstawie posiadanej bazy wiedzy. Oczywiście im bardziej złożony problem mamy do rozwiązania tym bardziej doświadczona musi być sieć neuronowa.

Jedną z metod sztucznej inteligencji (ang. Artificial Intelligence) są sztuczne sieci neuronowe. Ich ważną cechą jest możliwość manipulowania

obiektami z bazy zapisanych jako dyskretne struktury danych.

W przeprowadzonym eksperymencie wykorzystano sieć Kohonen-a [3], która została nazwana przez jego twórcę samoorganizującym odwzorowaniem (ang. Self-Organizing Map - SOM). W sieci tej mamy do czynienia z uczeniem konkurencyjnym. Oznacza to, że mamy do dyspozycji jedynie wzorce wejściowe, nie posiadamy natomiast żadnych wzorców wyjściowych. Zadaniem sieci w trakcie procesu uczenia jest wytworzenie takich wzorców oraz utworzenie takiej struktury, która w najlepszy sposób będzie odwzorowywała zależności w przestrzeni wektorów wejściowych. Dla sieci SOM przygotowano do przetwarzania danych wejściowych, którymi są współczynniki CWT obliczane tak jak w rozdziale 4. Schemat obrazowy sztucznej sieci samoorganizującej się przedstawiono na rys. 7. Przedstawia on liczbę 520 kanałów wejściowych oraz wyjście zawierające mapę 60 neuronów pozwalających reprezentować odwzorowanie cech danych wejściowych, a także sumator wag wejść układu.




Rys. 7. Widok schematu sztucznej sieci samoorganizującej się

Niezależnie od mechanizmów uczenia sieci samoorganizujących się, ważną rolę odgrywa nadmiarowość (redundancja) danych uczących, bez której nie byłoby możliwe uczenie. Szerokie spektrum danych uczących zawierające wielokrotne powtórzenia podobnych wzorców stanowi "bazę wiedzy" dla sieci, z której za pomocą odpowiednich skojarzeń wyciągane są wnioski decyzyjne po przyłożeniu na wejście sieci określonego wzorca poddawanego klasyfikacji.

Wiadomo, że algorytm SOM równocześnie realizuje dwa zadania - wektorowej kwantyzacji (kompresja danych) oraz zadanie odtwarzania przestrzennej organizacji danych wejściowych.

Przeprowadzono testy dla trzech topologii sieci SOM. Trenowano takie struktury sieci jak heksagonalna (Hextop), prostokątna (GridTop) oraz losowa (Randtop).


Na rys. 8 wykazano strukturę odległości pomiędzy otrzymanymi wagami neuronów. W tym przypadku nawet otrzymanie topologii sieci prostokątnej o zbliżonych odległościach wag neuronów była trudna. Objawiało się to wyłączeniem niektórych neuronów z rywalizacji o możliwość adaptacji swoich wag a przez co generowanie martwych bezużytecznych neuronów.



Rys. 8. Wyniki trenowania sieci SOM - wektory odległości wag neuronów

Porównując otrzymane wyniki w poszczególnych eksperymentach można zauważyć, że rozwój sieci neuronowej SOM przebiega w bardzo zróżnicowany sposób w zależności od przyjętych parametrów. W wyniku obserwacji trenowania sieci neuronowej możemy dojść do wniosku, iż na rezultaty uczenia główny mają wpływ: liczba i rodzaj parametrów wejściowych jak również parametry uczenia sieci takie jak ilość epok oraz funkcja odległości sąsiedztwa neuronów. Podobnie jak w rzeczywistym systemie zmiana parametrów pracy powoduje zmianę charakterystyki tak i przy trenowaniu sieci zmiana określonych wartości powoduje odmienny jej rozwój.

Faktem jest iż do tej pory nie zdefiniowano wzorców, które opisują w jednoznaczny sposób typowych wad w materiale poddanym badaniu. Ważne jest aby zbierać jak najwięcej danych, które m.in. udostępnia program UTracker przetwarzający dane z przetwornika i podający je na wejście sieci Kohonen-a. W obecnej fazie zdiagnozowano kilka płytek kompozytowych zawierających różne wady struktury. W wyniku samoorganizacji otrzymano różne rozmieszczenie cech wejść sieci neuronowej w przestrzeni dwuwymiarowej. Mapę zwycięskich neuronów dla blisko 80 pomiarów pokazano na rys.9.



Rys. 9. Mapa zwycięstw neuronów uzyskana w wyniku eksperymentu

5.1. Wnioski z symulacji SOM

Wprowadzając dane jako parametry wejściowe do sieci neuronowej samoorganizującej się SOM


można zauważyć pewne występujące w nich prawidłowości. Okazało się, że system zachowuje się bardzo stabilnie z występowaniem regularnych map cech istotnych. Można zauważyć pewne obszary, w których powtarza się pewien schemat jak na Rys.9 występowania określonych grup parametrów.

Neurony zazwyczaj grupują się wokół innych neuronów zwycięzców. Jeśli pewne zdarzenie porządkujące ma miejsce [6], to warunkiem pojawienia się samoorganizacji jest, by oddziaływanie rozbijające porządek w systemie, było słabsze od porządkującego. W przeprowadzonych eksperymentach nie udało się uzyskać pełnej sprawności sieci.

6. SYMULACJA MODELU SYSTEMU USTRACKER W SIMULINK-U

Simulink jest programowym narzędziem do modelowania, symulacji i analizy systemów dynamicznych [4]. Program umożliwia budowanie modeli dla systemów liniowych, nieliniowych, ciągłych w czasie lub dyskretnych, mieszanych czyli dyskretno - ciągłych (hybrydowych) oraz dyskretnych ze zmiennym czasem próbkowania. Ważną zaletą programu jest jego interaktywność, co oznacza, że można zmieniać parametry układu podczas symulacji i na bieżąco obserwować rezultaty wprowadzanych zmian.

Model systemu USTracker wykonano w postaci hierarchicznego schematu blokowego, czyli graficznego. Schemat blokowy USTracker zawiera bloczki stanowiące wejście systemu odpowiedzialne za pobieranie danych oraz bloczki odpowiedzialne za przetwarzanie i wizualizację wyników. Jeden z podsystemów przetwarzających dane pokazano na Rys.10. Każdy z podsystemów zawiera jedno lub więcej wejść, wyjść oraz stanów.



Rys. 10. Schemat blokowy podsystemu dla sztucznej sieci neuronowej

Tak więc na potrzeby badań stworzono model systemu w Simulink-u podobny do programu analizującego USTracker. Jego głównym zadaniem jest możliwość tworzenia wymuszeń na wejściach systemu i obserwowanie jak zachowują się wyjście wzorcowe sztucznej sieci neuronowej. Symulacja tych wymuszeń przebiega z wykorzystaniem całkowania numerycznego. Wybór algorytmu symulacji zależy od zdolności modelu do obliczania pochodnych jego stanów ciągłych.

Obliczanie pochodnych składa się z dwóch etapów. Najpierw jest wyznaczany sygnał wyjściowy każdego bloczka, w kolejności wynikającej z sortowania przeprowadzonego

podczas etapu inicjalizacji. Następnie w każdym bloczku są obliczane wartości pochodnych na podstawie aktualnego czasu oraz wartości wejściowych i stanu bloczka. Powstały w ten sposób wektor pochodnych jest wprowadzany do algorytmu numerycznego, który jest używany do obliczenia nowego wektora stanu w następnym punkcie czasowym.

Powyższy system jest w fazie rozwojowej i jego zadaniem jest poprawa efektywności klasyfikacji wykrywanych wad w materiałach kompozytowych.

7. WNIOSKI

Metody komputerowego przetwarzania sygnałów ultradźwiękowych jakie przedstawiono w tym artykule pozwalają na dokładniejszą ocenę stanu struktury materiału kompozytowego. Ze względu na dużą różnorodność warunków badań ultradźwiękowych brak jest jakichkolwiek uniwersalnych wzorców oraz reguł regulujących ten obszar badań.

LITERATURA

- [1] Lee Fugal D. *Conceptual wavelets in digital signal processing*. San Diego, Space & Signals Technologies, 2006.
- [2] Stephane M. *A wavelet tour of signal processing*. San Diego, Academic Press, 1999.
- [3] Kohonen T. *Associative Memory: A System – Theoretical Approach*. Berlin, Springer – Verlag, 1982.
- [4] Brzózka J., Dobroczyński L. *Programowanie w Matlab*. Warszawa, Mikom, 1998.
- [5] Morse P. M., Ingard K. U. *Theoretical Acoustics*. New York, McGraw-Hill, 1968.
- [6] Osowski S. *Sieci neuronowemu w ujęciu algorytmicznym*. Warszawa, WNT, 1996.
- [7] Zimmer A.. *Identyfikacja obiektów i sygnałów - Teoria i praktyka dla użytkowników MATLABA*, Kraków, Politechnika Krakowska, 1998.



Marcin STARNACKI urodzony w 1980 r. w Siedlcach. Posiada tytuł magistra w dziedzinie projektowania sieci i systemów komputerowych. Pracownik PIT S.A. w Warszawie na stanowisku programisty. Od roku 2007 doktorant w Instytucie Badań Systemowych PAN w Warszawie. Od 2005 roku członek polskiej sekcji IEEE.