ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 2003
Seria: TRANSPORT z. 49 Nr kol. 1605

Zbigniew ŁUKASIK
Tomasz CISZEWSKI

ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH DO ROZPOZNAWANIA WZORCÓW WAD NA PODSTAWIE DANYCH POMIAROWYCH Z AUTOMATYCZNYCH BADAŃ ULTRADŹWIĘKOWYCH SZYN

Streszczenie. Artykuł opisuje zastosowanie przetwarzania sygnałów z użyciem sieci neuronowych do rozpoznawania wzorców w danych pomiarowych pochodzących z wagonu defektoskopowego, badającego szyny kolejowe metodą ultradźwiękową. Aparatura pomiarowa wagonu stosuje cyfrowe przetwarzanie sygnału, umożliwiając rejestrację wielkiej liczby danych. Stwarza to potrzebę opracowania dobrych automatycznych procedur oceny. Ze swej natury, muszą one mieć charakter statystycznej estymacji sygnału. Sieci neuronowe umo¿liwiaj' konstrukcję takich procedur.

NEURAL NETWORK BASED RECOGNITION OF SIGNAL PATTERNS IN APPLI-CATION TO AUTOMATIC ULTRASONIC TESTING OF RAILS

Summary. The paper describes application of the method of neural network learning for recognition of signal patterns in measurement data gathered by railroad ultrasound testing car. Digital conversion of the measurement signal allows for storing and processing of large quantities of data. This results in the need for effective automatic procedures of signal estimation. The paper describes application of the neural networks in designing such automatic pattern recognition procedure.

1. WSTĘP

Potrzeba automatyzacji badań ultradźwiękowych w transporcie jest oczywista ze względ na fakt, że badania prowadzone ręcznie nie zapewniają wymaganej wydajności i jakości, a ic koszt jest znacznie wyższy niż w badaniach automatycznych [1]. Przedsiębiorstwa kolejow na całym świecie używają do automatycznego ultradźwiękowego badania szyn kolejowyc tzw. wagonów defektoskopowych. Przegląd stosowanych rozwiązań można znaleźć w [5 i [7]. W Polsce stosuje się wagon opracowany przez pracowników Wyższej Szkol

Inżynierskiej w Radomiu (obecnie Politechnika Radomska) w latach osiemdziesiątych [8]. W latach 1999-2002 wagon ten został gruntownie zmodernizowany. Zastosowana została sterowana komputerowo aparatura ultradźwiękowa z cyfrowym przetwarzaniem sygnału [3, 9]. System komputerowy obsługujący tę aparaturę składa się z czterech jednostek sterujących pomiarami i umożliwiających wizualizację i analizę danych pomiarowych.

Wagon defektoskopowy używa do prowadzenia pomiarów szyn nieniszczącej metody badania - metody ultradźwiękowej [11], której zasada opiera na zjawisku odbicia fali na granicy dwóch ośrodków znacznie różniących się prędkością rozchodzenia się fali. Fala mechaniczna, wytworzona przez tzw. czujnik ultradźwiękowy, odbija się od nieciągłości struktury, takiej jak wada, wytwarzając w aparaturze rejestrującej tzw. echo. Charakterystycznymi parametrami echa są amplituda i czas rejestracji, odpowiadający głębokości położenia nieciągłości, od której nastąpiło odbicie. Jeżeli cykl rejestracji i pomiaru parametrów echa jest powtarzany przy jednoczesnym przesuwaniu głowicy względem badanego obiektu, powstaje seria pomiarów amplitudy i położenia zarejestrowanego echa, tzw. obwiednia. Na rysunku 1 została zilustrowana koncepcja tworzenia serii pomiarów.

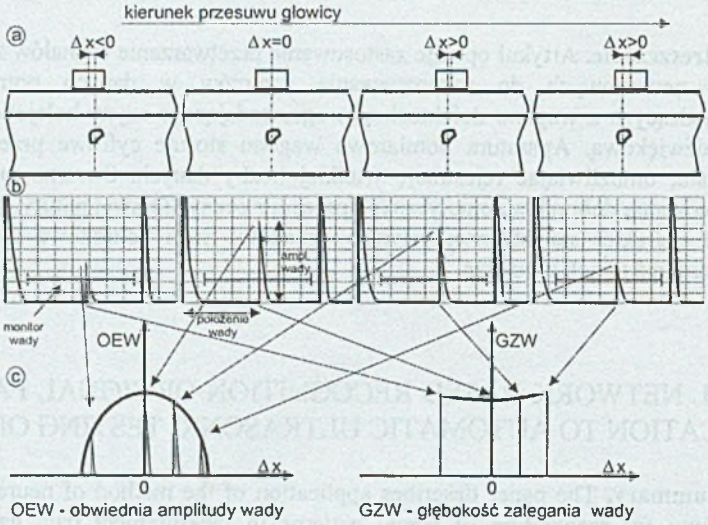

Rys.1. Zasada tworzenia obwiedni sygnału a) przedstawiony jest ruch głowicy ultradźwiękowej, b) odpowiadające mu echa ultradźwiękowe rejestrowane przez aparaturę, c) formowane obwiednie amplitudy i położenia echa wady

Fig.1. Signal envelope construction a) probe movement, b) corresponding ultrasonic echoes, c) amplitude envelope and location envelope

W wagonie defektoskopowym pomiary są realizowane nie przez jedną, ale przez 7 do 9 głowic (normalne i kątowe 45°, 72°, badania prowadzone są metodą echa i tandem). Rejestrując wszystkie echa przy rozdzielczości pomiaru rzędu 1 cm i prędkości pomiarowej ok. 50 km/h uzyskano by olbrzymi strumień danych (rzędu 10 MB/s). Dlatego też aparatura wyposażona jest w sprzętowe dyskryminatory amplitudy (tzw. monitory), dopuszczające do rejestracji jedynie tych ech, które spełniają przynajmniej jedno z kryteriów rejestracji (np. są odpowiednio duże, odpowiadają wadom położonym w ściśle określonym fragmencie szyny, ...). Dzięki temu strumień danych zmniejsza się do ok. kilkudziesięciu kB/s. Mimo

wszystko, przy typowym dziennym badaniu odcinka o długości około 100 km, gromadzone są dane o objętości rzędu 500 MB.

W trakcie rejestracji pomiarów realizowane są proste, automatyczne procedury oceny wad, bazujące na progowych rozstrzygnięciach. Gruntowna obróbka danych zachodzi po zakończeniu pomiarów, jej zadaniem jest połączenie cząstkowych wyników w mapę rozłożenia wad w badanej szynie. Opracowany system umożliwia przejrzystą wizualizację zarejestrowanych wad i prostą korekcję wyników automatycznych procedur oceny. Jednak w praktyce obsługa wagonu zazwyczaj akceptuje bez poprawek wyniki działania procedur oceny.

Wielka liczba surowych danych pomiarowych praktycznie uniemożliwia ich obróbkę przez człowieka. Wytwarza to potrzebę doskonalenia procedur automatycznej oceny wad. Jednocześnie konstrukcja takich procedur napotyka wielką przeszkodę – brak jest informacji korygującej pochodzącej od eksperta. Tworzy to pewien paradoks, który można próbować rozwiązać, stosując statystyczną obróbkę danych pomiarowych, przy czym jej celem nie jest jedynie wypracowanie pewnych deskryptorów zgromadzonego zbioru danych, ale także konstrukcja procedur statystycznej oceny nowych danych pomiarowych. Jest to typowe zadanie uczenia się na podstawie danych, naturalne jest więc sięgnięcie w tym przypadku po metody uczenia się maszyn (ang. *machine learning*). Jedną z takich metod jest zastosowanie sztucznych sieci neuronowych [2, 12].

2. WSTĘPNE PRZETWARZANIE I WYKORZYSTYWANIE DANYCH, METODOLOGIA EKSPERYMENTÓW

Do eksperymentów użyte zostały wyniki pomiarów dokonanych przez wagon defektoskopowy. Wybrana została część pomiarów, która została oceniona już przez operatora, pochodząca z odcinka wzorcowego, w którym utworzono sztuczne modele typowych wad występujących w torach kolejowych. Odcinka tego używa się do kalibracji aparatury przed przeprowadzeniem pomiarów. Wykrywanie sztucznych wad w odcinku wzorcowym jest gwarancją wykrywania rzeczywistych wad na szlaku. Zgodnie z tą samą filozofią, uznano, że poprawne rozpoznawanie wzorców w sygnałach pomiarowych z odcinka wzorcowego świadczy o przydatności tej technologii do rzeczywistych warunków pomiarowych. Dostępne zapisy badań kalibracyjnych obejmowały jazdy próbne przeprowadzane w różnych warunkach, w szczególności przy różnym stopniu zużycia głowic, przy jeździe z różną prędkością, a także z różnymi stałymi impulsatora drogi[1] (a więc z różną gęstością strumienia pomiarowego). Jak wspomniano, dane te są przetworzone przez operatora i wyposażone w klasyfikację określającą, czy odpowiedni fragment sygnału reprezentuje obraz wady niebezpiecznej, wady do obserwacji czy też złącza. Dostępna jest więc wiedza eksperta, niezbędna do przeprowadzenia nadzorowanego uczenia sieci. Podjęte zostały próby zastosowania różnych rodzajów sieci, m.in. zwykłej warstwowej sieci realizującej klasyfikację wzorców statycznych. Aby przygotować odpowiednie zbiory danych (trenujące i testujące), zostały przygotowane dodatkowe programy narzędziowe do wstępnego przetwarzania danych. Programy zostały napisane w języku Object Pascal (kompilator Delphi).

[1] Układ taktujący pomiary, każdy kolejny cykl pomiarowy wyzwalany jest po przebyciu zadanego odcinka drogi (obrotu obręczy, przejechania fragmentu toru), pomiary więc wykonywane są w stałych odstępach drogi, a nie czasu.

Zakres funkcjonalny tych narzędzi obejmuje m.in.:

- selekcję pomiarów źródłowych, które mają zostać umieszczone w zbiorze danych (czas pomiaru, kanał aparatury),
- ustalanie rodzajów wzorców, które zostaną umieszczone w zbiorze danych (wada niebezpieczna, wada do obserwacji, złącze),
- ustalanie podzbioru pomiarów umieszczanych w zbiorze (np. tylko informacja o amplitudzie wady albo także dodatkowo wyniki pomiaru położenia wady, itp.),
- okienkowanie sygnałów pomiarowych poprzez określenie długości okienka, a także minimalnej długości fragmentu pierwotnego wzorca, obejmowanego przez okienko,
- dodawanie do sygnału szumu o rozkładzie Gaussowskim, o zadawanej wartości średniej i wariancji,
- generację zbiorów danych (w tym zbiorów zawierających oczekiwane wartości wyjścia klasyfikatora w formacie akceptowanym przez oprogramowanie realizujące trening sieci neuronowej),
- wizualną inspekcję wygenerowanych zbiorów danych, w celu skontrolowania poprawności przeprowadzonej operacji.

Potrzeba przeprowadzania poszczególnych, wymienionych powyżej operacji wynikała z zakładanej metodologii eksperymentów.

Jako zadanie do realizacji przyjęte zostało rozpoznawanie wzorca sygnału pomiarowego tworzonego przez śrubowe złącze szynowe, w szczególności odróżnianie go od innych wzorców sygnałowych, np. wzorca wady. Ograniczono się do sygnałów pochodzących z głowic normalnych (dwa kanały aparatury). Sygnał złącza pojawia się także w kanałach z głowicami kątowymi 45°, jednak wzorzec rejestrowany przez te głowice jest inny niż wzorzec sygnału z głowic normalnych, ograniczono się więc tylko do tych ostatnich. Powodzenie w rozpoznawaniu wzorca złącza w głowicach normalnych oznacza, że sieć neuronowa jest w stanie przeprowadzić analogiczną operację dla innego wzorca sygnałowego, także dla sygnału pochodzącego z innego typu głowic. Dodatkowo, zadanie poprawnego rozpoznania wzorca złącza zawiera w sobie problem odróżnienia go od całego zbioru wzorców wywoływanych w sygnale przez wady. Mamy więc i tak do czynienia z sytuacją, kiedy konieczna jest dyskryminacja pomiędzy całymi rodzinami wzorców.

Poza eksperymentami obejmującymi rozpoznawanie na podstawie pełnej informacji: amplitudy i położenia wady, postanowiono podjąć znacznie trudniejsze próby dyskryminacji tylko na podstawie sygnału amplitudowego. Położenie wady jest dla złącza bardzo charakterystycznym parametrem – wszystkie otwory leżą na jednej głębokości. Jeśli sieć neuronowa potrafi utworzyć klasyfikator, używający do dyskryminacji głównie informacji o położeniu, przemawia to tylko na korzyść tej metody. Dobrze jest, kiedy elastyczna procedura zdolna tworzyć modele o dużej złożoności, konstruuje prosty model, jeśli ma ku temu możliwości. Jednak rozciągnięcie wniosków z eksperymentów na inne, mniej oczywiste przypadki wzorców sygnałowych, wymagało przetestowania metody w trudniejszych warunkach. Odróżnienie sygnału złącza od sygnału wady bez informacji o położeniu może być trudne nawet dla człowieka. Jest to więc bardzo wymagający test dla sztucznego systemu wnioskującego. Poza tym zawarty jest w tym aspekt ekonomiczny. Zmniejszenie strumienia danych potrzebnych do przeprowadzenia koniecznych rozstrzygnięć zawsze wiąże się z oszczędnościami.

W podobnym duchu założone zostało dodatkowe utrudnienie – pominięcie w klasyfikacji informacji z licznika drogi. Innymi słowy, w danych trenujących pomijana jest informacja o dokładnych relacjach przestrzennych między poszczególnymi próbkami wzorca. Ocalone jest jedynie naturalne uporządkowanie próbek, a więc informacja o sąsiedztwie i następstwie. Należy pamiętać, że w aparaturze wagonu stosowana jest warunkowa rejestracja pomiarów -

rejestrowane są tylko te pomiary, dla których amplituda przekracza próg dyskryminacji monitora. Oznacza to, że sąsiednie próbki pomiarów mogą reprezentować dowolnie od siebie odległe punkty toru. Odwołując się znowu do intuicji ludzkiej należy stwierdzić, że znacznie utrudnia to rozpoznanie wzorca złącza. Zilustrowane jest to na rys. 2, na którym przedstawione są wzorce złącza przy rejestracji pełnej oraz przy rejestracji warunkowej. Dla porównania pokazany jest też wzorzec wady przy rejestracji warunkowej. Widać, że najwyraźniej sieć neuronowa zdolna do dyskryminacji wzorców musi rozpoznawać subtelne relacje pomiędzy próbkami wynikające z ich sąsiedztwa i następstwa.

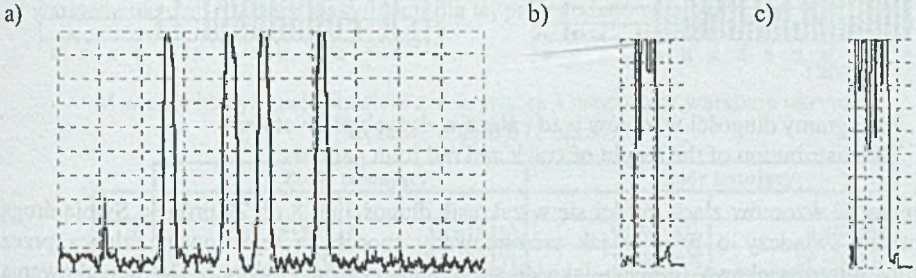

Rys.2. Wzorce sygnałów a) złącza z zachowaniem relacji przestrzennych (rejestracja pełna), b) złącz przy rejestracji warunkowej, c) wady niebezpiecznej przy rejestracji warunkowej

Fig.2. Signal patterns a) rail joint (full recording), b) rail joint (conditional recording), c) dangerous crack (conditional recording)

Do oceny jakości stworzonego klasyfikatora przyjęte zostało oszacowanie generalizacji. Dobra generalizacja jest prawdziwym celem procesu uczenia sieci neuronowej. Dobry klasyfikator nie tyle powinien być wierny danym trenującym – to można osiągnąć prawie zawsze poprzez odpowiednie zwiększenie złożoności modelu. Prawdziwym testem jest dobra dokładność klasyfikacji dla danych, które nie uczestniczyły w procesie uczenia. Na gruncie uczenia się maszyn błąd generalizacji jest zdefiniowany jako wartość oczekiwana błędu na wszystkich możliwych zbiorach danych o określonym rozmiarze i takim samym rozkładzie gęstości prawdopodobieństwa, jak cała populacja danych wejściowych. W praktyce oszacowanie to jest realizowane poprzez sprawdzenie klasyfikatora na niezależnym zbiorze testującym, pod warunkiem, że jest on odpowiednio liczny. Najczęściej przyjmowaną regułą postępowania jest wydzielenie ze zbioru wszystkich danych 30% elementów na potrzeby testowania i 70% elementów do zbioru trenującego. Jakość skonstruowanego klasyfikatora jest oceniana jako błąd na zbiorze testującym.

Do symulacji użyte zostało oprogramowanie NeuroSolutions 4.0, stosujące obiektowe podejście do modelowania sieci neuronowych. Pakiet ten jest bardzo złożonym systemem w którym można przeprowadzić symulację większości architektur sieci neuronowych.

3. ROZPOZNAWANIE ZŁĄCZA ZA POMOCĄ KLASYFIKACJI WZORCÓW STATYCZNYCH

W eksperymencie tym podjęto próbę uczenia warstwowej sieci neuronowej rozpoznawania sygnału złącza na podstawie 30-próbkowych fragmentów sygnałów, obejmujących obraz złącz i wad. Długość okienka została dobrana na podstawie histogramu długości przykładów

pochodzących z danych pierwotnych, wygenerowanych za pomocą jednego z opisanych wcześniej programów narzędziowych na podstawie pomiarów zebranych na torze próbnym z wadami sztucznymi. Histogramy te przedstawione są na rys. 3.

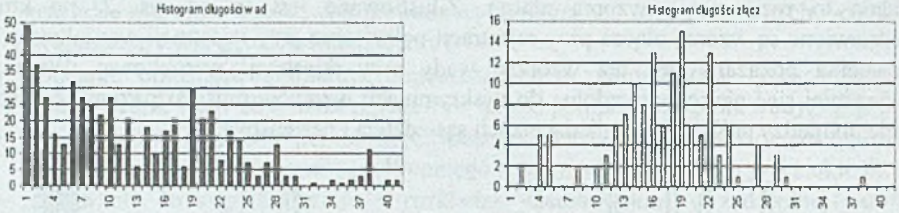

Rys.3. Histogramy długości wzorców wad i złącz w danych pierwotnych
Fig.3. The distribution of the lenght of crack and rail joint patterns

Większość wzorców złącz mieści się w zakresie długości od 8 do 29 próbek. Swoją drogą rozrzut ten świadczy o tym, w jak zróżnicowany sposób są rejestrowane złącza przez aparaturę ultradźwiękową (zmiana jakości sprzężenia głowic z szyną). Do okienkowania przyjęto wszystkie złącza o długości z tego zakresu. Jako minimalną długość wzorca w okienku przyjęto wartość 8. Ze 129 przykładów złącz z danych pierwotnych powstało w ten sposób 5128 okienek, dla których klasyfikator powinien udzielić odpowiedzi „złącze" (kodowanej w pliku z informacją o wartościach oczekiwanych jako wartość 1). Jeżeli chodzi o wzorce wad, to większość masy histogramu również mieści się w okienku o długości 30, jednak w tym wypadku minimalna przyjęta długość wady przyjęta została równa 1. W wyniku okienkowania powstało w ten sposób 21 749 przykładów, na które klasyfikator powinien udzielić odpowiedzi „nie złącze" (kodowanej jako zero). Każda próbka w okienku to dwuwymiarowy wektor, którego składowe opisują wyrażoną na jednym bajcie amplitudę i wyrażone na 1 bajcie położenie wady.

Zbiory danych zostały podzielone w stosunku 70%-30%, co dało w sumie 18 814 przykładów w zbiorze trenującym i 8063 przykłady w zbiorze testującym. Przyjęta została architektura warstwowa z jedną warstwą ukrytą z pięcioma neuronami. Zastosowany został algorytm uczenia o nazwie Delta-Bar-Delta – odmiana algorytmu wstecznej propagacji ze złożoną heurystyką adaptacji szybkości uczenia.

Rys.4. Fragment ekranu programu Neurosolutions, pokazujący zaprojektowaną architekturę sieci oraz okienka pokazujące uśredniony błąd na zbiorze trenującym i testującym, macierze klasyfikacji dla obu zbiorów oraz okienko obrazujące przebieg procesu uczenia
Fig.4. Fragment of the Neurosolutions window: neural network architecture and additional display panels showing: mean square error calculated on the training and testing set; misclassification matrices for both sets; learning progress monitor

Na rys. 4 przedstawiony został fragment okna programu Neurosolutions przedstawiający graficzny projekt sieci oraz okna wyświetlające stan procesu uczenia po przeprowadzeniu 791

iteracji. największy błąd klasyfikacji (tak złącz, jak i wad) jest rzędu 10%, zarówno na zbiorze trenującym, jak i testowym. Zważywszy, że dokładność badań ultradźwiękowych, zwłaszcza o takim charakterze, jak badania wagonowe, nie jest wyśrubowana (czego znakiem jest chociażby rozrzut długości wzorców sygnału złącza), jest to dobry wynik. Osiągnięcie takiego wyniku wymagało 791 epok uczenia. Kontynuacja uczenia od tego momentu nadal zmniejsza błąd na zbiorze trenującym, ale zaczyna wzrastać wartość błędu na zbiorze testującym, co jest wyraźnym znakiem postępującego przetrenowania sieci.

Eksperyment został powtórzony dla zredukowanej architektury, obejmującej trzy neurony w warstwie ukrytej. Macierz klasyfikacji dla tej prób podano w tabeli 1.

Tabela 1

Macierze klasyfikacji dla sieci zawierającej 3 neurony w warstwie ukrytej; uczenie objęło 672 epoki

	Zbiór trenujący		Zbiór testujący	
	0	1	0	1
0	89.381767	10.618233	95.595436	4.404568
1	4.463670	95.536331	10.095098	89.904900

Sieć nauczyła się poprawnie rozpoznawać wzorce złącza równie łatwo jak w poprzednim przypadku.

W dalszej kolejności podjęto próbę klasyfikacji w oparciu o jedynie sygnał amplitudowy. Wstępne próby wykazały, że proces uczenia dla tych samych architektur, co w poprzednich eksperymentach, jest bardzo powolny i nie daje dobrych efektów. Dlatego też zastosowano architekturę zdolną do wytworzenia silnie nieliniowej funkcji przetwarzania – sieć z dwoma warstwami ukrytymi, z 15 neuronami w pierwszej warstwie ukrytej i 5 w drugiej. Nakład obliczeniowy związany z uczeniem takiej sieci jest dużo większy. Mimo to osiągnięte wyniki nie są dużo lepsze niż dla małych sieci. Tabela 2 podaje macierz klasyfikacji dla tego przypadku po przeprowadzeni 12 600 epok uczenia.

Tabela 2

Macierze klasyfikacji dla sieci z dwoma warstwami ukrytymi (15 i 5 neuronów), uczonych przez 12600 epok

	Zbiór trenujący		Zbiór testujący	
	0	1	0	1
0	35.197552	64.802452	39.415585	60.584415
1	5.243790	94.756210	11.096434	88.903564

Z tabeli widać, że sieć ma tendencję do klasyfikowania wszystkiego jako złącza. Należy podkreślić, że skuteczność klasyfikacji rzędu 40% (suma kolumny 0) jest gorsza niż ślepy traf który daje oczekiwaną wartość błędu 50% przy dychotomicznej dyskryminacji. Tak więc sieci warstwowe przeprowadzające klasyfikację statycznych wzorców bez trudu dokonują rozpoznania wzorca przy pełnej informacji o amplitudzie i położeniu, ale testowane architektury zupełnie nie radzą sobie z zagadnieniem rozpoznawania wyłącznie na podstawie informacji amplitudowej.

4. WNIOSKI

W wyniku przeprowadzonych eksperymentów pokazane zostało, że adaptacyjne, nieliniowe schematy przetwarzania sygnału, takie jak sieci neuronowe, nadają się dobrze do obróbki danych pomiarowych. Sieci wykazały zadowalającą pewność klasyfikacji. Niestety, dla zbadanego podejścia (rozpoznawanie wzorców statycznych) nie ujawniła się możliwość ograniczenia danych niezbędnych do podjęcia charakterystycznych dla badanego procesu pomiarowego decyzji, co pozwoliłoby ograniczyć wielkość rejestrowanego przez system strumienia danych. Być może lepsze wyniki uda się autorom uzyskać przy zastosowaniu metod klasyfikacji dynamicznej i zastosowaniu sieci neuronowych w architekturze z pamięcią.

Przedstawione badania dotyczą rozpoznawania jedynie dwu klas wzorców, jednak zdaniem autorów, przy dostarczeniu odpowiednio dużej ilości sklasyfikowanych danych trenujących, możliwe byłoby jej zastosowanie w systemie rozpoznającym wiele klas.

Literatura

1. Bałuch H.: Diagnostyka nawierzchni kolejowej. WKi£, Warszawa 1978.
2. Bishop C. M.: Neural Networks for Pattern Recognition, Oxford University Press, 1997.
3. Bojarczak P., Ciszewski T., Gołąbek P., Korneta A., Lesiak P., Rojek B., Wieczorek D.: Nowa inteligentna aparatura ultradźwiękowa do badania szyn w torze. Materiały XXIX Krajowej Konferencji Badań Nieniszczących, Krynica 2000, s. 187-194.
4. Ciszewski T., Gołąbek P., Lesiak P.: Rozpoznawanie wzorców w defektoskopowych danych pomiarowych za pomocą sieci neuronowych. Zastosowanie Komputerów w Nauce i Technice, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej, nr 18, Gdańsk 2002, s. 27-32.
5. Ciszewski T.: Metoda kompresji i obróbki sygnałów w automatycznych badaniach ultradźwiękowych szyn i obręczy kół kolejowych. Praca doktorska, Wydział Transportu Politechniki Radomskiej, Radom 2003.
6. Korneta A., Rojek B.: Problemy ultradźwiękowych badań automatycznych. Pracownia ultradźwiękowych badań materiałów IPPT PAN, Biuro Gamma, Wykłady seminaryjne: Ultradźwiękowe badania materiałów, Zakopane, marzec 1997, s. 4.1-4.23.
7. Lesiak P.: System for Automatic Ultrasonic Quality Control of Railroad Rails, Russian Journal Of Nondestructive Testing, Vol. 28:7, 1992, pp. 383 388.
8. Lesiak P., Wojutyński J.: Opracowanie i wykonanie elektronicznych układów pomiarowych i analizujących oraz wagonu pomiarowego do defektoskopowej kontroli szyn w torze, WSI, Radom 1986.
9. Lesiak P., Bojarczak P., Ciszewski T., Gołąbek P., Wieczorek D.: Opracowanie i wykonanie aparatury defektoskopowej wraz z oprogramowaniem dla wagonu pomiarowego do ultradźwiękowego badania szyn kolejowych. Wydział Transportu Politechniki Radomskiej, Radom 2000.
10. Pniewski R.: Komputerowe systemy gromadzenia i przetwarzania danych w defektoskopii ultradźwiękowej. Praca doktorska, Wydział Elektryczny Politechniki Warszawskiej, Warszawa 1996.
11. Śliwiński A.: Ultradźwięki i ich zastosowania, WNT, Warszawa 1993.
12. Żurada J., Barski M., Jędruch W.: Sztuczne sieci neuronowe. Wydawnictwo Naukowe PWN, Warszawa 1996.

Recenzent: Dr hab. Andrzej Nowak

Abstract

The paper describes application of the method of neural network learning for recognition of signal patterns in measurement data gathered by railroad ultrasound testing car. Digital conversion of the measurement signal allows for storing and processing of large quantities of data. This results in the need for effective automatic procedures of signal estimation. The paper describes application of the neural networks in designing such automatic pattern recognition procedure.

Authors examine a few neural network architectures suitable to recognize static patterns. The main task was to recognize signal pattern created by rail joint and especially distinguish it from other signal patterns, e.g. crack pattern. Only signals gathered by normal probes (0°, two flaw detector channels) were analyzed.

Because the automatic measurement systems, such a railroad ultrasound testing car, produce large quantities of data the test of recognition in case of limited information was done (concluding only on the basis signal amplitude). In this case tested neural network architecture didn't manage task. In case of full information neural network without difficulty recognized static signal patterns.

Presented test shows only two pattern class recognition. In authors opinion if we deliver enough quantity of classified training data, presented method is applicable in a system that recognizes many classes.