

Zastosowanie sztucznych sieci neuronowych do klasyfikacji uszkodzeń układów biegowych pojazdów szynowych za pomocą sygnałów wibroakustycznych

Praca przedstawia wyniki badań dotyczących możliwości wykorzystania sygnałów wibroakustycznych do określania (klasyfikacji) uszkodzeń układów biegowych pojazdów szynowych i stanowi kontynuację artykułu [2] w oparciu o nową serię pomiarów, jak też w oparciu o zastosowanie innych metod przetwarzania sygnałów pomiarowych.

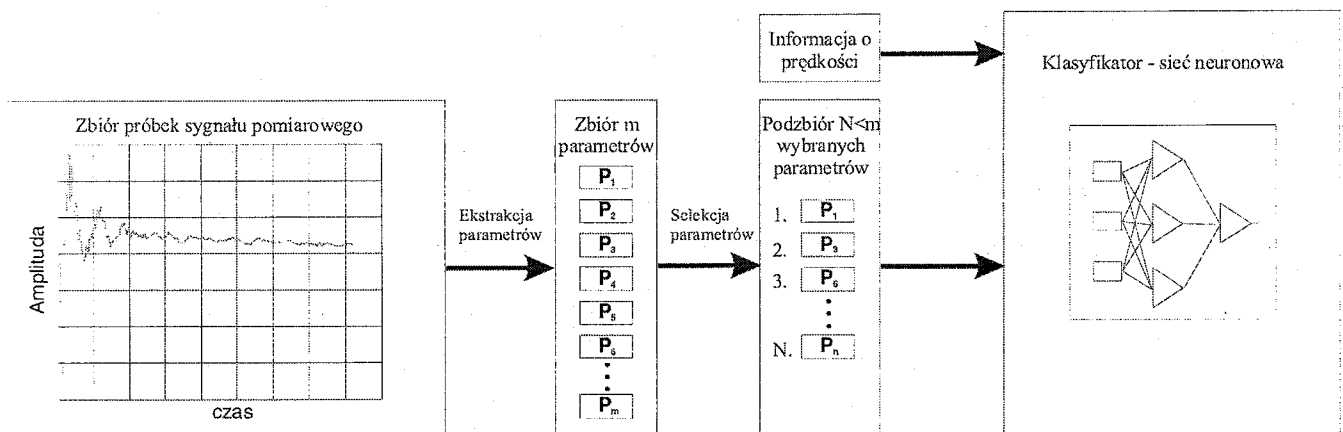
1. Wstęp

Celem pracy jest odpowiedź na pytanie czy sygnały wibroakustyczne rejestrowane w szynie niosą dostateczną informację pozwalającą na wiarygodne wykrywanie na ich podstawie uszkodzeń układów biegowych przejeżdżających pojazdów. Dodatkowym celem pracy było też przebadanie i zaproponowanie efektywnych procedur ekstrakcji cech istotnych z sygnału wibroakustycznego oraz metod klasyfikacji z zastosowaniem sieci neuronowych pozwalających przeprowadzić możliwie poprawną klasyfikację uszkodzeń. Praca niniejsza jest częścią tematu badawczego, którego genezę i aspekty pomiarowe omówiono w artykułach [2,3,4]. Prace realizowane były w ramach projektu badawczego nr 9 T12C 017 15 pt. „Wybór sygnałów wibroakustycznych oraz metod ich przetwarzania i analizowania dla oceny stanu technicznego układu biegowego pojazdów szynowych”.

W odróżnieniu od eksperymentów opisanych w artykule [2] znacznie rozszerzony został zbiór danych pomiarowych (patrz tabela 1) - przeprowadzono 82 nowe pomiary o numerach 72-153. Część nowych pomiarów, tak jak poprzednio, dotyczyła braku uszkodzenia oraz uszkodzenia sprężyny zawieszenia I stopnia w wózku, symulowanego jej zablokowaniem. Pozostałe pomiary zostały przeprowadzone podczas symulacji awarii tłumika ciernego, jako nowego typu uszkodzenia. W ten sposób wszystkie pomiary można przypisać do

jednej z 3 klas (brak uszkodzenia i 2 typy uszkodzeń), co pozwala na przeprowadzenie znacznie głębszej analizy możliwości wykrywania wielu uszkodzeń jednocześnie, a nie tak jak dotychczas jedynie uszkodzenia lub braku uszkodzenia. Część nowych pomiarów (o numerach 109-116 i 122-153) zostało przeprowadzonych przy wyższych prędkościach przejazdu wagonu na odcinku pomiarowym ($10 < v < 16$ km/h). Przy tak dużej prędkości widmo sygnału znacznie różni się od widm sygnałów pomierzonych przy prędkościach 2-4 km/h i tym samym połączenie pomiarów o tak zróżnicowanych prędkościach w jeden zbiór znacznie komplikuje problem klasyfikacji w sytuacji braku jakiegokolwiek informacji o prędkości ruchu wagonu. Z tej przyczyny uwzględniono informację o prędkości jako jeden z parametrów podawanych na wejście systemu klasyfikującego.

Cały schemat przetwarzania sygnałów pomiarowych (system klasyfikacyjny) przedstawiony na rys. 1 jest podobny do modelu zaproponowanego i uzasadnionego w poprzedniej pracy. Składa się z 2 zasadniczych faz: fazy wydobywania cech istotnych (parametryzacja) z fragmentów sygnałów wibroakustycznych przedstawionych w dziedzinie czasu i w dziedzinie widma oraz fazy klasyfikacji. Wybrane cechy istotne po połączeniu z innymi dostępnymi informacjami np. o prędkości przejazdu stanowią zbiór parametrów podawanych na wejście systemu klasyfikującego. Systemem



Rys. 1. Schemat systemu klasyfikacyjnego wykorzystanego w eksperymentach opisanych w pracy

klasyfikującym może być w tym wypadku algorytm oparty o pewne kryterium geometryczne przynależności przykładów do pewnych obszarów (klastrów) w przestrzeni parametrów,

drzewo decyzyjne lub sieć neuronowa. Ze względu na nieliniowość problemu jak też ciągłość występujących tu wartości parametrów, najlepsze perspektywy przedstawia ta ostatnia.

Tabela 1

Zestawienie pomiarów

Pomiary przeprowadzone w okresie od 11.1999 do 03.2000						Pomiary przeprowadzone od 03.2000 – nowa grupa pomiarów					
Lp.	Data pomiaru	typ uszkodzenia	typ wymuszenia	typ czujnika	V [km/h]	Lp.	data pomiaru	typ uszkodzenia	typ wymuszenia	typ czujnika	V [km/h]
1	19.11	brak	blaszka	Piezo	2	72-74	30.05	tłu	blaszka	piezo	2
2-6	19.11	brak	blaszka	Piezo	4	75-86	30.05	tłu	blaszka	piezo	4
7-9	19.11	spr	blaszka	Piezo	4	87-89	30.05	tłu	blaszka	poj	2
10-13	19.11	spr	blaszka	Piezo	2	90-101	30.05	tłu	blaszka	poj	4
14-15	08.03	spr	klin	Piezo	2	102-106	31.05	tłu	klin	piezo	4
16-18	08.03	spr	blaszka	Piezo	2	107-108	31.05	tłu	klin	piezo	2
19-22	08.03	spr	blaszka	Piezo	4	109-112	31.05	tłu	klin	piezo	10-16
23-24	08.03	spr	klin	Piezo	4	113-116	31.05	tłu	blaszka	piezo	10-16
25-27	08.03	spr	klin	Piezo	2	117-120	31.05	tłu	klin	poj	4
28	09.03	spr	klin	Ind	2	121	31.05	tłu	klin	poj	2
29-31	09.03	spr	blaszka	Ind	2	122-124	31.05	tłu	klin	poj	10-16
32-36	09.03	spr	blaszka	Ind	4	125-126	31.05	tłu	blaszka	poj	10-16
37	09.03	spr	klin	Ind	2	127-130	08.06	brak	klin	piezo	10-16
38-40	09.03	spr	klin	Ind	4	131-133	08.06	brak	blaszka	piezo	10-16
41	09.03	spr	klin	Ind	0	134-136	08.06	spr	blaszka	piezo	10-16
42	09.03	spr	klin	Ind	2	137-139	08.06	spr	klin	piezo	10-16
43	09.03	spr	blaszka	Ind	2	140	08.06	spr	blaszka	piezo	10-16
44-46	30.03	brak	blaszka	Piezo	2	141-144	08.06	brak	klin	poj	10-16
47-49	30.03	brak	blaszka	Piezo	4	145-147	08.06	brak	blaszka	poj	10-16
50-51	30.03	brak	Klin	Piezo	2	148-150	08.06	spr	blaszka	poj	10-16
52-56	30.03	brak	Klin	Piezo	4	151-152	08.06	spr	klin	poj	10-16
57-59	30.03	brak	Blaszka	Poj	2	153	08.06	spr	blaszka	poj	10-16
60-63	30.03	brak	Blaszka	Poj	4	Zastosowane skróty: spr-uszkodzenie sprężyny, tłu-uszkodzenie tłumika, poj-czujnik pojemnościowy, ind-czujnik indukcyjny					
64-66	30.03	brak	Klin	Poj	2						
67-71	30.03	brak	Klin	Poj	4						

W artykule przedyskutowano sposób podziału danych na podzbiory do uczenia i testowania, opisano zastosowaną metodę ekstrakcji i selekcji cech istotnych, gdzie podano też wyniki klasyfikacji uzyskane w zależności od wyboru zakresu częstotliwości widma sygnałów pomiarowych, omówiono wpływ struktury sieci neuronowej na jakość klasyfikacji oraz dodatkowo przedstawiono wykresy obrazujące rozmieszczenie przykładów z różnych klas po transformacji przestrzeni wybranej grupy parametrów do dwóch wymiarów przy pomocy metody PCA (Principal Component Analysis).

Nie wszystkie sposoby rozwiązania problemu, zarówno wydobywania cech jak i samej klasyfikacji, dostępne w literaturze jak i autorskie były możliwe do zweryfikowania z powodu małej liczby sygnałów pomiarowych, dlatego w ostatnim punkcie przedstawiono dyskusję dotyczącą możliwości poprawienia jakości klasyfikacji, dzięki m. in. ewolucyjnym metodom selekcji parametrów, zastosowaniem innych metod wydobywania cech zwłaszcza w dziedzinie czasu, jak też niekonwencjonalnym (dedykowanym dla konkretnego problemu) metodom budowy sieci neuronowej.

2. Sposób przeprowadzenia eksperymentów

2.1. Podział zbioru przykładów na podzbiory do testu i nauki

Głównymi założeniami podziału było z jednej strony zapewnienie niezależności systemu klasyfikującego od przykładów testowych tak, żeby na podstawie wyników klasyfikacji tych przykładów można było przewidzieć zachowanie systemu w stosunku do sygnałów pomierzonych w przyszłości już w trakcie pracy gotowego systemu, a z drugiej strony zapewnienie odpowiedniej reprezentacji przykładów do nauki pozyskanych w różnych okolicznościach tzn. w różnych warunkach pogodowych, przy różnych prędkościach przetaczania wagonów, różnych typach czujników i wymuszeniach. Niestety, ze względu na małą liczbę przykładów w stosunku do różnorodności tych atrybutów oba powyższe założenia mogą być spełnione tylko częściowo, dlatego zdecydowano się na zbadanie jakości klasyfikacji dla dwóch różnych metod podziału.

Pierwsza metoda podziału na przykłady o numerach parzystych do nauki i nieparzystych do testowania spośród 153 przykładów ułożonych w kolejności chronologicznej opiera się na pewnym intuicyjnym spostrzeżeniu, że warunki w jakich wykonywane były pomiary niewiele zmieniały się w długich okresach czasu i dzięki temu można założyć, że zarówno w zbiorze do nauki jak i testowym pomiary przeprowadzane w różnych warunkach (z różnymi atrybutami) są dobrze reprezentowane. Metoda ta jednak nie uwzględnia innych, nieznanych warunków dokonywania pomiarów, które mogą wystąpić w przyszłości i znacznie pogorszyć jakość klasyfikacji nieprzygotowanego do nich systemu.

Wadę tę częściowo eliminuje druga metoda podziału polegająca na losowaniu przykładów do nauki i testu z podzbiorów przykładów odpowiadających poszczególnym klasom uszkodzeń. Jednak i tutaj można się spodziewać uzyskania wyników przesadnie pesymistycznych, co związane jest z małą liczbą przykładów. Należy spodziewać się, że przy dużej liczbie pomiarów w różnych warunkach wzrośnie prawdopodobieństwo pełnej reprezentacji wszystkich atrybutów w zbiorze do nauki i tym samym oczekiwana rzeczy-

wista jakość klasyfikacji mierzona procentowym błędem klasyfikacji przykładów testowych będzie zbliżała się do wyniku uzyskanego z zastosowaniem metody podziału na zbiory parzyste i nieparzyste.

2.2 Parametryzacja

Parametryzacja polega z grubsza na wydobyciu możliwie najlepiej dyskryminującej grupy cech sygnałów na podstawie wszelkich dostępnych informacji tzn. cech najbardziej charakterystycznych pod względem przynależności poszczególnych sygnałów do klas. W tym wypadku źródłem informacji wejściowej do parametryzacji jest ciąg próbek sygnału w dziedzinie czasu i w dziedzinie widma po przeprowadzeniu transformacji FFT z fragmentu sygnału pomiarowego dotyczącego zjazdu pierwszego koła wózka wagonu z elementu wymuszającego. Znalezienie optymalnego zbioru parametrów nie jest zadaniem łatwym ze względu na dużą nieliniowość problemu optymalizacyjnego i brak dokładnych kryteriów oceny przydatności grup parametrów. Najważniejszymi zadaniami parametryzacji jest ekstrakcja cech czyli wydobycie najbardziej wartościowych dla potrzeb klasyfikacji parametrów z nieobrobionego sygnału oraz selekcja tak uzyskanych parametrów czyli określenie optymalnej ich liczby i wybór najlepszego ich zestawu do celów klasyfikacji.

Dla oceny jakości grup parametrów, czyli stopnia separowalności przykładów należących do poszczególnych klas w oparciu daną grupę parametrów możliwe jest skorzystanie z różnych kryteriów oceny stopnia złożoności problemu. Literatura [1,5,12] podaje wiele takich kryteriów związanych z odległością poszczególnych klas od siebie (kryterium odległościowe), estymatorami wariancji i wartości średnich dla poszczególnych parametrów (test Bahrensa-Fishera), jak i kryteria bazujące na macierzy kowariancji klas (odległość Mahalonobisa). Jednak wszystkie powyższe kryteria tylko w stopniu mniej lub bardziej adekwatnym do typu problemu przybliżają rzeczywistość jego złożoność. W tej sytuacji najlepszym kryterium oceny separowalności wydaje się użycie samego klasyfikatora i zmierzenie błędu klasyfikacji przykładów testowych.

2.2.1. Ekstrakcja parametrów

Ze względu na bardzo dużą wymiarowość sygnałów pomiarowych (od 3280 do 16384 próbek dla każdego sygnału) ekstrakcja najbardziej istotnych cech może odbywać się drogą eksperymentalną przy pomocy programowania ewolucyjnego z każdorazowym sprawdzaniem przydatności parametrów przy użyciu systemu klasyfikującego umożliwiającego obliczenie średniego błędu klasyfikacji przykładów testowych. Jest to metoda bardzo czasochłonna obliczeniowo i wymagająca dużej liczby przykładów zapewniającej odpowiednią wiarygodność oceny przydatności parametrów. Drugą możliwością ekstrakcji parametrów jest częściowo intuicyjny, a częściowo poparty literaturą wybór rozwiązań stosowanych w praktyce przetwarzania tego typu sygnałów. W pracy wykorzystano tę drugą metodę i skupiono się na średnich amplitudach w wybranych przedziałach częstotliwości widma sygnału znormalizowanych względem średniego widma całego sygnału (wzór 1),

$$P_i = \frac{n_{i2} - n_{i1}}{N_2 - N_1} \frac{\sum_{j=n_{i1}}^{n_{i2}} |X_j|}{\sum_{j=N_1}^{N_2} |X_j|}, \quad (1)$$

gdzie:

- P_i jest wartością i -tego parametru,
- X_j , $j = N_1, N_1+1, \dots, N_2$ jest widmem pomierzonego sygnału,
- n_{i1} , n_{i2} oznaczają numery pierwszej i ostatniej próbki widma sygnału w i -tym przedziale częstotliwości.

Dodatkowo przetestowano przydatność momentów widmowych oraz niektórych parametrów w dziedzinie czasu.

2.2.2. Selekcja parametrów

Traktując każdy parametr jako współrzędną można wyobrazić sobie każdy przykład do nauki lub testu jako punkt w N -wymiarowej przestrzeni, gdzie N -liczba parametrów w wybranym zbiorze parametrów. Budowa systemu klasyfikującego w fazie następczej polega na znalezieniu takiej funkcji f , która przyporządkowuje każdemu przykładowi do nauki odpowiednią klasę i jednocześnie aproksymuje nieznaną funkcję f^* realizującą to przyporządkowanie również dla przykładów nieprzyjętych do nauki, w tym przykładów testowych oraz nieznanych w danej chwili, ale możliwych do pozyskania w przyszłości. Zdolność takiej aproksymacji, inaczej uogólniania lub generalizacji, wiąże się z wyznaczeniem w trakcie nauki pewnych obszarów w przestrzeni parametrów w otoczeniu punktów odpowiadających przykładom do nauki. Im większa jest wymiarowość przestrzeni parametrów (więcej parametrów), tym łatwiej jest znaleźć funkcję f , ale mniejsze jest prawdopodobieństwo, że funkcja ta dobrze aproksymuje funkcję f^* za względu na wzrost ilości możliwych funkcji realizujących to samo odwzorowanie w oparciu o zbiór przykładów do nauki, ale źle klasyfikujących pozostałe przykłady. Istnieje pewien optymalny (dla znanego zbioru przykładów) zbiór parametrów o optymalnej liczności trudny do wyznaczenia nawet w przybliżeniu ze względu na brak dokładnych kryteriów oceny stopnia złożoności problemu objawiającego się w dużej mierze rodzajem rozkładu wartości parametrów wokół wartości średnich. Przy założeniu rozkładu losowego i pewnych uproszczeniach w pracy Vapnika i Chervonenkisa ([6], str.184) podane zostały wzory uzależniające błąd klasyfikacji wszystkich przykładów od liczby przykładów do nauki oraz złożoności sieci neuronowej związanej między innymi z liczbą parametrów wejściowych. Przy mniej oczywistych rodzajach rozkładów optymalna liczba parametrów może być wyznaczona jedynie eksperymentalnie na podstawie dużej liczby prób nauki i testowania systemu klasyfikującego przy różnych zestawach parametrów.

2.3. Metody klasyfikacji

Jako standardowego klasyfikatora użytego we wszystkich eksperymentach opisanych w pracy wykorzystano sieć neuronową dwuwarstwową z propagacją wsteczną błędów [1,6,7,13]. Sieć uczona była metodą wsadową (*batch learning*) przy pomocy algorytmu Levenberga-Marquardta [7] na podstawie zbioru przykładów do nauki, a następnie testowana na całym zbiorze przykładów (uczącym i testującym) i jeśli bezbłędnie klasyfikowała wszystkie przykłady do nauki to wynik klasyfikacji przykładów testowych wliczany był do średniej.


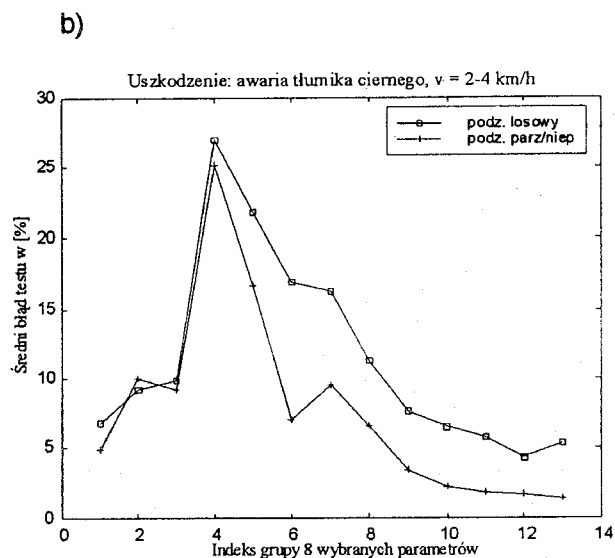
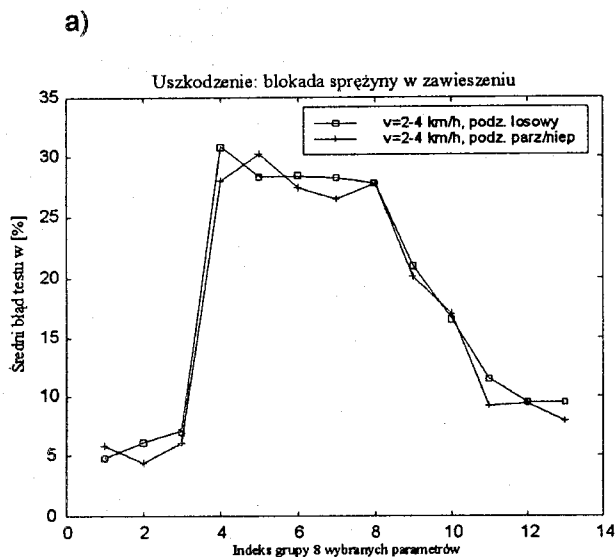
W pracy zrezygnowano na obecnym etapie z użycia drzew decyzyjnych jako mniej przydatnych w przypadku ciągłych wartości parametrów, chociaż w praktycznych zastosowaniach systemu klasyfikacyjnego może zaistnieć potrzeba wstępnego podziału zbioru przykładów w oparciu o pewne parametry o wartościach symbolicznych lub dyskretnych np. różne rodzaje czujników, różne klasy uszkodzeń itd.

2.4. Sposób oceny jakości klasyfikacji i podział problemu klasyfikacji

Korzystając ze zbioru 153 sygnałów pomiarowych wraz z informacją o prędkości przetaczania wagonów po odcinku pomiarowym (tabela 1), oraz na podstawie modelu przedstawionego na rys. 1 wykonano szereg symulacji komputerowych systemu klasyfikującego z zastosowaniem pakietu Matlab. Głównym kryterium oceny każdej wersji systemu był średni błąd klasyfikacji przykładów testowych, nie używanych podczas budowy i nauki systemu. Każdorazowo obliczane było również odchylenie standardowe błędów klasyfikacji w celu sprawdzenia wiarygodności uzyskanych wyników. Zarówno błąd testu jak i odchylenie standardowe tego błędu obliczane były tylko dla nauki sieci neuronowej zakończonej pełnym sukcesem, tj. zerowym błędem klasyfikacji przykładów użytych do nauki. Ze względu na duże różnice w przebiegu widma sygnału dla małych i dużych prędkości przetaczania wagonów zdecydowano się na podział problemu klasyfikacji dla prędkości 2-4 km/h oraz 10-16 km/h. Kolejny podział problemu dotyczy podziału przykładów związanych z uszkodzeniem na dwie klasy uszkodzeń: uszkodzenie sprężyny w zawieszeniu oraz awarię tłumika ciernego. Powodem oddzielnego klasyfikowania obu uszkodzeń jest różny charakter badanych uszkodzeń objawiający się potencjalnie różnymi optymalnymi zakresami częstotliwości wydobywania parametrów, różnymi prędkościami ruchu wagonów sprzyjającymi wykryciu różnych uszkodzeń oraz różnym stopniem złożoności problemów klasyfikacji różnych uszkodzeń.

3. Wyniki eksperymentów

Ze względu na zbyt małą liczbę sygnałów pomiarowych po dotychczasowych pomiarach w stosunku do złożoności problemu, nie pozwalającą na uzyskanie wiarygodnych wartości kryteriów porównawczych, parametryzacja ograniczona została do intuicyjnego wyboru 8-9 parametrów jako optymalnej liczby parametrów podanej na wejście sieci neuronowej. W większości eksperymentów wykorzystano średnie wartości amplitud widma sygnału w wybranych przedziałach częstotliwości (według wzoru 1) wraz z informacją o prędkości jako standardowy zbiór parametrów. Ponadto porównano jakość klasyfikacji parametrów uzyskanych z sygnału w dziedzinie czasu, jak również momentów widmowych w dziedzinie częstotliwości. Jednak wyniki tych symulacji okazały się nieco gorsze od wyników symulacji dla standardowego zbioru parametrów. W przypadku parametrów w dziedzinie czasu głównym problemem okazały się trudności związane z wyznaczeniem chwili spadku koła z przeszkody oraz duża zmienność obwiedni amplitudy sygnału związana prawdopodobnie z różnymi warunkami wykonywania pomiarów, natomiast momenty widmowe prawdopodobnie nie wniosły żadnej nowej informacji w stosunku do zbioru parametrów standardowych.



d)

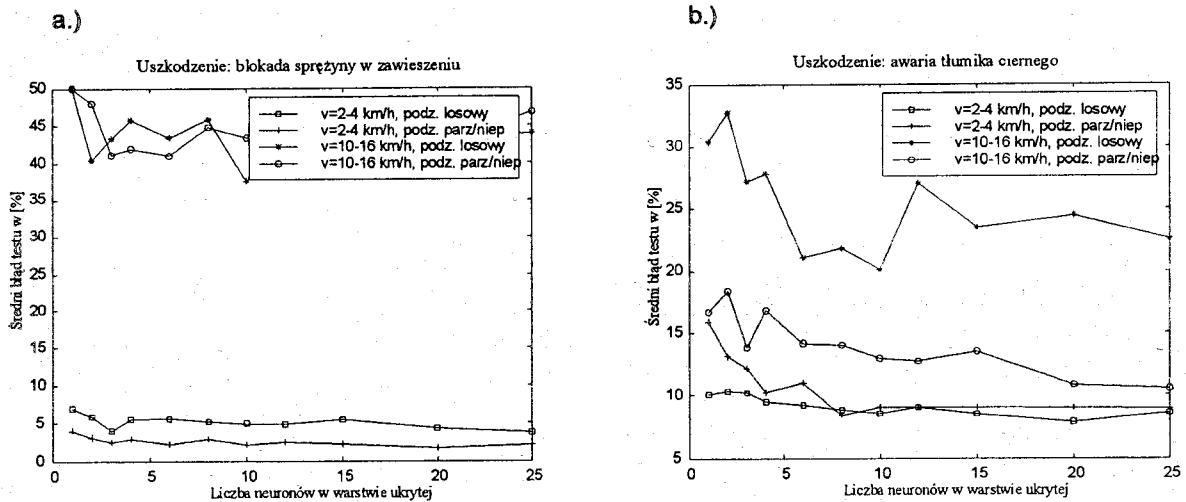
Indeksy grup parametrów i odpowiadające im przedziały częstotliwości

Indeksy	Przedziały
1	20-300 Hz
2	30-370 Hz
3	50-450 Hz
4	80-550 Hz
5	110-700 Hz
6	140-900 Hz
7	180-1200 Hz
8	230-1500 Hz
9	300-2200 Hz
10	370-3200 Hz
11	450-5000 Hz
12	550-7000 Hz
13	700-9000 Hz

Rys. 2. Wyniki klasyfikacji przykładów testowych w zależności od zakresu częstotliwości widma sygnału użytego do ekstrakcji parametrów

W celu sprawdzenia optymalnego zakresu częstotliwości widma dla celów parametryzacji porównano jakość klasyfikacji w oparciu o 8 parametrów zgrupowanych w okienku częstotliwościowym przesuwającym się od najmniejszych do największych częstotliwości widma (rys. 2) w przedziałach od 10-300 Hz do 700-9000 Hz. Jako klasyfikatora użyto sieci neuronowej z 10 neuronami w warstwie ukrytej. Paradoksalnie okazało się, że najlepsze wyniki w przypadku obu uszkodzeń otrzymano dla parametrów związanych z najmniejszymi i największymi częstotliwościami widma przy prędkościach 2-4 km/h. Może mieć to związek z występowaniem wyższych składowych harmonicznymi wywołanych drganiami niskoczęstotliwościowymi, ale o większej stabilności ze względu na większą liczbę okresów takich drgań jak i większą moc sygnału w tym zakresie. Nieco gorsze i bardziej nieregularne wyniki uzyskano w przypadku awarii tłumika ciemnego dla sygnałów pomiarowych przy dużej prędkości ruchu wagonu (rys. 2c). Powodem takiej nieregularności jest prawdopodobnie mała liczba dostępnych przykładów takich sygnałów, zaledwie 27 przykładów ogółem, czyli 13-14 przykładów do

nauki/testu. Tak mała liczba przykładów przy dużej zmienności atrybutów, takich jak: prędkość (10-16 km/h), typ przeskody (blaszka, klin) oraz typ czujnika (piezoelektryczny, pojemnościowy) jest przyczyną braku odpowiedniej reprezentacji wszystkich kombinacji powyższych atrybutów w zbiorze do nauki i tym samym prowadzi do błędnego skorelowania niektórych atrybutów z klasami uszkodzeń co jest widoczne zwłaszcza w wypadku losowego podziału zbioru do testu i nauki (8-21% błędów testu) w porównaniu do podziału na parzyste/nieparzyste (6-16%). Przy pewnym szczególnym doborze parametrów w zakresie 20-2000 Hz dla tej samej klasy uszkodzenia przy prędkościach 10-16 km/h uzyskano poniżej 1% błędów dla podziału parzyste/nieparzyste, co może świadczyć o większej ilości informacji dotyczącej awarii tłumika ciemnego możliwej do uzyskania z sygnałów pomiarowych przy dużych prędkościach ruchu wagonu, jednak pełnego potwierdzenia tych rezultatów można oczekiwać dopiero po wykonaniu większej liczby pomiarów.



Rys. 3. Wyniki klasyfikacji przykładów testowych w zależności od liczby neuronów w warstwie ukrytej sieci neuronowej

W kolejnej serii eksperymentów porównano średni błąd klasyfikacji przykładów testowych dla różnych liczb neuronów w warstwie ukrytej sieci neuronowej na oddzielnych wykresach dla obu klas uszkodzeń. Przy obu uszkodzeniach poziom błędu wyraźnie zmniejsza się wraz z większą liczbą neuronów w warstwie ukrytej, co może być związane z dużą złożonością i wielowymiarowością problemu wymagającą stosowania sieci o bardziej rozbudowanej architekturze, dostosowanej do bardziej skomplikowanych, wielomodalnych rozkładów wartości poszczególnych parametrów i tym samym zakodowania informacji o klasach uszkodzeń raczej w większych grupach niż w pojedynczych parametrach (wielowymiarowość problemu). Dla potwierdzenia dużej wielowymiarowości problemu wykonano eksperymenty z klasyfikacją wielu grup jedno, dwu i trójparametrowych i uzyskano wyniki dużo gorsze niż dla grupy ośmioparametrowej. Potwierdzeniem natomiast dużej złożoności problemu mogą być wyniki klasyfikacji grupy ośmioparametrowej uzyskane przy pomocy algorytmu najbliższego sąsiada (dany przykład testowy zostaje zakwalifikowany do tej klasy, do której należy najbliższy przykład w sensie odległości euklidesowej w przestrzeni 8-wymiarowej). Przy takim sposobie obliczania odległości wszystkie wymiary (parametry) traktowane są równorzędnie bez uwzględnienia różnic w ich istotności czy wreszcie istotności ich poszczególnych zakresów wartości. Dla algorytmu najbliższego sąsiada przy prędkościach 2-4 km/h uzyskano odpowiednio 30-40% błędu dla awarii tłumika ciemnego i 50% błędu (dla 2 klas oznacza to brak jakiegokolwiek informacji dyskryminacyjnej) dla uszkodzenia sprężyny.

W przypadku symulacji uszkodzenia sprężyny (rys. 3a) ujawnia się ponadto wyraźny podział pomiędzy wynikami klasyfikacji dla pomiarów przy małych i dużych prędkościach. Trochę inaczej jest w przypadku awarii tłumika ciemnego (rys. 3b), gdzie analogicznie do rysunku (rys. 2c) duży błąd klasyfikacji przykładów testowych przy dużych prędkościach jest spowodowany raczej małą liczbą przykładów w tym zakresie prędkości i w miarę powiększania zbioru przykładów pomiarowych może jeszcze okazać się mniejszy niż dla małych prędkości ruchu wagonów. Dla potwierdzenia tej tezy przy klasyfikacji obu typów uszkodzeń sprawdzono liczbę błędnych klasyfikacji dla poszczególnych przykładów

i okazało się, że można wyróżnić zaledwie po kilka przykładów dla różnych typów uszkodzeń, które są przyczyną większości błędów. Są to prawdopodobnie przykłady o wartościach parametrów wyraźnie odbiegających od wartości pozostałych przykładów, prawdopodobnie wynikającymi z dużego błędu pomiaru. Stąd kolejnym wnioskiem jest bezcelowość dalszych poszukiwań lepszych metod parametryzacji bądź lepszych metod budowy i treningu sieci neuronowej przy obecnej liczbie przykładów do nauki.

4. Wizualizacja danych pomiarowych

W celu weryfikacji przydatności do klasyfikacji wybranej grupy parametrów, jak również wizualnej oceny stopnia separowalności podzbiorów przykładów należących do różnych klas istnieje możliwość wizualizacji rozkładu danych pomiarowych po zmniejszeniu wymiarowości wektorów parametrów do dwóch lub trzech wymiarów. Do tego celu użyć można transformacji liniowej lub nieliniowej. Do bardziej znanych transformacji nieliniowych należy metoda wykorzystująca autoasocjacyjną, 4-warstwową sieć neuronową [1,6] lub metoda Sammona [9] bazująca na kryterium maksymalnego zachowania odległości pomiędzy punktami w przestrzeni o zmniejszonej liczbie wymiarów w stosunku do przestrzeni wejściowej. Najprostszą jednak metodą zmniejszenia wymiarowości jest transformacja liniowa polegająca na rzutowaniu punktów z przestrzeni wejściowej na płaszczyznę, w przypadku 2-wymiarowej przestrzeni wyjściowej, wyznaczoną przez dwa kierunki odpowiadające największej wariancji wartości parametrów. W literaturze przyjmuje się dwie równorzędne nazwy tej transformacji: PCA lub metoda Karhunen-Loeve. Metoda opiera się na wyznaczeniu macierzy kowariancji parametrów:

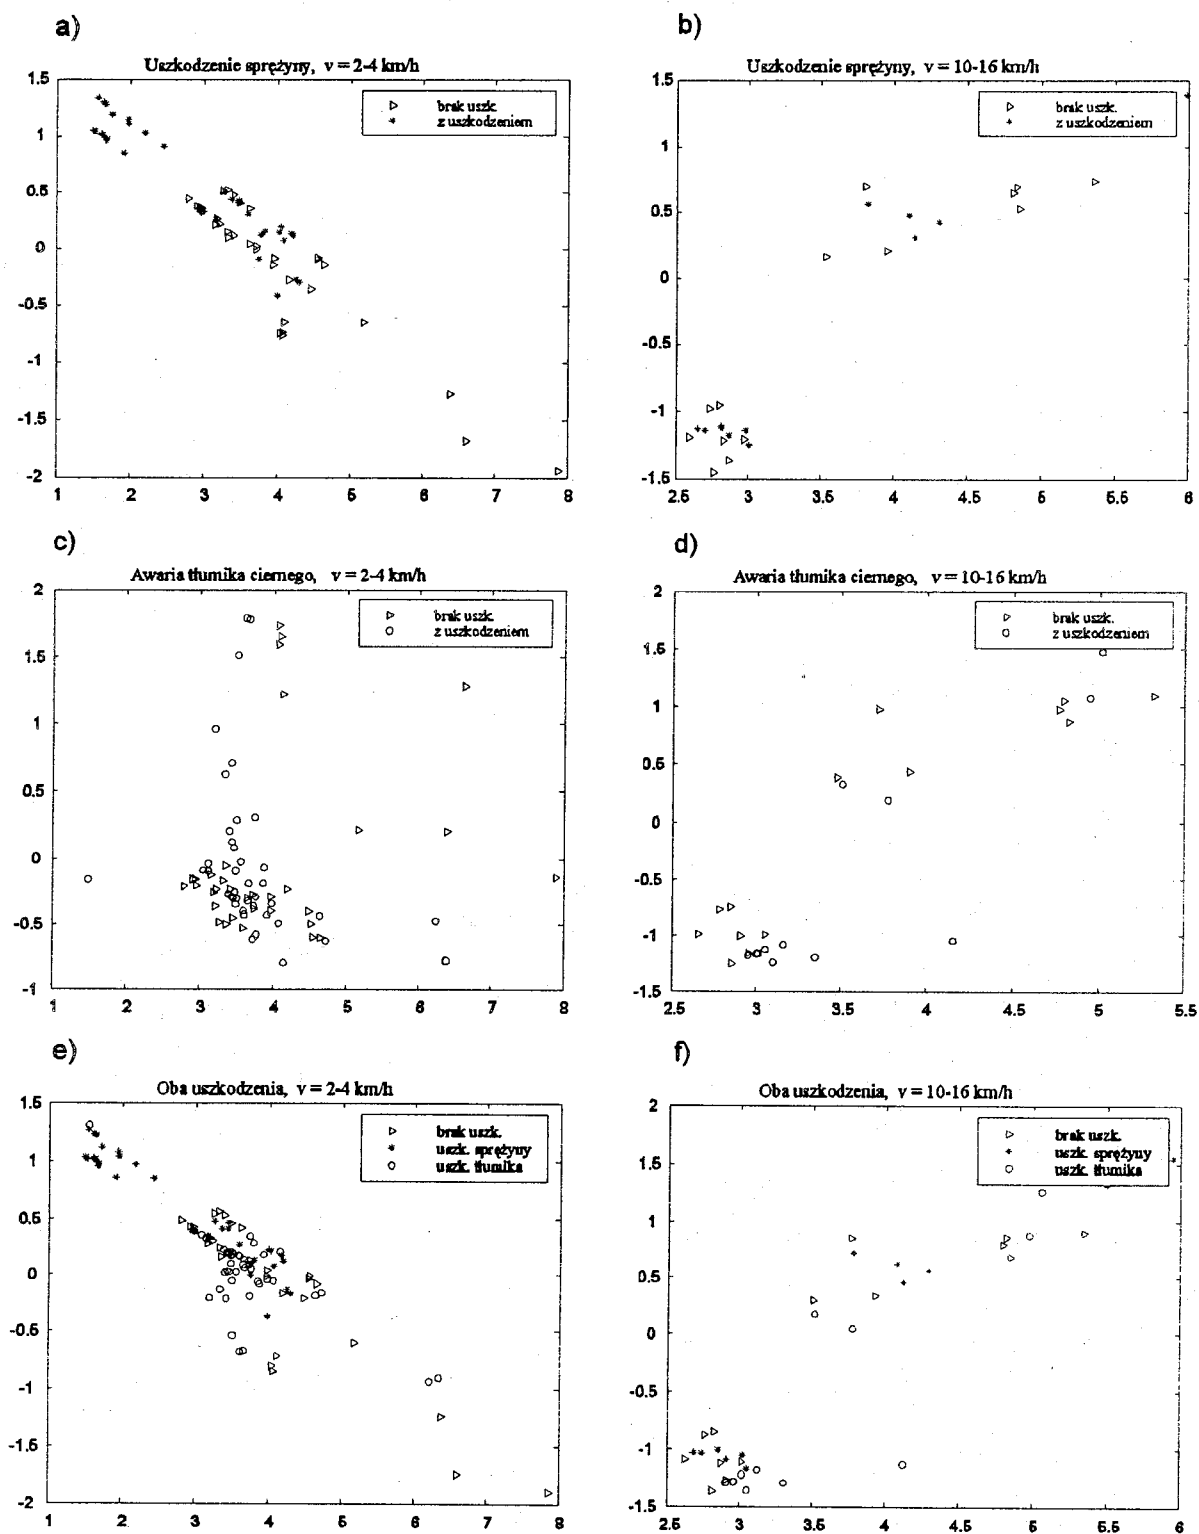
$$K = \frac{1}{P} \sum_{i=1}^P (c_i - \mu)(c_i - \mu)^T, \quad (2)$$

gdzie P - liczba przykładów, c_i - wektor kolumnowy parametrów dla i-tego przykładu, μ - wektor wartości parametrów uśrednionych po wszystkich przykładach opisany wzorem:

$$\mu = \frac{1}{P} \sum_{i=1}^P c_i$$

Wektory własne macierzy kowariancji odpowiadające największym wartościom własnym odpowiadają kierunkom o

największym rozproszeniu wartości parametrów. Transformację PCA można wyobrazić sobie jako obrót osi współrzędnych w przestrzeni wielowymiarowej, tak, by poszczególne osie odpowiadały kierunkom kolejnych maksymalnych rozprożeń wartości parametrów.



Rys. 4. Rozkład przykładów pomiarowych po parametryzacji i zmniejszeniu wymiarowości przestrzeni parametrów do 2 wymiarów metodą transformacji PCA

Na rysunku 4 przedstawione są zbiory punktów odpowiadające przykładom pomiarowym w postaci standardowych wektorów 8-parametrowych (średnie amplitudy w wybranych przedziałach widma) sprowadzonych do dwóch wymiarów przy pomocy transformacji PCA. Na poszczególnych wykresach łatwo można zauważyć pewne zgrupowania przykładów należących do różnych klas w oddzielnych rejonach płaszczyzny, świadczące o istnieniu pewnych cech charakterystycznych dla poszczególnych klas. Należy zdać sobie ponadto sprawę z tego, że sama transformacja PCA znacznie zmniejsza separowalność wyjściowych wektorów cech z powodu swojej liniowości, jak również nieuwzględnienia w dużej mierze nieproporcjonalnego stosunku istotności parametrów do wielkości rozrzutu ich wartości (parametry o małym rozproszeniu wartości mogą zawierać więcej informacji o przynależności do poszczególnych klas i na odwrót). Biorąc pod uwagę powyższe wady transformacji PCA można przypuszczać, że w przestrzeni wejściowej (przed wizualizacją) stopień separowalności klas jest znacznie lepszy.

5. Wnioski

Po wykonaniu szeregu eksperymentów klasyfikacji znacznie poszerzonego zbioru przykładów w stosunku do eksperymentów opisanych w artykule poprzednim [2] uzyskano dobre wyniki potwierdzające wcześniejsze wnioski o przydatności metod uczenia, a zwłaszcza zastosowania sztucznej sieci neuronowej przy odpowiednio dobranej grupie parametrów wejściowych do diagnostyki wibroakustycznej układów biegowych pojazdów szynowych. W przebadanych sygnałach stwierdzono wystarczającą zawartość informacji umożliwiającą klasyfikację uszkodzeń dwóch typów, co potwierdzają również wykresy rozmieszczenia przykładowych sygnałów po ich wizualizacji.

W przypadku symulacji uszkodzenia sprężyny w zawieszeniu I stopnia pierwszego koła uzyskano błąd klasyfikacji przykładów testowych w zbiorze sygnałów mierzonych przy prędkościach 2-4 km/h i przy standardowym zbiorze parametrów związanych z pasmem 20-1000 Hz częstotliwości widma na poziomie 5% dla losowego podziału przykładów do nauki/testu, oraz 3% dla podziału na przykłady o numerach parzystych i nieparzystych. W przypadku symulacji awarii tłumika ściernego uzyskano błąd testu na poziomie 9,5% dla losowego podziału przykładów do nauki/testu, oraz 1,5% dla podziału na przykłady o numerach parzystych i nieparzystych w obrębie prędkości 2-4 km/h i najlepiej dobranej grupy parametrów wydobytych z górnego pasma częstotliwości (700-9000Hz). Znacznie większy poziom błędów uzyskiwano dla przykładów pozyskanych przy prędkościach 10-16 km/h, jednak z powodu małej liczby przykładów w zakresie tych prędkości uzyskane wyniki są bardzo nieregularnie rozłożone w zależności od zakresu badanej częstotliwości, o dużym odchyleniu od wartości średniej i tym samym mało wiarygodne. Wyniki niektórych eksperymentów dla odpowiednio dobranej grupy parametrów w przypadku awarii tłumika w tym zakresie prędkości są bardzo obiecujące i celowe wydaje się potwierdzenie tych wyników po dokonaniu większej liczby pomiarów.

Uzyskane w trakcie eksperymentów wyniki potwierdziły również celowość podziału problemu klasyfikacji na 4 podproblemy, oddzielne dla różnych zakresów prędkości i dla różnych klas uszkodzeń. Dla każdej z 2 badanych klas znale-

zono inne grupy parametrów umożliwiające uzyskanie optymalnych wyników klasyfikacji, z czego wynika konieczność oddzielnej parametryzacji i tym samym klasyfikacji dla każdego uszkodzenia w celu uzyskania optymalnych wyników klasyfikacji całego zbioru przykładów.

6. Dyskusja

Pomimo dobrych wyników uzyskanych przy pomocy zaproponowanego w tej pracy systemu klasyfikującego istnieją możliwości budowy systemu jeszcze lepiej rozwiązującego ten problem klasyfikacji. Warunkiem wdrożenia takiego systemu jest zwiększenie liczby pomiarów w celu uzyskania odpowiedniego stopnia wiarygodności porównania jego wyników z wynikami systemu już istniejącego.

Niewiadomą pozostaje jednak separowalność sygnałów pomiarowych w przypadku występowania bardzo dużej, spotykanej w praktyce, liczby typów uszkodzeń. Odpowiedź na to pytanie mogą przynieść dalsze pomiary uwzględniające wiele typów uszkodzeń lub analiza dokładnych modeli matematycznych uszkodzonych pojazdów. Modelami takimi mogą być modele opisywane w pracy [11] po weryfikacji ich zgodności z dotychczas przeprowadzonymi pomiarami.

W fazie ekstrakcji i selekcji cech istotnych (parametrów) możliwe jest zastosowanie metod programowania genetycznego [8,10], umożliwiającego automatyczną ekstrakcję cech istotnych w oparciu o genetyczne metody selekcji i rekombinacji najlepszych funkcji lub programów operujących bezpośrednio na próbkach sygnału jako argumentach wejściowych. Funkcja przystosowania poszczególnych programów byłaby w tym wypadku obliczana jako średnia błędów klasyfikacji przykładów testowych przez standardowy klasyfikator, np. sieć neuronową. Jednak zmierzenie w tym wypadku stopnia przystosowania wymaga dużej liczby przykładów do nauki i testu.

W fazie klasyfikacji przykładów przy pomocy sieci neuronowej możliwe wydaje się zwiększenie jej zdolności generalizacji (uogólniania) poprzez wprowadzenie nauki z krytykiem tzn. bez podawania informacji o konkretnych klasach poszczególnych przykładów, a jedynie ogólnej oceny klasyfikacji przykładów do nauki. Taki sposób uczenia umożliwia nie tylko nauczenie sieci rozpoznawania zadanych wzorców, ale również skomplikowanego, wielomodalnego rozkładu wartości parametrów wejściowych.

Literatura

- [1] Bishop C.M., *Neural Networks for Pattern Recognition*, Clarendon Press, Oxford 1995.
- [2] Dembski J., Jędruch W., *Metody uczenia się maszyn w diagnostyce układów biegowych pojazdów szynowych za pomocą sygnałów wibroakustycznych*, *Pojazdy Szynowe*, Nr 3/2000, str. 4-15.
- [3] Durzyński Z., *Diagnostyka układów biegowych pojazdów szynowych na bazie sygnałów wibroakustycznych*, III Krajowa Konferencja Naukowo-Techniczna: Diagnostyka Procesów Przemysłowych, Jurata, 7-10 września 1998, str. 355-360.
- [4] Durzyński Z., *Stanowisko badawcze do diagnozowania układów biegowych za pomocą sygnałów wibroakustycznych*, XIV Konferencja Naukowa: Pojazdy Szynowe 2000, Kraków, Arłamów, 9-13 październik 2000, str. 59-70.

- [5] Fu K.S., *Sequential Methods in Pattern Recognition and Machine Learning*, Academic Press, New York and London 1968.
- [6] Hertz J., Krogh A., Palmer R., *Wstęp do teorii obliczeń neuronowych*, WNT, Warszawa 1995.
- [7] Jang J-S.R., Sun C-T., Mizutani E., *Neuro-Fuzzy and Soft Computing*, Prentice Hall, Upper Saddle River 1997.
- [8] Koza J., *Genetic Programming*, Bradford Books, Cambridge, Mass., 1992.
- [9] Niemann H., *Linear and Nonlinear Mapping of Patterns*, *Pattern Recognition*, 1980, 12, (2), 83.
- [10] Sherrah J., *Automatic Feature Extraction for Pattern Recognition*, PhD. Thesis, Dept. of Electrical and Electronic Eng., Faculty of Engineering, The University of Adelaide, South Australia, 1998 .
- [11] Sienicki A., *Model matematyczny układu: tor pomiarowy-wagon typu 415W, do diagnozowania uszkodzeń układów biegowych pojazdów szynowych*, *Pojazdy szynowe*, Nr 3/2000, str. 53-58.
- [12] Sobczak W., Malina W., *Metody selekcji i redukcji informacji*, WNT, Warszawa 1985.
- [13] Żurada J., Barski M., Jędruch W., *Sztuczne sieci neuronowe*, PWN, Warszawa 1996.
-