ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 2003
Seria: TRANSPORT z. 48 Nr kol. 1604

Bogusław ŁAZARZ, Henryk MADEJ, Piotr CZECH

SIEĆ NEURONOWA TYPU SVM JAKO SYSTEM IDENTYFIKACJI STOPNIA PĘKNIĘCIA PODSTAWY ZĘBA

Streszczenie. W opracowaniu przedstawiono wyniki eksperymentu będącego próbą zastosowania sztucznej sieci neuronowej typu SVM jako klasyfikatora stopnia uszkodzenia kół zębatych.

THE SVM NEURAL NETWORK AS THE DEGREE OF THE TOOTH ROOT CRACKING IDENTIFICATION SYSTEM

Summary. The work presents findings of the experiment which is an application test of the SVM neural network as the tooth root cracking classification system.

1. WPROWADZENIE

W ostatnich latach można zauważyć rosnące zainteresowanie sztucznymi sieciami neuronowymi. Zaczęto interesować się i z powodzeniem stosować metody sztucznej inteligencji między innymi w diagnostyce urządzeń [1]. Sieci neuronowe wykazują własności aproksymujące, które pozwalają odwzorować wielowymiarowe zbiory danych [8].

Zasada działania sztucznych sieci neuronowych oparta jest na zdolności uczenia się i przystosowywania się do zmiennych warunków środowiskowych [8,12]. W procesie uczenia sieci neuronowe nabywają umiejętności generalizacji nabytej wiedzy [12]. Nauczona sztuczna sieć neuronowa korzysta ze swojej wiedzy na zasadzie asocjacji, podobnie jak dzieje się to w mózgu człowieka [6].

Sztuczna sieć neuronowa składa się z połączonych ze sobą elementów, zwanych neuronami [6,8,12]. Do każdego neuronu docierają dane, podawane na jego wejście z odpowiednią „siłą" (wagą). Proces uczenia sztucznej sieci neuronowej polega na ustaleniu wag poszczególnych neuronów [6,8,12]. Sztuczne sieci neuronowe mają tendencję do „samooczyszczania", czyli do samoistnej likwidacji połączeń neuronowych, jeśli nie są przydatne w rozwiązaniu problemu.

W literaturze można się spotkać z wieloma typami sztucznych sieci neuronowych [1,8,12]. Struktury sieci neuronowe można podzielić ze względu na typ problemu, do jakiego zostały one użyte. Należą do nich następujące zadania [12]:

- klasyfikacji → podział na kategorie według kryteriów,
- klasteryzacji → klasyfikacja bezwzorcowa,

- aproksymacji → zadania regresyjne,
- prognozowania → przewidywanie zjawisk w przyszłości na podstawie danych retrospekcyjnych.

Ze względu na sposób uczenia sztuczne sieci neuronowe dzielą się na samoorganizujące (uczone bez nauczyciela) oraz na uczone z nauczycielem. Zasada nauki z nauczycielem opiera się na fakcie, że w trakcie procesu uczenia, oprócz danych wejściowych (symptomów) sieci, zostaje pokazany stan jej wyjść. Proces uczenia opiera się w tym przypadku na minimalizacji błędu między uzyskaną z sieci neuronowej wartością na wyjściu a oczekiwaną jej wartością [8,12].

Zgodnie ze sposobem przepływu danych w sieciach neuronowych można je podzielić na sieci jednokierunkowe i sieci ze sprzężeniem zwrotnym (rekurencyjne) [8,12]. W sieciach jednokierunkowych informacja przebiega od wejść sieci do jej wyjść, natomiast w sieciach ze sprzężeniem zwrotnym stan wyjść neuronów może być źródłem danych wejściowych podawanych na wcześniejsze warstwy sieci.

2. OBIEKT BADAŃ

Celem eksperymentu była próba użycia sztucznej sieci neuronowej w problemie oceny stopnia pęknięcia u podstawy zęba.

Za obiekt badań posłużyła przekładnia zębata pracująca w układzie mocy krążącej. W badaniach posłużono się zidentyfikowanym modelem takiej przekładni dokładnie opisanej w pracy [2].

W eksperymencie zidentyfikowany model przekładni posłużył do symulacji przyspieszeń drgań zębnika przy różnym stopniu pęknięcia u podstawy zęba (rys. 1). Symulowanie pęknięcia zęba u podstawy polegało na obniżeniu jego sztywności o ustaloną wartość w stosunku do sztywności zęba nieuszkodzonego. Symulacje zostały przeprowadzone dla różnych klas dokładności wykonania kół zębatych oraz dla różnych wartości błędów cyklicznych i losowych. Dla kół zębatych w każdej przyjętej klasie dokładności przeprowadzono symulacje dla uszkodzenia zęba w postaci podcięcia jego podstawy w zakresie od 0 do 100%. W sumie otrzymano 1111 symulacji.

3. DOBÓR TYPU I ARCHITEKTURY SZTUCZNEJ SIECI NEURONOWEJ ORAZ DANYCH WEJŚCIOWYCH UŻYTYCH W EKSPERYMENCIE

W przeprowadzonym eksperymencie postanowiono sprawdzić przydatność wykorzystania metody sztucznej inteligencji w diagnozowaniu stopnia uszkodzenia kół zębatych.

W literaturze można spotkać udane eksperymenty mające na celu wykorzystanie metod sztucznej inteligencji w diagnostyce stanu maszyn [1].

W eksperymencie za dane wejściowe do sieci neuronowej zostały wybrane miary statystyczne uzyskane z przebiegów przyspieszeń drgań zębnika.

Spośród miar statystycznych do eksperymentu wybrano następujące:

- wartość skuteczną,
- kurtozę,
- dyskryminantę FM0,

- dyskryminantę NA4,
- współczynnik szczytu,
- współczynnik asymetrii,
- współczynnik kształtu.

Miary te są dokładnie opisane w literaturze [3,5,10,11].

Poszczególne miary były wyznaczone dla sygnałów resztkowych uzyskanych z przebiegów czasowych przyspieszeń drgań zębnika [3].

Sygnał resztkowy otrzymano usuwając z widma przyspieszeń drgań pasm zawierających składowe obrotowe wałów kół oraz składowe częstotliwości zazębienia i jej harmonicznych.

Za typ sztucznej sieci neuronowej posłużyła sieć SVM (Support Vector Machine) [4,7,9]. Sieć ta należy do sieci jednokierunkowych. Sieci te mają najczęściej budowę dwuwarstwową i posiadają warstwę ukrytą i wyjściową. Za funkcję aktywacji w tym typie sieci można przyjąć:

- funkcję liniową,
- funkcję wielomianową,
- funkcję radialną,
- funkcję sigmoidalną.

W eksperymencie badawczym za funkcję aktywacji przyjęto funkcję radialną.

Przy uczeniu tego typu sieci należy się posłużyć nauczaniem z nauczycielem.

Do algorytmów uczenia tego typu sieci neuronowych należą strategie: „jeden przeciw wszystkim", „jeden przeciw jednemu" oraz ich kombinacje [7,9].

Problem klasyfikacji wzorców nieseparowalnych liniowo sprowadza się do określenia takiej optymalnej hiperpłaszczyzny, która zminimalizuje prawdopodobieństwo wystąpienia błędu klasyfikacji na zbiorze uczącym z możliwie najszerszym marginesem separacji.

4. WYNIKI I WNIOSKI EKSPERYMENTU BADAWCZEGO

Użycie sztucznej sieci neuronowej typu SVM jako klasyfikatora prowadzi do konieczności optymalizacji następujących współczynników:

- szerokości marginesu błędu uczenia i testowania sieci (ε),
- kosztu (C),
- wartości gamma.

Szerokość marginesu błędu określa dopuszczalną odchyłkę, dla której wyniki o mniejszej odchyłce nie są traktowane jako błąd.

Parametr kosztu jest parametrem sterującym złożonością sieci SVM. Określa on wagę, z jaką traktujemy błędy testowania sieci w stosunku do ustalonego marginesu separacji.

Parametr gamma określony jest dla radialnej funkcji jądra z zależności: $\gamma = \frac{1}{\sigma^2}$.

Wpływ wielkości współczynnika kosztu w sieciach SVM został zilustrowany na rysunku 2. Natomiast wpływ wielkości szerokości marginesu błędu uczenia i testowania dla sieci SVM oraz wpływ współczynnika σ na rozwiązywanie problemów regresyjnych przedstawia rysunek 3.

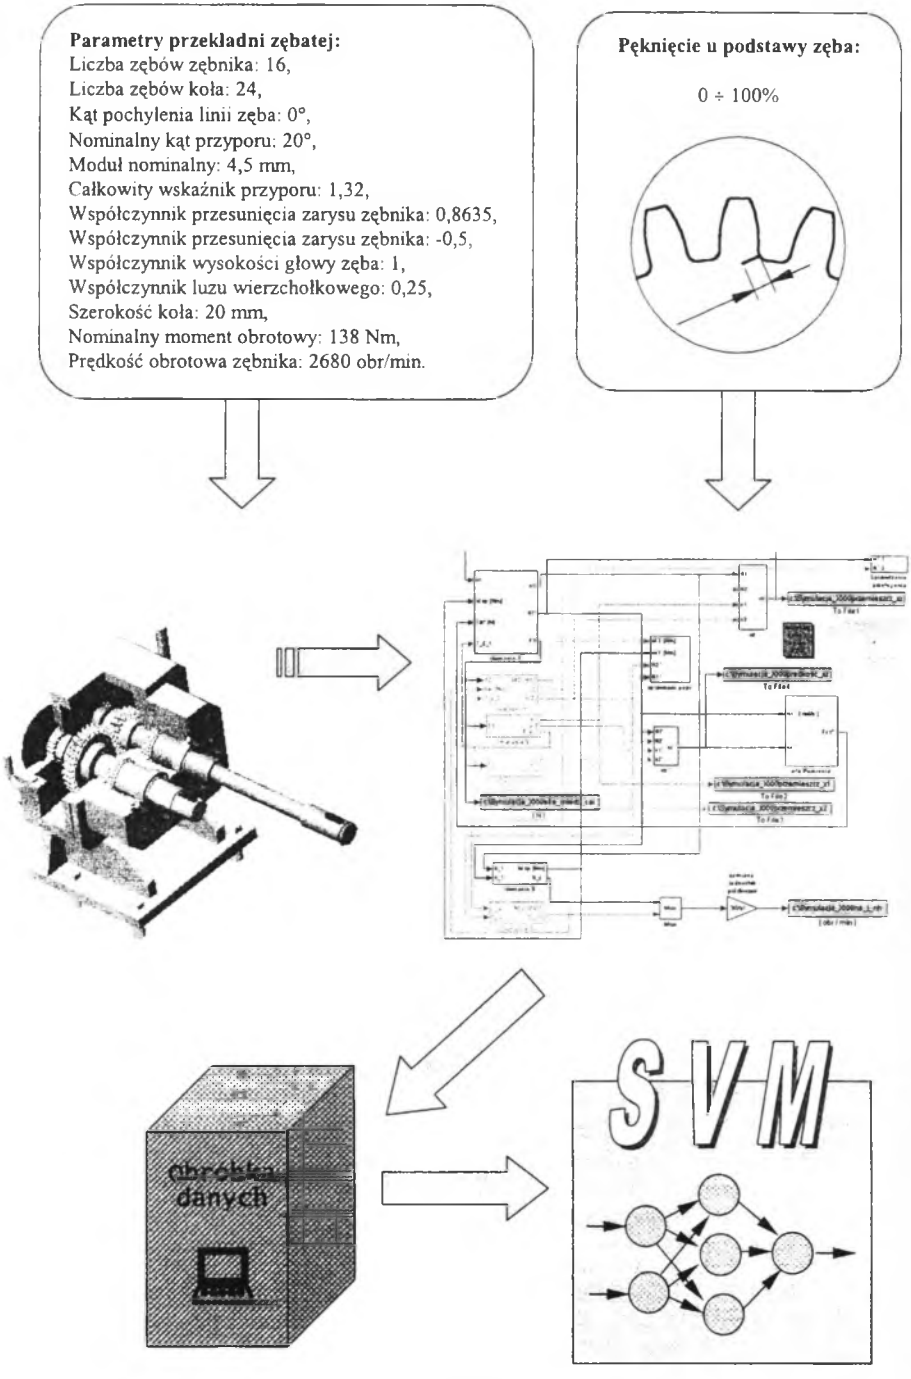

Rys. 1. Metodologia przeprowadzonego eksperymentu
Fig. 1. Metodology of the experiment process

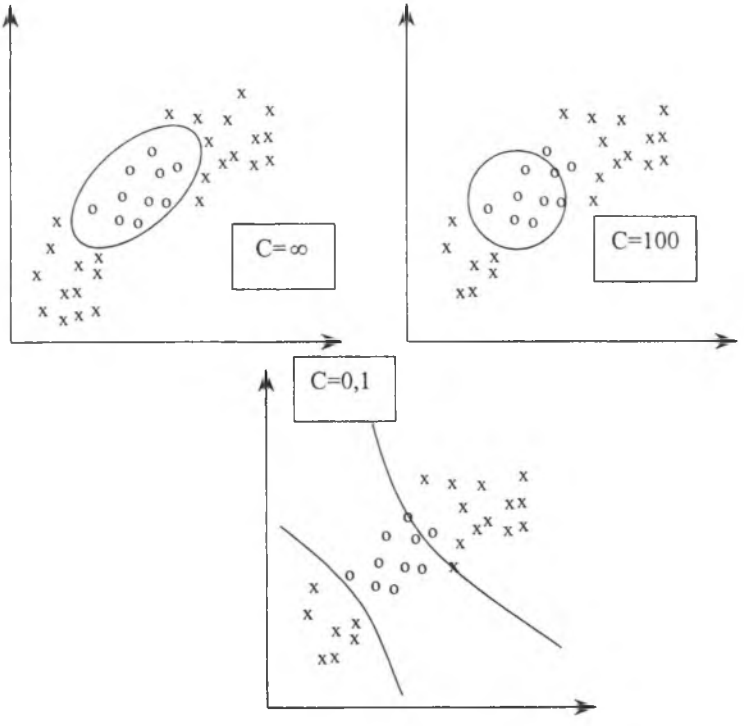

Rys. 2. Wpływ współczynnika kosztu na proces klasyfikacji wzorców
Fig. 2. Effect of a cost factor on the pattern classification process

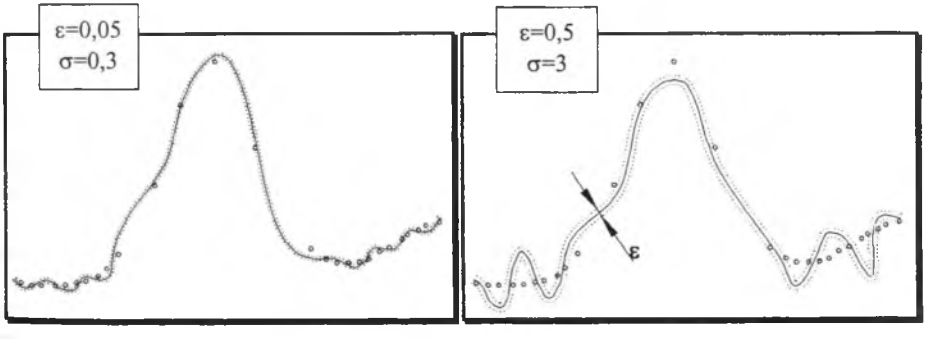

Rys. 3. Wpływ wielkości szerokości marginesu błędu oraz wpływ współczynnika σ na rozwiązywanie problemów regresyjnych
Fig. 3. Effect of width of defect range and σ on regress problem solving

Optymalizację sieci SVM można przeprowadzać w następujący sposób:
- optymalizując za każdym razem wszystkie parametry sieci (ε, C, γ),
- zakładając współczynnik tolerancji błędów na stałym poziomie i optymalizując pozostałe parametry sieci (C, γ),
- zakładając współczynnik C i γ i optymalizując współczynnik tolerancji.

W pracy wybrano optymalizację współczynników C i γ przy założonym współczynniku tolerancji błędów ε.

W eksperymencie podzielono zakres stopnia pęknięcia podstawy zęba na pięć klas:
- 0 ÷ 20 %,
- 21 ÷ 40 %,
- 41 ÷ 60 %,
- 61 ÷ 80 %,
- 81 ÷ 100 %,

do których nauczona sztuczna sieć neuronowa miała klasyfikować przypadki z uszkodzeniami kół zębatych.

W pierwszej fazie eksperymentu dla założonej wartości współczynnika tolerancji ε=0,1 szukano wartości współczynnika kosztów, dla którego sieć cechowała się najmniejszym popełnianym błędem testowania (rys. 4).

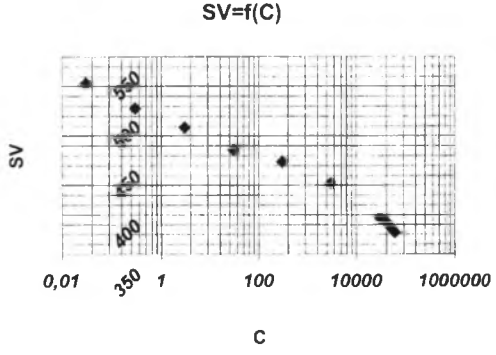

Rys. 4. Zależność stopnia złożoności sieci (SV) od wartości kosztu (C)
Fig. 4. Dependence of a degree of the network complexity SV upon a cost value c

Druga faza eksperymentu polegała na poszukiwaniu wartości współczynnika γ, dla której przy założonym współczynniku tolerancji ε=0,1 i dobranym współczynniku kosztów C=30000 sieć SVM charakteryzowała się najmniejszym błędem testowania.

Wyniki pierwszej fazy eksperymentu zostały zamieszczone w tabeli 1, natomiast drugiej części eksperymentu w tabeli 2.

Na podstawie wyników można zauważyć zależność pomiędzy złożonością sieci neuronowej, czyli ilością wektorów podtrzymujących (SV), a ilością popełnianych przez sieć błędów w czasie testowania. Jest to zależność odwrotnie proporcjonalna.

Minimalny procent błędów testowania wynoszący 17,2973 % otrzymano dla sieci o 260 wektorach podtrzymujących.

Z przeprowadzonego eksperymentu wynika konieczność dalszych badań mających na celu znalezienie miar, które dostarczyłyby pełniejszych informacji diagnostycznych dotyczących powstałego uszkodzenia zęba.

Dalsze badania powinny objąć poszukiwanie odpowiednich miar sygnałów uzyskanych z obwiedni, cepstrum, korelacji, bispectrum, transformaty falkowej lub Wignera-Ville'a itp., lub zastosowania innego rodzaju sztucznej sieci neuronowej.

Tabela 1

Wyniki pierwszego etapu eksperymentu

ε	γ	C	SV	Błąd uczenia		Błąd testowania	
				Ilość	%	*Ilość*	%
0,1	1	0,03	523	330	59,3525	330	59,4595
0,1	1	0,3	498	332	59,7122	330	59,4595
0,1	1	3	479	315	56,6547	313	56,3964
0,1	1	30	456	295	55,0576	298	53,6937
0,1	1	300	444	245	44,0647	245	44,1441
0,1	1	3000	422	193	34,7122	245	44,1441
0,1	1	30000	387	163	29,3165	172	30,991
0,1	1	40000	383	167	30,036	173	31,1712
0,1	1	50000	377	163	29,3165	173	31,1712
0,1	1	60000	372	155	27,8777	173	31,1712

Tabela 2

Wyniki drugiego etapu eksperymentu

ε	γ	C	SV	Błąd uczenia		Błąd testowania	
				Ilość	%	*Ilość*	%
0,1	0,01	30000	443	300	53,9568	209	37,6577
0,1	0,1	30000	435	210	37,7698	209	376577
0,1	1	30000	387	163	29,3165	172	30,991
0,1	10	30000	332	101	18,1655	115	20,7207
0,1	100	30000	290	36	6,4748	97	17,4775
0,1	150	30000	273	34	6,1151	93	16,7568
0,1	200	30000	260	28	5,036	96	17,2973
0,1	300	30000	251	19	3,4173	110	19,8198
0,1	400	30000	256	19	3,4173	116	20,9000
0,1	500	30000	243	14	2,518	121	21,8018
0,1	600	30000	252	10	1,7986	121	21,8018
0,1	700	30000	254	10	1,7986	121	21,8018
0,1	800	30000	255	10	1,7986	212	21,8018
0,1	900	30000	248	10	1,7986	125	22,5225
0,1	1000	30000	251	9	1,6187	131	23,6036

Literatura

1. Korbowicz J., Kościelny J., Kowalczuk Z., Cholewa W.: Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania, Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
2. Łazarz B.: Zidentyfikowany model dynamiczny przekładni zębatej jako podstawa projektowania. Biblioteka Problemów Eksploatacji, Katowice-Radom 2001.

3. Madej H., Czech P., Konieczny Ł.: Diagnostyka przekładni zębatych klatek walcowniczych, Diagnostyka nr 28, 2003.
4. Mangasarian O. L.: Lagrangian Support Vector Machines, Journal of Machine Learning Research, 2001.
5. Martin H. R.: Statistical Moment Analysis as a Means of Surface Damage Detection. Proceedings of the 7th International Modal Analysis Conference, Society of Experimental Mechanics, Schenectady, NY 1989.
6. Nałęcz M., Duch W., Korbowicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Biocybernetyka i Inżynieria Biomedyczna 2000, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
7. Sieci neuronowe SVM w zastosowaniu do problemów regresji, Przegląd Elektrotechniczny nr 86, 2002.
8. Osowski S.: Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
9. Zastosowanie sieci SVM do klasyfikacji wzorców, Przegląd Elektrotechniczny nr 78, 2002.
10. Radkowski S.: Wibroakustyczna diagnostyka uszkodzeń niskoenergetycznych, Biblioteka Problemów Eksploatacyjnych, Warszawa-Radom 2002.
11. Stewart R. M.: Some Useful Data Analysis Techniques for Gearbox Diagnostics. Report MHM/R/10/77, Machine Health Monitoring Group, Institute of Sound and Vibration Research, University of Southampton 1977.
12. Tadeusiewicz R.: Sieci neuronowe, Akademicka Oficyna Wydawnicza, Warszawa 1993.
13. Wilk A., Łazarz B., Madej H.: Vibration Processing Techniques for Fault Detection in Gearboxes, Proceedings of DETC'2003 ASME 2003 Design Engineering Technical Conferences and Computers and Information in Engineering Conference Chicago, Illinois, USA, 2003.

Recenzent: Prof. dr hab. inż. Zbigniew Dąbrowski

Abstract

Results of the experiment show inversely proportional dependence of the network complexity, i. e. on amount of the SV parameters, upon the defect range. Minimal percent of the test defects equals 17,2973 % for network of 260 SV. The experiment indicates to ecessity of further strudies on the problem in order to find such measures that can give a detailed diagnostic description of the tooth damage.

Publikacja powstała w wyniku realizacji pracy BW-453/RT2/2003