

Jakub Piekoszewski

Diagnozowanie uszkodzeń łożysk tocznych z wykorzystaniem wybranych klasyfikatorów

JEL: L62 DOI: 10.24136/atest.2018.460

Data zgłoszenia: 19.11.2018 Data akceptacji: 15.12.2018

Niewielkie uszkodzenie łożysk tocznych może prowadzić do poważnej awarii urządzenia. Zatem, bardzo ważnym jest wykrycie takich defektów na ich początkowym etapie powstawania aby zapobiec dalszemu uszkodzeniu. W pracy przedstawiono kilka wybranych teoretycznych narzędzi z obszaru sztucznej inteligencji zastosowanych do rozwiązania problemu diagnozowania uszkodzeń łożysk tocznych. Rozważanymi narzędziami są: algorytm *k* najbliższych sąsiadów, drzewo decyzyjne, maszyna wektorów podpierających, perceptron wielowarstwowy, sieć bayesowska oraz sieć neuronowa o radialnych funkcjach bazowych. Rezultaty wszystkich eksperymentów zostały otrzymane z wykorzystaniem rzeczywistych danych oraz aplikacji WEKA (ang. Waikato Environment for Knowledge Analysis) dostępnej na stronach Uniwersytetu Waikato w Nowej Zelandii.


Słowa kluczowe: analiza uszkodzeń, perceptron wielowarstwowy, sieć bayesowska, drzewo decyzyjne, sieć neuronowa o radialnych funkcjach bazowych, algorytm *k* najbliższych sąsiadów, aplikacja WEKA.

Wstęp

Łożyska toczne są podstawowymi elementami wielu maszyn. Służą do przenoszenia obciążeń promieniowych i osiowych działających w obu kierunkach z elementu wirującego na pozostałe części mechanizmu. Głównymi częściami typowego łożyska tocznego są pierścienie wraz z bieżniami przenoszącymi obciążenie, elementy toczne oraz koszyk, którego zadaniem jest ich odseparowanie w celu wyeliminowania ich wzajemnego tarcia [5]. Budowę klasycznego łożyska zaprezentowano na rys. 1. Obecnie diagnozowanie na wczesnym etapie uszkodzeń łożysk tocznych stanowi istotny element monitoringu stanu technicznego urządzeń, gdyż jest to element, który najczęściej ulega uszkodzeniu [1]. Zbyt późne wykrycie uszkodzenia łożyska może skutkować znacznie poważniejszymi awariami a ich koszt jest znacznie większy niż koszt wymiany samych łożysk. Ponadto monitorowanie ich stanu umożliwia zaplanowanie odpowiedniego terminu na konserwację co pozwala uniknąć nieplanowanych przestojów. Rodzaje uszkodzeń łożysk tocznych określa międzynarodowa norma ISO15243 (Rolling bearings - damage and failures - term, characteristics and causes), klasyfikując je na bazie widocznych zmian na elementach tocznych, bieżniach i innych powierzchniach pracujących. Możliwe przyczyny uszkodzeń eksploatacyjnych zostały podzielone na sześć głównych grup oraz szesnaście podgrup [2]:

1. Zmęczenie materiału: a) zapoczątkowane pod powierzchnią w skutek mikropęknięć pod powierzchnią bieżni oraz b) zapoczątkowane na powierzchni mikronierówności spowodowane niewystarczającym smarowaniem.
2. Zużycie: a) ściernie powstałe na skutek niewystarczającego smarowania lub wnikięciem zanieczyszczeń do łożyska oraz b) przyłgowe będące przenoszeniem materiału pomiędzy powierzchniami w wyniku ciepła generowanego pod wpływem tarcia.

3. Korozja: a) powierzchni spowodowana obecnością wilgoci, b) cierna powstająca na skutek niewielkich ruchów oscylacyjnych między oddziaływującymi powierzchniami oraz c) fałszywe odciski Brinella będące niewielkimi wgłębieniami na powierzchniach bieżni i elementów tocznych powstającymi w skutek cyklicznych drgań niepracującego łożyska.
4. Erozja elektryczna: a) miejscowe uszkodzenie powierzchni spowodowane przepływem prądu oraz b) upływ prądu tworzący płytkie kraterki, rozwijające się z biegiem czasem w równoległe rowki.
5. Odształcenie plastyczne: a) przeciążenie spowodowane działaniem obciążeń statycznych lub udarowych (prawdziwe odciski Brinella), b) wgniecenie cząstek zanieczyszczeń w elementy toczne i bieżnie oraz c) wgniecenie w wyniku nieprawidłowej obsługi.
6. Pęknięcie: a) wymuszone w wyniku koncentracji naprężeń przekraczających wytrzymałość materiału na rozciąganie, b) zmęczeniowe będące wynikiem częstego przekraczania granicy wytrzymałości materiału oraz c) termiczne powstałe w rezultacie nadmiernego ciepła powstającego przy wysokim tarcu.



Rys. 1. Budowa typowego łożyska tocznego [3]

Istnieje wiele różnych metod opracowanych w celu diagnostyki uszkodzeń łożysk tocznych, wśród których najczęściej stosowanymi są [2]:

1. Pomiar akustyczny szumu obrotowego łożyska przy wykorzystaniu urządzeń detekcji dźwięku np. stetoskopu. Zmiana parametru głośności może sugerować uszkodzenie takiego elementu.
2. Obrazowanie termiczne. Temperatura pracy łożyska nie powinna przekraczać 70°C. Nieprawidłowy montaż lub niewystarczające smarowanie mogą przyczynić się do znacznego wzrostu temperatury i jego uszkodzenia.

- Analiza ferrograficzna zawartości smaru pod kątem występowania w nim śladów zużycia elementów łożyska.
- Monitorowanie drgań generowanych podczas pracy urządzenia.

Pomiar drgań pochodzących z łożysk tocznych jest najpopularniejszą i najczęściej stosowaną metodą diagnozowania ich uszkodzeń. Sprowadza się ona do odróżnienia drgań podczas normalnej pracy urządzenia od wibracji wynikających z nieprawidłowości. Analiza rezultatów pozwala także na określenie prawdopodobnych przyczyn nieprawidłowego działania łożyska. Niewątpliwą zaletą takiego rozwiązania jest brak potrzeby wyłączenia urządzenia na czas testu. Wiele uszkodzeń w ich początkowej fazie może nie powodować zauważalnych zmian poziomu drgań dla operatora urządzenia, dlatego też kilka metod z obszaru sztucznej inteligencji zostało wykorzystanych do budowy systemów klasyfikacyjnych wspomagających diagnozowanie uszkodzeń łożysk tocznych [3].

Niniejsza praca również adresuje ten problem. Do budowy modeli klasyfikatorów wykorzystano następujące narzędzia: perceptron wielowarstwowy MLP (ang. *multilayer perceptron*), sieć neuronową o radialnych funkcjach bazowych RBF (ang. *radial basis function*), drzewo decyzyjne, sieć bayesowska, maszyna wektorów podpierających SVM (ang. *support vector machine*) oraz algorytm k najbliższych sąsiadów k -NN (ang. *k-nearest neighbor algorithm*). Przegląd wybranych narzędzi można odnaleźć w pracach [5,6]. Wszystkie eksperymenty numeryczne przedstawione w pracy otrzymano z wykorzystaniem aplikacji WEKA (ang. *Waikato Environment for Knowledge Analysis*) dostępnej na stronach Uniwersytetu Waikato w Nowej Zelandii (<https://www.cs.waikato.ac.nz/ml/weka/>).

1. Projekt klasyfikatora

Rozważany jest system klasyfikacyjny o n wejściach x_1, x_2, \dots, x_n oraz m wyjściach y_1, y_2, \dots, y_m . Liczba klas rozpoznawanych przez klasyfikator jest równa liczbie jego wyjść. Odpowiedź systemu na j -tym wyjściu $y_j \in [0, 1]$, $j = 1, 2, \dots, m$ (obliczana w trakcie prezentacji kolejnych próbek danych na wejściach klasyfikatora) reprezentuje stopień przynależności wektora wejściowego dla j -tej klasy. Budowa klasyfikatora odbywa się w trybie uczenia nadzorowanego – zbiór danych uczących $L_1^{(lrm)}$ ma postać p par próbek danych wejściowych i wyjściowych:

$$L_1^{(lrm)} = \{ \mathbf{x}_s^{r(lrm)}, c_s^{r(lrm)} \}_{s=1}^p \quad (1)$$

gdzie $\mathbf{x}_s^{r(lrm)} = [x_{s1}^{r(lrm)}, x_{s2}^{r(lrm)}, \dots, x_{sn}^{r(lrm)}]$ ($x_{si}^{r(lrm)} \in \mathfrak{R}$, $i = 1, 2, \dots, n$) jest wektorem danych wejściowych, $c_s^{r(lrm)}$ jest etykietą klasy przypisaną wektorowi $\mathbf{x}_s^{r(lrm)}$. W ramach etapu przygotowania danych do klasyfikacji oryginalny zbiór danych uczących $L_1^{(lrm)}$ przekształcany jest w nowy zbiór danych uczących:

$$L_2^{(lrm)} = \{ \mathbf{x}_s^{r(lrm)}, \mathbf{d}_s^{r(lrm)} \}_{s=1}^p \quad (2)$$

gdzie $\mathbf{x}_s^{r(lrm)}$ jest taki jak w warunku (1), natomiast $\mathbf{d}_s^{r(lrm)} = [d_{s1}^{r(lrm)}, d_{s2}^{r(lrm)}, \dots, d_{sm}^{r(lrm)}]$ ($d_{sj}^{r(lrm)} \in \{0, 1\}$, $j = 1, 2, \dots, m$) jest pożądaną odpowiedzią systemu, gdy wektor $\mathbf{x}_s^{r(lrm)}$ prezentowany jest na wejściach klasyfikatora ($d_{sj}^{r(lrm)} = 1$ jeżeli wektor $\mathbf{x}_s^{r(lrm)}$ jest przypisany do j -tej klasy oraz $d_{sj}^{r(lrm)} = 0$ w przeciwnym


przypadku). W trakcie procesu uczenia, błąd odpowiedzi systemu $Q_{RMSE}^{(lrm)}$ dla zbioru uczącego $L_2^{(lrm)}$ jest minimalizowany:

$$Q_{RMSE}^{(lrm)} = \sqrt{\frac{1}{p} \frac{1}{m} \sum_{s=1}^p \sum_{j=1}^m (y_{sj}^{r(lrm)} - d_{sj}^{r(lrm)})^2} \quad (3)$$

gdzie $y_{sj}^{r(lrm)} \in [0, 1]$ jest rzeczywistą odpowiedzią systemu na j -tym wyjściu y_j , obliczaną gdy wektor $\mathbf{x}_s^{r(lrm)}$ prezentowany jest na wejściach klasyfikatora [3].


2. Badania eksperymentalne

Do oceny efektywności proponowanych narzędzi wspomagających diagnozowanie uszkodzeń łożysk tocznych wykorzystano dane udostępnione przez Bearing Data Center Uniwersytetu Case Western Reserve w Cleveland w Stanach Zjednoczonych [7]. Ich autorzy przeprowadzili szereg pomiarów drgań na stanowisku testowym składającym się z silnika indukcyjnego o mocy 2KM, przekładni oraz obciążenia przedstawionych na rys. 2.



Rys. 2. Stanowisko do badań uszkodzeń łożysk tocznych [7]

Badania eksperymentalne przeprowadzono na jednorzędowych łożyskach kulkowych typu 6205-2RSJEM szwedzkiej firmy SKF zamontowanych na wale silnika. Parametry łożyska przedstawia rys. 3.



Rys. 3. Parametry łożyska typu SKF 6205-2RSJEM [2]

Dokonano pomiarów drgań łożyska sprawnego, oraz z uszkodzeniami: kulki, bieżni zewnętrznej i wewnętrznej. Pojedyncze, punktowe uszkodzenia tych elementów o średnicy od 7 do 28 mils (1/1000 cala) zrealizowano z wykorzystaniem obróbki elektroerozyj-

nej. Każdy z pomiarów drgań badanych elementów został przeprowadzony przy prędkości obrotowej wału 1750 obr/min. Wielkości generowanych drgań zostały odczytane przy użyciu akcelerometru przymocowanego bezpośrednio do obudowy silnika. Częstotliwość próbkowania sygnału wynosiła 12kHz. Otrzymane przebiegi zostały zarejestrowane z wykorzystaniem 16 kanałowego przetwornika A/C w środowisku MATLAB.

Przygotowanie danych

Pomiar drgań każdego łożyska trwał niewiele ponad 10s. co przy częstotliwości próbkowania 12kHz daje szereg czasowy składający się z ponad 120000 próbek sygnału. Na potrzebę testów modeli klasyfikatorów w tej pracy stworzono dwa zbiory danych, różniące się stopniem uszkodzenia łożysk (punktowe defekty o średnicy 7 oraz 21 mils). Każdy ze zbiorów zawiera 240 rekordów danych przypisanych do jednej z 4 klas (nieuszkodzone łożysko, oraz uszkodzona kulka, bieżnia zewnętrzna i wewnętrzna). Po uwzględnieniu prędkości obrotowej silnika 1750 obr/min oraz częstotliwości próbkowania 12 kHz, każdy rekord danych w obu zbiorach składa się z 411 próbek sygnału, co odpowiada jednemu pełnemu obrotowi wału silnika. Przykładowe przebiegi czasowe wybranych rekordów zostały przedstawione na rys. 4.

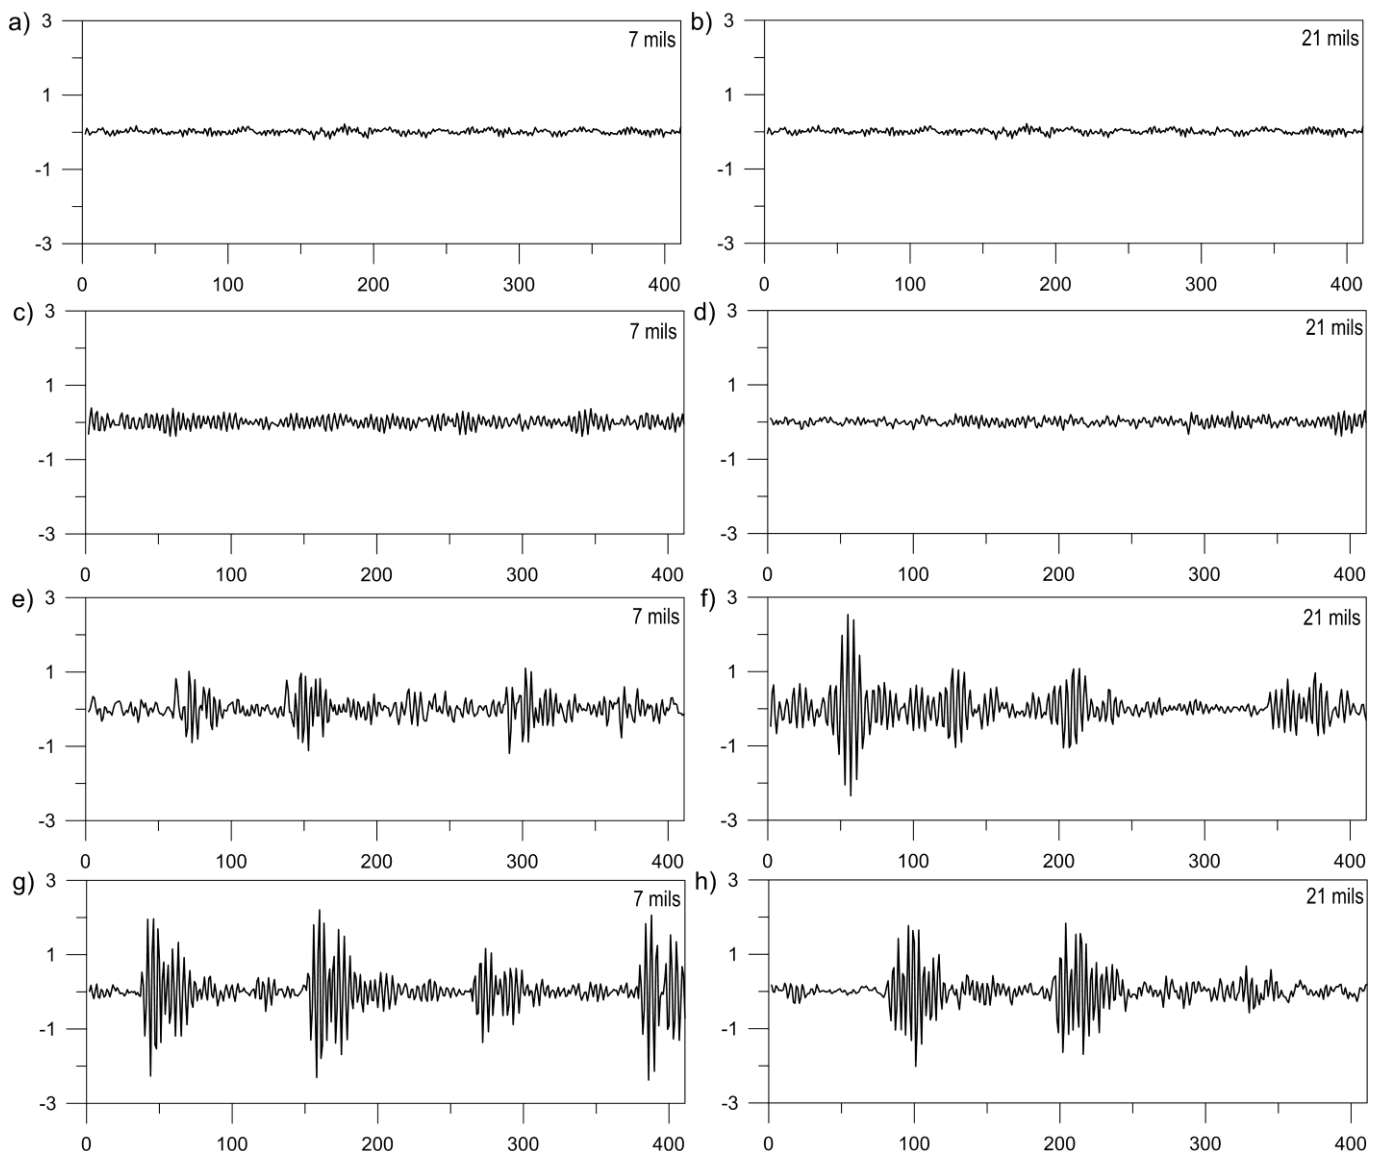
Wyniki badań

Przygotowano i przetestowano sześć klasyfikatorów bazując na:

1. perceptronie dwuwarstwowej (MLP) wykorzystującym algorytm wstecznej propagacji o 4 neuronach w warstwie wyjściowej i 200 neuronach w warstwie ukrytej (współczynnik uczenia równy 0.3; wartość momentu równa 0.2; liczba epok uczenia równa 1000),
2. sieci neuronowej o radialnych funkcjach bazowych wykorzystującej algorytm k średnich (RBF),
3. drzewie decyzyjnym z algorytmem uczenia C4.5,
4. maszynie wektorów podpierających (SVM),
5. sieci bayesowskiej,
6. algorytmie k najbliższych sąsiadów (k -NN).

Dla wszystkich klasyfikatorów, za wyjątkiem sieci MLP, korzystano z domyślnych ustawień parametrów dostępnych w aplikacji WEKA. Szczegółowe informacje dotyczące metod uczenia wszystkich rozważanych w pracy narzędzi można odnaleźć w pracy [8]. Czas budowy poszczególnych klasyfikatorów został przedstawiony na rys. 5. Tab. 1 zawiera szczegółowe zestawienie wyników dla poszczególnych narzędzi.

Otrzymane wyniki jednoznacznie wskazują na możliwość wyko-



Rys. 4. Amplitudy drgań przykładowych rekordów dla zbiorów o uszkodzeniach 7 i 21 mils: nieuszkodzone łożysko kulkowe (a,b), uszkodzona kulka (c,d), uszkodzona bieżnia wewnętrzna (e,f), oraz uszkodzona bieżnia zewnętrzna (g,h)


rzystania proponowanych modeli klasyfikatorów do budowy systemów wspomagania w diagnozowaniu uszkodzeń łożysk tocznych. Zdecydowanie najlepsze rezultaty osiągnęły modele klasyfikatorów bazujących na sieci neuronowej o radialnych funkcjach bazowych i sieci bayesowskiej. Średni procent ich poprawnych decyzji był bliski 100% (odpowiednio 99.17% i 98.55%). Również wysoki procent poprawnych decyzji (87.71%) uzyskał perceptron dwuwarstwowy. Jednakże jego pewnym mankamentem jest stosunkowo długi czas budowy (ok. 500s.), w przeciwieństwie do pozostałych narzędzi, których czas budowy oscyluje w granicach 1 sekundy. Wyniki pozostałych narzędzi wynoszące pomiędzy 70% a 80% także można uznać za zadowalające (odpowiednio 71.25% dla maszyny wektorów podpierających, 74.38% dla drzewa decyzyjnego i 78.13% dla algorytmu k najbliższych sąsiadów). Rezultaty otrzymane dla obu zbiorów są zbliżone co świadczy o wysokiej skuteczności w wykrywaniu nawet niewielkich uszkodzeń łożysk tocznych.

Podsumowanie

W niniejszej pracy przedstawiono wybrane narzędzia teoretyczne z obszaru sztucznej inteligencji, zastosowane do budowy systemów wspomagających wykrywanie uszkodzeń łożysk tocznych. Wykonane badania eksperymentalne jednoznacznie wskazują na możliwość ich stosowania. Zaproponowane narzędzia uzyskały dobre i bardzo dobre wyniki poprawnych decyzji dla klasyfikowanych próbek danych. Wykorzystanie tych narzędzi może w znacznym stopniu pomóc w diagnostyce uszkodzeń nie tylko łożysk tocznych, ale również innych elementów urządzeń takich jak np. przekładni zębatych [9].

W najbliższej przyszłości planuje się zastosowanie alternatywnych metod z obszaru sztucznej inteligencji, tj. systemów regulowalnych [10,11] oraz samoorganizujących się sieci neuronowych

o drzewiastych strukturach topologicznych [12,13] w celu rozwiązywania zbliżonych zagadnień wykrywania uszkodzeń.



*MLP - dwuwarstwowy perceptron, RBF - sieć neuronowa o radialnych funkcjach bazowych, SVM - maszyna wektorów podpierających, SB - sieć bayesowska, k-NN - algorytm k najbliższych sąsiadów

Rys. 5. Średni czas budowy rozpatrywanych klasyfikatorów

Bibliografia:

1. Muthukumarasamy A., Ganeriwala S., *Diagnosis of rolling element bearing faults using envelope analysis*, Tech Note, 2009.
2. *Uszkodzenia łożysk oraz ich przyczyny*, podręczniku obsługi łożysk firmy SKF.
3. Kutalek D., Hammer M., *Vibration diagnostics of rolling bearings using the time series analysis*, MM Science Journal, 2015.
4. Li B., Chow Mo-Y., Tipsuwan Y., Hung J.C., *Neural network*

Tab. 1. Rezultaty klasyfikacji poszczególnych narzędzi dla zbiorów o uszkodzeniach 7 i 21 mils.

Klasyfikator	Zbiór danych o uszkodzeniach 7 mils					Liczba poprawnych decyzji	Zbiór danych o uszkodzeniach 21 mils					Średni procent poprawnych decyzji	
	Macierz błędów				Liczba poprawnych decyzji		Macierz błędów				Liczba poprawnych decyzji		
	n ¹⁾	uw ²⁾	uk ³⁾	uz ⁴⁾			n ¹⁾	uw ²⁾	uk ³⁾	uz ⁴⁾			
Perceptron wielowarstwowy	n ¹⁾	60	0	0	0	229 (89.58%)	n ¹⁾	60	0	0	0	212 (85.83%)	87.71%
	uw ²⁾	7	39	0	0		uw ²⁾	2	52	6	0		
	uk ³⁾	3	0	57	0		uk ³⁾	1	0	59	0		
	uz ⁴⁾	0	0	1	59		uz ⁴⁾	8	1	16	35		
Sieć neuronowa o radialnych funkcjach bazowych	n ¹⁾	60	0	0	0	240 (100.00%)	n ¹⁾	60	0	0	0	236 (98.33%)	99.17%
	uw ²⁾	0	60	0	0		uw ²⁾	0	60	0	0		
	uk ³⁾	0	0	60	0		uk ³⁾	0	0	60	0		
	uz ⁴⁾	0	0	0	60		uz ⁴⁾	0	4	0	56		
Drzewo decyzyjne	n ¹⁾	57	0	3	0	174 (72.50%)	n ¹⁾	48	0	11	1	183 (76.25%)	74.38%
	uw ²⁾	3	35	10	12		uw ²⁾	1	51	2	6		
	uk ³⁾	7	11	39	3		uk ³⁾	13	1	43	3		
	uz ⁴⁾	1	14	2	43		uz ⁴⁾	4	9	6	41		
Maszyna wektorów podpierających	n ¹⁾	59	0	1	0	169 (70.42%)	n ¹⁾	60	0	0	0	173 (72.08%)	71.25%
	uw ²⁾	12	25	23	0		uw ²⁾	11	29	19	1		
	uk ³⁾	28	6	26	0		uk ³⁾	1	7	52	0		
	uz ⁴⁾	0	0	1	59		uz ⁴⁾	6	10	12	32		
Sieć bayesowska	n ¹⁾	60	0	0	0	235 (97.92%)	n ¹⁾	60	0	0	0	238 (99.17%)	98.55%
	uw ²⁾	0	60	0	0		uw ²⁾	0	59	0	1		
	uk ³⁾	0	3	57	0		uk ³⁾	0	0	60	0		
	uz ⁴⁾	0	2	0	58		uz ⁴⁾	0	1	0	59		
Algorytm k najbliższych sąsiadów	n ¹⁾	60	0	0	0	170 (70.83%)	n ¹⁾	60	0	0	0	205 (85.42%)	78.13%
	uw ²⁾	30	30	0	0		uw ²⁾	0	55	5	0		
	uk ³⁾	39	0	21	0		uk ³⁾	7	0	53	0		
	uz ⁴⁾	0	0	1	59		uz ⁴⁾	13	0	10	37		

¹⁾ n – łożysko nieuszkodzone (etykieta klasy), ²⁾ uw – uszkodzenie wewnętrznej bieżni, ³⁾ uk – uszkodzenie kulki, ⁴⁾ uz – uszkodzenie zewnętrznej bieżni

- based motor rolling bearing fault diagnosis, IEEE Transactions on Industrial Electronics, vol. 47, 2000.
5. Klimowski M., *Diagnostyka łożysk tocznych silników elektrycznych przy wykorzystaniu metody analizy częstotliwościowej oraz metody detekcji obwiedni*, Maszyny Elektryczne, tom 2 (102), 2014.
 6. Koronacki J., *Statystyczne systemy uczące się*, Akademicka Oficyna Wydawnicza EXIT, 2008
 7. Mitchell T., *Machine Learning*, McGraw Hill, 1997.
 8. Case Western Reserve University Bearing Data Center Website (<http://csegroups.case.edu/bearingdatacenter/home>).
 9. Bishop C. M., *Pattern Recognition and Machine Learning*, Springer-Verlag, New York, 2006.
 10. Piekoszewski J., *Analiza porównawcza wybranych klasyfikatorów w diagnozowaniu uszkodzeń przekładni zębatych*, Autobusy: technika, eksploatacja, systemy transportowe, tom 18, 2017.
 11. Rudziński F., A multi-objective genetic optimization of interpretability-oriented fuzzy rule-based classifiers, Applied Soft Computing, vol. 38, 2016.
 12. Gorzałczany M. B., Rudziński F., A multi-objective genetic optimization for fast, fuzzy rule-based credit classification with balanced accuracy and interpretability, Applied Soft Computing, vol. 50(50), 2016.
 13. Gorzałczany M. B., Piekoszewski J., Rudziński F., *Generalized tree-like self-organizing neural networks with dynamically defined neighborhood for cluster analysis*, Artificial Intelligence and Soft Computing, 13th International Conference, ICAISC 2014, Zakopane, Poland, June 1-5, 2014, Proceedings, Part II, 2014.
 14. Gorzałczany M. B., Piekoszewski J., Rudziński F., *Generalized SOMs with Splitting-Merging Tree-Like Structures for WWW-Document Clustering*, Advances in Intelligent Systems Research, vol. 89, 2015.

Fault diagnosis of roller bearings using selected classifiers

Minor roller bearing damage may lead to serious failures of the device. Thus, it is very important to detect such damage as early as possible to prevent further damage. This paper presents a selection of several theoretical tools from the field of artificial intelligence and their application in roller bearings fault classification. The considered tools are: k -nearest neighbor algorithm, decision tree, support vector machine, feed forward neural network (multilayer perceptron), Bayesian network and neural network with radial basis functions. All numerical experiments presented in the paper were performed with the use of real-world dataset and WEKA (Waikato Environment for Knowledge Analysis) software, available at the server of the University of Waikato.

Keywords: fault detection, multilayer perceptron, Bayesian network, decision tree, neural network with radial basis functions, k -nearest neighbor algorithm, WEKA application.

Autor:

dr **Jakub Piekoszewski** – Politechnika Świętokrzyska w Kielcach, Wydział Elektrotechniki, Automatyki i Informatyki, email: j.piekoszewski@tu.kielce.pl