

Prof. dr hab. inż. Konrad Skowronek

Wydział Elektryczny

Politechnika Poznańska

ul. Piotrowo 3a, 60-965 Poznań

[E-mail: Konrad.Skowronek@put.poznan.pl](mailto:Konrad.Skowronek@put.poznan.pl)

Mgr inż. Artur Woźniak

Wood-Mizer Industries Sp. z o.o.

Nagórna 114, 62-600 Koło

[E-mail: artur_wozniak@o2.pl](mailto:artur_wozniak@o2.pl)

Klasyfikator FFT-PCA-LDA w diagnostyce alternatora

Słowa kluczowe: diagnostyka alternatora, klasyfikacja, metoda hybrydowa

Streszczenie: Omówiono metody diagnostyki alternatorów. Uzasadniono konieczność konstrukcji nowych metod. Zaprezentowano nową metodę klasyfikacyjną wykorzystaną do diagnostyki uszkodzeń alternatora. Przedstawiono cechy metody. Działanie metody przeanalizowano na podstawie badania uszkodzeń diod alternatora. Metodę porównano z metodami diagnostyki maszyn elektrycznych stosowanymi w praktyce.

1. Wstęp

Tematyka diagnostyki alternatora jest aktualna ze względu na potrzeby przemysłu motoryzacyjnego oraz użytkowników pojazdów. W pierwszym przypadku pozwala na ocenę wyrobu w czasie produkcji, w drugim - w trakcie eksploatacji.

W praktyce do diagnozowania stanu alternatora w pojeździe lub poza nim stosuje się następujące metody [12]:

- porównawczą
- oscyloskopową;
- woltomierzową;
- przy wykorzystaniu specjalizowanych urządzeń diagnostycznych, na przykład przyrządu indykatorowego.

W metodzie porównawczej sprawdza się stopień zgodności pomierzonych charakterystyk alternatora z wzorcowymi. Jest to metoda żmudna i niedokładna. Ma charakter rozwiązania indywidualnego, oceniającego zdatność alternatora, ale nie pozwala na określanie rodzaju i miejsca uszkodzenia. W zasadzie odpowiada potraktowaniu maszyny jako „czarnej skrzynki” bez uwidocznienia roli połączeń i bez dostępu do wyprowadzeń. Statystyka przypadków nie pozwala na wyciąganie wniosków na przykład co do rodzaju błędu produkcyjnego.

Najbardziej rozpowszechnioną w praktyce jest tzw. metoda „oscyloskopowa”. Polega ona na porównywaniu przebiegów wzorcowych oscylogramów sygnałów z przebiegami uzyskanymi dla danego alternatora. Ta metoda umożliwia lokalizację miejsc powstawania zarówno błędów produkcyjnych jak i uszkodzeń, na przykład zwarć uzwojenia stojana z masą. Głównymi sygnałami są zazwyczaj napięcia: wyjściowe, fazowe i międzyfazowe. Sygnały są mierzone w różnych punktach w zależności od typu alternatora, w szczególności punktów dostępu dla sond pomiarowych. Nie jest to więc metoda dostatecznie ogólna. Nie pozwala też na rozróżnianie pojedynczych uszkodzeń i błędów produkcyjnych.

W metodzie woltomierzowej mierzy się woltomierzem najczęściej takie same sygnały jak w metodzie oscyloskopowej. Te same są więc wady tej metody.

Wykorzystanie specjalizowanych urządzeń diagnostycznych ograniczone jest do danego typu alternatora. Najczęściej powinny też być dostępne określone wyprowadzenia alternatora, w szczególności uzwojeń fazowych. Ta prosta metoda umożliwia jej stosowanie słabo wyszkolonym pracownikom, zapewnia wykrywanie uszkodzeń i błędów, lecz nie prowadzi do ich rozróżnienia.

W przeciwieństwie do diagnostyki silników indukcyjnych w literaturze niewiele jest informacji o stosowaniu dla alternatorów bardziej wyszukanych metod diagnostycznych. Na przykład w [5] zaproponowano komputerową analizę stanu alternatora przy wykorzystaniu sztucznej sieci neuronowej. Uzyskano dobre wyniki identyfikacji tylko niektórych typów błędów i uszkodzeń. Nie znaleziono w literaturze prac:

- zawierających propozycję stworzenia algorytmu, który oceny stanu dokonywałby na podstawie wielu sygnałów przy dynamicznej zmianie warunków pracy,
- zawierających propozycję algorytmu, który realizowałby zadania klasyfikacji i regresji w ocenie stanu,
- zawierających propozycję algorytmu, który zachowałby poprawność działania również dla przypadków silnie odstających,
- pozwalających na adaptację modelu użytego w ocenie dla różnych zadań: w dziedzinie częstotliwości i w dziedzinie czasu (dopasowanie ilości zmiennych, parametrów modelu),
- prac zawierających propozycję metody prognozowania wybranych parametrów pracy urządzenia.

Stąd uznano za celowe zaproponowanie nowej metody diagnostyki alternatorów na taśmie produkcyjnej oraz zamontowanych w pojazdach. Cechami metody powinny być: uniwersalność, zdolność wykrywania i klasyfikowania zarówno grup jak i pojedynczych uszkodzeń oraz umożliwienia wskazania miejsca ich wystąpienia.

2. Analiza możliwych rozwiązań

W celu automatyzacji i ujednoczenia ocen stanu alternatorów nowych i używanych należy usunąć z wyników diagnozowania składowe zależne od czynników nieobiektywnych. Jednocześnie powinno się zapewnić dostateczną elastyczność metody, rozumianą jako możliwość tworzenia subiektywnych wzorców odchylenia od norm, na przykład wzorców uszkodzeń. W tym sensie do najważniejszych należą metody wykorzystujące opisy losowe sygnałów.

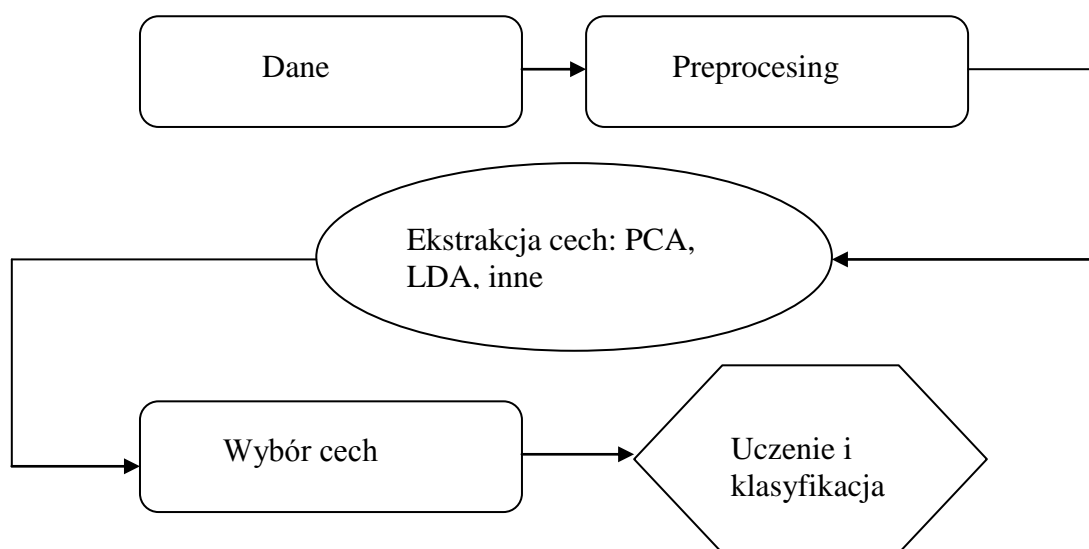
Istnieje wiele metod diagnostyki [2]. Do najbardziej ogólnych należą statystyczne metody klasyfikacyjne takie jak: PCA, ICA, LDA, B&B, SFS, SBS, SFFS&SBFS, SVM, Bayes, LDC, k-NN, i inne. Do analiz dużych zbiorów danych z prób pomiarowych wykorzystuje się wiele metod, stosowanych np. w uczeniu wzorców [9]. Powszechnie rozróżnia się techniki uczenia bez nadzoru i z nadzorem. Do pierwszych należą m.in. PCA, PP, SOM (mapy Kohonena), itd. Drugie dzieli się najczęściej, w zależności od problemu badawczego, na kalibracyjne, dyskryminacyjne i klasyfikacyjne.

W omawianym przypadku, czyli w diagnostyce alternatora, ze względu na jego fizyczną budowę i miejsce pracy zachodzi konieczność przeszukiwania dużej liczby danych, silnie ze sobą skorelowanych. Dlatego przeprowadzono wstępne badania porównawcze wybranych metod. W tym celu dokonano prób identyfikacji stanu obiektu lub estymacji wartości parametrów pracy z wykorzystaniem metod PCA (analiza czynników głównych), LDA (liniowa analiza dyskryminacyjna), SVM (metoda wektorów wspierających), SNN (sztuczne

sieci neuronowe), MARSPlines (wielozmienna regresja adaptacyjna z użyciem funkcji sklepanych).

W przeszukiwaniu wielkich zbiorów danych optymalną okazała się metoda PCA (analiza czynników głównych). PCA jest typową metodą uczenia bez nadzoru opartą o liniowy algorytm ekstrakcji cech przy jednoczesnym zredukowaniu zbiorów danych.

Z kolei optymalną dla klasyfikacji grup zmiennych okazała się LDA (liniowa analiza dyskryminacyjna). Liniowa analiza dyskryminacyjna należy do najczęściej stosowanych w technice. LDA służy do konstruowania liniowych funkcji dyskryminacyjnych. Tworzy się je dla próbek zbioru modelowego. Próbki te konstruują wstępnie definiowane grupy. Utworzone dla nich funkcje dyskryminacyjne są wykorzystane do zaklasyfikowania nowych „wirtualnych“ próbek do jednej z rozpatrywanych grup.



Rys.1. Etapy klasyfikacji statystycznej

Obie powyższe metody (ich miejsce w łańcuchu zdarzeń diagnostycznych przedstawiono na rys.1) są szczególnie przydatne dla danych charakteryzowanych rozkładami gaussowskimi. Na skuteczność jednoczesnego stosowania obu metod opracowywania zbiorów próbek zwrócono uwagę m.in. w [11].

Jedną z możliwości zbudowania metody o cechach wskazanych wyżej jest łączenie obu metod w różnych etapach klasyfikacji i jednocześnie uzupełnianie ich o algorytm ułatwiający tworzenie wzorców. Do tego celu wykorzystuje się np. transformację falkową lub Karhunana-Loevego. W pracy zastosowano transformację Fouriera ze względu na powszechność implementacji algorytmów FFT.

Zaproponowano więc nową metodę hybrydową FFT-PCA-LDA klasyfikacji uszkodzeń alternatora samochodowego w oparciu o analizę zredukowanego zbioru zmiennych w dziedzinie częstotliwościowej, przy wykorzystaniu metody wielowymiarowej analizy danych. Same analizy częstotliwościowe, prowadzone w diagnostyce, opisano na przykład w [3, 6, 7, 8, 10]. W [7] pokazano wykrywanie uszkodzenia diody za pomocą filtru, śledzącego pojawienie się określonej składowej częstotliwości. Mają one jednak istotne ograniczenia. Ponadto, jak wyżej wspomniano, występuje konieczność analizowania dużych zbiorów danych. Szczególnie istotna więc staje się eksploracja danych pod kątem optymalizacji ilości informacji oraz jej treści.

Reasumując, przy opracowywaniu nowej uwzględniono metody diagnozy stosowane dla typowych maszyn elektrycznych z jednoczesnym wykorzystaniem metod stosowanych dla

diagnostyki wyposażenia elektrycznego pojazdu. Tego typu postępowanie nie było dotąd proponowane w literaturze tematu.

W alternatorach i innych maszynach elektrycznych najczęściej występującym uszkodzeniem są uszkodzenia łożysk. Drugim najczęściej występującym uszkodzeniem, które dotyczy zwłaszcza alternatora, jest awaria mostka prostowniczego. Ze względu na powyższe w pracy proponowana metoda klasyfikacyjna jest weryfikowana dla uszkodzeń mostka prostowniczego.

3. Klasyfikator FFT-PCA-LDA

Dla systemów diagnostyki pokładowej brak jest rozwiązań zarówno sprzętowych jak i programowych, które jednoznacznie określałyby typ uszkodzenia alternatora. Dostarczane przez wytwórcę lub inne podmioty gospodarcze kody informują o zaledwie kilku uszkodzeniach (tablica 1). Dlatego podjęto próbę stworzenia nowego podejścia w diagnostyce alternatora do wykorzystania na stanowisku pomiarowym oraz w diagnostyce pokładowej pojazdu.

Założono:


- wykorzystanie analizy częstotliwościowej sygnałów,
- wnioskowanie oparte o sygnał napięciowy lub prądowy alternatora,
- budowę modelu statystycznego przy wykorzystaniu wielowymiarowej analizy danych do redukcji wymiarów zmiennych oraz rozpoznawania wzorców uszkodzeń,
- minimalizację punktów akwizycji sygnałów (nieinwazyjność w stosunku do struktury alternatora).

Tablica 1 Przykładowe kody usterek alternatorów

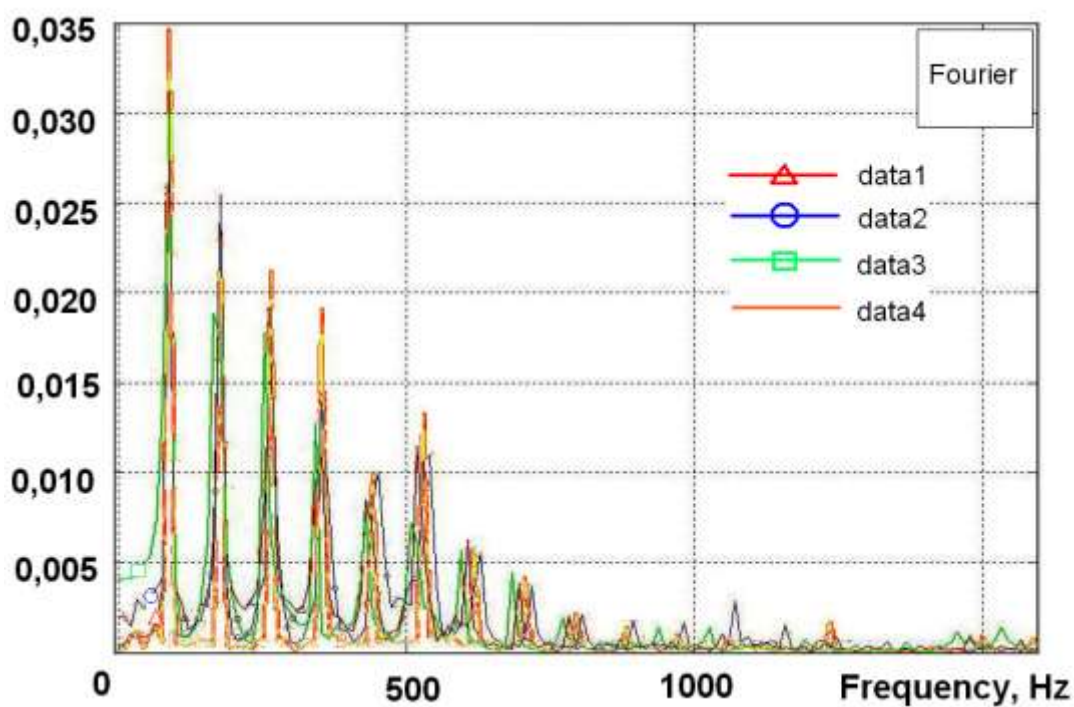
Kod	Opis usterki	System
1117	Sygnał obciążenia z zacisku alternatora DF	VAG
1209	Sygnał obrotów-alternator, zacisk	VAG

Należy podkreślić, że dokonanie rozróżnialności różnych typów uszkodzeń mostka prostowniczego ma mieć miejsce tylko w oparciu o sygnały wyjściowe: np. prądu bądź napięcia. Dla porównania, takie rozróżnienie dla metody oscyloskopowej nie było możliwe (rys. 2), bo wymagało uwzględnienia napięcia punktu zerowego stojana alternatora. Ponadto, jak wynika z rys.2, konieczna jest tu znajomość budowy alternatora albo chociaż wzorcowego przebiegu sygnału.

Również sama analiza FFT, metodą porównania nie przynosi spodziewanych rezultatów (rys.3). Jak wynika z przeprowadzonych pomiarów (rys.2.) rozróżnienie rodzaju uszkodzenia (a nawet samego stanu uszkodzenia) nie jest w tym przypadku możliwe.




Rys.2. Przebiegi czasowe napięcia dla uszkodzeń: A(+), A(-), B(+) oraz B(-), uszkodzenie w 1 diodzie



Rys.3. Analiza FFT dla uszkodzeń: A(+), A(-), B(+) oraz B(-), uszkodzenie w 1 diodzie

Powyższe problemy mogą być również związane z wyraźną losowością (rys.4.) mierzonych przebiegów wszystkich sygnałów.



Rys.4. Rzeczywiste sygnały alternatora, od góry: napięcia, hałasu i częstotliwości

Klasyfikacja metodą liniowej analizy dyskryminacyjnej (LDA) z wstępną ekstrakcją cech sygnału z wykorzystaniem analizy składowych głównych (PCA) automatycznie dobiera wektor zmiennych na podstawie których klasyfikuje obiekt do danej grupy stanów wzorcowych. Rozważa się zbiór N -próbek w n -wymiarowej przestrzeni i przyjmuje się, że każdy obraz należy do jednej z K -klas $\{C_1, C_2, \dots, C_K\}$. N_j jest numerem próbek w klasie C_j , $u_j = (1/N_j) \sum_{x \in C_j} x$ jest średnią obrazu z klasy C_j , $u = (1/N) \sum_{j=1}^K \sum_{x \in C_j} x$ jest średnią obrazu ze wszystkich próbek. Macierz rozproszenia w klasie jest dana w postaci:

$$S_w = (1/N) \sum_{j=1}^K \sum_{x \in C_j} (x - u_j)(x - u_j)^T = \Phi_w \Phi_w^T \quad (1)$$

Macierz rozproszenia między klasami jest określona jako:

$$S_b = (1/N) \sum_{j=1}^K N_j (u_j - u)(u_j - u)^T = \Phi_b \Phi_b^T \quad (2)$$

Macierz rozproszenia ma postać:

$$S_t = (1/N) \sum_{j=1}^K \sum_{x \in C_j} (x - u)(x - u)^T = \Phi_t \Phi_t^T = S_w + S_b \quad (3)$$

W przypadku, gdy macierz S_w nie jest osobliwa, metoda LDA próbuje określić projekcję $W_{opt} = (w_1, w_2, \dots, w_L)$, która spełnia kryterium Fishera:

$$W_{opt} = \arg \max_w \frac{|W^T S_b W|}{|W^T S_w W|}, \quad (4)$$

gdzie: w_1, w_2, \dots, w_L tworzą wektor wartości własnych $S_w^{-1} S_b$ w odniesieniu do L ($\leq K-1$) największych wartości własnych $\lambda_1, \lambda_2, \dots, \lambda_L$.

W przypadku, gdy macierz S_w jest osobliwa, jej odwrotność nie istnieje. Wówczas stosuje się metodę PCA [6] do projekcji wektora zmiennych na przestrzeń o mniejszym wymiarze, eliminując osobliwość.

Analiza czynników głównych (Principal Component Analysis - PCA) polega na zastosowaniu algorytmu statystycznego do wyodrębnienia małej liczby współczynników, które najlepiej przedstawiają swoimi wartościami dużą liczbę właściwości bardzo dużego zbioru danych. Obecnie jest bardzo często wykorzystywana, np. w pakietach typu MatLab, również ze względu na umożliwienie graficznego, przybliżonego oceniania struktur zbiorów danych. W metodzie PCA powstają sztuczne czynniki główne (Principal Components, PC), wchodzące w skład optymalnych kombinacji liniowych przedstawiających sobą sumy ważone danych wyjściowych. Kombinacje te wynikają ze stopniowego transformowania układu współrzędnych według kolejnych malejących wariancji danych. Te kolejne osie współrzędnych tworzą zbiór kolejnych czynników głównych.

Zaproponowaną metodę realizuje się w dwóch krokach: trenowanie modelu i wnioskowanie. Klasyfikator nazwano liniowym z uwagi na metody opisu zależności pomiędzy zmiennymi, które wykorzystują funkcje liniowe (PCA i LDA). Liniowość cechuje również trend uszkodzeń dla analizy wykonanej w oparciu o macierz kowariancji. Ostatecznie więc, PCA zapewnia maksymalizację wariancji a LDA – separację klas. Właściwe wykorzystanie LDA ma miejsce wtedy, gdy [9]:

- rozkład obiektów w każdej grupie próbek powinien być zbliżony do rozkładu normalnego,
- grupy próbek powinny być liniowo separowalne,
- macierze wariancji-kowariancji każdej grupy próbek powinny być porównywalne, a
- całkowita liczba obiektów musi być większa niż liczba zmiennych przynajmniej trzykrotnie.

Stwierdzono, że powyższe założenia odpowiadają warunkom gromadzenia danych w przypadku badań alternatorów.

Dla tworzenia wzorców wprowadzono analizę FFT, zawężając okna częstotliwościowe. Analiza pierwotnych „surowych” danych polega jedynie na zebraniu wzorców uszkodzeń przy pomocy analizy FFT z oknem prostokątnym. Wstępnego przetworzenia dokonuje się przez wymnożenie uzyskanego sygnału z oknem Hanninga i dodatkowo uśrednienie otrzymanych wartości dla poszczególnych składowych częstotliwości, dla ograniczonej liczby okien z ograniczoną liczbą punktów.

4. Pomiary i wyniki weryfikacji

Zaproponowany klasyfikator weryfikowano podczas badań na stanowisku pomiarowym przedstawionym na rys. 5. Zawierającym m.in.: kartę muzyczną 4-kanalową ESI Quata Fire 610, przetwornik pomiarowy SENSOR AMP-4ICP, czujniki drgań DYTRAN i stanowisko testowania alternatorów.

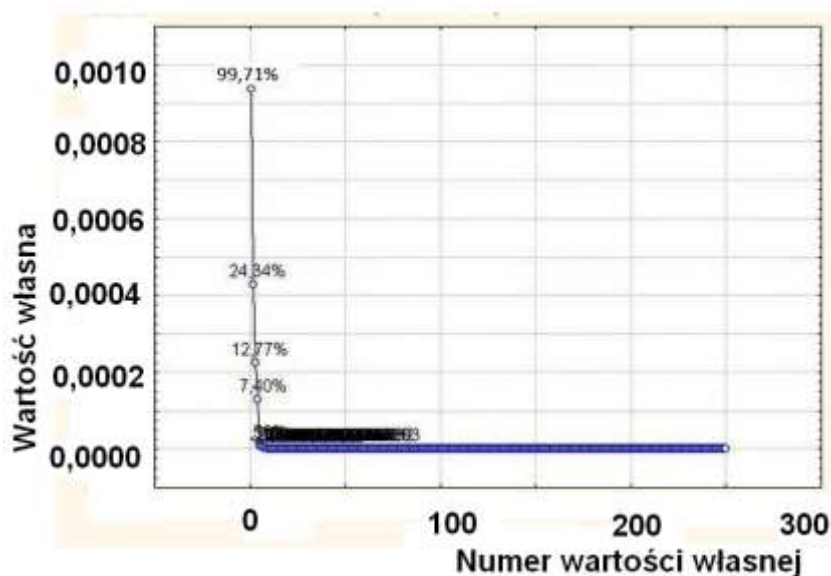
Symulowano uszkodzenia mostka prostowniczego dla 1 diody i 2 diod. Zgromadzono wzorce uszkodzeń z okna czasowego dla 4000 próbek, na potrzeby którego dokonano analizę FFT dla 250 punktów. Próbkę zostały zebrane dla prędkości wału alternatora 800 i 1000 obr/min.



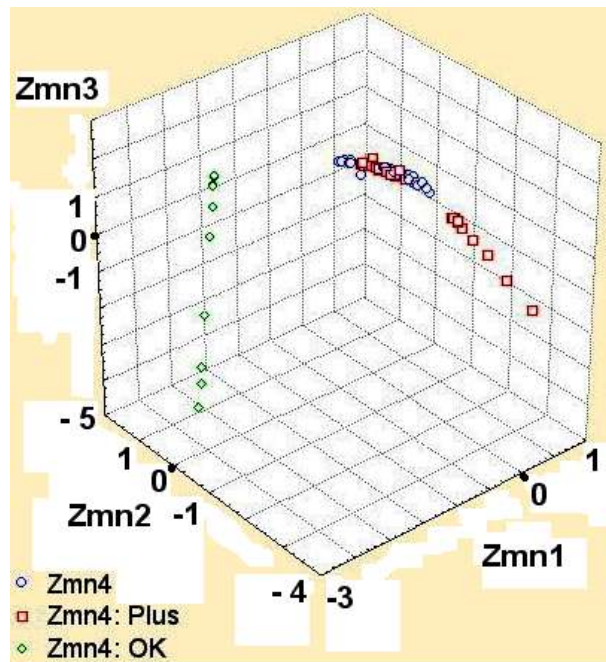
Rys.5. Stanowisko pomiarowe alternatorów.

Przypadki uszkodzeń zgrupowano, tworząc zbiory. Wydzielono wzorce uczące dla: uszkodzeń w poszczególnych fazach stojana, uszkodzeń dla diod dodatnich i ujemnych i uszkodzeń dla poszczególnych faz i biegunowości. W toku badań stwierdzono, że wartości własne macierzy kowariancji dla każdego z przebadanych przypadków były bardzo do siebie zbliżone i podobnie rozłożone jak dla przypadku przedstawionego rys. 6.

W trakcie badań nad rozróżnialnością uszkodzeń 1 diody na poziomie biegunowości przy zmiennej prędkości stwierdzono, że uzyskane wyniki są dobre. Poprawność klasyfikacji jest jednak dość silnie zależna od prędkości (rys.7. i rys.8.). Z kolei we wszystkich przebadanych przypadkach wyraźny był trend dla zmiennych przetworzonych metodą FFT-PDA-LDA.




Rys.6. Wartości własne macierzy kowariancji dla 1 diody uszkodzonej i prędkości 800 obr/min



Rys.7. Wykres skategoryzowany 3D składników głównych dla 1 diody uszkodzonej i prędkości 800 obr/min

Tablica 2. Procentowa jakość klasyfikacji dla 1 diody uszkodzonej i prędkości 800 obr/min


Stan	Procent
OK	100,00
Fault_Minus	66,67
Fault_Plus	90,00
Razem	81,43



Rys.8. Wykres skategoryzowany 3D składników głównych dla 1 diody uszkodzonej i prędkości 1000 obr/min

Tablica 3. Procentowa jakość klasyfikacji dla 1 diody uszkodzonej i prędkości 1000 obr/min

Stan	Procent
OK	100,00
Fault_Minus	66,67
Fault_Plus	66,67
Razem	71,43



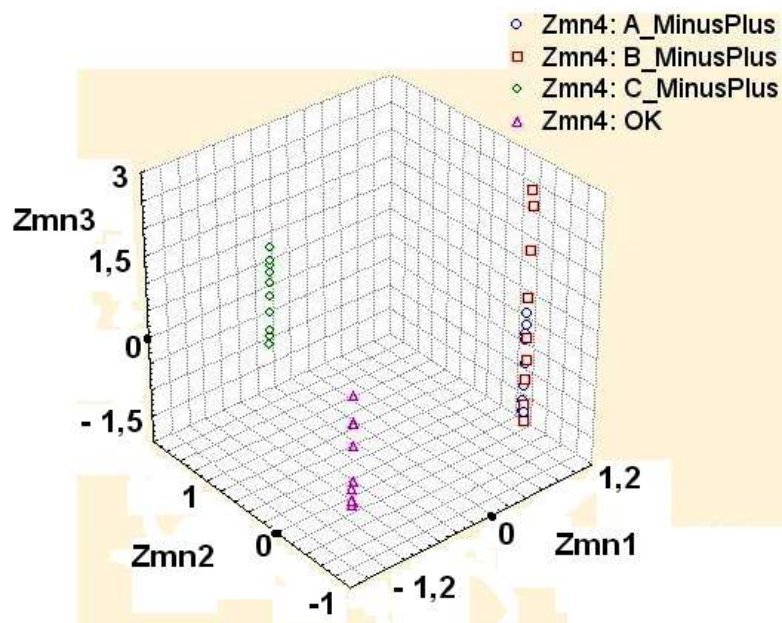
Rys.9. Wykres skategoryzowany 3D składników głównych dla 1 diody uszkodzonej na poziomie biegunowości i faz przy prędkości 800 obr/min

Tablica 4: Procentowa jakość klasyfikacji dla 1 diody uszkodzonej na poziomie biegunowości i faz przy prędkości 800 obr/min

Stan	Procent
OK	100,00
Fault_AMinus	100,00
Fault_APlus	70,00
Fault_BMinus	100,00
Fault_BPlus	90,00
Fault_CMinus	100,00
Fault_CPlus	100,00
Razem	94,28

Ze względu na niezadowalające rezultaty klasyfikowania (tablica 2 i tablica 3) przy wykorzystaniu tylko biegunowości lub fazy przeprowadzono klasyfikację uszkodzeń przy uwzględnieniu jednocześnie obu sygnałów. W wyniku okazało się, że skuteczność klasyfikacji wyraźnie wzrosła. Przykładowo na rys. 9 i w tablicy 4 przedstawiono wyniki badania rozróżnialności uszkodzeń 1 diody na poziomie biegunowości i faz przy prędkości 800 obr/min.

Interesujące wyniki uzyskano w badaniach uszkodzeń więcej, niż jednego elementu w jednej fazie. We wszystkich badanych przypadkach uzyskano 100%-ową skuteczność, co pokazano przykładowo, na rys.10. i w tablicy 5.



Rys.10. Wykres skategoryzowany 3D składników głównych w przypadku uszkodzeń 2 diod dla tej samej fazy przy prędkości 800 obr/min

Tablica 5: Procentowa jakość klasyfikacji w przypadku uszkodzeń 2 diod dla tej samej fazy przy prędkości 800 obr/min

Stan	Procent
OK	100,00
Fault_A	100,00
Fault_B	100,00
Fault_C	100,00
Razem	100,00


Stwierdzono, że najlepsze wyniki daje zastosowanie klasyfikatora FFT-PCA-LDA dla sygnałów uwzględniających i biegunowość i fazę oraz dla więcej niż jednego uszkodzenia.

5. Wyniki klasyfikacji innymi metodami

5.1. Sztuczne sieci neuronowe


W celu potwierdzenia dobrej jakości zaproponowanego klasyfikatora przeprowadzono analogiczne badania dla innych wybranych metod klasyfikacji.

Dokonano porównania klasyfikacji dla typów sieci: liniowa, PNN, RBN, perceptron trójwarstwowy oraz perceptron czterowarstwowy. Dokonano prób dla 20 rodzajów tych sieci i dla przypadku zbioru zmiennych niezredukowanych i zredukowanych. Dla zbioru niezredukowanego – 250 zmiennych – uszkodzenie 1 diody na poziomie biegunowości i fazy, najlepszy wynik otrzymano dla sieci liniowej 248:248-7:1, jakość uczenia: 1,000000, jakość walidacji: 0,705882, jakość testowania: 0,823529, błąd uczenia: 0,000000, błąd walidacji: 2,254002, błąd testowania: 2,254002. Schemat zwycięskiej sieci przedstawiono na rysunku 11.




Rys.11. Schemat sieci liniowej

Dla zbioru zredukowanego – 3 zmienne (składowe główne) – uszkodzenie 1 diody na poziomie biegunowości i faz, najlepszy wynik otrzymano dla sieci MLP 3:3-9-9-7:1, jakość uczenia: 1,000000, jakość walidacji: 0,941176, jakość testowania: 1,000000, błąd uczenia: 0,042153, błąd walidacji: 2,763365, błąd testowania: 0,048920. Schemat zwycięskiej sieci przedstawiono na rysunku 12.



Rys.12. Schemat sieci MLP

Dla zbioru zredukowanego – 3 zmienne (składowe główne) – uszkodzenie 1 diody na poziomie faz, najlepszy wynik otrzymano dla sieci RBF 3:3-7-4:1, jakość uczenia: 0,888889, jakość walidacji: 0,823529, jakość testowania: 0,823529, błąd uczenia: 0,232214, błąd walidacji: 2,030926, błąd testowania: 5,351756. Schemat zwycięskiej sieci przedstawiono na rysunku 13.



Rys.13. Schemat sieci RBF

5.2. Grupowanie metodą k-średnich

Dokonano klasyfikacji dla zredukowanego zbioru zmiennych – 3zmiennie (składniki główne), dla liczby 70 przypadków, wiązanie przypadków dokonano metodą k-średnich, braki danych usuwano przypadkami. Wyodrębniono 7 skupień, a rozwiązanie znaleziono po 2 iteracjach. Wyniki przedstawiono w tabelicy 6.

Tablica 6: Wyniki przyporządkowania

Numer skupienia	Liczba przypadków
1	20
2	3
3	10
4	2
5	20
6	8
7	7

6. Podsumowanie

Alternator samochodowy jest maszyną elektryczną pracującą w specyficznych warunkach, które tak jak obciążenia alternatora zmieniają się cyklicznie w czasie jego użytkowania. Metody, które pozwalają na dokładną identyfikację stanu alternatora mają zastosowanie dopiero po wymontowaniu z pojazdu.

Wstępne wyniki badań i analizy pomiarów z wykorzystaniem analizy FFT sygnału wyjściowego napięcia alternatora i metod data mining wykazują iż klasyfikator hierarchiczny FFT-PCA-LDA bardzo dobrze radzi sobie z rozróżnianiem uszkodzeń mostka prostowniczego alternatora, które w przestrzeni 3D składników głównych wszystkich stanów wykazują liniowy trend dla próbek uszkodzeń.

Metody data mining pozwalają na wykorzystanie „starszych“ danych, wcześniej wielokrotnie analizowanych.

Obecnie większość systemów diagnostyki, nie tylko pojazdowej, opiera się o wykorzystanie sztucznych sieci neuronowych, które bardzo dobrze radzą sobie z problemami regresji czy klasyfikacji. Zaproponowany hybrydowy klasyfikator FFT-PCA-LDA, który dla

uszkodzeń, reprezentujących liniowy trend wykazał dobrą zdolność dyskryminacji, przy znacznie prostszym procesie nastajania niż inne znane klasyfikatory. Klasyfikator pozwala na zredukowanie zmiennych do liczby 3, przy zachowaniu poprawności działania. Klasyfikator wykazał najwięcej błędnie sklasyfikowanych danych dla uszkodzeń uogólnionych do grup (np. uszkodzenia w poszczególnych fazach), dla przypadku wszystkich uszkodzeń dane zostały poprawnie przydzielone do odpowiednich klas. Otrzymane wyniki pozwalają na dalszą analizę. Konieczne staje się sprawdzenie klasyfikatora dla różnych prędkości obrotowych i obciążeń, ponieważ zwiększenie liczby sygnałów polepszyło jakość klasyfikacji. Dalsze badania prowadzone będą w kierunku wykorzystania korelacji sygnałów mechanicznych i sygnałów elektrycznych w alternatorze. Liczba i rodzaj sygnałów zależą będzie m.in. od tego, czy alternator będzie badany na taśmie produkcyjnej, czy w pojeździe. W pierwszym przypadku ważne jest wykrycie większej liczby niekorzystnych zdarzeń, w drugim – stwierdzenie zdatności do użycia.

Literatura

1. Alternator test apparatus and method. United States Patent; 4 178 546, 1979.
2. Chen V C. Evaluation of Bayes, ICA, PCA and SVM Methods for Classification. RTO-MP-SET-080 2004.
3. Dziubiński M. Koncepcja diagnostyki wyposażenia elektrycznego samochodu. Eksploatacja i Niezawodność 2002; 2: 39-47.
4. Haardle W, Simar L. Applied Multivariate Statistics Analysis, MDTech 2003.
5. Jastriebow A, Gad S, Słoń G. Analiza komputerowa diagnozowania defektów alternatora z wykorzystaniem sztucznej sieci neuronowej. Diagnostyka 2002; 27: 7-10.
6. Jolliffe I T. Principal Component Analysis. New York: Springer-Verlag, 2002.
7. Kościelny J M. Diagnostyka zautomatyzowanych procesów przemysłowych. Warszawa: Exit, 2001.
8. Rawicki S, Stein Z, Stolpe M, Zielińska M. Analiza harmoniczných w prądach i napięciach samochodowej prądnicy prądu przemiennego (alternatorze) z układem prostownikowym. Poznań: Konferencja ZKwE 1999; 567-570.
9. Stanimirova I, Daszykowski M, Walczak B. Metody uczenia z nadzorem – kalibracja, dyskryminacja i klasyfikacja. Kraków: Chemometria w analityce. IES, 2008.
10. Stein Z, Zielińska M. Problems of electromagnetic compatibility of Automotive alternating current generator (alternator). Pilsen: Conference AMTEE 2005; H13-H17.
11. Sudarshan S D, Pooja S D, Sawalkar S S. Pose Variant Based Comparative Analysis of PCA and LDA. Washington: Conference ICETE 2009; 188-191.
12. Żółtowski B, Tylicki H. Osprzęt elektryczny pojazdów mechanicznych. Bydgoszcz: Wyd. ATR, 1999.