

Mgr inż. Łukasz Jedliński

Katedra Podstaw Konstrukcji Maszyn
Politechnika Lubelska
Ul. Nadbystrzycka 36, 20-618 Lublin, Polska
E-mail: l.jedlinski@pollub.pl

Odszumianie danych rejestrowanych wielokanałowo z użyciem transformaty falkowej

Słowa kluczowe: *odszumianie danych, transformata falkowa, sztuczne sieci neuronowe, przekładnia stożkowa*

Streszczenie: W celu uzyskania informacji o interesującym nas zjawisku lub obiekcie najczęściej rejestrowane są wybrane sygnały pomiarowe otrzymane za pośrednictwem czujników. Niestety uzyskane sygnały oprócz pożądanej informacji zawierają również zakłócenia, które są spowodowane m.in. właściwościami toru pomiarowego i procesami towarzyszącymi działaniu obiektu. W wielu przypadkach zachodzi potrzeba pomiaru takiej samej wielkości w różnych miejscach obiektu i/lub kierunkach. Potrzebne są zatem narzędzia do poprawy stosunku sygnału do szumu sygnałów rejestrowanych wielokanałowo.

Transformata falkowa jest stosunkowo nową metodą przetwarzania danych, która znalazła zastosowanie w różnych dziedzinach takich jak technika i fizyka. W odniesieniu do sygnałów może być używana do odszumiania, kompresji, wykrywania trendu czy nieciągłości sygnału. W pracy tej transformata falkowa została użyta do odszumiania sygnałów drgań zarejestrowanych z dwóch trójosiowych czujników. Obiektem badań była przekładnia zębata stożkowa. Odszumianie sygnałów miało na celu poprawę skuteczności diagnozy uszkodzenia kół zębatych przekładni.

1. Wstęp


W diagnostyce wibroakustycznej, jak i w innych dziedzinach nauki, dąży się do poprawy uzyskiwanych rezultatów [2]. W ostatnich latach obserwuje się ciągły rozwój algorytmów wnioskowana diagnostycznego i metod przetwarzania sygnałów [3,11,16]. Sprzęt pomiarowy i komputery pozwalają na pomiar sygnałów ze znacznie większą dokładnością oraz z wielu kanałów pomiarowych jednocześnie.

W przypadku badania złożonych obiektów zachodzi potrzeba rejestracji wielu sygnałów. Również na początku badań typuje się więcej punktów pomiarowych, aby nie stracić istotnej informacji i wybrać te optymalne.

Uzyskane sygnały pomiarowe zawsze zawierają zakłócenia. W prostym modelu sygnału [1,4,10] zakłada się, że sygnał składa się ze składowej zdeterminowanej zawierającej użyteczną informację oraz składowej losowej czyli szumu. Istnieje wiele metod ekstrakcji użytecznej informacji z sygnału np. poprzez filtrację sygnału, analizę składowych głównych PCA, uśrednianie sygnałów. Wśród tych metod możemy wyróżnić transformatę falkową (WT), która znalazła zastosowanie m.in. w odszumianiu sygnałów [14]. Uogólnieniem odszumiania za pomocą WT dla jednego sygnału jest procedura zaproponowana w artykule [1] dla wielu sygnałów, która została wykorzystana w tej pracy.

2. Stanowisko badawcze

Badaną przekładnią jest przekładnia zębata stożkowa jednostopniowa. Na korpusie przekładni zamontowano dwa trójosiowe czujniki przyspieszeń drgań oznaczone na rysunku 1 liczbą 1 i 2. Oś X czujników jest zgodna z kierunkiem osi wału wejściowego a oś Z z osią wału wyjściowego. Drgania rejestrowano dla przekładni w stanie dobrym oraz z uszkodzoną powierzchnią zębów w wyniku zacierania. Dokładniejszy opis stanowiska badawczego można znaleźć w pracy [9].



Rys. 1. Widok badanej przekładni z zaznaczonym położeniem czujników drgań

3. Dyskretna transformata falkowa (DWT)

W przypadku ciągłej transformaty falkowej (CWT) obliczane są współczynniki falkowe dla każdej skali, co generuje dużą ilość danych oraz wymaga długotrwałych obliczeń. Dyskretna transformata falkowa wywodzi się z CWT i umożliwia wybór skal. DWT można zdefiniować jako [17]:

$$DWT(j, k) = |S_0^j|^{-1/2} \sum_k x|k| \psi \left(\frac{t - k\tau_0 S_0^j}{S_0^j} \right) \quad (1)$$

gdzie:

$S_0 > 1$, $\tau_0 > 1$,

ψ – falka podstawowa,

$x|k|$ – badany sygnał,

j, k – liczby całkowite dodatnie.

Do szybkich i wydajnych obliczeń DWT stosowany jest algorytm wprowadzony przez Mallata [12,15] znany pod nazwą multi-resolution analysis (MRA). W wyniku jego działania uzyskujemy wielorozdzielczą reprezentację sygnału w postaci aproksymacji i detali.

Kompletne podstawy teoretyczne MRA możemy znaleźć w pracy Mallata [12] natomiast zależność, która go opisuje wyrażona jest wzorem [17]:

$$x(t) = \sum_{\tau} S_0(\tau)\phi(t-\tau) + \sum_{\tau} \sum_{j=0}^{j-1} d_j(\tau)^{j/2} \psi(2^j t - \tau) \quad (2)$$

gdzie:

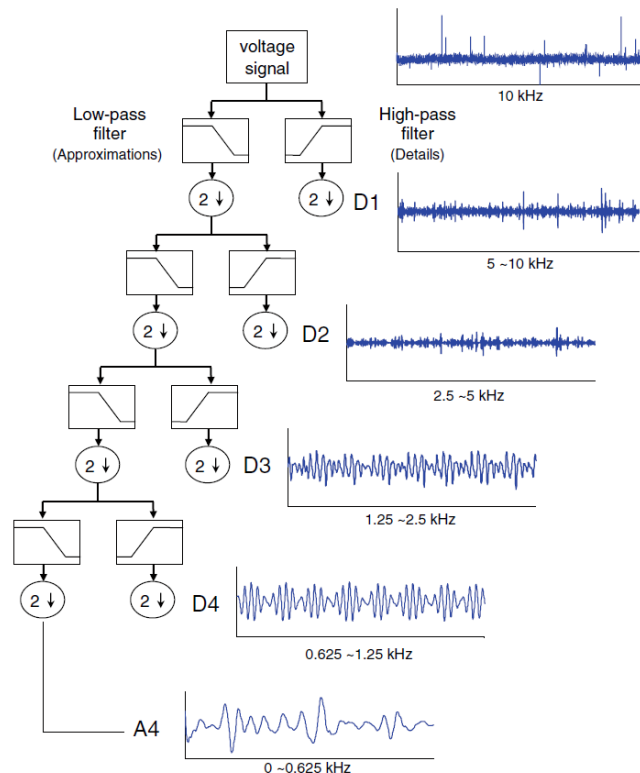
τ – współczynnik przesunięcia,

S_0 – współczynnik skali,

d_j – współczynnik falkowy dla skali j ,

$\phi(t)$, $\psi(t)$ – funkcja skalująca i falkowa.

Detale i aproksymacje obliczane są w wyniku filtracji dwukanałowym zespołem filtrów (zwierciadlanymi filtrami kwadraturowymi [5,6]). Aby otrzymać rozkład sygnału na kilka poziomów operację filtracji wykonujemy w sposób iteracyjny (rys. 2). Z filtra dolnoprzepustowego otrzymujemy aproksymację A_j (składowa sygnału o niskiej częstotliwości) a z filtra górnoprzepustowego detal D_j (składowa sygnału o wysokiej częstotliwości)[7]. Na rysunku 2, przedstawiono przykładowy sygnał, który był rejestrowany z częstotliwością 10 kHz. W wyniku rozkładu, na pierwszym poziomie aproksymacja A_1 sygnału, zawiera sygnał o częstotliwości z zakresu 0 – 5 kHz a detal D_1 z zakresu 5 – 10 kHz. Jeżeli sygnał oryginalny składał się ze 100 próbek to w wyniku filtracji otrzymaliśmy detal o długości ok. 100 próbek i aproksymację o długości ok. 100 próbek. Suma sygnałów wynikowych jest w przybliżeniu dwa razy większa niż sygnału oryginalnego. Aby uniknąć takiego wzrostu liczby próbek stosuje się decymację usuwając co drugą próbkę z otrzymanej reprezentacji sygnału. Następnie możemy dokonać dalszej dekompozycji. Najczęściej dalszej analizie poddawana jest aproksymacja, w wyniku której otrzymujemy kolejny detal i aproksymację. Dekompozycja sygnału odbywa się na skończoną wartość poziomów ze względu na ograniczoną długość sygnału czy sens fizyczny uzyskanych detali i aproksymacji [18]. Zazwyczaj poziom dekompozycji nie jest większy niż 8.



Rys. 2. Dekompozycja sygnału przy użyciu algorytmu multi-resolution analysis [17]

Usuwanie zbędnej informacji w postaci szumu z sygnału po dekompozycji falkowej może być realizowane kilkoma metodami. Kolejne aproksymacje sygnału zawierają składową sygnału o coraz niższych częstotliwościach, a więc wybór odpowiedniej aproksymacji jako reprezentacji sygnału będzie metodą usuwania szumu. Inną możliwością jest prosta modyfikacja pierwszego detalu lub pierwszych detali poprzez zmianę wartości współczynników falkowych na zero. Przedstawione metody odszumiania sygnału są metodami niezbyt dokładnymi. Bardziej wyrafinowane algorytmy odszumiania sygnału bazują na zerowaniu współczynników falkowych detali na podstawie kryterium obliczanego dla każdego detalu. Oprócz wyboru odpowiedniego kryterium obliczania progu, poniżej którego, współczynniki falkowe są zerowane, należy także wybrać sposób egzekwowania progu. Metoda hard thresholding realizuje proces odszumiania ustawiając wartość zero dla elementów o wartości absolutnej poniżej wartości progu, pozostałe elementy nie są zmieniane. Odmianą metody hard thresholding jest metoda soft thresholding, która różni się od poprzedniej metody tym, że zmienia elementy, które nie są zerowane. Dzięki temu nie powstaje nieciągłość w miejscu, w którym elementy mają wartość równą wartości progu [13].

Rekonstrukcja sygnału odbywa się w podobny sposób jak dekompozycja. Należy nadpróbować detale i aproksymacje przed syntezą w filtrach, których wybór jest krytyczny do pełnego odtworzenia oryginalnego sygnału.

3.1 Procedura odszumiania

Procedura odszumiania danych wielowymiarowych jest uogólnieniem procedury odszumiania danych jednowymiarowych. Rozważania są zgodne z pracą Aminghafari i in. [1].

Założmy następujący p -wymiarowy model sygnału:

$$X(t) = f(t) + \varepsilon(t), t = 1, \dots, n \quad (3)$$

gdzie:

$X(t), f(t), \varepsilon(t)$ są wymiaru $1 \times p$,

$f(t)$ – sygnał, który chcemy odszumieć,

$\varepsilon(t)$ – szum Gaussowski z nieznaną macierzą kowariancji $E(\varepsilon(t)^T \varepsilon(t)) = \Sigma_\varepsilon$.

Każda składowa $X(t)$ jest postaci dla $1 \leq i \leq p$:

$$X^i(t) = f^i(t) + \varepsilon^i(t), t = 1, \dots, n \quad (4)$$

gdzie:

f^i – należy do pewnej przestrzeni funkcyjnej (najczęściej przestrzeni L^2 lub Besova).

Macierz kowariancji Σ_ε , która powinna być dodatnio określona, uchwyci stochastyczną zależność pomiędzy składowymi $X(t)$ i modelami przestrzennej korelacji.

Procedura odszumiania może być wyrażona za pomocą trzech kroków [1] dla macierzy X , która jest wymiaru $n \times p$ i składa się z p sygnałów (kolumn macierzy X) tak, że $n \gg p$:


- Dla każdej kolumny macierzy X wykonaj dekompozycję falkową stopnia J . W tym kroku uzyskuje się $J+1$ macierzy D_1, \dots, D_J zawierających współczynniki detali stopnia od 1 do J z p sygnałów i współczynniki aproksymacji A_J z p sygnałów. Macierze D_j i A_J są wymiaru $n2^j \times p$ oraz $n2^J \times p$;
- Wyznacz estymator $\hat{\Sigma}_\varepsilon$ macierzy kowariancji szumu a następnie dokonaj dekompozycji SVD (singular value decomposition) macierzy $\hat{\Sigma}_\varepsilon$ za pomocą macierzy ortogonalnej V takiej, że $\hat{\Sigma}_\varepsilon = VAV^T$. Następnie zmień bazę przestrzeni za pomocą macierzy przejścia V (dokładnie obliczając $D_j V, 1 \leq i \leq p$) i zastosuj filtrowanie $t_i = \sqrt{2\lambda_i \log(n)}$ jednowymiarowe za pomocą progu dla i -tej kolumny

macierzy $D_j V$;

- Dokonaj rekonstrukcji odszumionej macierzy \check{X} za pomocą uproszczonych macierzy detali i aproksymacji poprzez zmianę bazy przestrzeni za pomocą macierzy V^T i odwrotnego przekształcenia falkowego.

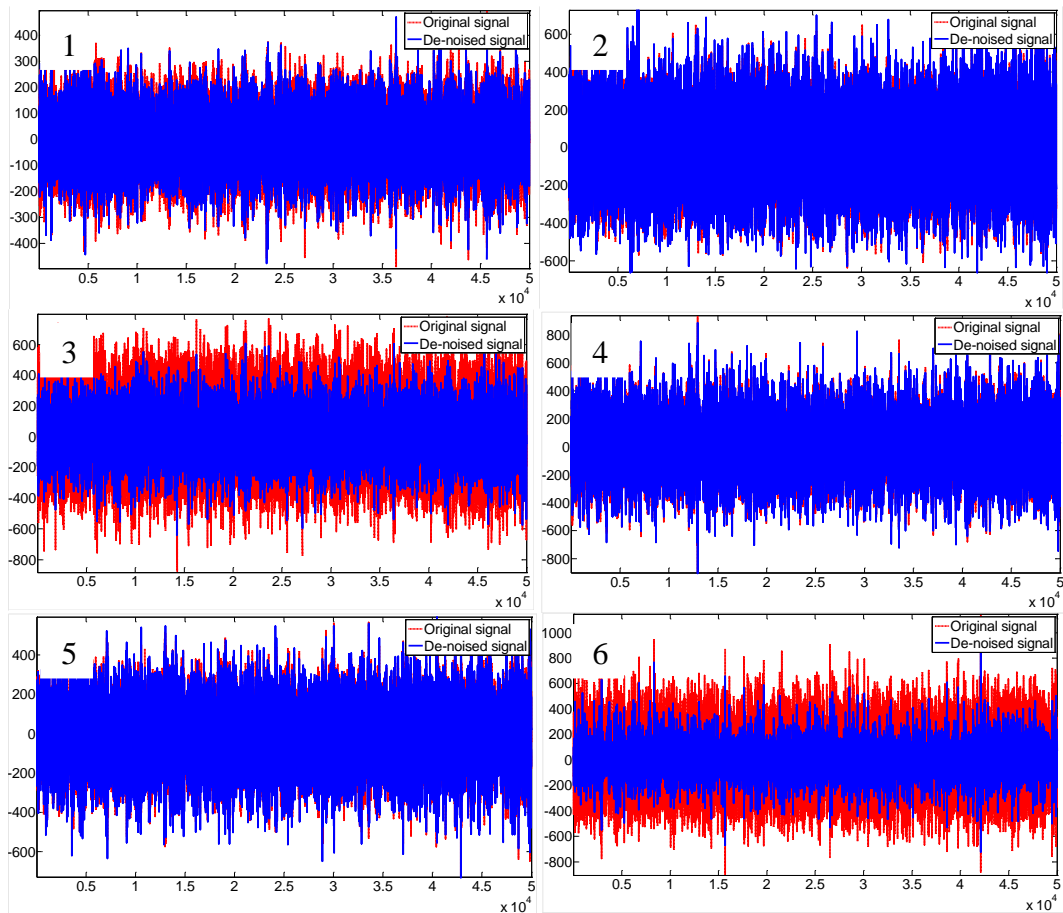
4. Wyniki badań

Sygnaly drgań zarejestrowane w trakcie badań zostały poddane odszumianiu zgodnie z przedstawioną powyżej procedurą. Odszumianie przeprowadzono dla sygnałów z przekładni w stanie dobrym i uszkodzonym dla sześciu rejestrowanych kanałów. Na rys. 3 przedstawiono wykres współczynników falkowych obrazujących zmianę częstotliwości sygnału drgań w czasie.




Rys. 3. Wykres 3D sygnału drgań

Wyniki odszumiania dla sygnałów w dziedzinie czasu dla przekładni uszkodzonej przedstawiono na rysunku 4. Na podstawie wykresów dla osi czujników zgodnych z kierunkiem osi wału wyjściowego można zauważyć, że sygnały te zawierają najwięcej szumu.



Rys. 4. Sygnały drgań dla przekładni uszkodzonej dla sześciu kanałów pomiarowych przed i po odszumieniu

Poziom dekompozycji sygnałów wynosił trzy a na falkę bazową wybrano Coiflet 1 (rys. 5)



Rys. 5. Falka Coiflet 1

Dla tego samego kryterium obliczania progów dla detali sygnału odszumianie zrealizowano dla metody soft i hard thresholding. Następnie obliczono cechy sygnałów i wybrano osiem cech z dwudziestu za pomocą algorytmu przedstawionego w pracy [8]. Wybrane cechy to:

- wartość średnia,
- wartość skuteczna,
- wartość szczytowa,
- współczynnik szczytu,
- współczynnik luzu,
- odchylenie standardowe,
- energy ratio,
- FM0.

Aby porównać skuteczność odszumiania sygnałów obliczono także takie same cechy dla sygnałów bez przetwarzania. Klasyfikacja stanu została wykonana za pomocą sztucznej sieci neuronowej multi layer perceptron (MLP).

Tabela 1. Wyniki klasyfikacji stanu dla sygnału bez przetwarzania

Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Wszystkie próby
MLP 8-4-2	89,88	91,66	91,66	90,41

Tabela 2. Wyniki klasyfikacji stanu dla sygnału odszumionego (soft thresholding)

Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Wszystkie próby
MLP 8-4-2	95,53	95,83	95,83	95,62

Tabela 3. Wyniki klasyfikacji stanu dla sygnału odszumionego (hard thresholding)

Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Wszystkie próby
MLP 8-9-2	97,02	94,44	94,44	96,24

Rezultaty klasyfikacji sieci podano w tabelach. Skuteczność klasyfikacji dla sygnału bez przetwarzania wyniosła około 90% a dla sygnału po odszumianiu odnotowano około 5% poprawę wyników. Różnice między metodą hard i soft thresholding są nieznaczne.

5. Podsumowanie

W pracy przedstawiono metodę odszumiania sygnałów przyspieszeń drgań rejestrowanych jednocześnie dla tego samego obiektu. Porównując sygnały przed i po odszumianiu można zauważyć, że dla obu czujników, na tym samym kierunku (zgodnym z osią wału wyjściowego) rejestracji drgań, występuje najwięcej zakłóceń.

Odszumianie sygnałów wykonano dwoma metodami soft i hard thresholding. Następnie sieć neuronowa miała za zadanie rozróżnić stan przekładni. Dla obu metod uzyskano bardzo zbliżone i zadowalające wyniki. Jakość klasyfikacji wyniosła ok. 96%. Aby zweryfikować skuteczność metody wykonano taką samą procedurę dla sygnału oryginalnego. Poprawność klasyfikacji była mniejsza w przybliżeniu o 5%.

Literatura

1. Aminghafari M, Cheze N, Poggi J M. Multivariate denoising using wavelets and principal component analysis. *Computational Statistics & Data Analysis* 2006; 50: 2381-2398.
2. Antoni J, Bonnardot F, Raad A, El Badaoui M. Cyclostationary modelling of rotating machine vibration signals. *Mechanical Systems and Signal Processing* 2004; 18: 1285-1314.
3. Antoni J, Randall R B. Unsupervised noise cancellation for vibration signals: part I-evaluation of adaptive algorithms. *Mechanical Systems and Signal Processing* 2004; 18: 89-101.
4. Barszcz T. Decomposition of vibration signals into deterministic and nondeterministic components and its capabilities of fault detection and identification. *Int. J. Appl. Math. Comput. Sci.* 2009; 19(2): 327-335.

5. Batko W, Dąbrowski Z, Engel Z, Kiciński J, Weyna S. Nowoczesne metody procesów wibroakustycznych. Radom: Wydawnictwo Instytutu Technologii Eksploatacji, 2005.
6. Białasiewicz J T. Falki i aproksymacje. Warszawa: WNT, 2004.
7. Bilgin S, Colak O H, Koklukaya E, Ari N. Efficient solution for frequency band decomposition problem using wavelet packet in HRV. Digital Signal Processing 2008; 18: 892-899.
8. Jedliński Ł, Jonak J. Optimum choice of signals' features used in toothed gears' diagnosis. Diagnostyka 2010; 55: 9-12.
9. Jedliński Ł, Jonak J. Quality evaluation of the bevel gear assembly based on analysis of the vibration signal. Diagnostyka 2010; 53: 23-26.
10. Krukowski W, Józefczyk I. Transformacja falkowa w diagnostyce urządzeń mechanicznych. Diagnostyka 2008; 46: 75-82.
11. Łazarz B, Wojnar G, Czech P. Early fault detection of toothed gear in exploitation conditions. Eksploatacja i Niezawodność – Maintenance and Reliability 2011; 1: 68-77.
12. Mallat S G. A theory for multiresolution signal decomposition: the wavelet representation. IEEE Transactions on Pattern Analysis and Machine Intelligence 1989; 7: 674-693.
13. Misiti M, Misiti Y, Oppenheim G, Poggi J M. Wavelet toolbox™ 4. User's guide. The MathWorks, Inc. 2010.
14. Peng Z K, Chu F L. Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. Mechanical Systems and Signal Processing 2004; 18: 199-221.
15. Seker S, Ayaz E. Feature extraction related to bearing damage in electric motors by wavelet analysis. Journal of the Franklin Institute 2003; 340: 125-134.
16. Wang Y, Zuo M, Lei Y, Fan X. Improvement of local mean approximation in empirical mode decomposition for gear fault detection. Eksploatacja i Niezawodność – Maintenance and Reliability 2010; 2: 59-66.
17. Wu J D, Kuo J M. An automotive generator fault diagnosis system using discrete wavelet transform and artificial neural network. Expert Systems with Applications 2009; 36: 9776-9783.
18. Zimroz R. Zastosowanie analizy falkowej w diagnostyce uszkodzeń lokalnych układów napędowych maszyn górniczych. Diagnostyka 2009; 49: 113-122.