

Time-frequency methods for processing non-stationary diagnostic vibroacoustic signals

Czasowo-częstotliwościowe metody przetwarzania niestacjonarnych diagnostycznych sygnałów wibroakustycznych

The article presents the issues of interpretation of non-stationary vibroacoustic diagnostic signals. The reasons of the incomplete usefulness of the traditional analysis solely in the field of time or frequency for such cases are explained. The use of time-frequency methods is presented as the proposed solution. The literature was reviewed in aspect of the methods currently used or on which the research is carried out. Older applications, such as the short-time Fourier transform and more complex and contemporary applications such as the Hilbert-Huang transform, are mentioned. Further development directions were also assessed, taking into account the combination of methods and the use of artificial neural networks, assessing the latter as giving the greatest potential in aspect of the evolution of signal processing methods.

W artykule zaprezentowano problematykę interpretacji niestacjonarnych wibroakustycznych sygnałów diagnostycznych. Wyjaśniono przyczyny niepełnej przydatności tradycyjnej analizy wyłącznie w dziedzinie czasu lub częstotliwości dla takich przypadków. Jako proponowane rozwiązanie przedstawiono wykorzystanie metod czasowo-częstotliwościowych. Dokonano przeglądu literatury w aspekcie metod obecnie wykorzystywanych lub nad którymi prowadzone są badania. Wymieniono zarówno zastosowania starsze jak krótkoczasowa transformata Fouriera oraz bardziej złożone i współczesne jak transformata Hilberta-Huanga. Dokonano również oceny dalszych kierunków rozwoju z uwzględnieniem kombinacji metod oraz wykorzystania sztucznych sieci neuronowych oceniając te ostatnie jako dające największy potencjał w aspekcie ewolucji metod przetwarzania sygnałów.

Keywords: vibroacoustic diagnostics, non-stationary signals, time-frequency methods

Słowa kluczowe: diagnostyka wibroakustyczna, sygnały niestacjonarne, metody czasowo-częstotliwościowe

1. INTRODUCTION

Most of the vibroacoustic signals recorded and processed during the operation of machines and vehicles, including rail vehicles, are in fact variable in time and non-stationary [37,40]. It results, among others, from what that most of the real systems are non-linear systems, whose features can be characterized as corresponding to a linear system only with low-amplitude vibrations [2]. Another aspect influencing on the non-stationarity of the signal is occurring the failure of the systems - at each stage of the use of a technical device there are defects affecting the signals of the processes taking place during the operation of machine, from imperfections during designing and production to failures caused by extreme wearing out. Moreover, the very nature of the work of a technical object may be non-stationary, e.g. variable rotational speed during use or variable speed of movement [6].

1. WPROWADZENIE

Większość sygnałów wibroakustycznych rejestrowanych i przetwarzanych w trakcie eksploatacji maszyn i pojazdów, w tym pojazdów szynowych, jest w istocie zmienna w czasie i niestacjonarna [37,40]. Wynika to między innymi z tego, że większość układów rzeczywistych to układy nieliniowe, których cechy można scharakteryzować jako odpowiadające układowi liniowemu tylko przy drganiach nisko amplitudowych [2]. Innym aspektem wpływającym na niestacjonarność sygnału jest powstawanie uszkodzeń w układach. Na każdym etapie użytkowania urządzenia technicznego, występują defekty wpływające na sygnały procesów zachodzących podczas pracy maszyny, poczynając od niedoskonałości w trakcie konstruowania i wytwarzania, kończąc na awariach spowodowanych skrajnym wyeksploatowaniem. Ponadto sama natura pracy obiektu technicznego może być niestacjonarna np. zmienna

Such variability of signals in time, which is characterized by aperiodicity, causes that the usefulness of only time or only frequency analysis becomes limited in aspect of technical diagnostics [32]. The Fourier transform analyses the signal globally - it makes it possible to determine the characteristics of frequency components for the entire tested signal. However thanks to it, it cannot be determined how these components changed with the course of time. A practical example of limited usefulness in the diagnostic aspect is a technical examination of a reducer with a damaged toothed wheel, where the defect manifests itself in the form of crushing a single tooth. The spectrum of vibrations during the operation of a damaged gear will differ from the spectrum of vibrations of a technically efficient gear, which in fact will allow to state that the defect has occurred. However, it will be impossible to precisely define the form of the damage and the exact place of its occurrence [4,29].

The presented state of affairs also applies to the operation and diagnostics of elements of the rail transport system. In [5,8,19,33,37] it is presented, among others, the use of non-stationary vibroacoustics signals for the detection of flat places on wheels, the detection of a slip phenomenon, identification of damage to the gear transmission or analysis of vibrations surrounded by railways. Therefore, it determines the necessity to develop the methods of signal processing allowing for the correct interpretation of the non-stationary diagnostic vibroacoustic signal. Such methods include the time-frequency methods.

2. STATIONARITY OF SIGNALS

To determine the stationarity of the process, it is necessary to know the value of mean described by the equation (1) and the correlation function expressed by the relation (2).

$$m_s(t_1) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} s_k(t_1), \quad (1)$$

$$R_s(t_1, t_1 + \tau) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} s_k(t_1) \cdot s_k(t_1 + \tau), \quad (2)$$

The stochastic process $\{s(t)\}$ is stationary in the broader sense (poorly stationary), when the value of the function $m_s(t_1)$ and $R_s(t_1, t_1 + \tau)$ do not depend on time t . In practice, this means that the average value of poorly stationary processes is constant, and the autocorrelation function depends only on the shift τ , i.e. $m_s(t_1) = m_s$ and $R_s(t_1, t_1 + \tau) = R_s(\tau)$.

If for the stochastic process $\{s(t)\}$ an infinite set of moments of higher orders and total moments can be calculated, and if all possible moments and total moments do not depend on the time of the process, then the process $\{s(t)\}$ is strictly called stationary or stationary in a narrower sense.

prędkość obrotowa w trakcie użytkowania lub zmienna prędkość poruszania się [6].

Taka zmienność sygnałów w czasie charakteryzowana aperiodycznością powoduje, że przydatność analizy wyłącznie czasowej lub wyłącznie częstotliwościowej staje się ograniczona w aspekcie diagnostyki technicznej [32]. Transformata Fouriera analizuje sygnał w sposób globalny i pozwala ona wyznaczyć charakterystyki składowych częstotliwościowych dla całego badanego sygnału. Nie można jednak dzięki niej rozstrzygnąć jak te składowe się zmieniały wraz z przebiegiem czasu. Praktycznym przykładem ograniczonej przydatności w aspekcie diagnostycznym jest badanie techniczne reduktora z uszkodzonym kołem zębatym, gdzie defekt objawia się w postaci skręcenia pojedynczego zęba. Widmo drgań podczas pracy przekładni uszkodzonej będzie różnić się od widma drgań przekładni sprawnej technicznie, co w istocie pozwoli stwierdzić, że defekt wystąpił. Niemożliwe jednak będzie dokładne określenie postaci uszkodzenia oraz dokładnego miejsca jego wystąpienia [4, 29].

Przedstawiony stan rzeczy dotyczy także eksploatacji i diagnostyki elementów systemu transportu szynowego. W kilku publikacjach [5, 8, 19, 33, 37] przedstawiono między innymi wykorzystanie niestacjonarnych sygnałów wibroakustycznych do detekcji płaskich miejsc na kołach, wykrywania zjawiska poślizgu, identyfikowanie uszkodzeń przekładni zębatej i analizy drgań w otoczeniu dróg szynowych. Determinuje więc to konieczność opracowania metod przetwarzania sygnałów pozwalających poprawnie zinterpretować niestacjonarny diagnostyczny sygnał wibroakustyczny. Do takich metod należą metody czasowo-częstotliwościowe.

2. STACJONARNOŚĆ SYGNAŁÓW

Do określenia stacjonarności procesu niezbędna jest znajomość wartości średniej opisanej równaniem (1) oraz funkcji korelacji wyrażonej zależnością (2).

$$m_s(t_1) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} s_k(t_1), \quad (1)$$

$$R_s(t_1, t_1 + \tau) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} s_k(t_1) \cdot s_k(t_1 + \tau), \quad (2)$$

Proces stochastyczny $\{s(t)\}$ jest stacjonarny w szerszym sensie (słabo stacjonarny), kiedy wartość funkcji $m_s(t_1)$ i $R_s(t_1, t_1 + \tau)$ nie zależą od czasu t . W praktyce oznacza to, że średnia wartość słabo stacjonarnych procesów jest stała, a funkcja autokorelacji zależy tylko od przesunięcia τ , tzn. $m_s(t_1) = m_s$ oraz $R_s(t_1, t_1 + \tau) = R_s(\tau)$.

Jeżeli dla procesu stochastycznego $\{s(t)\}$ można obliczyć nieskończony zbiór momentów wyższych rzędów i momentów łącznych oraz gdy wszystkie możliwe momenty oraz momenty łączne nie zależą od czasu procesu, wtedy proces $\{s(t)\}$ nazywa się

If the statistical functions are used to description of the stochastic process, i.e. the mean value written in the form of the relation (3) and the autocorrelation function (4), then if the random process $\{s(t)\}$ is stationary and the values $m_s(k)$ and $R_s(\tau, k)$ defined by the formulas (3) and (4) are the same for the different random functions, then such a random process is called ergodic. If the signal is ergodic, then it can be concluded about the entire population of implementations based on the analysis of one implementation.

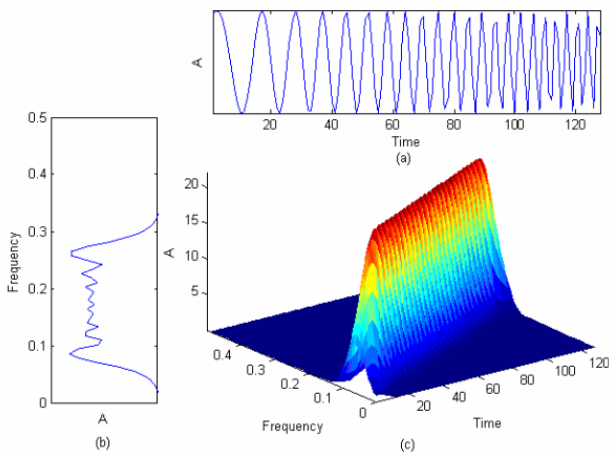
$$m_s(k) = \lim_{N \rightarrow \infty} \frac{1}{T} \int_0^T s_k(t) dt, \quad (3)$$

$$R_s(\tau, k) = \lim_{N \rightarrow \infty} \frac{1}{T} \int_0^T s_k(t) \cdot s_k(t + \tau) dt, \quad (4)$$

From the analysis of relations (1) to (4) it is concluded that the ergodic processes are a special case of stationary processes [28].

3. THE USE OF TIME - FREQUENCY METHODS

The solution that allows to increase the amount of information obtained from the tested vibration signal is the use of the analysis that uses joint time-frequency (t/f) representations of Joint Time-Frequency Analysis (JTFA) signals. A graphic example of such a joint representation compared to the time and frequency domain representations is presented in Fig.1.



Rys. 1. Porównanie dziedzin czasu, częstotliwości i czasowo-częstotliwościowej [41]

Fig. 1. Comparison of time, frequency and time-frequency domain [41]

The list of characteristics presented in Fig. 1 clearly presents the differences between the time, frequency and time-frequency representation of the signal. The diagnostic usefulness of the latter is also clearly visible. By analyzing only the overall spectrum of the signal, it is difficult to obtain feedback that is suitable for diagnostic conclusion - it is difficult to distinguish the possible dominant components. Using JTFA, such information is

ściśle stacjonarnym lub stacjonarnym w węższym sensie.

Jeśli do opisu procesu stochastycznego zostaną użyte funkcje statystyczne, tzn. wartość średnia zapisana w postaci zależności (3) i funkcja autokorelacji (4), to jeżeli proces losowy $\{s(t)\}$ jest stacjonarny i wartości $m_s(k)$ i $R_s(\tau, k)$ określone wzorami (3) i (4) są jednakowe dla różnych funkcji losowych, to taki proces losowy nazywa się ergodycznym. Jeżeli sygnał jest ergodyczny to na podstawie analizy jednej realizacji można wnioskować o całej populacji realizacji.

$$m_s(k) = \lim_{N \rightarrow \infty} \frac{1}{T} \int_0^T s_k(t) dt, \quad (3)$$

$$R_s(\tau, k) = \lim_{N \rightarrow \infty} \frac{1}{T} \int_0^T s_k(t) \cdot s_k(t + \tau) dt, \quad (4)$$

Z analizy zależności (1) do (4) wynika wniosek, że procesy ergodyczne są szczególnym przypadkiem procesów stacjonarnych [28].

3. WYKORZYSTANIE METOD CZASOWO-CZĘSTOTLIWOŚCIOWYCH

Rozwiązaniem pozwalającym zwiększyć ilość informacji uzyskanych z badanego sygnału drgań, jest zastosowanie analizy, która wykorzystuje łączne czasowo-częstotliwościowe (t/f) reprezentacje sygnałów *Joint Time-Frequency Analysis* (JTFA). Przykład graficzny takiej reprezentacji łączonej porównany z reprezentacjami w domenie czasu i częstotliwości przedstawiony jest na rys. 1.

Zestawienie charakterystyk przedstawionych na rys. 1 klarownie przedstawia różnice między reprezentacją czasową, częstotliwościową oraz czasowo-częstotliwościową sygnału. Wyraźnie widoczna również jest przydatność diagnostyczna tej ostatniej. Analizując wyłącznie całościowe widmo sygnału trudno uzyskać informację zwrotną zdatną do przeprowadzenia wnioskowania diagnostycznego, trudno wyróżnić ew. składowe dominujące. Taka informacja zostaje uzyskana na podstawie JTFA. Sygnał jest niestacjonarny, charakteryzuje się pojedynczą składową częstotliwością dominującą, która ulega przesunięciu fazowemu wraz z przebiegiem czasu. Tak jednoznacznie sformułowany opis sygnału pozwalają wykorzystać go do przeprowadzenia precyzyjnego wnioskowania diagnostycznego. Można więc stwierdzić, że JTFA są zaawansowanymi metodami przetwarzania sygnałów pozwalającymi w pełniejszy sposób wykorzystać ich analizy w aspekcie diagnostyki technicznej [31].

Praktyczne wykorzystanie analizy czasowo-częstotliwościowej oraz jej zalety przedstawiono na rys. 2 przy sformułowaniu charakterystyk przyspieszeń drgań uszkodzonej przekładni stożkowej. Rysunek 2 przedstawia reprezentację JTFA sygnału przyspieszeń drgań zarejestrowanych w trakcie pracy przekładni stożkowej z uszkodzonym pojedyn-

obtained - the signal is non-stationary, characterized by a single dominant frequency component, which is phase shifted with the course of time. Such an explicitly formulated signal description allows to use it to carry out precise diagnostic conclusion. Therefore, it can be concluded that JTFA are the advanced methods of signal processing that allow for a more fully use of their analysis in the aspect of technical diagnostics [31].

The practical use of time-frequency analysis and its advantages are presented in Fig. 2 with the formulation of the vibration acceleration characteristics of the damaged conical gear.

Fig. 2 presents the JTFA representation of the signal of vibration accelerations recorded during the operation of the conical gear with the damaged single tooth - the defect in the form of injured structure and broken part of the tooth. The repeatable presence of the dominant frequency component is visible, but the repetition is at equal time period. It results from the rotary motion of the gear - occurring the resonance frequencies can be interpreted as an effect of the entering of the damaged tooth in the contact points. The damage causes occurring the increased vibrations in relation to the undamaged element. In further analysis, knowing the rotational speed of the machine, it is possible to link the occurrence of the dominant component with the current angle of rotation of the gear - knowing the starting position it is possible to precisely indicate which tooth was damaged. This proves the advantage of time-frequency methods over the others - the determination of an ordinary spectrum would only allow to conclude that the tested gear is probably damaged, because it has different frequency characteristics than the reference gear. The use of JTFA allowed not only to detect the damage, but also to state that it is local and it is possible to mark the place of its occurrence.

4. VIBROACOUSTIC METHODS IN COMPOSITE DIAGNOSTICS


Now the following methods of determining the time-frequency characteristics are distinguished [41]:

- Short Time Fourier Transform (STFT)
- Wavelet Transform (WV)
- Wigner-Ville Distribution (WVD)
- Pseudo Wigner-Ville Distribution, (PWVD)
- Hilbert-Huang Transform (HHT)

4.1. Short Time Fourier Transform

The Short Time Fourier Transform can be defined as subjecting the spectral analysis using FFT, the short signal sequences treated as quasi-stationary. The division of the input signal into next analyzed segments is implemented with using the technique called a moving window. Presentation of the spectra

czym zębem - defekt w postaci naruszenia struktury i skruszenia części zęba. Widoczne jest powtarzalne występowanie składowej częstotliwościowej dominującej, przy czym powtarzanie następuje w równych przedziałach czasowych. Wynika to z ruchu obrotowego przekładni - występowanie częstości rezonansowych można zinterpretować jako efekt wchodzenia uszkodzonego zęba w przypór. Uszkodzenie powoduje powstawanie zwiększonych drgań w stosunku do elementu nieuszkodzonego. W dalszej analizie znając prędkość obrotową maszyny można powiązać wystąpienie składowej dominującej z aktualnym kątem obrotu przekładni - znając pozycję wyjściową możliwe jest dokładne wskazanie, który ząb uległ uszkodzeniu. Udowadnia to przewagę metod czasowo-częstotliwościowych na pozostałych - wyznaczenie zwykłego widma pozwoliłoby jedynie na stwierdzenie, że badana przekładnia jest prawdopodobnie uszkodzona, bo ma inne charakterystyki częstotliwościowe niż przekładnia wzorcowa. Zastosowanie JTFA pozwoliło nie tylko wykryć uszkodzenie, ale też stwierdzić, że jest ono lokalne i oznaczyć miejsce wystąpienia.



Rys. 2. Reprezentacja czasowo-częstotliwościowa drgań uszkodzonej przekładni stożkowej [13]

Fig. 2. Time-frequency representation of the vibrations of the damaged conical gear [13]

4. METODY WIBROAKUSTYCZNE W DIAGNOSTYCE KOMPOZYTÓW

Obecnie wyróżnia się następujące metody wyznaczania charakterystyk czasowo-częstotliwościowych [41]:

- Krótkoczasowa Transformata Fouriera (Short Time Fourier Transform, STFT)
- Transformata falkowa (Wavelet Transform, WV)
- Dystrybucja Wigner-Villea (Wigner-Ville Distribution, WVD)
- Funkcja pseudo-rozkładu Wignera (Pseudo Wigner-Ville Distribution, PWVD)
- Transformata Hilberta-Huanga (Hilbert-Huang Transform, HHT)

4.1. Krótkoczasowa Transformata Fouriera

Krótkoczasową Transformatę Fouriera można zdefiniować jako poddanie analizie widmowej, z wy-

obtained in this way on one characteristic allows to obtain the time-frequency representation of the analyzed process called a spectrogram. STFT can be defined by the following equation 5 [36].

$$STFT[x_w(t, \tau)] = \int_{-\infty}^{\infty} w(t, \tau)x(t) \cdot e^{-i2\pi ft} dt \quad (5)$$

gdzie/where:

$x(t)$ – reprezentacja analizowanego sygnału wejściowego w dziedzinie czasu/ representation of the analysed input signal in time domain

τ – pozycja ruchomego okna w dziedzinie czasu/ position of the moving window in the time domain

$x_w(t, \tau) = w(t-\tau)x(t)$ – wyodrębniony analizowany segment danych/ isolated analysed segment of data.

Therefore, the STFT result can be interpreted as a sequence of spectra determined for the shorter local time fragments. Among the advantages of the described method, it can be mentioned, among others, the short computation time required to determine the spectrogram, the requirement of small computing power and constant resolution in the entire range of spectrum. Moreover, the use of STFT for signal interpretation can be assessed as easy and intuitive compared to other methods. The fundamental disadvantages of this method include the inability to simultaneously obtain the high window resolution for time and frequency (Heisenberg's uncertainty principle). Increasing the resolution for one domain causes decreasing the other. It is possible to minimize the negative effects of this limitation by using the overlapping method consisting in partial overlapping of the analysed signal segments.

As a result, the increased resolution in the time domain is obtained without necessity of reducing it in the frequency domain [36]. Another disadvantage of the method is the possibility of occurring the frequency and amplitude estimation errors for the local peaks of the time-spectral representation. The solution is application of Amplitude and Frequency Correction (AFC), which allows about 50 times more precise estimation of frequency components in comparison to the FFT spectrum [2].

4.2. Wavelet Transform

To effectively analyse the spectral properties of non-stationary signals, there is a need to look at them in an appropriately wide and shifting time period. This requirement can be formulated as the necessity of using the windows that automatically narrow on high frequency analysis and similarly widen on low frequency analysis. These properties have the integral transformations based on wavelets due to using the scaling [3]. In the wavelet transformation, the wavelets are called the used base functions (mother function). They can be any functions. In an effort to simplify and speed up the computational

korzystaniem FFT, krótkich sekwencji sygnału traktowanych jako quasi-stacjonarne. Podział sygnału wejściowego na kolejne analizowane segmenty realizowany jest z wykorzystaniem techniki nazywanej ruchomym oknem. Przedstawienie uzyskanych w ten sposób widm na jednej charakterystyce pozwala uzyskać reprezentację czasowo-częstotliwościową analizowanego procesu nazywaną spektrogramem. STFT można zdefiniować następującym równaniem 5 [36].

$$STFT[x_w(t, \tau)] = \int_{-\infty}^{\infty} w(t, \tau)x(t) \cdot e^{-i2\pi ft} dt \quad (5)$$

gdzie:

$x(t)$ – reprezentacja analizowanego sygnału wejściowego w dziedzinie czasu

τ – pozycja ruchomego okna w dziedzinie czasu

$x_w(t, \tau) = w(t-\tau)x(t)$ – wyodrębniony analizowany segment danych.

Wynik STFT można więc interpretować jako ciąg widm wyznaczonych dla krótszych, lokalnych fragmentów czasowych. Pośród zalet opisywanej metody wymienić można m. in. krótki czas obliczeń wymaganych do wyznaczenia spektrogramu, wymóg niezmiennych mocy obliczeniowych oraz stałą rozdzielczość w całym zakresie widma. Ponadto wykorzystanie STFT do interpretacji sygnału można ocenić jako łatwe i intuicyjne w porównaniu do innych metod. Do zasadniczych wad tej metody można zaliczyć niemożność jednoczesnego uzyskania wysokiej rozdzielczości okna dla czasu i częstotliwości (zasada nieoznaczoności Heisenberga). Zwiększanie rozdzielczości dla jednej dziedziny powoduje jej zmniejszenie dla drugiej. Możliwe jest zminimalizowanie negatywnych skutków tego ograniczenia przez zastosowanie metody *overlapping* polegającej na częściowym nachodzeniu na siebie analizowanych segmentów sygnału.

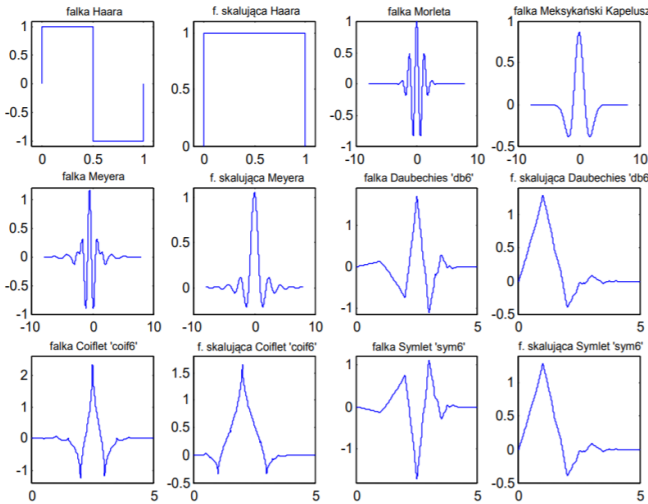
W rezultacie uzyskuje się zwiększoną rozdzielczość w dziedzinie czasu bez konieczności jej zmniejszenia w dziedzinie częstotliwości [36].

Inną wadą metody jest możliwość występowania błędów estymacji częstotliwości oraz amplitudy dla lokalnych maksimów reprezentacji czasowo-widmowej. Rozwiązaniem jest zastosowanie korekcji amplitudowo-częstotliwościowej (*Amplitude and Frequency Correction* - AFC), która pozwala na około 50-krotnie precyzyjniejsze oszacowanie składowych częstotliwościowych w porównaniu do widma FFT [2].

4.2. Transformata falkowa

W celu efektywnej analizy własności spektralnych sygnałów o charakterze niestacjonarnym istnieje potrzeba spojrzenia na nie w odpowiednio szerokim i przesuwalnym przedziale czasu. Można ten wymóg sformułować jako konieczność posługiwania się oknami, które automatycznie ulegają zwięźeniu się przy analizie wysokich częstotliwości oraz analo-

process in many cases it is used as a Morlet wavelet - its form and comparison with other used wavelets are shown in Fig. 3. The use of this wavelet enables the FFT procedure to be used in the processing, and as a result it accelerates calculation process. The form of the result depends on the adopted base functions, therefore the basic process of signal analysis is the appropriate selection of the wavelet [1,36].



Rys. 3. Porównanie falek stosowanych w transformacie falkowej
Fig. 3. Comparison of wavelets used in the wavelet transform

There are two forms of the wavelet transform - continuous (Continuous Wavelet Transform, CWT) and discrete (Discrete Wavelet Transform, DWT). CWT can be defined by equation 6.

$$CWT_{\Psi}(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \cdot \Psi^* \left(\frac{t-b}{a} \right) dt \quad (6)$$

gdzie/where:

- $\Psi(t-\tau)$ – falka bazowa/ base wavelet (mother function)
- $x(t)$ – sygnał ciągły w dziedzinie czasu/ continuous signal in the time domain
- a – parametr skali/ scale parameter
- b – parametr przesunięcia (miejsca)/ shift parameter (place)
- Ψ^* – sprzężenie funkcji $\Psi(t-\tau)$ / conjugation of the function $\Psi(t-\tau)$

The continuous wavelet transform can be presented as a sum after all time of the signal multiplied by the scaled, shifted version of the wavelet. The result of this process is the determination of the so-called wavelet coefficients which are a function of scale and shift. The described type of analysis can be compared to filtration with a constant relative bandwidth $\Delta f/fs$. The position of the filter on the time-spectral representation is determined by the scale and shift parameters (a, b). With moving towards the higher frequencies, the bandwidth of the analysis increases with decreasing analysis of the resolution in the frequency domain, while in turn the resolution increases in the time domain. This feature is potentially useful for the simultaneous analysis and observation with different time step of processes

gicznie rozszerzają się przy analizie niskich częstotliwości. Własności te posiadają transformacje całkowe oparte na falkach dzięki zastosowaniu skalowania [3]. W transformacji falkowej falkami nazywa się wykorzystywane funkcje bazowe (mother function). Mogą być nimi dowolne funkcje. W dążeniu do uproszczenia i przyspieszenia procesu obliczeniowego w wielu przypadkach stosowana jest jako falka Morleta – jej postać i porównanie z innymi stosowanymi falkami przedstawione są na Rys. 3. Zastosowanie tej falki umożliwi wykorzystanie w procesie przetwarzania procedury FFT, w rezultacie przyspieszając proces obliczeniowy. Postać wyniku jest zależna od przyjętych funkcji bazowych, dlatego zasadniczym procesem analizy sygnału jest odpowiedni dobór falki [1,36].

Rozróżnia się dwie postacie transformaty falkowej – ciągłą (Continuous Wavelet Transform, CWT) oraz dyskretną (Discrete Wavelet Transform, DWT). CWT można zdefiniować równaniem 6.

$$CWT_{\Psi}(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \cdot \Psi^* \left(\frac{t-b}{a} \right) dt \quad (6)$$

gdzie/where:


- $\Psi(t-\tau)$ – falka bazowa/ base wavelet (mother function)
- $x(t)$ – sygnał ciągły w dziedzinie czasu/ continuous signal in the time domain
- a – parametr skali/ scale parameter
- b – parametr przesunięcia (miejsca)/ shift parameter (place)
- Ψ^* – sprzężenie funkcji $\Psi(t-\tau)$ / conjugation of the function $\Psi(t-\tau)$

Ciągłą transformatę falkową można przedstawić jako sumę po całym czasie sygnału zwiokrotnionego o przeskalowaną, przesuniętą wersję falki. Wynikiem tego procesu jest wyznaczenie tzw. współczynników falkowych, które są funkcją skali i przesunięcia. Opisany typ analizy przyrównać można do filtracji o stałej względnej szerokości pasma $\Delta f/fs$. Pozycja filtra na reprezentacji czasowo-widmowej określona jest parametrami skali i przesunięcia (a, b). Wraz z przemieszczaniem w stronę częstotliwości wyższych, wzrasta szerokość pasma analizy, a przy zmniejszeniu rozdzielczości analizy w dziedzinie częstotliwości, jednocześnie wzrasta z kolei rozdzielczość w dziedzinie czasu. Cecha ta jest potencjalnie przydatna dla jednoczesnej analizy i obserwacji z różnym krokiem czasowym procesów charakteryzujących się szybkozmiennością i dużymi amplitudami składowych częstotliwościowych, np. praca zaworów proces spalania i analogicznie wolnozmiennych procesów niskoczęstotliwościowych. Różnicę pomiędzy skalowanymi oknami charakterystycznymi dla transformacji WV, a oknami o stałej rozdzielczości charakterystycznymi dla transformacji STFT przedstawiono na rys. 4. Do wad opisanej metody można zaliczyć zależność postaci wyniku od przyjętej funkcji bazowej oraz nie zawsze intuicyjną interpretację graficznej postaci wyniku [12, 23].

characterized by the fast changeability and the large amplitudes of frequency components, e.g. operation of valves, combustion process and analogously slow-changing low-frequency processes. The difference between the scaled windows characteristic for the WV transformation and the windows with the constant resolution characteristic for the STFT transformation is presented in Fig. 4. The disadvantages of the described method include the dependence of the result form on the adopted base function and the not always the intuitive interpretation of the graphical form of the result [12,23].

Calculation of the wavelet coefficients for each possible scale (the scale domain is continuous) requires a lot of work and computing time with simultaneous generation of a large data volume.

The solution is limitation of the subset of scales and positions for which the computation will be made (the scale domain is discrete). In order to increase the accuracy of calculations, the scales and positions based on the power of two, the so-called doubled (dyadic) are used. For this purpose, four wavelet filters are used: high-pass and low-pass and their equivalents for the inverse transform (Inverted Discrete Wavelet Transform, IDWT). The result of the described actions is the separation of the signal into two courses of the wavelet coefficients, the first cA with the large scale value describes the approximation component A, and the second cD with the smaller scale value representing the detailed component D. IDWT filters are used to reconstruct the original signal based on cA and cD [14]. The block diagram of carrying out the DWT and IDWT process is shown in Fig. 5.




Rys. 5. Dyskretna transformata falkowa DWT i odwrotna IDWT. HiFD – filtr górnoprzepustowy DWT, LoFD – filtr dolnoprzepustowy DWT, HiFR – filtr górnoprzepustowy IDWT, LoFR – filtr dolnoprzepustowy IDWT [14]

Fig. 5. Discrete wavelet transform DWT and reverse IDWT. HiFD – high-pass filter DWT, LoFD – low-pass filter DWT, HiFR – high-pass filter IDWT, LoFR – low-pass filter IDWT [14]

The difference in the time-frequency graphical representation between CWT and DWT is presented in Fig. 6.

Comparing DWT and CWT it can be found that the discrete form of the wavelet transform is useful for decomposition and selective reconstruction of the signal tested in the entire scope of the analysis. The continuous form of this transform is considered as especially predestined for the tests of internal processes of the machine, the manifestation of which is the local differentiation of the informational




Rys. 4. Porównanie okien pomiędzy FFT, STFT i WV [34]
Fig. 4. Comparison of windows between FFT, STFT and WV [34]

Obliczanie współczynników falkowych dla każdej możliwej skali (dziedzina skali jest ciągła) wymaga dużej ilości pracy i czasu obliczeniowego z jednoczesnym wygenerowaniem dużego woluminu danych.

Rozwiązaniem jest ograniczenie podzbioru skal i położzeń, dla których wykonywane będą obliczenia (dziedzina skali jest dyskretna). W celu zwiększenia dokładności obliczeń stosuje się skale i położenia oparte na potędze dwójki tzw. podwojone (dyadic). Wykorzystuje się do tego celu cztery filtry falkowe: górnoprzepustowe oraz dolnoprzepustowe oraz ich odpowiedniki dla transformaty odwrotnej (Inverted Discrete Wavelet Transform, IDWT). Wynikiem opisywanych działań jest rozdział sygnału na dwa przebiegi współczynników falkowych, pierwszy cA o dużej wartości skali opisuje składową aproksymacyjną A, a drugi cD o mniejszej wartości skali reprezentujący składową szczegółową D. Filtry IDWT służą do rekonstrukcji sygnału pierwotnego na podstawie cA i cD [14]. Schemat blokowy przeprowadzenia procesu DWT i IDWT przedstawiono na Rys. 5.

Różnicę w graficznej reprezentacji czasowo-częstotliwościowej pomiędzy CWT i DWT przedstawiono na Rys. 6.



Rys. 6. Przykład dyskretny (na górze) i ciągłej (na dole) transformaty falkowej [3]

Fig. 6. Example of the discrete (top) and continuous (bottom) wavelet transform [3]

changeability of external vibroacoustic phenomena, not only limited to the time domain [3].

4.3. Wigner-Ville Distribution

The Wigner-Ville distribution is implemented by the time-frequency window with a two-dimensional defined resolution. This type allows hypothetically to assume any size of the analysis window. Freedom in defining the size of the window analysis may lead to obtain the negative values of distribution, occurring the interference in the frequency and time domains, which in final effect leads to difficulties in the interpretation of the analysis results. WVD is characterized by a relatively long computation time, compared to previous methods, especially for long time series. The WVD distribution is more often defined as the windowed Wigner-Ville distribution in form presented in equation 7.

$$WVD_w(t, f) = \int_{-\infty}^{\infty} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) l_w(t) e^{-j2\pi f\tau} d\tau \quad (7)$$

gdzie/where:

$l_w(t)$ – symetryczna funkcja wagowa/ symmetric weighting function

The Gaussian function defined by equation 8 is considered as the optimal weight function.

$$l_w(t) = c^2 e^{-\frac{1}{2}p^2\tau^2} \quad (8)$$

gdzie/where:

$c; p$ – dodatnie stałe rzeczywiste/ positive real constants.

The STFT and WT transforms are based on similar assumptions in relation to each other - the difference between them comes down to a different definition of the base functions, and the processed signal is expressed in a direct form. The signal obtained as a result of applying the WVD distribution is expressed in the form of a double-differentiated autocorrelation function. For this reason, it can be defined as a bilinear transform. WVD is characterized by scaling and shift properties, like WT, which makes it useful in the context of numerical applications, including identification of faults using the analysed signals [16]. Taking into account the optimal resolution and the momentary spectrum of power density in time and frequency domains, WVD is considered as particularly useful in diagnosing the rotating machines [9,17,25,40].

The fundamental disadvantage of WVD for signals with non-stationary frequency modulation is occurrence of characteristic interferences called cross-terms. These are signals defined as parasitic with frequencies equal to the harmonics frequency differences that generate them. Therefore, it became justified to introduce the additional filtering windows reducing the resulting cross elements. There are many variants of methods using the mentioned windows enabling reduction of disruptions, e.g.

Porównując DWT i CWT można stwierdzić, że dyskretna forma transformaty falkowej jest przydatna przy dekompozycji i selektywnej rekonstrukcji sygnału badanego w całym zakresie analizy. Ciągła postać tej transformaty oceniana jest jako szczególnie predestynowana dla badań procesów wewnętrznych maszyny, których przejawem jest lokalne zróżnicowanie zmienności informacyjnej zewnętrznych zjawisk wibroakustycznych, nie tylko ograniczonych do dziedziny czasu [3].

4.3. Dystrybucja Wigner-Ville

Dystrybucja Wigner-Ville jest realizowana poprzez okno czasowo-częstotliwościowe o rozdzielczości definiowanej dwuwymiarowo. Taki rodzaj pozwala hipotetycznie na przyjmowanie dowolnego rozmiaru okna analizy. Dowolność w definiowaniu rozmiaru okna analizy, może prowadzić do uzyskania ujemnych wartości dystrybucji, powstawania interferencji w dziedzinach częstotliwości i czasu, co w efekcie końcowym prowadzi do utrudnień w interpretacji wyników analizy. WVD charakteryzuje się w porównaniu z poprzednimi metodami stosunkowo długim czasem obliczeń, zwłaszcza dla długich szeregów czasowych. Dystrybucja WVD jest częściej definiowana jako oknowana dystrybucja Wigner-Ville w postaci przedstawionej równaniem 7.

$$WVD_w(t, f) = \int_{-\infty}^{\infty} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) l_w(t) e^{-j2\pi f\tau} d\tau \quad (7)$$

gdzie/where:

$l_w(t)$ – symetryczna funkcja wagowa/ symmetric weighting function

Za optymalną funkcję wagową uznaje się funkcję Gaussa definiowaną równaniem 8.

$$l_w(t) = c^2 e^{-\frac{1}{2}p^2\tau^2} \quad (8)$$

gdzie:

$c; p$ – dodatnie stałe rzeczywiste.

Transformaty STFT i WT opierają się na podobnych względem siebie założeniach – różnica między nimi sprowadza się do innego definiowania funkcji bazowych, a przetworzony sygnał jest wyrażony w formie bezpośredniej. Sygnał uzyskany w wyniku zastosowania dystrybucji WVD jest natomiast wyrażony w postaci funkcji autokorelacji, podwójnie różniczkowanej. Z tego powodu można ją określić jako transformatę biliniową. WVD charakteryzuje się własnościami skalowania i przesunięcia, podobnie jak WT, co czyni ją przydatną w kontekście zastosowań numerycznych, w tym identyfikacji uszkodzeń za pomocą analizowanych sygnałów [16]. Biorąc pod uwagę optymalną rozdzielczość i widmo chwilowe gęstości mocy w dziedzinach czasu i częstotliwości, WVD jest uznawana za szczególnie przydatną w diagnozowaniu maszyn wirujących [9,17,25,40].

Zasadniczą wadą WVD dla sygnałów o niestacjonarnej modulacji częstotliwości jest pojawianie się

Wigner-Ville Pseudo-Distribution (PWVD), [11,35,41]. They are defined by equations 9 and 10.

$$PWVD_w(t, f) = \int_{-\infty}^{\infty} h(\tau) x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) l_w(t) e^{-j2\pi f \tau} d\tau \quad (9)$$


$$SPWVD_w(t, f) = \int_{-\infty}^{\infty} q(u-t) \int_{-\infty}^{\infty} h(\tau) x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) l_w(t) e^{-j2\pi f \tau} d\tau du \quad (10)$$

gdzie/where:

$h(\tau)$ – okno redukujące częstotliwościowe człony krzyżowe/ window reducing frequency cross elements

$q(u-t)$ – okno redukujące czasowe człony krzyżowe/ window reducing temporal cross elements

Both in the case of $h(\tau)$ like $q(u-t)$ parametric and non-parametric windows can be used. However, in carrying out the measurements for diagnostic purposes, rectangular or Hanning windows are most often used [35]. A comparison of the time-frequency representations of the signal with using WVD, PWVD, SPWVD is presented in Fig. 7.



Rys. 7. Porównanie reprezentacji czasowo-częstotliwościowej uzyskanej przy użyciu WVD, PWVD, SPWVD [10]

Fig. 7. Comparison of the time-frequency representation obtained using WVD, PWVD, SPWVD [10]

The disadvantage of the above solutions is the loss of the original very good resolution properties of the WVD method. Choosing the form of the transform, it should be considered whether, in the aspect of the analysis, it is more important to freely shape the resolution of the processed signal window or the necessity of disturbing the result by excessive interference [32].

4.4. Hilbert-Huang Transform

In 1998 Norden Huang proposed a new method of the time-frequency analysis called the Hilbert-Huang transformation. This method can be divided into two main stages [41]:

- Empirical Mode Decomposition (EMD) used to separate a non-linear and non-stationary signal into its individual components, each with one dominant frequency, and as a result to obtain an intrinsic mode function (IMF). The EMD can be presented as the relation described in equation 11.

$$x(t) = \sum_{i=1}^N imf(i) + reszta \quad (11)$$

charakterystycznych interferencji zwanych członami krzyżowymi (cross-terms). Są to sygnały określane

gdzie:

$h(\tau)$ – okno redukujące częstotliwościowe człony krzyżowe

$q(u-t)$ – okno redukujące czasowe człony krzyżowe

jako pasożytnicze o częstotliwościach równych różnicom częstotliwości generujących je harmonicznych. Zasadne stało się więc wprowadzenie dodatkowych okien filtrujących redukujących powstałe człony krzyżowe. Istnieje wiele odmian metod wykorzystujących wspomniane okna umożliwiające redukcję zakłóceń m.in. pseudodystrybucja Wignera-Ville'a (Pseudo Wigner-Ville Distribution, PWVD), wygładzona pseudodystrybucja Wignera-Ville'a (Smoothed Pseudo Wigner-Ville Distribution, SPWVD) [11,35,41]. Definiują je równania 9 i 10.

Zarówno w przypadku $h(\tau)$ jak $q(u-t)$ zastosowanie mogą mieć okna parametryczne jak i nieparametryczne. W wykonywaniu pomiarów dla celów diagnostycznych najczęściej jednak stosuje się okna prostokątne lub Hanninga [35]. Porównanie reprezentacji czasowo-częstotliwościowych sygnału z zastosowaniem WVD, PWVD, SPWVD przedstawiono na Rys. 7.

Wadą powyższych rozwiązań jest utrata pierwotnych bardzo dobrych właściwości rozdzielczych metody WVD. Przy wyborze formy transformaty należy więc rozważyć czy w aspekcie analizy ważniejsze jest swobodne kształtowanie rozdzielczości okna przetwarzanego sygnału czy konieczność zakłócenia wyniku przez nadmierne interferencje [32].

4.4. Transformata Hilberta-Huanga

W 1998 Norden Huang zaproponował nową metodę analizy czasowo-częstotliwościowej nazywaną transformacją Hilberta-Huanga. Metodę tą można podzielić na dwa zasadnicze etapy [41]:

- Dekompozycję empiryczną (Empirical Mode Decomposition, EMD) używaną w celu rozdelenia sygnału nieliniowego i niestacjonarnego na poszczególne jego składowe, każda z jedną częstotliwością dominującą, a w rezultacie uzyskania wewnętrznej funkcji składowej (Intrinsic Mode Function, IMF). EMD można przedstawić w postaci zależności opisanej w równaniu 11.

$$x(t) = \sum_{i=1}^N imf(i) + reszta \quad (11)$$

gdzie:

$x(t)$ – sygnał pomiarowy

$imf(i)$ – i-ta wewnętrzna funkcja składowa IMF

$reszta$ – sygnał posiadający cechy monotoniczności pozostały po określeniu wszystkich IMF

gdzie/where:

$x(t)$ – sygnał pomiarowy/ measurement signal

$imf(i)$ – i-ta wewnętrzna funkcja składowa IMF/ i-th IMF intrinsic mode function

$reszta/ rest$ – sygnał posiadający cechy monotoniczności pozostały po określeniu wszystkich IMF/ a signal having the features of monotonicity, remaining after determining all IMFs

- Spectral analysis using the Hilbert transform (Hilbert Spectral Analysis, HSA), the purpose of which is to present the individual component functions on a time-frequency diagram. Representation of the signal in this form is obtained by computing the Hilbert transform for each component function.

The signal after applying HSA on the IMF components can be presented by equation 12.

$$x(t) = \sum_{j=1}^N a_j(t) e^{i \int \omega_j(t) dt} \quad (12)$$

Equation 12 allows to generate the time-spectral map of the amplitude and instantaneous frequency called the Hilbert-Huang spectrum (HHS). The comparison of HHS with the scalogram of the continuous wavelet transformation of the signal is presented in Fig. 8.

HHT and the obtained HHS can be successfully used for technical diagnostics of machines. The experiment comparing HHT with CWT in the assessment of the technical condition of the rolling bearing showed that the good resolving properties of the Hilbert-Huang transformation allowed to identify more accurately the shocks in the vibration signal on the time-frequency map compared to the representation obtained with the continuous wavelet transformation [27]. However, it should be added that the Hilbert-Huang transform, due to the empirical approach, differs from the FFT in the approach to the analysis of signals. The obtained results must be appropriately interpreted, and the extraction of the desired information from the signal must be preceded by appropriate tests [39].

4.5. Further directions of method research of processing the vibroacoustic signals


All the above-mentioned transforms are still used in the analysis of vibroacoustic diagnostic signals undergoing the continuous development [20,22,24,30]. The increasing complexity of the operated devices and the simultaneous striving for sufficiently early detection of faults causes the necessity of further research aimed at the development of methods supporting the interpretation of diagnostic signals, in particular non-stationary ones. In the aspect of diagnostics of rail vehicles, it is particularly important for high-speed railways, where the forces acting on the structures are very large and a delay in detecting a technical defect could lead to a disaster

- Analizę spektralną z wykorzystaniem transformaty Hilberta (Hilbert Spectral Analysis, HSA), której celem jest przedstawienie poszczególnych funkcji składowych na wykresie czasowo-częstotliwościowym. Reprezentację sygnału w ten formie uzyskuje się przez obliczenie transformaty Hilberta dla każdej funkcji składowej.

Sygnał po zastosowaniu HSA na komponentach IMF można przedstawić za pomocą równania 12.

$$x(t) = \sum_{j=1}^N a_j(t) e^{i \int \omega_j(t) dt} \quad (12)$$

Równanie 12 pozwala na wygenerowanie mapy czasowo-widmowej amplitudy i częstotliwości chwilowej nazywanej widmem Hilberta-Huanga (Hilbert-Huang Spectrum, HHS). Porównanie HHS ze skalo-gramem ciągłej transformacji falkowej sygnału przedstawiono na Rys. 8.



Rys. 8. Porównanie zastosowania HHT i CWT do uzyskania mapy czasowo-częstotliwościowej analizowanego sygnału [27]
Fig. 8. Comparison of using HHT and CWT to obtain a time-frequency map of the analysed signal [27]

HHT i uzyskiwana dzięki niemu HHS z powodzeniem wykorzystywane może być do diagnostyki technicznej maszyn. Eksperyment porównujący HHT z CWT w ocenie stanu technicznego łożyska tocznego wykazał, że dobre własności rozdzielcze transformacji Hilberta-Huanga umożliwiły dokładniejsze zidentyfikowanie uderzeń w sygnale drgań na mapie czasowo-częstotliwościowej w porównaniu do reprezentacji uzyskanej za pomocą ciągłej transformacji falkowej [27]. Należy jednak dodać, że transformata Hilberta-Huanga z powodu podejścia empirycznego różni się od FFT w podejściu do analizowania sygnałów. Otrzymywane wyniki muszą być odpowiednio interpretowane a ekstrahowanie pożądaných informacji z sygnału poprzedzić należy odpowiednimi badaniami [39].

4.5. Dalsze kierunki badań metod przetwarzania sygnałów wibroakustycznych

Wszystkie wymienione wcześniej transformaty znajdują cały czas użycie w analizie wibroakustycznych sygnałów diagnostycznych ulegając ciągłemu rozwojowi [20,22,24,30]. Rosnąca komplikacja eksploatowanych urządzeń oraz jednocześnie dążenie do odpowiednio wczesnej detekcji uszkodzeń powoduje

[15].

Two directions of development are now the worth highlighting - by combination of the above-mentioned methods as in [7] and by supporting their application with using the artificial neural networks. The latter is currently used in the high-speed railways and railway infrastructure diagnostics. Algorithms of the detection of cracks in rails with the use of acoustic signal processing were developed using the wavelet transform and the classification of failures with using the multilayer convolutional neural networks [21]. A similar approach was used in the diagnosis of axle boxes, the neural networks with residual learning were used to develop a model of damage formation based on the vibroacoustic signals [26]. The authors of both publications concluded that the presented direction of signal processing gives the reliable results and presents the further development potential, which allows to predict that it will be a further path in the development of vibroacoustic diagnostics in applications of rail vehicle.

5. SUMMARY

The increasing complication of technical objects, including rail vehicles and the increasing the operational requirements in relation to them cause the necessity of constant development of the methods of their diagnostics. One of the most useful and constantly developed directions in this aspect is the vibroacoustic diagnostics. The difficulty in the proper analysis of the vibration and noise of signal is, however, the fact that in most cases it is non-stationary in time, which causes the limited usefulness of application of the traditional methods of signal processing.

One of the solutions of the presented problem is using the time-frequency methods. They allow the signal to be analysed simultaneously in the time and frequency domains. Obtaining the high frequencies in both domains at the same time is a complex issue and it is subjected to the constant research. This is due to the fact that increasing the frequency in one domain lowers it in the other. It is visible in the case of STFT, which is characterized by constant dimensions of time windows. Other methods of scaling domain windows allow to obtain more accurate results at the cost of making the computation process more difficult. In the case of the wavelet transform using the scaling coefficients, the problem is to increase the computational time, as well as the significant influence of the base wavelet selection on the final results. The Wigner-Ville distribution theoretically allows to obtain any size of the window of analysis. However, this causes a risk of obtaining the negative distribution and occurrence of interference, which finally makes the analysis difficult. The Hilbert-Huang transform also allows to obtain the accurate signal processing results, but due to the

konieczność dalszych badań ukierunkowanych na rozwój metod wspomagających interpretację sygnałów diagnostycznych, w szczególności niestacjonarnych. W aspekcie diagnostyki pojazdów szynowych jest to szczególnie ważne dla kolei dużych prędkości, gdzie siły działające na konstrukcje są bardzo duże i opóźnienie w wykryciu defektu technicznego mogłoby doprowadzić do katastrofy [15].

Warte wyróżnienia są obecnie dwa kierunki rozwoju – poprzez kombinacje wymienionych już metod jak w [7] oraz wspomaganie ich wykorzystania z użyciem sztucznych sieci neuronowych. Te ostatnie znajduje obecnie zastosowanie w kolejach wysokich prędkości oraz diagnostyce infrastruktury kolejowej. Opracowano algorytmy detekcji pęknięć w szynach z wykorzystaniem przetwarzania sygnału akustycznego przy pomocy transformaty falkowej oraz klasyfikacji uszkodzeń z użyciem wielowarstwowych konwolucyjnych sieci neuronowych [21]. Podobne podejście zastosowano przy diagnostyce maźnic, wykorzystano sieci neuronowe z nauczaniem rezydującym do opracowania modelu powstawania uszkodzeń w oparciu o sygnały wibroakustyczne [26]. Autorzy obydwu publikacji wywnioskowali, że przedstawiony kierunek przetwarzania sygnałów daje wiarygodne wyniki i wykazuje dalszy potencjał rozwojowy, co pozwala na przewidywanie, że będzie to dalsza ścieżka rozwoju diagnostyki wibroakustycznej w zastosowaniach pojazdów szynowych.

5. PODSUMOWANIE

Rosnąca komplikacja obiektów technicznych, w tym pojazdów szynowych oraz zwiększające się w stosunku do nich wymagania eksploatacyjne, powodują konieczność nieustannego rozwoju metod ich diagnostyki. Jednym z najbardziej przydatnych i stale rozwijanych w tym aspekcie kierunków jest diagnostyka wibroakustyczna. Utrudnieniem we właściwej analizie sygnału drgań i hałasu jest jednak to, że w większości przypadków jest on niestacjonarny w czasie, co powoduje ograniczoną przydatność wykorzystania tradycyjnych metod przetwarzania sygnałów.

Jednym z rozwiązań przedstawionego problemu jest wykorzystanie metod czasowo-częstotliwościowych. Pozwalają one na analizę sygnału jednocześnie w dziedzinie czasu i częstotliwości. Uzyskanie wysokiej częstotliwości w przypadku obu dziedzin jednocześnie, jest zagadnieniem złożonym i podlegającym nieustannym badaniom. Wynika to z faktu, że zwiększenie częstotliwości w jednej dziedzinie powoduje obniżenie jej w drugiej. Widoczne jest to w przypadku STFT, którą charakteryzują stałe wymiary okien czasowych. Inne metody skalowania okien dziedzinowych pozwalają uzyskać dokładniejsze wyniki kosztem utrudnienia procesu obliczeniowego. W przypadku transformaty falkowej wykorzystującej współczynniki skalujące problemem jest

empirical approach, it requires in-depth interpretation to obtain the results without unnecessary artefacts.

The presented state of affairs indicates the further development potential of time-frequency methods as a tool for interpreting the non-stationary signals. The main goal is to obtain the most accurate results from both domains at the same time. The direction of research, currently giving the promising results, is using the artificial neural networks in supporting the analysis with using the traditional methods. Self-learning algorithms allow for a more accurate classification of the technical condition based on the vibroacoustic signal, and thus for the improved diagnostics of technical objects. This allows to predict that it will be the most effective development direction.

zwiększenie czasu obliczeniowego, a także znaczny wpływ doboru falki bazowej na ostateczne wyniki. Dystrybucja Wigner-Ville'a teoretycznie pozwala uzyskać dowolne rozmiary okna analizy. Powoduje to jednak ryzyko uzyskania ujemnej dystrybucji i powstania interferencji, co w ostateczności powoduje utrudnienie analizy. Transformata Hilberta-Huanga pozwala również uzyskać dokładne wyniki przetworzenia sygnału, jednak z powodu podejścia empirycznego wymaga pogłębionej interpretacji w celu uzyskania rezultatów bez zbędnych artefaktów.

Przedstawiony stan rzeczy wskazuje na dalszy potencjał rozwojowy metod czasowo-częstotliwościowych jako narzędzia interpretacji sygnałów niestacjonarnych. Celem zasadniczym jest uzyskanie jak najdokładniejszych wyników z obydwu dziedzin jednocześnie. Kierunkiem badań dającym obecnie obiecujące wyniki jest wykorzystanie sztucznych sieci neuronowych we wspomaganianiu analizy z użyciem metod tradycyjnych. Algorytmy samouczące pozwalają na dokładniejszą klasyfikację stanu technicznego na podstawie sygnału wibroakustycznego, a tym samym na ulepszoną diagnostykę obiektów technicznych. Pozwala to przewidywać, że będzie to najbardziej efektywny kierunek rozwojowy.

Bibliography / Bibliografia

- [1] Augustyniak P. *Przybornik falkowej analizy sygnałów. I Krajowa Konferencja Użytkowników MATLAB-A 1995.*
- [2] Barczewski R. *Diagnozowanie układów na podstawie analizy zmian krzywej szkieletowej uzyskiwanej metodą STFT-AFC. Diagnostyka 2000;23:15–18.*
- [3] Batko W, Ziółko M. *Zastosowanie teorii falek w diagnostyce technicznej. Warszawa: WIMiR; 2002.*
- [4] Baydar N, Ball A. *A comparative study of acoustic and vibration signals in detection of gear failures using Wigner-Ville distribution. Mechanical Systems and Signal Processing 2001;15:1091–1107. <https://doi.org/10.1006/mssp.2000.1338>.*
- [5] Burdzik R, Konieczny Ł, Deuszkiewicz P, Vaskova I. *Application of time-frequency method for research on influence of locomotive wheel slip on vibration. Journal of Vibroengineering 2018;20:2998–3008. <https://doi.org/10.21595/jve.2018.20450>.*
- [6] Cempel C. *Diagnostyka wibroakustyczna maszyn. Poznań: Wydawnictwo Politechniki Poznańskiej; 1985.*
- [7] Chen Z-S, Rhee SH, Liu G-L. *Empirical mode decomposition based on Fourier transform and band-pass filter. International Journal of Naval Architecture and Ocean Engineering 2019;11:939–951. <https://doi.org/10.1016/j.ijnaoe.2019.04.004>.*
- [8] Cheng G, Cheng Y, Shen L, Qiu J, Zhang S. *Gear fault identification based on Hilbert–Huang transform and SOM neural network. Measurement 2013;46:1137–1146. <https://doi.org/10.1016/j.measurement.2012.10.026>.*
- [9] Climente-Alarcon V, Antonino-Daviu JA, Riera-Guasp M, Puche-Panadero R, Escobar L. *Application of the Wigner–Ville distribution for the detection of rotor asymmetries and eccentricity through high-order harmonics. Electric Power Systems Research 2012;91:28–36. <https://doi.org/10.1016/j.epsr.2012.05.001>.*
- [10] Fedotenkova M, Hutt A. *Research report: Comparison of different time-frequency representations. INRIA. Nancy: 2014.*
- [11] Górecki K, Szmajda M, Zygarlicki J, Zygarlicka M, Mroczka J. *Zaawansowane metody analiz w pomiarach jakości energii elektrycznej. Pomiar Automatyka Kontrola 2011;57:284–286.*
- [12] Haan JM De. *METHODS FOR TIME-FREQUENCY ANALYSIS. University of Karlskrona, 1998.*
- [13] Hartono D, Halim D, Widodo A, Roberts G. *Bevel Gearbox Fault Diagnosis using Vibration Measurements. MATEC Web of Conferences 2016;59:06002. <https://doi.org/10.1051/mateconf/20165906002>.*

- [14] Jaworek K, Kownacki C, Pauk J. Transformata falkowa - nowoczesne narzędzie do analizy sygnałów pomiarowych. *Zeszyty Naukowe Politechniki Białostockiej Budowa i Eksploatacja Maszyn* 2001;199–212.
- [15] Jin X. Key problems faced in high-speed train operation. *Journal of Zhejiang University Science A* 2014;15:936–945. <https://doi.org/10.1631/jzus.A1400338>.
- [16] Katunin A. Damage Identification and Quantification in Beams Using Wigner-Ville Distribution. *Sensors* 2020;20:6638. <https://doi.org/10.3390/s20226638>.
- [17] Kim BS, Lee SH, Lee MG, Ni J, Song JY, Lee CW. A comparative study on damage detection in speed-up and coast-down process of grinding spindle-typed rotor-bearing system. *Journal of Materials Processing Technology* 2007;187–188:30–36. <https://doi.org/10.1016/j.jmatprotec.2006.11.222>.
- [18] Klemiato M. *Przetwarzanie Sygnałów - Materiały dydaktyczne studiów podyplomowych AGH - Automatyka i Robotyka*. Kraków: 2021.
- [19] Komorski P, Szymański GM, Nowakowski T, Orczyk M, Awrejcewicz J. Advanced acoustic signal analysis used for wheel-flat detection. *Latin American Journal of Solids and Structures* 2021;18:1–14. <https://doi.org/10.1590/1679-78256086>.
- [20] Laval X, Mailhes C, Martin N, Bellemain P, Pachaud C. Amplitude and phase interaction in Hilbert demodulation of vibration signals: Natural gear wear modeling and time tracking for condition monitoring. *Mechanical Systems and Signal Processing* 2021;150:107321. <https://doi.org/10.1016/j.ymsp.2020.107321>.
- [21] Li D, Wang Y, Yan W-J, Ren W-X. Acoustic emission wave classification for rail crack monitoring based on synchrosqueezed wavelet transform and multi-branch convolutional neural network. *Structural Health Monitoring* 2021;20:1563–1582. <https://doi.org/10.1177/1475921720922797>.
- [22] Manhertz G, Bereczky A. STFT spectrogram based hybrid evaluation method for rotating machine transient vibration analysis. *Mechanical Systems and Signal Processing* 2021;154:107583. <https://doi.org/10.1016/j.ymsp.2020.107583>.
- [23] Newland DE. *Practical Signal Analysis: Do Wavelets Make Any Difference? Volume 1A: 16th Biennial Conference on Mechanical Vibration and Noise, American Society of Mechanical Engineers; 1997.* <https://doi.org/10.1115/DETC97/VIB-4135>.
- [24] Osadchiy A, Kamenev A, Saharov V, Chernyi S. Signal Processing Algorithm Based on Discrete Wavelet Transform. *Designs* 2021;5:41. <https://doi.org/10.3390/designs5030041>.
- [25] Padovese LR. Hybrid time–frequency methods for non-stationary mechanical signal analysis. *Mechanical Systems and Signal Processing* 2004;18:1047–1064. <https://doi.org/10.1016/j.ymsp.2003.12.003>.
- [26] Peng D, Liu Z, Wang H, Qin Y, Jia L. A Novel Deeper One-Dimensional CNN With Residual Learning for Fault Diagnosis of Wheelset Bearings in High-Speed Trains. *IEEE Access* 2019;7:10278–10293. <https://doi.org/10.1109/ACCESS.2018.2888842>.
- [27] Peng ZK, Tse PW, Chu FL. A comparison study of improved Hilbert–Huang transform and wavelet transform: Application to fault diagnosis for rolling bearing. *Mechanical Systems and Signal Processing* 2005;19:974–988. <https://doi.org/10.1016/j.ymsp.2004.01.006>.
- [28] Plucińska A, Pluciński E. *Probabilistyka. Statystyka matematyczna Procesy stochastyczne Rachunek prawdopodobieństwa*. Warszawa: Wydawnictwo Naukowe PWN; 2021.
- [29] Polyshchuk V V., Choy FK, Braun MJ. Gear Fault Detection with Time-Frequency Based Parameter NP4. *International Journal of Rotating Machinery* 2002;8:57–70. <https://doi.org/10.1155/S1023621X02000064>.
- [30] Rizvi SHM, Abbas M. An advanced Wigner–Ville time–frequency analysis of Lamb wave signals based upon an autoregressive model for efficient damage inspection. *Measurement Science and Technology* 2021;32:095601. <https://doi.org/10.1088/1361-6501/abef3c>.
- [31] Safizadeh MS, Lakis AA, Thomas M. Using Short-Time Fourier Transform in Machinery Diagnosis. *Proceedings of the 4th WSEAS International Conference on Electronic, Signal Processing and Control, Stevens Point, Wisconsin, USA: World Scientific and Engineering Academy and Society (WSEAS); 2007.*
- [32] Sandsten M. *Time-Frequency Analysis of Time-Varying Signals and Non-Stationary Processes. An Introduction*. Lund University; 2020.
- [33] Song Y, Liang L, Du Y, Sun B. Railway Polygonized Wheel Detection Based on Numerical Time-Frequency Analysis of Axle-Box Acceleration. *Applied Sciences* 2020;10:1613. <https://doi.org/10.3390/app10051613>.
- [34] Strackeljan J, Lahdelma S. *Smart Adaptive Monitoring and Diagnostic Systems. 2nd International Seminar on Maintenance, Condition Monitoring and Diagnostics, Oulu, Finland: 2005.*
- [35] Szmajda M, Górecki K, Mroczka J. Gabor Transform, SPWVD, Gabor-Wigner Transform and Wavelet Transform - Tools for Power Quality monitoring. *Metrology and Measurement Systems* 2010;17:383–396.

- [36] Szymański GM, Misztal A, Misztal W. Zastosowanie krótkoczasowej analizy częstotliwościowej do wyznaczenia częstotliwości wymuszeń odrzutowego silnika lotniczego na stanowisku badawczym. *Autobusy: Technika, Eksploatacja, Systemy Transportowe* 2017;18:1328–1332.
- [37] Tataro T, Kożuch B. Analiza propagacji drgań wywołanych przejazdami pociągów z zastosowaniem FFT i STFT. *Zeszyty Naukowo-Techniczne Stowarzyszenia Inżynierów i Techników Komunikacji w Krakowie* 2016;109:177–189.
- [38] Vu V-H, Thomas M, Lakis AA, Marcouiller L. Short-Time Autoregressive (STAR) Modeling for Operational Modal Analysis of Non-stationary Vibration. *Vibration and Structural Acoustics Analysis*, Dordrecht: Springer Netherlands; 2011, p. 59–77. https://doi.org/10.1007/978-94-007-1703-9_3.
- [39] Wójcik A, Pankanin G. Zastosowanie transformaty Hilberta-Huanga do przetwarzania sygnału z przepływomierza wirowego. *Przeład Elektrotechniczny* 2012;88:37–45.
- [40] Wu J-D, Huang C-K. An engine fault diagnosis system using intake manifold pressure signal and Wigner–Ville distribution technique. *Expert Systems with Applications* 2011;38:536–544. <https://doi.org/10.1016/j.eswa.2010.06.099>.
- [41] Zhu Q, Wang Y, Shen G. Research and comparison of time-frequency techniques for nonstationary signals. *Journal of Computers* 2012;7:954–958. <https://doi.org/10.4304/jcp.7.4.954-958>