

**POLITECHNIKA WROCŁAWSKA**  
**WYDZIAŁ GEOINŻYNIERII, GÓRNICCTWA I GEOLOGII**

Rozprawa doktorska w formie cyklu publikacji

**MODELOWANIE PROCESÓW W GÓRNICTWIE  
I GEOLOGII Z WYKORZYSTANIEM PROCESÓW  
STOCHASTYCZNYCH**

**mgr inż. Justyna Hebda-Sobkowicz**

**Promotorzy:**

**Prof. dr hab. inż. Radosław Zimroz**

Wydział Geoinżynierii, Górnictwa i Geologii, Politechnika Wrocławska

**Dr hab. inż. Agnieszka Wyłomańska, prof. uczelni**

Wydział Matematyki, Politechnika Wrocławska

Wrocław 2022



## Streszczenie

Celem niniejszej rozprawy było opracowanie metod/modeli matematycznych opisujących wybrane procesy technologiczne zachodzące w górnictwie. W dobie technologii Internetu Rzeczy (ang. Internet of Things - IoT) technologie sensoryczne umożliwiają pozyskiwanie danych dotyczących szerokiego spektrum zjawisk, w tym danych uwzględnionych w pracy badawczej, takich jak: sygnały drganiowe, dane z pokładowych systemów monitorowania maszyn, dane dotyczące stężenia gazów, czy też sygnały sejsmiczne.

Procesy technologiczne lub zjawiska naturalne, z którymi mamy do czynienia w górnictwie, są specyficzne i wymagają indywidualnego podejścia. W badaniach rozważono 4 obszary: procesy związane z analizą drgań układów napędowych, wentylacją kopalń, zarządzaniem efektywnością pracy samojezdnych maszyn dołowych oraz aktywnością górotworu - wykrywaniem fali podłużnej (P) w sygnałach sejsmicznych. Procesy te można opisać za pomocą modeli procesów losowych i metod statystycznych. Wymagają one zaawansowanego aparatu matematycznego do walidacji sygnałów, przetwarzania, analizy i wnioskowania statystycznego.

Przeprowadzone badania w dziedzinie diagnostyki maszyn pokazały, że popularne narzędzia/metody nie są wystarczające w przypadku przetwarzania sygnałów pochodzących z maszyn górniczych, w szczególności z łożysk tocznych kruszarki rudy miedzi. W związku z tym zaproponowano nową metodę opierającą się na wariancji warunkowej, która okazała się lepsza od wielu powszechnie stosowanych metod w dziedzinie diagnostyki maszyn, zwłaszcza dla sygnałów z niegaussowskim szumem (gdy impulsy niecykliczne niezwiązane z uszkodzeniem, ale z technologią pracy maszyny, dominują nad impulsami cyklicznymi, związanymi z lokalnym uszkodzeniem). Przedstawiono, że podejście oparte na wariancji warunkowej jest proste w implementacji i znacznie bardziej odporne na różne specyfikacje problemu, takie jak stosunek liczby impulsów cyklicznych do niecyklicznych, czy stosunek ich amplitudy.

W pracy testowano wiele metod diagnostycznych. Jedną z najbardziej zaawansowanych jest infogram, bazując na analizie entropii w dziedzinie czasu i częstotliwości, pozwala wyselekcjonować informację diagnostyczną (częstotliwość uszkodzenia). Wykazano, że infogram jest nieskuteczny w diagnozowaniu lokalnego uszkodzenia dla analizowanych danych pochodzących z kruszarki rudy miedzi. Zaproponowano proste modyfikacje infogramu, które polepszają jego skuteczność.

W przeprowadzonych badaniach zaproponowano również zastosowanie alternatywnych (dla powszechnie stosowanych) miar zależności do wykrywania lokalnych uszkodzeń, które wykazują większą odporność na występowanie niegaussowskiego szumu. Zbadano ich skuteczność dla różnych sygnałów symulacyjnych (z szumem gaussowskim/niegaussowskim), jak i dla sygnału rzeczywistego, pochodzącego z kruszarki rudy miedzi oraz z przenośnika taśmowego.

W pracy przeprowadzono również analizę stężeń wybranych, niebezpiecznych dla zdrowia, gazów w rozważanej głębokiej kopalni podziemnej tj. siarkowodoru oraz tlenku węgla. Są to jedne z pierwszych tego typu badań (bazujące na danych długoterminowych) w Polsce. Wykazano iż, zmienność stężenie tlenku węgla może być modelowane za pomocą mieszaniny komponentów deterministycznych oraz losowych. Wykazano, że wykryte skoki stężenia tlenku węgla (powyżej dopuszczalnego poziomu 26 ppm-ów) w wybranej kopalni rudy miedzi są w większości związane z robotami strzałowymi oraz określono (z zadaniem prawdopodobieństwem) czas potrzebny do osiągnięcia bezpiecznego poziomu stężenia tlenku węgla po robotach strzałowych.

Poprzez zastosowanie odpowiednich metod matematycznych i przetwarzania danych zaproponowano model zmienności siarkowodoru oraz wykazano zależność pomiędzy wielkością stężenia siarkowodoru, a procesem wentylacji. Pokazano, iż procesy eksploatacyjne/technologiczne znacząco wpływają na zmienność jego stężeń, mimo, iż źródło występowania tego gazu jest wyłącznie źródłem naturalnym (gaz uwalniany jest z górotworu). Badania wykazały że, zwiększona praca wentylatorów, które wspomagają odprowadzanie zużytego powietrza, paradoksalnie powoduje zwiększone uwalnianie siarkowodoru z górotworu (w określonych warunkach), ze względu na powstające podciśnienie.

W pracy przeprowadzono również analizę sygnału sejsmicznego i zaproponowano efektywny algorytm detekcji fali P, będącej tzw. falą zapowiadającą, kluczową w identyfikacji zagrożenia sejsmicznego. W algorytmie zastosowano metodę opartą na czasowo-częstotliwościowej reprezentacji danych i analizie głównych składowych (ang. Principal Component Analysis - PCA). Wyniki zostały porównane z popularną metodą wykorzystującą średnią krótkoterminową i długoterminową (ang. Short-Term Average/Long-Term Average - STA/LTA). Zaproponowana metoda wykazała lepszą skuteczność.

W przeprowadzonych badaniach rozważono również wybrane zagadnienia efektywności pracy samodzielnymi maszynami dołowymi. Przeprowadzono eksperymenty, które miały na

celu potwierdzić możliwość oceny jakości nawierzchni jezdnej w kopalni podziemnej na podstawie wzbudzenia zewnętrznego maszyny. W przeprowadzonych badaniach omówiono również ważny problem dotyczący próby automatycznego pomiaru efektywności produkcji tj. pomiaru liczby cykli roboczych maszyny (np. wozu odstawczego) pod ziemią w ciągu jednej zmiany. Zaproponowano wykorzystanie alternatywnych wskaźników do identyfikacji cykli pracy maszyny, które skutecznie mogą zastąpić aktualnie wykorzystywany wskaźnik (ciśnienie oleju hydraulicznego), który jest narażony na częste awarie tego kanału pomiarowego.

Podczas badań największą uwagę skupiono na diagnostyce maszyn. Nie mniej jednak, inne obszary ujęte w badaniach stanowią istotną część hipotezy badawczej. Każdy z analizowanych obszarów charakteryzuje się inną specyfiką problemu, jednak wspólnym mianownikiem działań było zastosowanie zaawansowanych metod/procesów matematycznych do opisu procesów w górnictwie. Opracowane metody mają na celu poprawić skuteczność prowadzonych prac w kopalni, zwiększyć bezpieczeństwo pracy oraz zoptymalizować wydatki związane z eksploatacją maszyn.

**Słowa kluczowe:** *lokalne uszkodzenia w maszynach, zagrożenia gazowe w kopalniach podziemnych, siarkowodór, tlenek węgla, detekcja cykli pracy, analiza efektywności pracy maszyn górniczych, zagrożenia sejsmiczne, fala P, szeregi czasowe, procesy stochastyczne, przetwarzanie sygnałów, szum niegaussowski, analiza czasowo-częstotliwościowa, miary zależności.*

## Abstract

The purpose of this research was to develop mathematical methods and models describing selected technological processes that occur in mining. In the era of the IoT (Internet of Things), sensory technologies make it possible to acquire data on a wide range of phenomena, including data considered in this research work such as vibration data, data from onboard machine monitoring systems, gas concentration data, or seismic signals.

The technological processes or natural phenomena involved in mining are specific and require individual approaches. This dissertation is focused on four areas, i.e. on processes related to: vibration diagnostics in drive systems (predictive maintenance), ventilation of mines, efficiency management of self-propelled underground machines, and rock mass activity detection of P-waves in seismic signals. These processes can be described using random process models and statistical methods. They require advanced mathematical techniques for signal validation, processing, analysis, and statistical inference.

Research carried out to date in the field of machine diagnostics has demonstrated that the available tools/methods are not sufficient in the case of processing signals from mining machinery, in particular from a rolling bearing of a copper ore crusher. Therefore, a new method based on the conditional variance was proposed, which proved to be superior with respect to many commonly used methods in the field of machine diagnostics, especially for signals with non-Gaussian noise (when noncyclic impulses related not to the fault but rather to the technology of machine operation dominate over cyclic impulses related to the local fault). The dissertation demonstrates that the conditional variance approach is simple to implement and much more robust to different specifications of the problem, such as the ratio of cyclic to noncyclic impulses or their amplitude ratio.

Several diagnostic methods were tested in this study. One of the most advanced methods is the infogram, which allows diagnostic information to be selected on the basis of entropy analysis in the time and frequency domains. However, the infogram was found to be ineffective in diagnosing local damage in the case of data from a copper ore crusher. Simple modifications applied to the infogram were proposed to improve its effectiveness.

Alternative measures of dependency for local damage detection were also proposed. In the case of non-Gaussian noise, they show higher robustness than the popular approaches do. Their effectiveness was investigated for different simulation signals (with Gaussian/non-Gaussian noise) and for actual signals from a copper ore crusher and from a conveyor belt.

The dissertation also analyzes concentrations of selected dangerous gases in the deep underground mine, i.e. hydrogen sulfide and carbon monoxide. This is one of the first such investigations (based on long-term data) in Poland. It demonstrates that carbon monoxide concentration can be modelled by a mixture of deterministic and random components. It also demonstrates that the detected high values of carbon monoxide concentrations (above the safe level of 26 ppm) in a selected copper ore mine are mostly related to the blasting procedures. The time needed to reach a safe level of carbon monoxide concentration after a blasting procedure was also determined (with a given probability).

Moreover, the use of appropriate mathematical methods for data processing allowed the author to propose a variation model of hydrogen sulfide concentrations and to demonstrate a relationship between the level of hydrogen sulfide concentration and the ventilation process. Mining/technological processes have been shown to significantly affect the variability of the hydrogen sulfide concentrations, although this gas is from an exclusively natural source (the gas is released from the rock mass). This research has demonstrated that an intensive operation of ventilators causes excessive release of hydrogen sulfide from the rock mass, due to the resulting negative pressure.

Moreover, this dissertation also analyzes seismic signals. It proposes a new algorithm for the detection of P-waves (the so-called foreshadowing wave, crucial in identifying seismic hazards). The algorithm uses the time-frequency representation of data and the PCA (Principal Component Analysis) method. The results were compared with the popular STA/LTA (Short-Term Average/Long-Term Average) method. The proposed algorithm gives more effective results.

The dissertation also discusses selected efficiency-related issues in the context of self-propelled underground machinery. It describes experiments which were conducted in order to confirm the possibility of evaluating the quality of the road and/or the driving style on the overall dynamic load of the machine, leading to accelerated wear. The study has also focused on an important problem of an automatic procedure for measuring production efficiency, i.e., measuring the number of machine (e.g., haul truck) cycles performed underground per shift. The author proposes to identify machine cycles by employing indicators alternative to the hydraulic oil pressure, which is the current standard, but which is subject to frequent failures.

This research has focused mainly on machine diagnostics. Nevertheless, other areas included in the investigations are an important part of the research hypothesis. Although each

of the analyzed areas is described by different characteristics, the common denominator in the entire research was the application of advanced mathematical methods/processes to describe mining-related processes. The methods proposed in this study are intended to improve the effectiveness of mining operations, to increase workplace safety, and to optimize expenses related to machine operation.

**Keywords:** *local damage in machinery, gas hazards of underground mines, hydrogen sulfide, carbon monoxide, duty cycle detection, efficiency analysis of mining machines, seismic hazards, P-wave, time series, stochastic processes, signal processing, non-Gaussian noise, time-frequency analysis, dependency measures.*

Badania przedstawione w niniejszej rozprawie były finansowane z dotacji celowej przyznawanej dla Wydziału Geoinżynierii, Górnictwa i Geologii Politechniki Wrocławskiej przez Ministra Nauki i Szkolnictwa Wyższego na prowadzenie badań naukowych lub prac rozwojowych oraz zadań z nimi związanych służących rozwojowi młodych naukowców oraz uczestników studiów doktoranckich oraz ze środków Unii Europejskiej w ramach Europejskiego Funduszu Społecznego, nr projektu POWR.03.02.00-00-I003/16 oraz w ramach Europejskiego Instytutu Innowacji i Technologii (EIT), na podstawie umowy partnerskiej nr 18253 (OPMO-Operational Monitoring of Mineral Crushing Machinery).

**Na rozprawę doktorską składają się wyniki badań opublikowane w następujących pracach:**

- [A1] Informative frequency band selection in the presence of non-Gaussian noise—a novel approach based on the conditional variance statistic with application to bearing fault diagnosis, Justyna Hebda-Sobkowicz, Radosław Zimroz, Marcin Pitera, Agnieszka Wyłomańska, Mechanical Systems and Signal Processing 145:106971, 2020. Punktacja MEiN z 2019-2021: **200**. Lista Filadelfijska. Impact Factor: 06.823 (2020).
- [A2] Infogram performance analysis and its enhancement for bearings diagnostics in presence of non-Gaussian noise, Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, Jerome Antoni, Mechanical Systems and Signal Processing 170:108764, 2022. Punktacja MEiN z 2019-2021: **200**. Lista Filadelfijska. Impact Factor: 08.934 (2021).
- [A3] Pattern of H<sub>2</sub>S concentration in a deep copper mine and its correlation with ventilation schedule, Justyna Hebda-Sobkowicz, Sebastian Gola, Radosław Zimroz, Agnieszka Wyłomańska, Measurement 140:373-381, 2019. Punktacja MEiN z 2019-2021: **200**. Lista Filadelfijska. Impact Factor: 03.364 (2019).



Praca doktorska współfinansowana ze środków Unii Europejskiej w ramach Europejskiego Funduszu Społecznego, nr projektu POWR.03.02.00-00-I003/16

- [A4] Local defect detection in bearings in the presence of heavy-tailed noise and spectral overlapping of informative and non-informative impulses, Jakub Nowicki, Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, *Sensors*, 20(22):6444, 2020. Punktacja MEiN z 2019-2021: **100**. Lista Filadelfijska. Impact Factor: 03.576 (2020).
- [A5] Identification and statistical analysis of impulse-like patterns of carbon monoxide variation in deep underground mines associated with the blasting procedure, Justyna Hebda-Sobkowicz, Sebastian Gola, Radosław Zimroz, Agnieszka Wyłomańska, *Sensors*, 19(12):2757, 2019. Punktacja MEiN z 2019-2021: **100**. Lista Filadelfijska. Impact Factor: 03.275 (2019).
- [A6] Selection of the informative frequency band in a bearing fault diagnosis in the presence of non-Gaussian noise – comparison of recently developed methods, Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, *Applied Sciences* 10(8):2657, 2020. Punktacja MEiN z 2019-2021: **100**. Lista Filadelfijska. Impact Factor: 02.679 (2020).
- [A7] Alternative measures of dependence for cyclic behaviour identification in the signal with impulsive noise – application to the local damage detection, Justyna Hebda-Sobkowicz, Jakub Nowicki, Radosław Zimroz, Agnieszka Wyłomańska, *Electronics* 10(15):1863, 2021. Punktacja MEiN z 2019-2021: **100**. Lista Filadelfijska. Impact Factor: 02.690 (2021).
- [A8] Dependency measures for the diagnosis of local faults in application to the heavy-tailed vibration signal, Jakub Nowicki, Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, *Applied Acoustics* 178:107974, 2021. Punktacja MEiN z 2019-2021: **100**. Lista Filadelfijska. Impact Factor: 03.614 (2021).
- [A9] Combination of Principal Component Analysis and Time-Frequency Representation for P-Wave Arrival Detection, Jacek Wodecki, Justyna Hebda-Sobkowicz, Adam Mirek, Radosław Zimroz, Agnieszka Wyłomańska, *Shock and Vibration*, 2019:5961073, 2019. Punktacja MEiN z 2019-2021: **70**. Lista Filadelfijska. Impact Factor: 01.298 (2019).
- [A10] Analysis of dynamic external loads to Haul Truck machine subsystems during operation in a deep underground mine, Paweł Śliwiński, Tomasz Kaniewski, Justyna

Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, Mining goes Digital: Proceedings of the 39th International Symposium 'Application of Computers and Operations Research in the Mineral Industry'. CRC Press, s. 515-524, 2019. Poziom wydawcy z wykazu MEiN: 1.

[A11] Selection of variables acquired by the onboard monitoring system to determine operational cycles for haul truck vehicle, Paweł Śliwiński, Marek Andrzejewski, Tomasz Kaniewski, Justyna Hebda-Sobkowicz, Radosław Zimroz, Mining goes Digital: Proceedings of the 39th International Symposium 'Application of Computers and Operations Research in the Mineral Industry'. CRC Press, s. 525-533, 2019. Poziom wydawcy z wykazu MEiN: 1.

[A12] Mobile based vibration monitoring and its application to road quality monitoring in deep underground mine, Radosław Zimroz, Jacek Wodecki, Justyna Hebda-Sobkowicz, Agnieszka Wyłomańska, Paweł Stefaniak, Paweł Śliwiński, Tomasz Kaniewski, Vibroengineering Procedia, 19:153-158, 2018. Punktacja spoza listy MNiSW: 001.

Doktorantka została również współautorem innych prac, które poruszają temat modelowania procesów w górnictwie z wykorzystaniem procesów stochastycznych:

1. Application of principal component analysis of time-frequency representation for gearbox fault detection, Jacek Wodecki, Justyna Hebda-Sobkowicz, Agnieszka Wyłomańska, Radosław Zimroz, K Gryllias, Vibroengineering Procedia, 19:82-85, 2018. Punktacja spoza listy MNiSW: 1.
2. Informative frequency band identification method using bi-frequency map clustering for fault detection in rotating machines, Jacek Wodecki, Paweł Kruczek, Justyna Hebda-Sobkowicz, Agnieszka Wyłomańska, Radosław Zimroz, Vibroengineering Procedia, 19:86-90, 2018. Punktacja spoza listy MNiSW: 1.
3. Predictive maintenance of mining machines using advanced data analysis system based on the cloud technology, Piotr Kruczek, Norbert Gomolla, Justyna Hebda-Sobkowicz, Anna Michalak, Paweł Śliwiński, Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection - MPES 2018. Springer, Cham, s. 459-470, 2019. Poziom wydawcy z wykazu MEiN: 1.

4. Comprehensive, experimental verification of the effects of the lock-up function implementation in LHD haul trucks in the deep underground mine, Tomasz Kaniewski, Paweł Śliwiński, Justyna Hebda-Sobkowicz, Radosław Zimroz, Mining goes Digital: Proceedings of the 39th International Symposium 'Application of Computers and Operations Research in the Mineral Industry', CRC Press, s. 506-514, 2019. Poziom wydawcy z wykazu MEiN: 1
5. Identification and statistical analysis of impulse-like patterns of carbon monoxide variation in deep underground mines associated with the blasting procedure, Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, Sebastian Gola, AIP Conference Proceedings, 2209(1):020005, 2020. Poziom wydawcy z wykazu MEiN: 1.

W czasie realizacji badań, doktorantka odbyła staż oraz brała czynny udział w krajowych i międzynarodowych konferencjach naukowych poświęconych górnictwie, matematyce i jej zastosowaniach do modelowania procesów przemysłowych tj.:

1. Odbycie 3 miesięcznego stażu naukowego w firmie Pruftechnik-Wibrem Sp. z o.o. w okresie od dnia 03.08.2020 do dnia 30.10.2020, Wrocław, Polska.
2. Infogram performance analysis and its enhancement for bearings diagnostics in presence of non-Gaussian noise, Justyna Hebda-Sobkowicz, 8-10.02.2021, Gródek nad Dunajcem, Polska (on-line mode), THE FOURTEENTH WORKSHOP ON NONSTATIONARY SYSTEMS AND THEIR APPLICATIONS, 2021.
3. Warunkowa wariancja w zastosowaniu do diagnostyki uszkodzeń lokalnych w maszynie górniczej, Justyna Hebda-Sobkowicz, 1-5.03.2020, Wisła, Polska, XLVII Sympozjum Diagnostyka Maszyn, **Wyróżnienie Dyplomem im. Ludwika Müllera za przygotowanie i wygłoszenie referatu.**
4. Conditional variance statistic in application to the local damage detection, Justyna Hebda-Sobkowicz, 02-05.02.2020, Gródek nad Dunajcem, Polska, 13<sup>th</sup> Workshop on Nonstationary Systems and Their Applications, 2020.
5. Gas variation pattern discovery and statistical analysis - application to H<sub>2</sub>S and CO in deep underground mine, Justyna Hebda-Sobkowicz, 13-15.02.2019, Warszawa, Polska, Between Cyclostationarity and the Artificial Intelligence. Methods and Applications, 2019.
6. Wykorzystanie narzędzi matematycznych do zautomatyzowanych procedur analizy szeregów czasowych stężeń szkodliwych gazów oraz wykrywania zagrożeń sejsmicznej w podziemnej kopalni rudy miedzi, Justyna Hebda-Sobkowicz, 9-16.09.2019, Zakopane-Kościelisko, Polska, Konferencja Zastosowań Matematyki, 2019.
7. The integrated modeling of the behaviour of the partial carbon monoxide concentration associated with the forced blasting events, Justyna Hebda-Sobkowicz, 29-31.05.2019, Sosnowka, Polska, XIX Conference of PhD Students and Young Scientists, 2019.
8. Mobile based vibration monitoring and its application to road quality monitoring in deep underground mine, Justyna Hebda-Sobkowicz, 24-26.09.2018, Zittau, Niemcy, 33rd International Conference on Vibroengineering, 2018.

Na dzień 13.12.2022 doktorantka ma 48 cytowań (bez autocytowań) według bazy Web of Science oraz Indeks Hirscha wynoszący 7. Następujące prace cytowano:

1. Informative frequency band selection in the presence of non-Gaussian noise—a novel approach based on the conditional variance statistic with application to bearing fault diagnosis, Justyna Hebda-Sobkowicz, Radosław Zimroz, Marcin Pitera, Agnieszka Wyłomańska, *Mechanical Systems and Signal Processing* 145, 106971, 2020 - 17 cytowań.
2. Selection of the informative frequency band in a bearing fault diagnosis in the presence of non-Gaussian noise – comparison of recently developed methods, Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, *Applied Sciences* 10 (8), 2657, 2020 - 14 cytowań.
3. Identification and statistical analysis of impulse-like patterns of carbon monoxide variation in deep underground mines associated with the blasting procedure, Justyna Hebda-Sobkowicz, Sebastian Gola, Radosław Zimroz, Agnieszka Wyłomańska, *Sensors*, 19 (12), 2757, 2019 - 3 cytowania.
4. Dependency measures for the diagnosis of local faults in application to the heavy-tailed vibration signal, Jakub Nowicki, Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, *Applied Acoustics* 178, 107974, 2021 - 3 cytowania.
5. Predictive maintenance of mining machines using advanced data analysis system based on the cloud technology, Piotr Kruczek, Norbert Gomolla, Justyna Hebda-Sobkowicz, Anna Michalak, Paweł Śliwiński, *Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection - MPES 2018*. Springer, Cham, 2019 - 3 cytowania.
6. Local defect detection in bearings in the presence of heavy-tailed noise and spectral overlapping of informative and non-informative impulses, Jakub Nowicki, Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, *Sensors*, 20 (22), 6444, 2020 - 2 cytowania.

# Podziękowania

Niniejsza rozprawa nie powstałaby bez wsparcia i zaangażowania moich promotorów, którym pragnę serdecznie podziękować:

Prof. Agnieszce Wyłomańskiej oraz Prof. Radosławowi Zimrozowi, za ogromną wiedzę i motywację, za pomoc na każdym etapie mojej pracy badawczej oraz za wskazówki udzielone mi podczas pisania pracy doktorskiej.

Współautorom za swój wkład, poświęcony czas we wspólnie prowadzonych badaniach, w szczególności dr inż. Jackowi Wodeckiemu i mgr inż. Jakubowi Nowickiemu za wspólne prace badawcze oraz kolegom z KGHM P.M. S.A za udostępnienie danych, doświadczenie i wiedzę praktyczną.

Programowi INTERDOK oraz Katedrze Górnictwa za wsparcie finansowe w realizacji swoich celów badawczych.

Pragnę również podziękować mojej rodzinie za nieustającą wiarę we mnie.

# Spis treści

1	Wybrane procesy technologiczne i naturalne w górnictwie - wprowadzenie . .	1
1.1	Diagnostyka maszyn górniczych . . . . .	2
1.2	Zagrożenia gazowe w kopalni podziemnej . . . . .	4
1.3	Zagrożenia sejsmiczne . . . . .	6
1.4	Analiza pracy maszyn dołowych . . . . .	7
2	Cele, hipotezy badawcze oraz zakres pracy . . . . .	10
2.1	Cele szczegółowe . . . . .	10
2.2	Hipotezy badawcze . . . . .	11
2.3	Zakres pracy . . . . .	13
3	Metodyka badawcza . . . . .	16
4	Metody i wyniki . . . . .	18
4.1	Obszar: diagnostyka maszyn . . . . .	18
4.1.1	Czasowo-częstotliwościowa reprezentacja danych . . . . .	18
4.1.2	Sygnał symulacyjny . . . . .	20
4.1.3	Sygnał rzeczywisty . . . . .	22
4.1.4	Selektor CVB . . . . .	23
4.1.5	Zmodyfikowany infogram . . . . .	32
4.1.6	Alternatywne miary zależności . . . . .	38
4.2	Obszar: wentylacja i zagrożenia gazowe . . . . .	51
4.2.1	Zmienność stężenia siarkowodoru ( $H_2S$ ) . . . . .	51
4.2.2	Zmienność stężenia tlenku węgla ( $CO$ ) . . . . .	62
4.3	Obszar: sejsmika . . . . .	69
4.4	Obszar: zarządzanie efektywnością pracy samojezdnych maszyn dołowych	74
4.4.1	Selekcja informacyjnych parametrów monitorowania maszyny	74

4.4.2	Analiza drgań maszyny podczas eksploatacji w kopalni głębiniowej . . . . .	79
5	Wnioski . . . . .	83
	Literatura . . . . .	86
	Lista rysunków . . . . .	102
	Lista tabel . . . . .	106

# 1 Wybrane procesy technologiczne i naturalne w górnictwie - wprowadzenie

Przeprowadzone badania zostały zrealizowane w ramach interdyscyplinarnego programu badawczego Interdok, którego celem jest łączenie różnych dziedzin naukowych tj. matematyki oraz górnictwa. Badania te miały na celu **modelowanie procesów w górnictwie i geologii z wykorzystaniem teorii procesów stochastycznych**. Globalna tendencja cyfryzacji górnictwa, koncepcja inteligentnej kopalni [6, 7], realizowane między innymi poprzez rozwój i wdrażania technologii Internetu Rzeczy (ang. Internet of Things - IoT), zaawansowanej analityki dla dużych zbiorów danych (ang. BIG DATA), techniki zarządzania parkiem maszynowym w oparciu o pomiary i analitykę (ang. Predictive Maintenance), czy technologii robotycznych (robotyzacja procesów technologicznych, wykorzystanie robotów do zastosowań inspekcyjnych) dotarła również do polskich przedsiębiorstw górniczych, które jak np. KGHM Polska Miedź S.A., uruchomiły dedykowane programy badawcze w tym obszarze.

Rozwój technologii pomiarowych, transmisji danych oraz systemów monitorowania obiektów (ang. Supervisory Control And Data Acquisition - SCADA), procesów środowiska kopalnianego, jest olbrzymią szansą, ale i dużym wyzwaniem dla specjalistów w zakresie analityki danych. W ostatnich latach firmy górnicze (Rio Tinto, KGHM, Jastrzębska Spółka Węglowa, Bogdanka) zainwestowały w zaawansowaną analitykę danych procesowych (np. KGHM buduje modelowy „inteligentny oddział” w kopalni Polkowice-Sieroszowice, a w centrali w Lubinie powstaje „CZAD” – Centrum Zaawansowanej Analityki Danych), co świadczy o dużym potencjale badawczym w tej dziedzinie. Niemniej jednak, wyjątkowo trudne warunki panujące w kopalni głębinowej (wysokie temperatury w wyrobiskach korytarzowych, tąpnięcia, zagrożenia gazowe, zapylenie, zasolenie) oraz złożony charakter procesów niosą ze sobą wiele wyzwań [8]. Czynniki te stanowią realne wyzwania w zakresie zapewnienia ciągłości produkcji, bezpieczeństwa pracowników, efektywnego wykorzystania infrastruktury i ograniczenia kosztów wydobycia.

Dane przemysłowe/środowiskowe/górnictwa pozyskane za pomocą różnych systemów SCADA wymagają walidacji, czyszczenia, ponownego próbkowania, segmentacji, filtrowania, detekcji, aproksymacji itp. [9–12]. Po wstępnym przetworzeniu sygnały są analizowane z wykorzystaniem szeregów czasowych lub modeli statystycznych w celu uzyskania charakterystycznych cech informacyjnych [13–23].

Przeprowadzone badania zostały podzielone na następujące obszary:

- analiza sygnałów drganiowych z wykorzystaniem metod analizy statystycznej na potrzeby wykrywania uszkodzeń w układach napędowych maszyn górniczych;
- monitorowanie i analiza zagrożeń gazowych z wykorzystaniem metod analizy statystycznej na potrzeby poprawy bezpieczeństwa pracy oraz efektywności wentylacji kopalń rud miedzi;
- monitorowanie i analiza danych z pokładowych systemów monitoringu maszyn dołowych w celu oceny jakości nawierzchni dróg transportowych oraz w celu wyznaczenia cykli pracy maszyny z wykorzystaniem metod statystycznych;
- analiza i modelowanie sygnałów sejsmicznych z wykorzystaniem metod stochastycznych na potrzeby poprawy jakości i automatyzacji detekcji fali P.

## 1.1 Diagnostyka maszyn górniczych

Jednym z głównych tematów rozprawy jest diagnostyka maszyn górniczych tj. ocena (detekcja zmiany stanu) i monitorowanie stanu maszyny na podstawie analizy drgań. Jest to powszechnie stosowane podejście w zarządzaniu eksploatacją układów mechanicznych (znane w literaturze jako ang. condition based monitoring and predictive maintenance) [24]. Nacisk kładzie się zwykle na przekładnie i łożyska, ponieważ elementy te występują w większości układów napędowych, a ich usterka jest najczęstszą przyczyną awarii maszyny [25, 26]. W przypadku maszyn górniczych problem ten jest bardzo ważny w szczególności ze względu na specyfikę maszyn górniczych: duże gabaryty, duża moc, jak również unikatowe rozwiązania konstrukcyjne (dostęp do części zamiennych jest utrudniony). Dodatkową trudnością w detekcji uszkodzeń w tych maszynach są zmienne obciążenia oraz występowanie zmiennych w czasie zakłóceń o charakterze niegaussowskim. **Awaria nawet niewielkich komponentów maszyny może pociągnąć za sobą awarię kolejnych podzespołów, czego konsekwencją jest bardzo kosztowny przestój w pracy lub narażone jest bezpieczeństwo pracy górników.** W badaniach skupiono się na analizie danych drganiowych pochodzących z łożyska kruszarki rudy miedzi [A1, A2, A4, A6, A7, A8]. Kruszarka ze względu na charakter pracy (realizowany proces technologiczny, tj. spadające bryły rudy miedzi oraz kruszenie) generuje zakłócenia, które wykazują charakter niegaussowski, co utrudnia analizę i uniemożliwia stosowanie klasycznych metod diagnostycznych. Problem ten został już niejednokrotnie poruszany w literaturze [27–30].

**Zagadnienie dotyczące detekcji lokalnych uszkodzeń w łożyskach** jest szeroko omawiane w literaturze [4, 31–34]. W przypadku stałej prędkości, zadanie jest definiowane jako **detekcja okresowego sygnału impulsowego** - który jest rozważany jako **sygnał informacyjny** (ang. Signal of the Interest - SOI). Najbardziej popularnym podejściem jest analiza obwiedni i wykrywanie częstotliwości uszkodzeń w widmie obwiedni dla wstępnie przefiltrowanego sygnału np. analiza SES (ang. Squared Envelope Spectrum) - analiza kwadratu widma obwiedni [32, 35]. Informacja o częstotliwości uszkodzenia jest kluczową informacją dla inżynierów. Znając częstotliwości obrotowe wału, łożyska, przekładni itp. (komponenty obrotowe) można powiązać otrzymane informacje dot. częstotliwości lokalnego uszkodzenia z konkretnym elementem maszyny. Jednak w przypadku sygnału drganiowego z szumem niegaussowskim, zadanie to jest znacznie utrudnione. Występujące niecykliczne impulsy w sygnale znacząco zniekształcają widmo obwiedni i uniemożliwiają skuteczną analizę. Dlatego w praktycznych zastosowaniach przed obwiednią sygnału należy zastosować wstępne filtrowanie sygnału, aby poprawić stosunek sygnału informacyjnego do szumu tła (ang. Signal to Noise Ratio - SNR). Innymi słowy, filtracja pozwala wybrać te składowe lub pasma, które niosą (zawierają) informację o lokalnym uszkodzeniu (składowe informacyjne), pomijając inne informacje spektralne, niezwiązane z uszkodzeniem, które zazwyczaj bardzo zakłócają analizowany sygnał.

W zależności od złożoności struktury sygnału można zastosować prostą filtrację pasmowo-przepustową, zaawansowaną dekompozycję EMD (ang. Empirical Mode Decomposition) lub transformację falkową [36–40]. W efekcie dekompozycji sygnału, w kolejnym kroku należy wybrać składowe informacyjne. Najpopularniejsze podejście opiera się na kurtozie widmowej [31], jako selektorze informacyjnego pasma częstotliwości (zawierającego informacje o lokalnym uszkodzeniu tj. częstotliwość uszkodzenia oraz jego częstotliwość nośną). Wartości selektora tworzą charakterystykę filtru. Filtr jest wektorem danych w skali 0 – 1, który dla informacyjnych pasm powinien przyjmować wartości bliskiej 1, a w przeciwnym wypadku bliskie 0. Obecnie wiadomo, że metody, które bazują na statystyce kurtozy, mają pewne ograniczenia. Wartość kurtozy maleje wraz ze wzrostem częstości powtarzania impulsów [41]. Z drugiej strony, gdy w zarejestrowanym sygnale zaobserwuje się wartości odstające (impulsy niecykliczne, niezwiązane z uszkodzeniem), wówczas wartość kurtozy rośnie. Problem ten został poruszony w artykule [33], w którym autorzy zaproponowali ciekawą alternatywę, a mianowicie protrugram. Opiera się on na kurtozie widma obwiedni, a nie sygnału. Pomimo swoich zalet protrugram ma również

pewne ograniczenia. Uwzględnia on tylko okresowość w sygnale, nie oceniając zachowań impulsowych. Co więcej, w przypadku wartości odstających widmo obwiedni ulega zniekształceniu, a zatem wyniki protruogramu mogą być mylące.

W literaturze [42] pokazano, że w kontekście diagnostyki maszyn można wykorzystać również inne (bardziej odporne niż wspomniana kurtoza) statystyki. Należą do nich metody oparte na spektralnym indeksie gładkości (ang. spectral smoothness index) [43], spektralnym indeksie Giniego (ang. Gini index) [44] oraz metody oparte na entropii (infogram) [45–47]. Jak również metody diagnostyczne dedykowane impulsowym sygnałom [27, 48–51], w szczególności wykorzystujące parametr stabilności z rozkładu  $\alpha$ -stabilnego (Alfa selektor, ang. Alpha selector) [30].

W literaturze można znaleźć również metody oparte na podejściu cyklostacjonarnym. Algorytmy te są dedykowane do identyfikacji zachowań cyklicznych dla sygnałów rzeczywistych. W klasycznym podejściu do technik opartych na cyklostacjonarności brane jest pod uwagę założenie o szumie gaussowskim [52–57]. Można jednak znaleźć prace, w których zaproponowano algorytmy dla sygnałów z szumem niegaussowskim [48, 49, 58–67].

Do wykrywania informacyjnego pasma częstotliwości wykorzystuje się również algorytmy oparte na sztucznej inteligencji [50, 68, 69]. **Nadal jednak istnieje potrzeba opracowania nowych podejść, prostych, zrozumiałych oraz skutecznych technik, bazujących na różnych miarach (entropia, alternatywne miary zależności, warunkowa wariancja), które pozwolą konsekwentnie radzić sobie z różnymi rodzajami zaszumienia.**

## 1.2 Zagrożenia gazowe w kopalni podziemnej

W górnictwie podziemnym zagrożenie gazowe, czyli obecność zwiększonych wartości stężeń szkodliwych substancji, takich jak tlenek/dwutlenek węgla ( $\text{CO}$ ,  $\text{CO}_2$ ), tlenki azotu ( $\text{NO}_x$ ) metan ( $\text{CH}_4$ ) czy siarkowodór ( $\text{H}_2\text{S}$ ) stanowi bezpośrednie zagrożenie dla zdrowia i życia górników.

Wszystkie te szkodliwe gazy są ważne dla określenia bezpieczeństwa przestrzeni roboczej. Każdy z nich w dużym stężeniu może powodować problemy zdrowotne, a nawet śmierć. **W rozważanej kopalni głębinowej rudy miedzi można zaobserwować obecność różnych substancji lotnych. W pracy ograniczono się do następujących gazów niebezpiecznych: siarkowodór oraz tlenek węgla.**

Siarkowódór należy zaliczyć do zagrożeń naturalnych, w przeciwieństwie do tlenku węgla, którego stężenie w znacznym stopniu zależy od harmonogramu robót strzałowych. Siarkowódór jest silnie trujący. Dopuszczalny bezpieczny poziom stężenia to 7 ppm. Powyżej 4 ppm zapach siarkowodoru jest odczuwany jako bardzo silny (charakterystyczny zapach zgniłych jaj), jednak przy stężeniach przekraczających 300 ppm staje się niewyczuwalny z powodu natychmiastowego porażenia nerwu węchowego. Gaz ten występuje tylko w niektórych rejonach kopalni, a w ostatnich latach jest stale monitorowany przez specjalistyczne urządzenia. Pochodzenie H<sub>2</sub>S jest organiczne, gaz uwalnia się z górotworu i nie jest bezpośrednio związany z gazami wytwarzanymi przez procesy technologiczne lub maszyny. Oznacza to, że jego zachowanie wydaje się być przypadkowe i powinno zależeć od lokalnych właściwości złóż. Badania stężenia H<sub>2</sub>S w kopalni podziemnej były do tej pory przedmiotem prac [70–74]. Większość z tych badań opierała się jednak na modelach fizycznych i geologicznych.

Jak wspomniano, wysokie stężenie CO jest w znacznym stopniu konsekwencją procesów technologicznych zachodzących w rozważanej kopalni rudy miedzi. Ponadto, w przeciwieństwie do siarkowodoru, tlenek węgla jest bezbarwnym, bezwonnym i pozbawionym walorów smakowych związkiem, który często nazywany jest "cichym zabójcą". Gaz ten można wykryć przy użyciu specjalistycznych urządzeń. Bezpieczny maksymalny poziom stężenia tlenku węgla to 26 ppm. Narażenie na wysokie stężenie, wynoszące 100-300 ppm, przez 2-3 godziny może powodować bóle głowy. Natomiast długotrwałe narażenie na niebezpieczny poziom tlenku węgla może spowodować trwałe pogorszenie stanu zdrowia, takie jak zaburzenia pamięci, upośledzenie umysłowe, utrata apetytu, utrata czucia w palcach, senność w ciągu dnia i bezsenność w nocy, a także zaburzenia krążenia.

Aby minimalizować zagrożenia gazowe, należy zapewnić odpowiednią ilość świeżego powietrza w przodkach eksploatacyjnych oraz określić właściwy czas oczekiwania po zakończeniu robót strzałowych, bezpieczny do rozpoczęcia prac górniczych. Ze względu na to, że kopalnia jest rozległa, a wyrobiska korytarzowe wykorzystywane jako kanały wentylacyjne są długie, proces wentylacji jest czasochłonny i niezwykle kosztowny. Górnicy nie mogą rozpocząć pracy, dopóki parametry atmosfery w kopalni nie osiągną dopuszczalnych granic. **W literaturze nie ma systematycznych badań (opartych na długoterminowych pomiarach i analizie statystycznej) w tej dziedzinie, zwłaszcza w odniesieniu do stężenia CO, czy też H<sub>2</sub>S.** Podobne prace związane z zagrożeniami gazowymi można znaleźć w [75–78]. Nie mniej jednak, jeśli wysokie stężenie gazu wytworzonego

podczas robót strzałowych po pewnym czasie zanika, to występują inne fluktuacje, które czasami mogą przekroczyć bezpieczny poziom stężenia analizowanych gazów. Ze względu na geometrię kopalni oraz sieć korytarzy, wydaje się być niemożliwe uzyskanie przestrzennego rozkładu tego parametru w czasie rzeczywistym. Najbardziej newralgiczna część kopalni, czyli okolice przodków, nie posiada żadnej infrastruktury (czujników, systemów monitoringu, elektryczności itp.), dlatego jedynym możliwym rozwiązaniem jest posiadanie indywidualnych detektorów gazu dla każdego górnika. Jest to w pewnym stopniu pomocne, jednak nie dostarcza danych historycznych do głębszej, bardziej kompleksowej analizy. **Dlatego powstała potrzeba analizy i modelowania danych historycznych, w celu uzyskania podstawowej wiedzy o ich zachowaniu.** Aby sprostać temu wyzwaniu, w ramach badań wykorzystano dane z kilkumiesięcznego eksperymentu przeprowadzonego w kopalni KGHM, oddział Polkowice-Sieroszowice. Eksperyment dostarczył danych długoterminowych dot. stężeń wybranych szkodliwych gazów, a szczegóły eksperymentu zostały opisane w pracach [A3, A5] oraz [2].

### 1.3 Zagrożenia sejsmiczne

**Kolejnym, równie ważnym obszarem uwzględnionym w rozprawie jest analiza danych sejsmicznych.** Analiza górniczych zdarzeń sejsmicznych, przewidywanie, ich ocena pod względem czasu nadejścia, lokalizacji i identyfikacji amplitudy (energii) mają kluczowe znaczenie w górnictwie podziemnym. Jednym z podstawowych zagadnień jest problem identyfikacji fali P (fala podłużna głębinowa, najszybsza fala sejsmiczna, może spowodować niewielkie uszkodzenia - tzw. fala zapowiadająca). Detekcja fali P jest niezbędna do opisu mechanizmu ogniska, obliczenia energii zdarzenia, jego lokalizacji itp. Można powiedzieć, że jej identyfikacja ma fundamentalne znaczenie w ocenie zagrożenia sejsmicznego. Zagrożenie sejsmiczne w Polsce jest stosunkowo duże w kopalniach podziemnych oraz istnieje wiele opracowań na ten temat [79–82]. **W przeprowadzonych badaniach skupiono się jednak tylko na technice wykrywania fali P.** Czas nadejścia fali sejsmicznej może być pozyskiwany ręcznie przez specjalistów ze stacji sejsmicznej, na podstawie analizy danych zmienności amplitud w sygnale sejsmicznym lub automatycznie przez wcześniej opracowane algorytmy. Te dwa podejścia różnią się pod względem czasochłonności i dokładności. Specjaliści mogą mieć do czynienia z setkami zdarzeń dziennie, dlatego zastosowanie automatycznych algorytmów wydaje się niezbędne. Wstępne zastosowanie dedykowanego

algorytmu, a następnie ich ręczna weryfikacja stało się powszechnym zwyczajem w stacjach sejsmicznych.

W erze BIG DATA rozsądne wydaje się wykorzystanie automatycznego, szybkiego i dokładnego algorytmu detekcji. Automatyzacja wykrywania fali P została podkreślona w wielu publikacjach [83–87]. Algorytm wykorzystujący średnią krótko i długookresową (ang. Short-Term Average/Long-Term Average - STA/LTA) [88] jest prawdopodobnie najszerszej stosowany ze względu na swoją prostotę, szybkie przetwarzanie i możliwość pracy w trybie online. Inne klasyczne metody to np. wielkoskalowa analiza falkowa [84], wykorzystanie sieci neuronowych [89], techniki oparte na autoregresji [90, 91]. Porównanie klasycznych metod można znaleźć w [83, 92, 93]. W ostatnich latach opracowano kilka nowych algorytmów, np. [94–102]. **Niemniej jednak główny cel, jakim jest automatyczne wykrycie nadejścia fali P z wysoką dokładnością i w jak najszybszym czasie jest nadal aktualny, ponieważ bezpośrednio przekłada się to na precyzję oceny zagrożenia (lokalizacja, energia wstrząsu).**

Z punktu widzenia przetwarzania sygnałów, problem pojawienia się fali P może być rozpatrywany jako problem segmentacji tzn. znalezienia momentu zmiany reżimu (gwałtownej zmiany wartości) jakiejś konkretnej statystyki. Zatem w celu zdiagnozowania momentu zmiany reżimu zasadne wydaje się wykorzystanie narzędzi stosowanych do rozwiązywania problemów izometrycznych. Przykładowe algorytmy rozwiązujące te równoległe zagadnienia zostały zamieszczone w następujących artykułach [103–113]. Sygnał sejsmiczny ze względu na swój impulsowy charakter jest procesem niestacjonarnym. Dla tego typu sygnałów najbardziej odpowiednim sposobem analizy i przetwarzania jest reprezentacja czasowo-częstotliwościowa. W przeprowadzonych badaniach zaproponowano innowacyjną metodę, która łączy analizę głównych składowych (ang. Principal Component Analysis - PCA) z czasowo-częstotliwościową reprezentacją sygnału [A9]. W celu wykazania skuteczności metody została ona przetestowana na rzeczywistych danych pochodzących z systemu monitoringu stosowanego w kopalni podziemnej oraz porównana z metodą STA/LTA.

## 1.4 Analiza pracy maszyn dołowych

Produkcja górnicza w kopalni podziemnej jest procesem bardzo złożonym. Wymaga znacznego wsparcia ze strony maszyn, zautomatyzowanych systemów mechanicznych, a nawet robotów. Ekstremalne warunki, zagrożenie gazowe, obecność trudnego środowiska (sól, pył,

woda), wysoka temperatura - wszystkie te czynniki powodują, że wydajność zarówno ludzi, jak i maszyn jest ograniczona. W przypadku maszyn w górnictwie podziemnym, ich żywotność jest znacznie krótsza, niż w przypadku górnictwa odkrywkowego i nieporównywalnie mniejsza niż w innych sektorach przemysłu.

Niedoskonałość techniki strzałowej, geometria korytarzy wydobywczych, **ukształtowanie nawierzchni**, ale także umiejętności i nawyki operatora maszyny (wpływające na **liczbę cykli pracy przeprowadzonych w ciągu zmiany roboczej**) mogą mieć poważny wpływ na ogólne obciążenie dynamiczne maszyny oraz produktywność.

W literaturze można znaleźć narzędzia umożliwiające monitorowanie parametrów pracy systemów wydobywczych [114]. Wizualizacja procesu technologicznego w procesie eksploatacji górniczej ma kluczowe znaczenie dla służb utrzymania ruchu i efektywności całego procesu produkcyjnego. System monitoringu pokładowego jest stosowany w podziemnych kopalniach KGHM w ponad 100 maszynach górniczych (ładowarki, wozy odstawcze, maszyny wiertnicze). Dostarcza on takie informacje jak wielkość zużycia paliwa, prędkość, aktualny bieg i wiele innych parametrów. Pozwala to na powiązanie pracy maszyny z przyspieszaniem, zwalnianiem, zmianą kierunku jazdy itp. Maszyny mobilne takie jak ładowarki, wozy odstawcze, maszyny wiertnicze są bardzo specyficzne, a ich użytkowanie i utrzymanie jest wymagające, co niejednokrotnie zostało omówione w literaturze [1, 3, 115–117]. Po udanej fazie pilotażowej, w maszynach rejestrowanych jest wiele informacji (co 1 sekundę), które są codziennie przesyłane do hurtowni danych. Niestety, problem walidacji danych, ich przetwarzania, analizy i wreszcie raportowania, wciąż stawia wiele wyzwań dla specjalistów [118, 119]. Rośnie zapotrzebowanie na wiarygodne informacje dla różnych szczebli kadry zarządzającej w kopalni. W przeprowadzonych badaniach omówiono ważny problem, **jak w sposób automatyczny przekształcić surowe dane z pokładowego systemu monitoringu wozów odstawczych w operacyjną informację o efektywności produkcji (tj. liczba cykli wozu odstawczego wykonanego pod ziemią w ciągu jednej zmiany)**. Problem ten został już częściowo rozwiązany dla ładowarki LHD [120], do identyfikacji liczby jej cykli roboczych - wykorzystano do tego sygnał ciśnienia oleju hydraulicznego. Niestety istnieje potrzeba zwiększenia niezawodności/odporności dotychczas wykorzystywanej procedury, ze względu na jej wysoką awaryjność (czujnik ciśnienia oleju jest wrażliwy i często ulega uszkodzeniu w bardzo trudnych warunkach jakie panują w kopalni podziemnej). W związku z tym w przeprowadzonych badaniach [A11] zaproponowano

alternatywne podejście, które pozwala na identyfikację cykli pracy, wykorzystując inne zmienne opisujące pracę maszyny.

Szybki rozwój elektroniki przemysłowej sprawił, że urządzenia/maszyny górnicze pracujące w podziemnych kopalniach można efektywnie monitorować. W literaturze niejednokrotnie wykorzystano telefony komórkowe do pomiaru niektórych parametrów (takich jak prędkość, przyspieszenie) i użyto ich do pomiaru przyspieszeń drgań na potrzeby oceny jakości dróg [121–123]. Występowanie niejednorodnej powierzchni drogi, elementów skał, wyrw, zagłębień, kolein itp. powoduje powstawanie dodatkowych drgań przenoszących się przez układ jezdny na całą maszynę. Inspirując się literaturą oraz wstępnymi eksperymentami przeprowadzonymi na drodze na powierzchni [A12] podjęto próbę **identyfikacji zmiany jakości nawierzchni dróg dojazdowych w kopalni podziemnej na podstawie analizy drgań [A10]. Przeprowadzona analiza oraz zaproponowana metodologia umożliwi wstępną ocenę jakości dróg w kopalni podziemnej.**

Każdy z wymienionych obszarów: **diagnostyka maszyn, wentylacja i zagrożenia gazowe, zarządzaniem efektywnością pracy samojezdnych maszyn dołowych oraz sejsmika, ma swoją niepowtarzalną specyfikę, ale wspólnym mianownikiem działań było zastosowanie zaawansowanych metod/procesów matematycznych (w szczególności statystycznych, uwzględniających specyfikę sygnałów) do opisu procesów w górnictwie.**

Niniejsza rozprawa powstała w oparciu o wyniki badań opublikowanych w dwunastu pracach [A1-A12] oraz była finansowana ze środków projektu Interdok wspierającego rozwój uczestników studiów doktoranckich oraz promującego interdyscyplinarność badań, jak również ze środków Katedry Górnictwa na Wydziale Geoinżynierii, Górnictwa i Geologii Politechniki Wrocławskiej. Wiele z opublikowanych prac było również wynikiem projektów finansowanych z UE dedykowanym górnictwie, tj. projekt OPMO, (ang. Operation monitoring of mineral crushing machinery) oraz projekt MaMMa (ang. Maintained Mine and Machine). Obydwa projekty finansowane z programów EIT KIC Raw Materials.

## 2 Cele, hipotezy badawcze oraz zakres pracy

Celem niniejszej rozprawy było **opracowanie metod umożliwiających modelowanie procesów technologicznych z wybranych obszarów w górnictwie z wykorzystaniem teorii procesów stochastycznych i metod statystycznych.**

Ze wstępnego rozpoznania, przeprowadzonego na przykładzie przedsiębiorstwa górniczego KGHM P.M. S.A, wynika, iż liczba procesów technologicznych, organizacyjnych, zarządczych itp. jest bardzo duża. Na potrzeby tej rozprawy pracę badawczą skupiono na wybranych obszarach górnictwa tj.: związanych z efektywnością i bezpieczeństwem pracy maszyn (cele szczegółowe 1 i 4) oraz z bezpieczeństwem pracy górników (zagrożenia sejsmiczne i gazowe - cele szczegółowe 2 i 3).

### 2.1 Cele szczegółowe

Cele szczegółowe obejmowały:

1. Przetwarzanie i analizę sygnałów drganiowych na potrzeby wykrywania uszkodzeń elementów układów napędowych w maszynach górniczych:
  - (a) opracowanie automatycznego algorytmu wykrywania uszkodzenia w łożysku w kruszarce rudy miedzi w obecności niegaussowskiego szumu, bazującego na impulsowości SOI;
  - (b) opracowanie automatycznego algorytmu wykrywania uszkodzenia w łożysku w kruszarce rudy miedzi w obecności niegaussowskiego szumu, bazującego na cykliczności SOI, zastosowanie alternatywnych miar zależności, analiza ich efektywności;
  - (c) adaptacja infogramu - poprawienie jego skuteczności w przypadku sygnałów z niegaussowskim szumem.
2. Modelowanie zmienności stężenia niebezpiecznych gazów (tlenek węgla, siarkowodór) w wybranej głębokiej kopalni rud miedzi:
  - (a) opracowanie modelu zmienności tlenu węgla oraz metod pozwalających na oszacowanie zagrożenia gazowego związanego z wielkością jego stężeń w wybranej kopalni, w tym wielkość skoków stężenia tego gazu oraz charakter zmienności;

- (b) opracowanie metody wstępnej identyfikacji źródła pochodzenia tlenku węgla (proces technologiczny związany z robotami strzałowymi/naturalne uwalnianie gazu z górotworu), wykorzystującej dane sejsmiczne;
- (c) opracowanie metody do wyznaczania czasu potrzebnego do osiągnięcia bezpiecznego poziomu stężenia tlenku węgla po robotach strzałowych (z zadaniem prawdopodobieństwem);
- (d) opracowanie metod pozwalających określić dzienny wzorzec zachowań zmienności stężenia siarkowodoru (proces losowy i/lub deterministyczny) oraz zbadanie wpływu parametrów wentylacji na wielkości jego stężenia w wybranej kopalni.

### 3. Modelowanie i analiza sygnału sejsmicznego na potrzeby wykrywania fali P

- (a) opracowanie automatycznego algorytmu wykrywania fali sejsmicznej (fali podłużnej - fala P), charakteryzującego się wysoką dokładnością (szybki czas wykrywania fali zapowiadającej, dokładniejszy od popularnej metody LTA/STA, zbliżony do czasu wyznaczonego przez ekspertów).

### 4. Analiza pracy maszyn dołowych

- (a) identyfikacja zmiany jakości nawierzchni dróg transportowych w kopalni podziemnej na podstawie wzbudzenia zewnętrznego maszyny (drżania obudowy maszyny);
- (b) wybór zmiennych dostępnych w systemie monitorowania maszyn do identyfikacji reżimów operacyjnych wozu odstawczego.

## 2.2 Hipotezy badawcze

W niniejszej rozprawie doktorskiej postawiono następującą hipotezę badawczą: **procesy technologiczne i naturalne w górnictwie można opisać za pomocą modeli procesów losowych z wykorzystaniem zaawansowanych metod statystycznych, którą następnie poddano weryfikacji.**

Główna hipoteza, została podzielona na kilka hipotez szczegółowych:

- H1 Wykorzystanie warunkowej wariancji w algorytmie wykrywania lokalnych uszkodzeń w maszynach wykazuje lepszą skuteczność od popularnych metod diagnostycznych, w szczególności dla sygnałów z niegaussowskim szumem.
- H2 Alternatywne miary uśredniania zastosowane do adaptacji infogramu poprawiają jego skuteczność diagnostyczną, w szczególności dla sygnałów z szumem niegaussowskim.
- H3 Alternatywne miary zależności tj. korelacja Spearmana, Kendalla oraz Quadrant mogą być skutecznie wykorzystywane do tworzenia map podobieństwa, na potrzeby wykrywania lokalnych uszkodzeń w przypadku sygnałów o niegaussowskim charakterze.
- H4 Spektralne nakładanie się pasm impulsów cyklicznych (lokalne uszkodzenie) oraz niecyklicznych (impulsy związane z technologią pracy maszyny) ma wpływ na skuteczność procedur diagnostycznych.
- H5 Procesy eksploatacyjne znacząco wpływają na zmienność stężenia siarkowodoru. Zmienność tego procesu nie jest wyłącznie losowa i można ją opisać modelem deterministycznym. Praca wentylatorów głównych powoduje zwiększone wydzielanie  $H_2S$  z górotworu. Poprzez zastosowanie odpowiednich metod matematycznych i przetwarzania danych możliwe jest wykazanie tej zależności.
- H6 Stężenie tlenu węgla związane z procedurą strzelania może być modelowane za pomocą mieszaniny deterministyczno-losowej. Wykryte gwałtowne wzrosty stężenia tlenu węgla w wybranej kopalni rudy miedzi są w większości związane z techniką urabiania skał za pomocą materiałów wybuchowych.
- H7 Wykorzystanie reprezentacji czasowo-częstotliwościowej i następnie zastosowanie algorytmu PCA do redukcji wymiarów/złożoności analizowanych danych pozwala na bardziej precyzyjne wykrycie fali P niż klasyczna metoda LTA/STA, operująca w dziedzinie czasu.
- H8 Analiza sygnału drganiowego z maszyny pozwala oszacować zmianę jakości nawierzchni po której się porusza.
- H9 Na podstawie innych wskaźników niż ciśnienie oleju hydraulicznego można wyznaczyć cykle pracy wozu odstawczego.

## 2.3 Zakres pracy

Przeprowadzone badania skupiają się na analizie danych symulacyjnych oraz rzeczywistych pochodzących z wybranych obszarów w górnictwie. Aby zrealizować cele i potwierdzić postawione hipotezy badawcze wykorzystano dane historyczne udostępnione przez KGHM. Zakres pracy badawczej to głównie analiza sygnałów, badania literaturowe, dobranie odpowiednich metod do modelowania/opisania danego zjawiska i ostatecznie wnioskowanie i próba potwierdzenia słuszności hipotez oraz interpretacja wyników. Ze względu na interdyscyplinarność badań i odmienność obszarów/procesów w górnictwie studia literaturowe zostały prowadzone przez cały okres badań. Załączone artykuły naukowe zawierają szczegółowy opis przeprowadzonych badań literaturowych każdego z analizowanych obszarów. **Największą uwagę podczas badań skupiono na diagnostyce maszyn**, o czym świadczy ilość/jakość artykułów związanych z tym tematem (6 artykułów, opublikowanych w czasopismach z listy filadelfiskiej, w tym dwa punktowane według punktacji MNiSW na 200 punktów). Nie mniej jednak, inne obszary ujęte w badaniach stanowią istotną część hipotezy badawczej.

W obszarze diagnostyki maszyn, większość algorytmów i modeli została zaproponowana w oparciu o sygnał drganiowy pochodzący z łożyska kruszarki rudy miedzi. Problem na którym skupiono się w badaniach dotyczy impulsowych zakłóceń, które uniemożliwiają wykorzystanie popularnych technik diagnostycznych. Impulsowy szum w tym przypadku związany jest z technologią pracy maszyn górniczych (w szczególności dla rozważanej kruszarki rudy miedzi są to impulsy związane z kruszonymi bryłami rudy miedzi) i większość dostępnych metod zwraca niepoprawne wyniki, błędnie traktując wspomniane impulsy jako szukane lokalne uszkodzenie. Impulsy związane z uszkodzeniem (cykliczne) mają mniejszą amplitudę przez co wykrycie ich staje się niemożliwe dla klasycznych podejść.

Obecnie wiadomo, że obecność szumu niegaussowskiego (impulsowego) może mieć negatywny wpływ na ostateczne wyniki diagnostyczne [53, 124]. W literaturze można znaleźć metody diagnostyczne dedykowane impulsowym sygnałom [27, 30, 113]. Nie mniej jednak, dla rozważanych danych z kruszarki rudy miedzi, z szumem o charakterze niegaussowskim, wyżej wymienione metody nie dają poprawnych wyników. W związku z tym zaproponowano nową metodę opierającą się na wariancji warunkowej [A1]. W szczególności pokazano, że proponowany algorytm jest lepszy od wielu powszechnie stosowanych, zwłaszcza, gdy impulsy niecykliczne dominują nad cyklicznymi. Ponadto wykazano, że podejście oparte na wariancji warunkowej jest proste w implementacji i znacznie bardziej odporne w przypadku zmiany

parametrów sygnału, takich jak stosunek liczby impulsów cyklicznych do niecyklicznych, czy stosunek ich amplitudy.

W pracy badawczej przedstawiono studium porównawcze (ujęte w artykule [A6]) popularnych metod wykorzystujących takie statystyki i narzędzia jak: kurtoza widomowa [125], Gini index [44], spectral smoothness index [43], Alfa selektor [30], kurtogram [126], infogram [45], stosowanych do lokalnej detekcji uszkodzeń dla sygnałów wzorcowych inspirowanych rzeczywistością (gaussowski biały szum, cykliczne sygnały impulsowe, niecykliczne sygnały impulsowe o losowej amplitudzie i lokalizacji impulsów oraz mieszanina wszystkich tych sygnałów) oraz dla sygnałów rzeczywistych.

Przeprowadzone badania pozwoliły na wyodrębnienie zalet i ograniczeń wybranych, wyżej wymienionych, metod. Co więcej przeprowadzona analiza pozwoliła zaproponować nową, prostą i skuteczną modyfikację zaawansowanego narzędzia diagnostycznego tj. infogramu.

Infogram [45], jako jeden z niewielu, łączy obie własności lokalnego uszkodzenia tj. impulsowość i cykliczność, podczas diagnozowania uszkodzenia. Nie mniej jednak, jak pokazano w przeprowadzonej analizie [A6], dla sygnału z szumem impulsowym, infogram zwraca fałszywe wyniki. Bazując na otrzymanych rezultatach w kolejnej pracy [A2], zaproponowano modyfikacje infogramu, które polepszają jego skuteczność.

W przeprowadzonych badaniach [A7, A8] zaproponowano również wykorzystanie miar zależności do tej pory niewykorzystywanych w diagnostyce maszyn tj. korelację Spearmana, korelację Kendalla oraz miarę Quadrant, do wykrywania cykliczności w analizowanym sygnale. Jednocześnie przeprowadzono analizę porównawczą z metodami diagnostycznymi badającymi cykliczności, znanymi w literaturze, wykorzystującymi autokorelację Pearsona, autokowariancję i autokodyferencję. Przedstawiono, które metody i dla jakich warunków/założeń wykazują najlepszą skuteczność. Ponadto, przeprowadzono symulacje, które przedstawiły wpływ spektralnego nakładania się impulsów uszkodzenia oraz nieinformacyjnych impulsów pochodzących z niegaussowskiego szumu, na skuteczność procedur diagnostycznych [A4].

W obszarze wentylacja i zagrożenia gazowe skupiono się na analizie danych dotyczących stężenia siarkowodoru [A3] oraz tlenku węgla [A5], jak również reżimów pracy wentylatorów w tym samym okresie czasu w kopalni rudy miedzi, oddział Polkowice-Sieroszowice. Analiza statystyczna danych pomiarowych siarkowodoru oraz tlenku węgla nie jest powszechna w literaturze, natomiast korelacja stężenia siarkowodoru z parametrami wentylacji nie została dotychczas zbadana, co było szczególną motywacją w przeprowadzonych badaniach.

Głównym celem analizy było poznanie charakteru zmienności tych procesów, wyodrębnienie komponentów deterministycznych i opracowanie modelu zmienności. Przeprowadzona analiza danych pokazała, iż wartości stężeń siarkowodoru oraz tlenku węgla w rozważanej kopalni charakteryzują się dużą zmiennością, jednak można zaobserwować pewien trend/determinizm. Poznanie zmienności tych procesów, w tym kontrolowanie momentu osiągnięcia bezpiecznej wartości, może umożliwić bardziej bezpieczne warunki pracy. Co więcej, wykazano zależność pomiędzy wielkością stężenia siarkowodoru, a procesem wentylacji, co jest wartościową informacją dla inżynierów odpowiedzialnych za parametry pracy wentylatorów.

W obszarze sejsmiki zostało zaproponowane nowe zastosowanie analizy składowych głównych (ang. Principal Component Analysis - PCA). Z punktu widzenia przetwarzania sygnałów, problem pojawienia się fali P, może być rozpatrywany np. jako uproszczony problem znalezienia momentu zmiany reżimu (gwałtownej zmiany wartości) pewnej statystyki. Zatem w celu zdiagnozowania momentu zmiany reżimu zasadne wydaje się wykorzystanie narzędzi stosowanych do rozwiązywania problemów izometrycznych. Przykładowe algorytmy rozwiązujące te równoległe zagadnienia zostały zamieszczone w następujących artykułach [103–113]. W przeprowadzonych badaniach [A9] zaproponowano innowacyjną metodę, która łączy analizę głównych składowych PCA z czasowo-częstotliwościową reprezentacją sygnału. Wyniki zostały porównane z popularną metodą STA/LTA. Do walidacji zaproponowanego algorytmu wykorzystano dane pochodzące z systemu monitoringu sejsmicznego ELOGOR-C, który jest wykorzystywany do obserwacji górotworu w podziemnej kopalni rudy miedzi O/ZG "Rudna". Dla rozważanych danych zaproponowana metoda wykazała lepszą skuteczność, niż wspomniana metoda STA/LTA.

Bazując na przeprowadzonej analizie danych [A11] z pokładowych systemów monitoringu maszyn dołowych zaproponowano wskaźniki, które skutecznie identyfikują cykle pracy maszyn dołowych (analizę przeprowadzono na przykładzie wozu odstawczego) i stanowią alternatywę dla powszechnie wykorzystywanego indykatora, którym jest ciśnienie oleju hydraulicznego. W tym celu wykorzystano między innymi funkcję autokorelacji oraz błąd średnio-kwadratowy.

W przypadku danych wibracyjnych pochodzących z obudowy maszyny do oceny jakości nawierzchni dróg transportowych zaproponowano selekcje wybranych fragmentów sygnału, wykorzystując dane dotyczące numeru biegu, w celu uproszczenia analizy. W badaniach [A10, A12] przedstawiono różnice w sygnale wibracyjnym w zależności od stanu nawierzchni. Do

wyznaczenia zmienności drgań zaproponowano statystyki takie jak: empiryczna wariancja oraz empiryczne kwantyle.

### 3 Metodyka badawcza

W niniejszym rozdziale przedstawiono zarys metodyki przeprowadzonych badań. Pełny opis metodyki poszczególnych etapów pracy badawczej przedstawiony jest w publikacjach stanowiących integralną część niniejszej rozprawy doktorskiej. W poniższym opisie ograniczono się do podania kluczowych zagadnień.

Stopień złożoności analizowanych zagadnień z obszarów: diagnostyka maszyn, wentylacja i zagrożenia gazowe, monitorowanie i analiza danych z pokładowych systemów monitoringu maszyn oraz sejsmika wymagał adaptacji klasycznych metod modelowania stochastycznego, a także opracowania nowych modeli opisujących procesy występujące w górnictwie. Warte podkreślenia są interdyscyplinarność badań oraz szerokie spektrum zastosowań, co wymagało przede wszystkim zrozumienia istoty wielu problemów i realiów głębokiej kopalni podziemnej, poznania technologii pracy maszyn górniczych, doboru odpowiednich technik analitycznych, modelowania procesów, przetwarzania danych zaszumionych, stanowiących mieszaninę procesów losowych i deterministycznych i wreszcie interpretacji uzyskanych wyników. Przeprowadzone prace nie mają charakteru teoretycznego, metody badawcze zawsze odnoszą się do realnych problemów, danych rzeczywistych z kopalni, a wyniki badań wiążą się z możliwością ich wdrażania w kolejnych latach.

Wszystkie procedury pracy badawczej zostały zaprogramowane w środowisku MATLAB, a w szczególnych przypadkach (diagnostyka maszyn) przetestowane dla danych symulacyjnych i zastosowane dla danych rzeczywistych. Wyniki zostały opracowane w formie artykułów naukowych w czasopismach o zasięgu międzynarodowym z listy filadelfijskiej. Najważniejsze wyniki zostały również zaprezentowane na konferencjach o zasięgu międzynarodowym. W ramach pracy badawczej wykorzystane zostały następujące narzędzia i metody:

- rachunek prawdopodobieństwa i teoria procesów stochastycznych, rozkłady prawdopodobieństwa, w szczególności teoria rozkładów  $\alpha$ -stabilnych oraz innych rozkładów niegaussowskich;
- analiza matematyczna, pochodne funkcji, szeregi czasowe oraz analiza Fouriera;

- miary zależności, w szczególności współczynnik korelacji liniowej Pearsona, współczynnik korelacji rang Spearmana oraz rang Kendalla, korelacja Quadrant, kowariancja, kodyferencja;
- algorytmika, metody Monte Carlo;
- metody statystyczne, analiza czynnikowa, w tym analiza głównych składowych, metody klasteryzacji;
- statystyka nieparametryczna, teoria estymacji, (estymator jądrowy gęstości, test Kołmogorowa-Smirnowa), wnioskowanie statystyczne.

## 4 Metody i wyniki

Poniżej omówione są najważniejsze wyniki dotyczące przeprowadzonych badań. Każdy z przedstawionych obszarów tj.: obszar diagnostyka i ocena efektywności pracy maszyn górniczych, obszar wentylacja i zagrożenia gazowe oraz obszar sejsmika opiera się przede wszystkim na analizie danych rzeczywistych. Dane pochodzą z różnych systemów pomiarowych/eksperymentów - co zostało opisane w poszczególnych artykułach. Wybrane procesy/zjawiska zostały zwizualizowane. Następnie analiza danych w każdym przypadku wymagała dopasowania odpowiednich metod/modeli/procesów - różnych w zależności od analizowanego obszaru. Podczas tworzenia schematu analizy szczególną uwagę zwracano na tworzenie procedur automatycznych, łatwych do odtworzenia w przypadku nowych/zaktualizowanych danych. W każdym z przedstawionych obszarów skutecznie udało się dopasować odpowiedni model matematyczny do procesu technologicznego - co pozwoliło odpowiedzieć na postawione hipotezy badawcze.

### 4.1 Obszar: diagnostyka maszyn

W przedstawionej pracy badawczej zaproponowano nowatorskie podejścia dotyczące wykrywania lokalnych uszkodzeń w obecności szumu niegaussowskiego (impulsowego). Zaproponowano algorytmy, które zostały przetestowane do wykrywania lokalnych uszkodzeń w łożysku tocznym w kruszarce rudy miedzi, co zostało ujęte w artykułach [A1, A2, A4, A6, A7, A8]. Wykrywanie lokalnych uszkodzeń, w dużym uproszczeniu, polega na identyfikacji cyklicznych i niecyklicznych impulsów w sygnale drganiowym. Kruszararka ze względu na specyfikę swojej pracy generuje zakłócenia (wysokoenergetyczne, niecykliczne impulsy), które bardzo utrudniają analizę. Dlatego w przeprowadzonych badaniach skupiono się na metodach, które są bardziej odporne na impulsowy szum niż klasyczne algorytmy.

#### 4.1.1 Czasowo-częstotliwościowa reprezentacja danych

Sygnał drganiowy uzyskany z uszkodzonej maszyny jest zwykle niestacjonarny (jego parametry ulegają zmianie w funkcji czasu). W zależności od konstrukcji maszyny może on być złożoną mieszaniną składowych deterministycznych i losowych, które w pewnych częstotliwościach zachowują się w określony sposób. Dlatego w praktycznych zastosowaniach przed obliczeniem obwiedni sygnału (chwilowa wartość amplitudy sygnału, jako funkcja czasu, zmieniająca się znacznie wolniej niż sam sygnał) należy zastosować wstępne filtrowanie

sygnału, aby poprawić SNR i wybrać te składowe lub pasma widma sygnału, które zawierają informację o uszkodzeniu. Najpopularniejsza procedura (kurtoza widmowa) jest wykonywana na czasowo-częstotliwościowej reprezentacji danych [31]. Zaletą reprezentacji czasowo-częstotliwościowej jest możliwość jednoczesnej obserwacji zachowania się sygnału w dziedzinie czasu (jak w sygnale surowym) oraz w dziedzinie częstotliwości. Daje to dodatkowe możliwości dalszego przetwarzania i interpretacji danych.

Dekompozycja sygnału na zbiór wąskopasmowych podsygnałów z wykorzystaniem reprezentacji czasowo-częstotliwościowej umożliwia uzyskanie kilkuset szeregów czasowych, które są badane w dalszych krokach. W przeprowadzonych badaniach wykorzystywano do tego głównie krótko-okresową transformatę Fouriera (STFT) (ang. Short-Time Fourier Transform - STFT) oraz spektrogram. Krótko-okresowa transformata Fouriera sygnału zdefiniowana jest następująco [127]:

$$\text{STFT}_x(t, f) = \sum_{k=1}^N x_k w_{t-k} e^{\frac{-2j\pi f k}{N}}, \quad (1)$$

gdzie  $w_{t-k}$  jest oknem przesunięcia czasowego (jako funkcję okna zastosowano okno Hamminga [127]),  $x = x_1, \dots, x_N$  jest analizowanym sygnałem długości  $N$ ,  $t \in T$  jest punktem czasowym,  $f \in F$  jest częstotliwością, a  $j$  oznacza część urojona. Spektrogram jest mapą czasowo-częstotliwościową opisaną jako:

$$S(t, f) = |\text{STFT}_x(t, f)|^2. \quad (2)$$

Innym podejściem dekompozycji sygnału jest wykorzystanie zestawu filtrów (ang. filter bank) o określonych charakterystykach, np. struktury drzewa 1/3-binarnego [126]. Tą formę reprezentacji sygnału, na płaszczyźnie  $(f, \Delta f)$ , gdzie  $\Delta f = f(2) - f(1)$ , wykorzystano w literaturze do zdefiniowania kurtogramu [126] oraz alternatywnych narzędzi inspirowanych kurtogramem, jak np. infogram [45]. Dokładniej mówiąc, dla danej liczby  $k$  ( $k$  może być ułamkowe) poziomów dekompozycji, filtry pasmowo-przepustowe są wykorzystywane do dekompozycji sygnału na  $[2^k]$  podsygnałów, odpowiadających określonej szerokości pasma  $\Delta f$  i określonej częstotliwości centralnej  $f$ . Struktura drzewa 1/3-binarnego umożliwia utworzenie płaszczyzny częstotliwość/rozdzielczość częstotliwości.

Dekompozycja sygnału umożliwia wyszczególnienie w sygnale składowych o różnych częstotliwościach i różnym zachowaniu w czasie. W dalszym kroku analiza obejmuje

zastosowanie odpowiednich selektorów informacyjnych pasm częstotliwości, czyli pasm które wykazują zachowania typowe dla lokalnych uszkodzeń.

W przeprowadzonych badaniach selektorem nazywana jest statystyka wykorzystana do selekcji informacyjnego pasma częstotliwości (ang. Informative Frequency Band - IFB), obliczona dla każdego  $f \in F$  ze spektrogramu. Selektory mogą być wykorzystywane jako charakterystyki filtrów [42, 125]. W poniższym streszczeniu przeprowadzonych badań zostaną zaprezentowane wybrane wyniki przedstawiające selektory IFB. Ich wykorzystanie jako charakterystyki filtrów, filtracja, a następnie widma przefiltrowanych danych zostały zaprezentowane w poszczególnych artykułach [A1, A2, A4, A6, A8].

#### 4.1.2 Sygnał symulacyjny

Praca nad metodami diagnostycznymi umożliwiającymi wykrycie lokalnego uszkodzenia w maszynach górniczych charakteryzujących się trudnymi warunkami wymagała dokładnego zrozumienia analizowanych sygnałów o skomplikowanej strukturze. Aby uprościć problem zbudowano model sygnału z lokalnym uszkodzeniem, inspirowany sygnałem pochodzącym z łożyska kruszarki rudy miedzi. Sygnał ten jest mieszaniną takich składowych jak: cykliczny, impulsowy sygnał (sygnał informacyjny, reprezentujący uszkodzenie) i niecykliczny, impulsowy sygnał (szum niegaussowski).

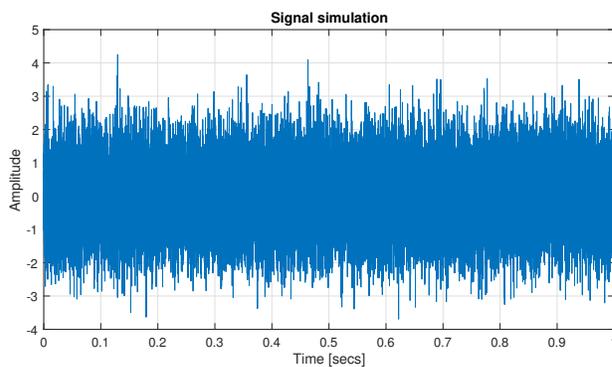
Proponowane algorytmy umożliwiające skuteczną diagnostykę uszkodzenia dla sygnałów z niegaussowskim szumem, zostały porównane z klasycznymi oraz zaawansowanymi metodami, wykorzystując sygnały symulacyjne oraz rzeczywiste. Skuteczność działania metod jest interpretowana jako zdolność wykrycia częstotliwości uszkodzenia. Szczególną uwagę zwrócono również na parametry sygnału, które mogą ulec zmianie w zależności od warunków pracy maszyny oraz rodzaju uszkodzenia, co może wpłynąć na skuteczność analizowanych metod diagnostycznych. Wszystkie proponowane metody (jak również wybrane metody z literatury) zostały sprawdzone pod kątem skuteczności działania dla następujących sygnałów symulowanych:

- szum gaussowski zadaną amplitudą ANO (ang. Amplitude of Noise) - brak uszkodzeń, brak impulsów w otoczeniu, brak zakłóceń związanych z procesem technologicznym - nazywany sygnałem s1;
- s1 z dodanymi, widocznymi lub ukrytymi seriami cyklicznych impulsów, zadaną amplitudą impulsów ACI (ang. Amplitude of Cyclic Impulses), związanych z

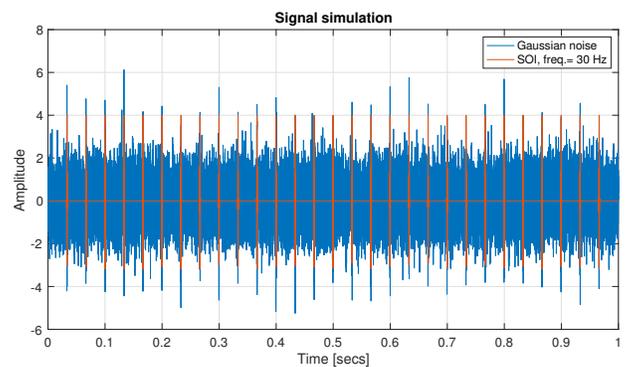
lokalnymi uszkodzeniami - SOI (ang. Signal of the Interest), zwany sygnałem  $s_2$ . W przeprowadzonych badaniach założono występowanie SOI w paśmie częstotliwości nośnej na poziomie 2 - 3 kHz, o częstotliwości środkowej  $f_c = 2.5$  kHz (częstotliwość nośna);

- $s_1$  z dodanymi, widocznymi lub ukrytymi seriami niecyklicznych impulsów związanych z procesami technologicznymi (urabianie nożem na głowicy kombajnu, skrawanie, kruszenie, przesiewanie, cięcie (np. blachy), kompresja (gazu, ropy), uderzanie (np. rozbijanie brył na kracie)) - sygnał  $s_3$ ;
- $s_2$  z dodanymi, widocznymi lub ukrytymi seriami niecyklicznych impulsów związanych z procesami technologicznymi - sygnał  $s_4$ .

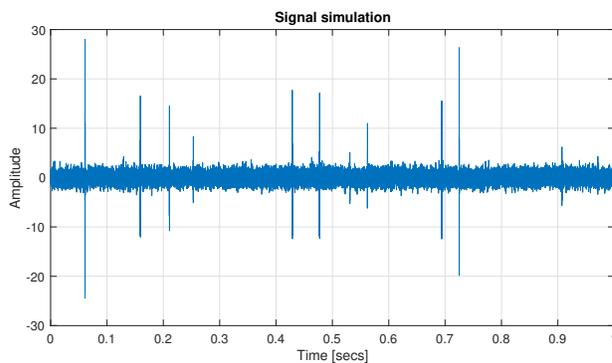
Wyżej wymienione sygnały  $s_1$ ,  $s_2$ ,  $s_3$  oraz sygnał docelowy  $s_4$ , będący mieszaniną cyklicznych i niecyklicznych impulsów oraz szumu, zostały zaprezentowane na Rys. 1. Szczegółowy opis



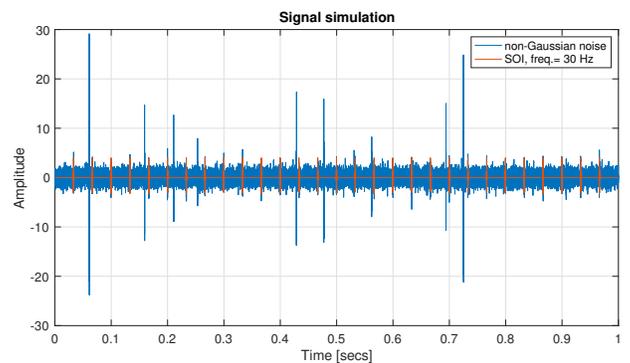
(a) Symulowany sygnał  $s_1$



(b) Symulowany sygnał  $s_2$



(c) Symulowany sygnał  $s_3$



(d) Symulowany sygnał  $s_4$

Rysunek 1: Symulowane sygnały drganiowe z łożyska kruszarki rudy miedzi [A6]

symulacji sygnału został przedstawiony w pracy [A1].

#### 4.1.3 Sygnał rzeczywisty

Do zweryfikowania skuteczności proponowanych algorytmów wykorzystano również sygnały rzeczywiste, przede wszystkim sygnały drganiowe pochodzące z łożyska kruszarki rudy miedzi, udostępnione przez KGHM.

Kruszarka pracująca w przemyśle wydobywczym jest traktowana jako studium przypadku w celu pokazania korzyści płynących z proponowanych algorytmów. Na Rys. 2 przedstawiono kruszarkę młotkową rudy miedzi z zaznaczoną lokalizacją przenośnika taśmowego (ang. belt conveyor), łożyska (ang. bearing) oraz kierunkiem spadania brył (ang. falling rocks).

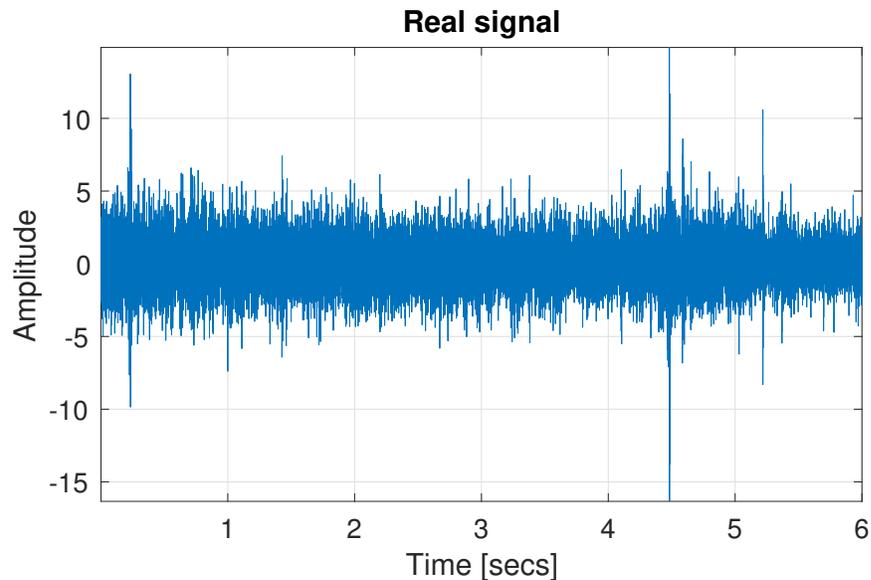


Rysunek 2: Kruszarka młotkowa rudy miedzi [A2]

Sygnał drganiowy został zmierzony na obudowie łożyska tocznego, które utrzymuje wał maszyny. Sygnał został zmierzony przy użyciu akcelometru Endevco, model 751-10 oraz systemu akwizycji danych obsługiwane przez oprogramowanie Labview Signal Express. Parametry sygnału są następujące: częstotliwość próbkowania - 25 kHz, czas trwania pomiarów ok. 6 minut. Podczas analizy wykorzystano głównie 6-sekundowe odcinki. Strumień materiału podawany do kruszarki jest zmienny w czasie (jego objętość i granulacja), więc maszyna pracuje w zmiennych w czasie warunkach obciążenia/prędkości. Jednak w przypadku 6-sekundowego odcinka prędkość obrotowa wału jest traktowana jako, w przybliżeniu, stała.

W analizie uwzględniono uszkodzenie bieżni wewnętrznej jednego z łożysk. Rozważane łożysko to SKF 23264.

Na Rys. 3 został przedstawiony sygnał drganiowy pochodzących z łożyska maszyny kruszącej ze sztucznie wprowadzoną składową związaną z lokalnym uszkodzeniem. Podobne podejście zostało wykonane w [27, 128]. Lokalne uszkodzenie zostało dodane z częstotliwością

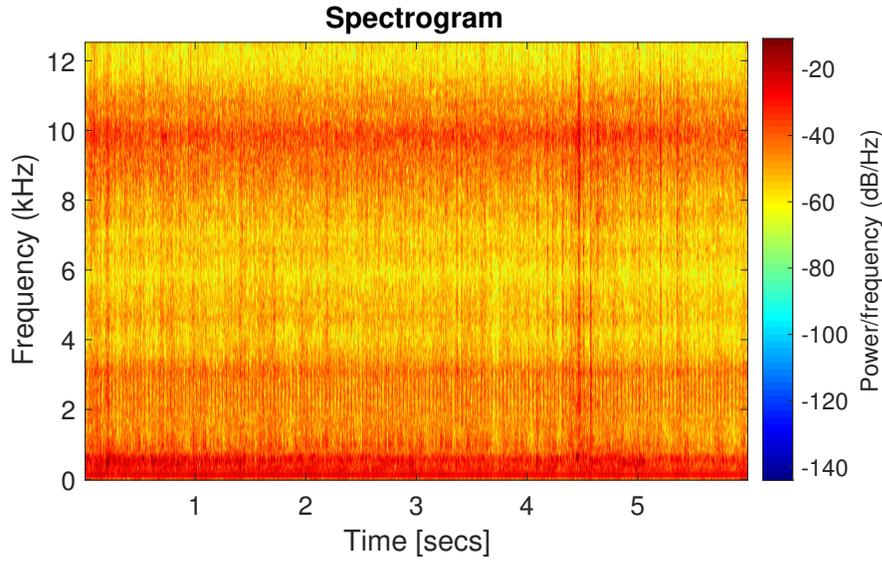


Rysunek 3: Sygnał drganiowy z łożyska kruszarki rudy miedzi z dodanym lokalnym uszkodzeniem [A6]

modulującą równą 30 kHz, częstotliwością nośną równą 2.5 kHz (2-3 kHz) i amplitudą impulsów równą 4. Spektrogram danych został przedstawiony na Rys. 4. Jak można zauważyć, dane przedstawiają wysokoenergetyczne impulsy szerokopasmowe w okolicach 0.25, 4.5 i 5.25 sekundy, które są związane ze spadającymi bryłami rudy miedzi. Rzeczywisty sygnał drganiowy zawiera różne składowe o złożonej strukturze, a składowa związana z uszkodzeniem, (Rys. 4, pasmo 2.5 kHz), jest zazwyczaj niewidoczna w sygnale w dziedzinie czasu, ze względu na występujący szum. Dla zaprezentowanego sygnału (Rys. 3) poniżej zostaną pokazane wybrane, najważniejsze wyniki pracy badawczej.

#### 4.1.4 Selektor CVB

W przeprowadzonych badaniach opublikowanych w pracy [A1] zaproponowano m.in. nowy selektor informacyjnego pasma częstotliwości oparty na warunkowej wariancji, dotychczas niestosowanej w diagnostyce maszyn. Idea warunkowej wariancji nawiązuje do znanej reguły



Rysunek 4: Spektrogram sygnału rzeczywistego [A6]

zwanej równowagą rozproszenia (Reguła 20/60/20) [129]. Zasada ta mówi, że jeśli populację podzielimy na trzy grupy według jakiegoś arbitralnie przyjętego kryterium odniesienia (np. 20% najmniejszych, 60% średnich i 20% największych wartości), to ta szczególna relacja 20/60/20 często oznacza pewien rodzaj równowagi, tzn. przy założeniu, iż populacja ma rozkład gaussowski, grupy te wykazują podobną zmienność (w sensie wariancji każdej z grupy).

Założmy, że  $Y \sim N(\mu, \sigma)$  jest gaussowską zmienną losową o średniej  $\mu$  i odchyleniu standardowym  $\sigma$ . Niech  $\phi_{\mu, \sigma}(\cdot)$  oraz  $\Phi_{\mu, \sigma}(\cdot)$  oznaczają odpowiednio funkcję gęstości (ang. probability density function - pdf) oraz funkcję dystrybuanty (ang. cumulative distribution function - cdf) zmiennej  $Y$ . Lewostronny, prawostronny i środkowy kwantyl zmiennej  $Y$  rzędu  $0 < q < 0.5$  jest zdefiniowany w następujący sposób:

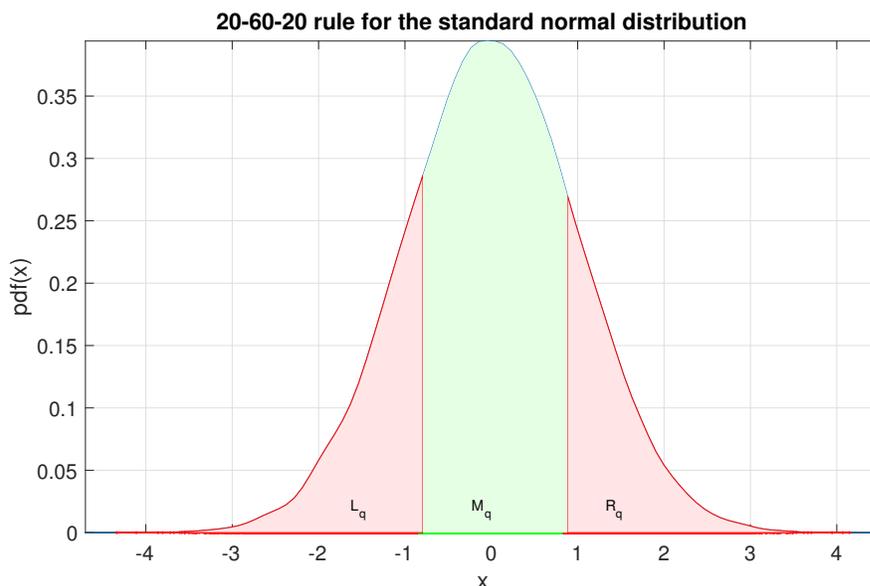
$$L_q := (-\infty, \Phi_{\mu, \sigma}^{-1}(q)], \quad R_q := [\Phi_{\mu, \sigma}^{-1}(1 - q), \infty),$$

$$M_q := (\Phi_{\mu, \sigma}^{-1}(q), \Phi_{\mu, \sigma}^{-1}(1 - q)), \quad (3)$$

gdzie  $\Phi_{\mu, \sigma}^{-1}(\cdot)$  oznacza odwrotność  $\Phi_{\mu, \sigma}(\cdot)$ , tzn.  $\Phi_{\mu, \sigma}^{-1}(d)$  oznacza  $d$ -kwantyl zmiennej  $Y$ . Przy założeniach gaussowości i podziału zbioru 20/60/20, tj. dla  $q \approx 0.2$ , otrzymujemy

$$\sigma_{L_q}^2 = \sigma_{M_q}^2 = \sigma_{R_q}^2, \quad (4)$$

gdzie  $\sigma_A^2 := \text{Var}(Y|Y \in A)$  jest warunkową wariancją zmiennej  $Y$  na zbiorze  $A$ . Podział 20/60/20 dla którego równość (4) zachodzi jest unikatowy. Na Rys. 5 przedstawiono gęstość standardowego rozkładu gaussowskiego z zaznaczonymi podziałami odpowiadającymi Regule 20/60/20.



Rysunek 5: Gęstość standardowego rozkładu gaussowskiego z zaznaczonymi podziałami odpowiadającymi Regule 20/60/20 [A1]

Można rozważyć różną liczbę podzbiorów dla których równość wariancji tych podzbiorów nadal będzie zachodzić, co zostało szczegółowo omówione w literaturze [129].

Reguła 20/60/20 była inspiracją do zdefiniowania statystyki testującej pasma częstotliwości spektrogramu w celu selekcji IFB. Dla rozważanego problemu lokalnego uszkodzenia w sygnale o niegaussowskim szumie problem jest złożony i należy uwzględnić dwie kwestie tj. statystyka powinna zareagować w sytuacji wystąpienia w danych impulsów pochodzących z uszkodzenia i jednocześnie zlekceważyć impulsy pochodzące z innego źródła. W zdefiniowaniu statystyki testowej wykorzystano podział zbioru na siedem podzbiorów. Kwantyle (unikatowe) gwarantujące równość warunkowych wariancji, dla zmiennej o rozkładzie gaussowskim, przy takim podziale są następujące [130]:

$$0.004/0.058/0.246/0.384/0.246/0.058/0.004.$$

Na potrzeby niniejszej pracy została skonstruowana statystyka testowa, która uwzględnia wariancje warunkowe próby tylko dla zbiorów  $A_3$ ,  $A_4$  i  $A_5$ . Resztę zbiorów ( $A_1$ ,  $A_2$ ,  $A_6$

oraz  $A_7$ ) celowo wyklucza ze względu na nietrwałą naturę zbiorów brzegowych. Impulsy niecykliczne, które ze względu na swoją wysoką energię (wysoka amplituda w porównaniu do większości wartości populacji) oraz stosunkowo rzadkie występowanie tworzą grube ogony rozkładu (w rozważanym przypadku w większości ujęte w zbiorach brzegowych  $A_1$ ,  $A_2$ ,  $A_6$  oraz  $A_7$ ). Grube (ciężkie) ogony rozkładu oznaczają zdarzenia nietypowe, tj. wyższe niż w rozkładzie normalnym prawdopodobieństwo wystąpienia skrajnie wysokich wartości (innymi słowy, wspomniana, nietrwała natura zbiorów brzegowych). Szczegółowe informacje zostały ujęte w pracy [A1].

Statystyka wariancji warunkowej zastosowana do diagnozowania uszkodzeń łożysk została zdefiniowana w następujący sposób [A1]:

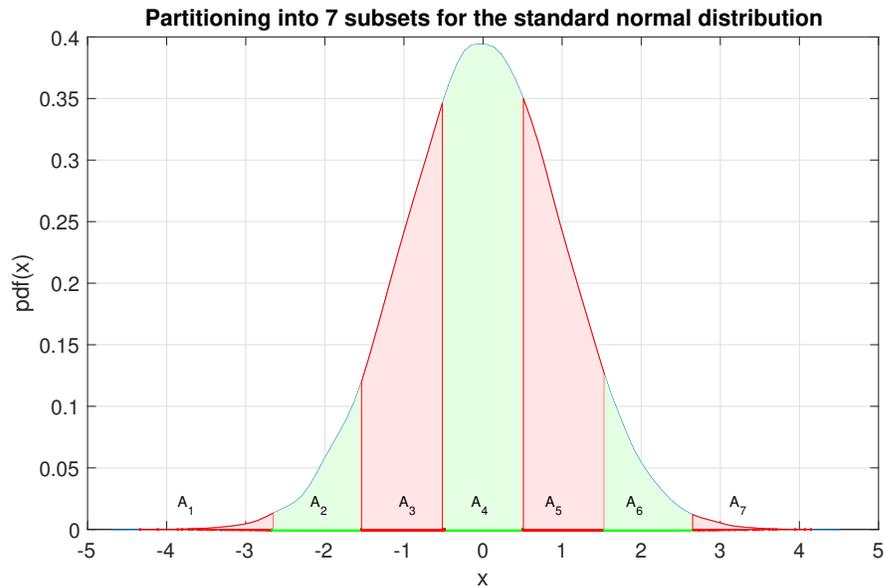
$$\hat{C}_7(x) := \left( \frac{\hat{\sigma}_{A_3}^2 - \hat{\sigma}_{A_4}^2}{\hat{\sigma}} + \frac{\hat{\sigma}_{A_5}^2 - \hat{\sigma}_{A_4}^2}{\hat{\sigma}} \right)^2 \sqrt{N}. \quad (5)$$

Dolny index 7 w statystyce  $\hat{C}_7(\cdot)$  odnosi się do ilości podziałów i podzbiorów  $A_i$  na które zostaje podzielony rozkład wektora  $x = x_1, \dots, x_N$ . Górny daszek oznacza estymator. Natomiast  $\sigma_{A_i}^2$  jest estymatorem wariancji podzbioru  $A_i$ . Zmienna  $n$  to wielkość populacji. Główną własnością podzbiorów  $A_i$  jest równość ich wariancji  $\sigma_{A_i}^2$ , co jak wspomniano, dla podziału na 7 podzbiorów zachodzi dla następująco zdefiniowanych podzbiorów [129]:

$$\begin{aligned} \hat{A}_1 &:= (-\infty, \hat{x}_{.004}], \\ \hat{A}_2 &:= (\hat{x}_{.004}, \hat{x}_{.062}], \\ \hat{A}_3 &:= (\hat{x}_{.062}, \hat{x}_{.308}], \\ \hat{A}_4 &:= (\hat{x}_{.308}, \hat{x}_{.692}], \\ \hat{A}_5 &:= (\hat{x}_{.692}, \hat{x}_{.938}], \\ \hat{A}_6 &:= (\hat{x}_{.938}, \hat{x}_{.996}] \\ \hat{A}_7 &:= (\hat{x}_{.996}, \infty), \end{aligned}$$

gdzie  $\hat{x}_q$  jest empirycznym kwantylem stopnia  $q$  wektora  $x$ . Rys. 6 przedstawia graficzną ilustracją podziału rozkładu wektora danych (wektora  $x$ ) na 7 podzbiorów. Wówczas, zakładając, iż wektor  $x$  ma rozkład gaussowski, zachodzi następująca zależność [129]:

$$\sigma_{A_1}^2 = \sigma_{A_2}^2 = \sigma_{A_3}^2 = \sigma_{A_4}^2 = \sigma_{A_5}^2 = \sigma_{A_6}^2 = \sigma_{A_7}^2. \quad (6)$$



Rysunek 6: Funkcja rozkładu prawdopodobieństwa dla rozkładu gaussowskiego  $N(0,1)$  z zaznaczonym podziałem na 7 podzbiorów [A1]

Przy spełnionym założeniu gaussowości rozkładu wektora  $x$ , statystyka testowa  $\hat{C}_7(\cdot)$  przyjmuje wartości bliskie zera. W przypadku kiedy w sygnale pojawiają się impulsy związane uszkodzeniem jej wartość rośnie.

Po dekompozycji czasowo-częstotliwościowej sygnału (spektrogram, Rys. 4) estymator  $\hat{C}_7(\cdot)$  zastosowany do poszczególnych pasm częstotliwości  $f_i : \hat{C}_7(f_i)$  nazywany jest selektorem opartym na warunkowej wariancji (ang. conditional variance-based selector) tj. selektor CVB. Selektor ten jest w stanie rozróżnić występujące różne impulsy na podstawie rozkładu ich amplitud i został zdefiniowany w taki sposób aby ignorować wysoko-energetyczne impulsy związane z technologią pracy, jednocześnie nie będąc obojętnym na istniejące impulsy związane z lokalnym uszkodzeniem (o mniejszej amplitudzie energii). Niemniej jednak zaproponowany selektor nie bierze pod uwagę okresowości impulsów. Jest to ogólny problem dla selektorów bazujących na jednej charakterystyce uszkodzenia – impulsowości.

Zaproponowana metoda została porównana z popularnymi metodami stosowanymi w omawianym problemie, tj. z selektorem wykorzystującym kurtozę widmową, z selektorem wykorzystującym spektralny indeks gładkości (ang. spectral smoothness index) [43] - spectral smoothness selektor, z selektorem wykorzystującym spektralny indeks Giniego (ang. Gini index) [44] - Gini selektor, z Alfa selektorem (ang. Alpha selector, selektor wykorzystujący parametr stabilności  $\alpha$  z rozkładu  $\alpha$ -stabilnego [30]) oraz z kurtogramem

[126] i z infogramem [45]. Zdolność wykrywania informacyjnego pasma częstotliwości w przypadku wyżej wymienionych metod została zbadana dla sygnałów symulacyjnych o różnych parametrach oraz dla sygnału drganiowego pochodzącego z łożyska kruszarki rudy miedzi. Na Rys. 7 oraz Rys. 8 zaprezentowane zostały wybrane wyniki. Pełne zestawienie wraz ze szczegółowym opisem zostało zawarte w pracach [A1] oraz [A6].

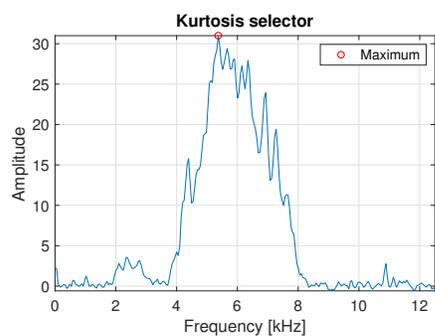
Rys. 7 przedstawia selektory (charakterystyki filtra) dla sygnału symulacyjnego s4, natomiast Rys. 8 dla sygnału rzeczywistego - opisanych w rozdziałach 4.1.2 – 4.1.3. Dla obu sygnałów IFB znajduje się na częstotliwości nośnej 2.5 kHz, natomiast impulsy niecykliczne na częstotliwości nośnej 6 kHz.

Dla najbardziej skomplikowanego przypadku, jakim jest sygnał s4, w którym stosunek amplitudy impulsów niecyklicznych do cyklicznych jest wysoki, spodziewamy się znaleźć informacyjne pasmo częstotliwości ze stłumioną informacją o impulsach niecyklicznych. Jak można zauważyć na Rys. 7 selektor CVB poprawnie zidentyfikował pasmo częstotliwości lokalnego uszkodzenia. Kurtoza widmowa, kurtogram oraz spektralny indeks gładkości błędnie wskazują pasmo częstotliwości związane z niecyklicznymi, wysokoenergetycznymi impulsami, jako informacyjne. Alfa selektor, spektralny indeks Giniego i infogram wskazują zarówno pasma częstotliwości impulsów cyklicznych, jak i niecyklicznych. Podsumowując, proponowany selektor CVB wykazał najlepszą skuteczność dla rozważanego sygnału impulsowego s4.

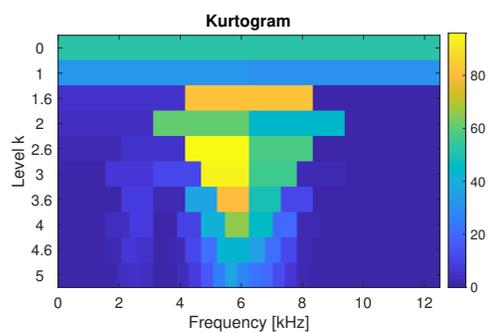
Szczególą uwagę poświęcono infogramowi, który stał się motywacją do głębszej analizy jego skuteczności, a wyniki badań zostały opublikowane w pracy [A2].

Infogram to zaawansowane narzędzie [45], które uwzględnia obie charakterystyki uszkodzenia, tj. zarówno impulsowość sygnału w dziedzinie czasu, jak i okresowość w widmie obwiedni. Wyróżnia go to wśród dostępnych metod diagnostycznych. Mimo tej istotnej przewagi infogram nie dostarczył jednoznacznej informacji o lokalnym uszkodzeniu w analizowanym sygnale s4. Infogram do fuzji informacji z dziedziny czasu i częstotliwości wykorzystuje funkcję entropii oraz średnią arytmetyczną. Jak się okazuje ze względu na nieodporność średniej arytmetycznej na wartości odstające uzyskane wyniki mogą być niemiarodajne, w szczególności dla danych z szumem niegaussowskim.

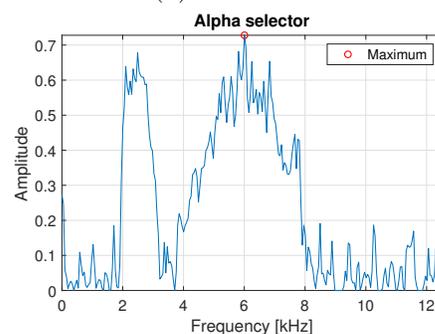
W przypadku sygnału rzeczywistego (opisanego w rozdziale 4.1.3) amplituda impulsów niecyklicznych jest mniejsza, niż w rozważanych danych symulowanych (sygnał s4). Nie mniej jednak, wyniki dla kurtozy widmowej, dla kurtogramu, dla selektora, wykorzystującego spektralny indeks gładkości oraz dla infogramu nie są zadowalające, Rys. 8. Warty



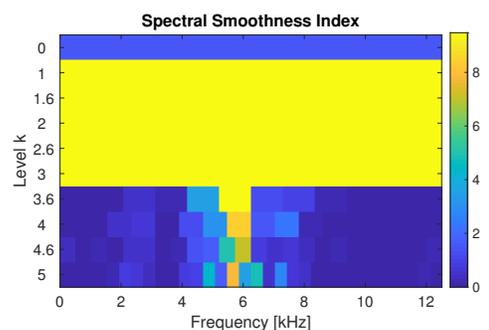
(a) Kurtoza widmowa



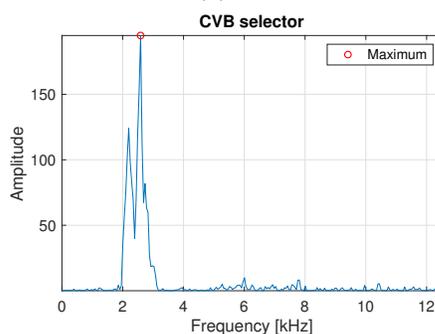
(b) Kurtogram



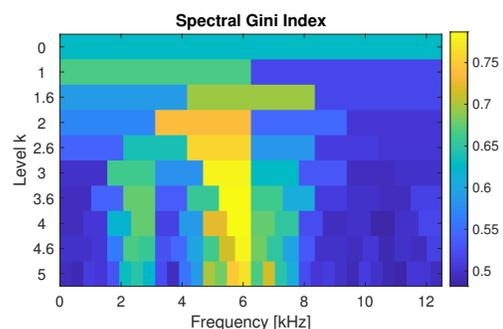
(c) Alfa selektor



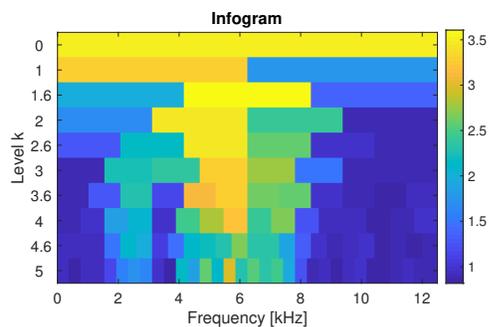
(d) Spectral smoothness selektor



(e) Selektor CVB

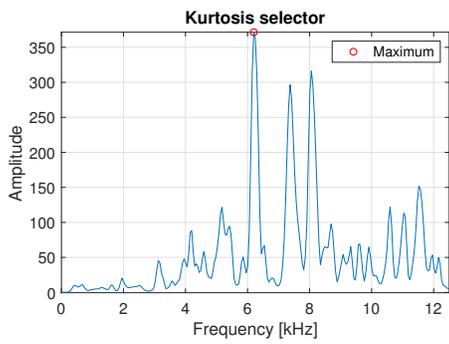


(f) Gini selektor

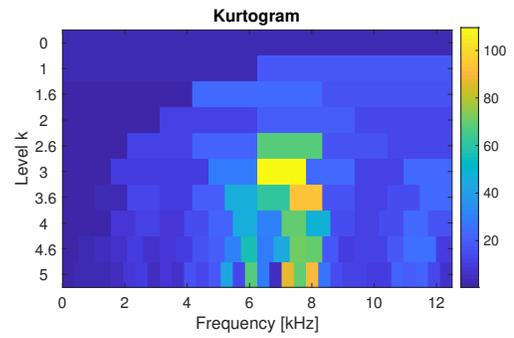


(g) Infogram

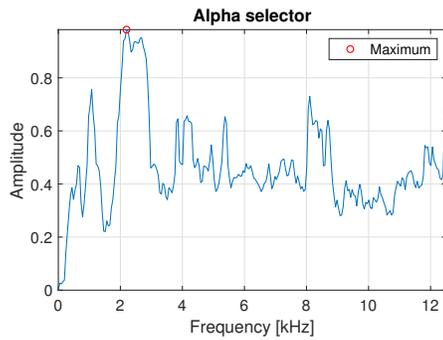
Rysunek 7: Wyniki selekcji informacyjnego pasma częstotliwości dla sygnału s4 przez wybrane metody diagnostyczne tj. kurtoza widmowa, Alfa selektor, selektor CVB, kurtogram, spectral smoothness selektor, Gini selektor, infogram [A6]



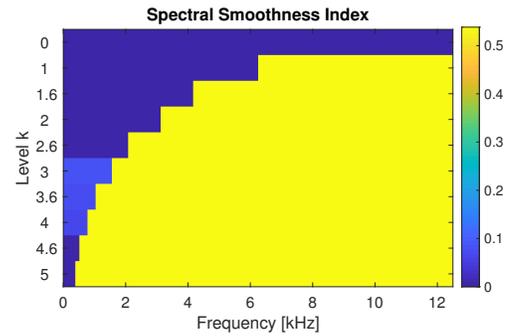
(a) Kurtoza widmowa



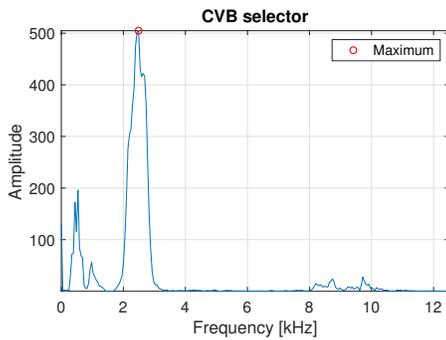
(b) Kurtogram



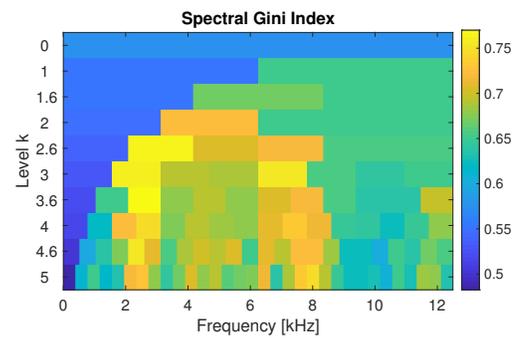
(c) Alfa selektor



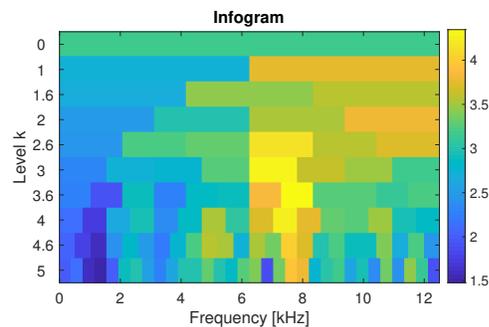
(d) Spectral smoothness selektor



(e) Selektor CVB



(f) Gini selektor



(g) Infogram

Rysunek 8: Wyniki selekcji informacyjnego pasma częstotliwości dla rzeczywistego sygnału drganiowego przez wybrane metody diagnostyczne tj. kurtoza widmowa, Alfa selektor, selektor CVB, kurtogram, spectral smoothness selektor, Gini selektor, infogram [A6]

uwagi jest fakt, iż spektralny indeks gładkości jest wrażliwy numerycznie (wrażliwy na małe wartości sygnału oraz ilość próbek), co zostało szczegółowo opisane w pracy [A6]. Wada ta uniemożliwia uzyskanie jakiegokolwiek sensownego wyniku (nieskończone wartości zaznaczone na żółto na Rys. 8 pojawiają się aż do 5 poziomu dekompozycji). Alfa selektor i spektralny indeks Giniego prawidłowo wskazują IFB, ale ze znacznie mniejszą dokładnością niż selektor CVB.

Może się zdarzyć, że liczba impulsów losowych (niecyklicznych, niezwiązanych z uszkodzeniem) rośnie i/lub ich amplituda wzrasta. W takim przypadku rozkład spektralny energii analizowanego sygnału będzie inny i selektywność testowanych selektorów może ulec zmianie. W artykule [A1] zostało pokazane, że podejście oparte na wariancji warunkowej jest proste do wdrożenia i efektywne również w zakresie zmiennych parametrów sygnału, takich jak stosunek liczby impulsów cyklicznych do niecyklicznych, czy stosunek ich amplitud. Do walidacji odporności metody użyto symulacje Monte Carlo (MC).

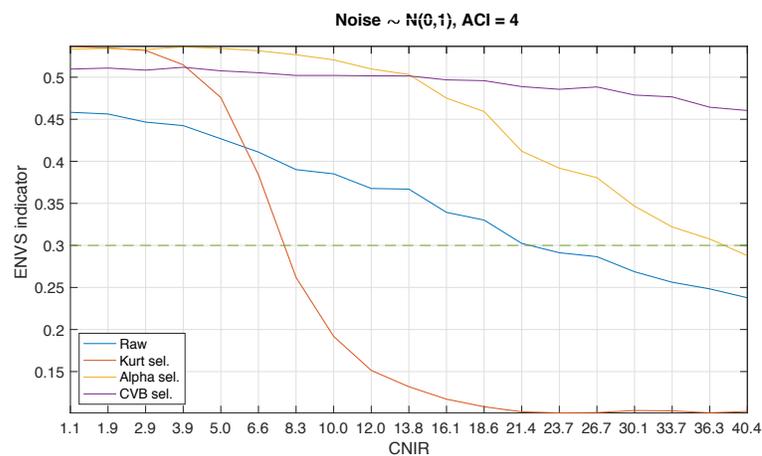
W celu potwierdzenia skuteczności nowego selektora dla różnej wartości amplitudy impulsów niecyklicznych przeprowadzono symulację MC wartości indykatora ENVSI (ang. Envelope Spectrum Based Indicator - ENVSI, szczegółowo opisany w artykule [A8]), wykorzystującego widmo obwiedni sygnału do oceny jakości widma obwiedni, w kontekście wskazania prawidłowej częstotliwości uszkodzenia - im większe amplitudy o częstotliwości uszkodzenia na widmie obwiedni, w porównaniu do tła, tym większa wartość indykatora. Selektor o najwyższej wartości indykatora ENVSI jest najbardziej skuteczny.

Indykator ENVSI został policzony dla przefiltrowanych sygnałów przez wybrane selektory IFB. Wyniki zostały porównane z wartościami ENVSI dla surowego sygnału, przy zmieniającym się stosunku amplitudy impulsów niecyklicznych do cyklicznych (ang. Cyclic to Noncyclic Ratio - CNIR). Sygnał testowy to sygnał  $s_4$ , opisany w rozdziale 4.1.2 oraz szczegółowo w pracy [A1], będący mieszaniną białego szumu, cyklicznych impulsów o amplitudzie 4 ( $ACI = 4$ ) i częstotliwości 30 Hz ( $FIM_1 = 30$ ) oraz niecyklicznych impulsów o zmiennej amplitudzie ( $ANCI$ ) i zmiennej częstotliwości ( $FIM_2$ ). Wyniki zostały przedstawione na Rys. 9. Szczegółowy opis algorytmu został przedstawiony w pracy [A1].

Jak można zauważyć, na Rys. 9, skuteczność selektora CVB jest porównywalna ze skutecznością Alfa selektora i kurtozy widomej, aż do współczynnika CNI równego 2.2 (2.2 przedstawia przypadek sygnału, w którym amplituda impulsów niecyklicznych jest ponad 2 razy większa niż amplituda impulsów cyklicznych). Gdy współczynnik CNI jest większy niż 2.2 (innymi słowy dla rosnącej amplitudy impulsów niecyklicznych w porównaniu do

cyklicznych), wówczas skuteczność selektora wykorzystującego kurtozę widomową znacząco maleje. Natomiast jeśli amplituda współczynnika CNI przekracza 13.9, to selektor CVB okazał się lepszy od Alfa selektora.

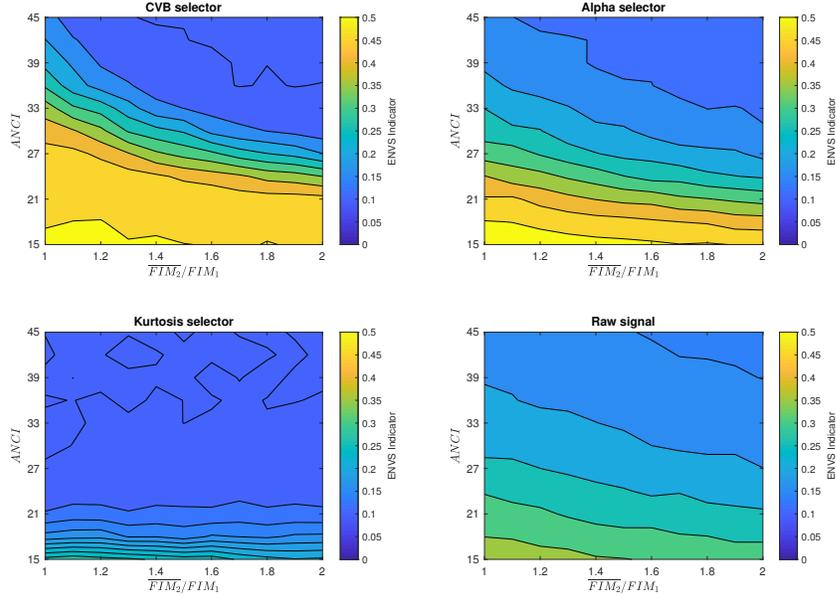
Na Rys. 10 została przedstawiona wartość ENVSI obliczona dla przefiltrowanych sygnałów oraz dla sygnału surowego w odniesieniu do stosunku częstotliwości impulsów niecyklicznych do cyklicznych ( $\overline{FIM}_2/FIM_1$ ) i zmiennej wartości amplitudy impulsów niecyklicznych ANCI. Selektor CVB jest bardziej odporny dla rosnącego stosunku  $\overline{FIM}_2/FIM_1$ , odpowiadającego przypadkom zwiększającej się liczby impulsów niecyklicznych w odniesieniu do liczby impulsów cyklicznych oraz dla zwiększającej się wartości amplitudy impulsów niecyklicznych, tj. ANCI. Wyniki otrzymane dla selektora wykorzystującego kurtozę widmową potwierdzają fakt, iż statystyka ta zdecydowanie nie jest dedykowana dla sygnałów impulsowych i jej zastosowanie pogarsza wyniki widma obwiedni w porównaniu do widma obwiedni surowego sygnału (bez filtracji).



Rysunek 9: Symulacje Monte Carlo wartości indykatora ENVSI dla różnych wartości współczynnika CNI

#### 4.1.5 Zmodyfikowany infogram

W dalszych badaniach zaproponowano modyfikacje infogramu - zaawansowanego narzędzia do identyfikacji lokalnych uszkodzeń [45]. Jak wspomniano, szczególna zaleta infogramu polega na uwzględnieniu obu charakterystyk lokalnego uszkodzenia tj. impulsowości i okresowości. Antoni w definicji infogramu [45] zaproponował wykorzystanie negentropii - przeciwieństwa entropii, jako miary impulsywności w dziedzinie czasu, wykorzystując obwiednie sygnału



Rysunek 10: Symulacje Monte Carlo wartości indykatora ENVSI dla różnych wartości amplitudy ( $ANCI$ ), jak również dla zmiennej wartości współczynnika  $\overline{FIM}_2/FIM_1$

(ang. Squared Envelope - SE) i w dziedzinie częstotliwości - w widmie obwiedni sygnału (ang. Squared Envelope Spectrum - SES). Estymator negentropii dla wektora  $x = x_1, \dots, x_N$  jest zdefiniowany następująco:

$$\hat{I}(x) = \frac{1}{N} \sum_{i=1}^N \left( \frac{x_i^2}{\frac{1}{N} \sum_{i=1}^N x_i^2} \ln \frac{x_i^2}{\frac{1}{N} \sum_{i=1}^N x_i^2} \right). \quad (7)$$

W infogramie do dekompozycji sygnału na serię podszygnałów wykorzystano strukturę drzewa 1/3-binarnego [126]. Następnie dla każdego podszygnału obliczana jest negentropia  $I(\cdot)$ , tworząc w ten sposób macierz  $I_{SE}$  zawierającą wartości negentropii dla kwadratu obwiedni (SE) przefiltrowanego sygnału analitycznego  $x_a(n, f, \Delta f) = x(n, f, \Delta f) + j\mathcal{H}\{x(n)\}$  dla badanego pasma częstotliwości  $[f - \Delta f; f + \Delta f]$  (podszygnał). Analogicznie powstaje macierz  $I_{SES}$  obliczana jako negentropia dla wartości bezwzględnej kwadratu widma obwiedni (SES) badanego podszygnału. Macierze  $I_{SE}$  oraz  $I_{SES}$  reprezentują zaburzenia od stanu równowagi w dziedzinie czasu (SE) i w dziedzinie częstotliwości (SES). Dokładne definicje parametrów  $SE$  i  $SES$  podano w równaniu (9) oraz równaniu (8):

$$SE(n) = |x_a(n, f, \Delta f)|^2, \quad n = 0, \dots, N-1, \quad (8)$$

$$SES(f_k) = \left| \sum_{n=0}^{N-1} SE(n) e^{-j2\pi f_k n} \right|^2, \quad k = 0, \dots, N/2, \quad (9)$$

gdzie  $x_a(n, f, \Delta f) = x(n, f, \Delta f) + j\mathcal{H}\{x(n)\}$  ( $\mathcal{H}$  jest transformatą Hilberta) oznacza analityczną wersję sygnału  $x(n, f, \Delta f)$ , próbkowanego przy indeksie czasowym  $n$  i wstępnie filtrowanego w określonym paśmie  $[f - \Delta f; f + \Delta f]$  i  $f_k = kF_s/N$ , gdzie  $F_s$  jest częstotliwością próbkowania,  $f$  odpowiada częstotliwości środkowej, a  $\Delta f$  jest szerokością pasma.

Wielkości  $I_{SE}$  oraz  $I_{SES}$  są addytywne, a ich średnia została zaproponowana przez Jerome Antoni [45] jako narzędzie do wykrywania lokalnych uszkodzeń (impulsów i cykli):

$$\Delta I(f, \Delta f) = \frac{I_{SE}(f, \Delta f) + I_{SES}(f, \Delta f)}{2}. \quad (10)$$

Jednak amplituda obwiedni sygnału i amplituda jego widma obwiedni mogą mieć różną skalę wartości, dlatego ostateczny wynik jest zawsze na korzyść składowej o większej skali. Jest to typowy problem dla narzędzi wykorzystujących średnią arytmetyczną, która jest wrażliwa na wartości odstające. Dlatego sposób w jaki obie charakterystyki są agregowane do ostatecznej informacji na temat informacyjnego pasma częstotliwości dotyczącego lokalnego uszkodzenia jest efektywny tylko w szczególnych przypadkach.

Przeprowadzone badania, ujęte w artykule [A6], wykazały w jakich przypadkach sygnału drganiowego infogram daje fałszywe wyniki, w szczególności dla sygnału z niegaussowskim szumem. Natomiast w artykule [A2] przedstawiono modyfikacje infogramu wraz ze szczegółowym omówieniem korzyści, jakie mogą nieść zaproponowane modyfikacje. Naturalnym rozszerzeniem klasycznego infogramu jest zastąpienie średniej arytmetycznej w równaniu (10) przez średnią ważoną, co zostało wspomniane w artykule [45], gdzie odpowiednimi wagami są  $\rho \in [0, 1]$  i  $1 - \rho$ . Ważony infogram  $\Delta I_\rho(f, \Delta f)$  jest zdefiniowany następująco:

$$\Delta I_\rho(f, \Delta f) = \rho I_{SE} + (1 - \rho) I_{SES}. \quad (11)$$

Dla  $\rho = \frac{1}{2}$  ważony infogram redukuje się do klasycznego infogramu:  $\Delta I_{1/2}$ . Zastosowanie infogramu ważonego jest uzasadnione, zwłaszcza gdy skale infogramów  $SE$  i  $SES$  znacznie

się różnią. Oczekiwanym wynikiem jest uwzględnienie wag w równaniu (11), które powodują, że informacje z dziedziny czasu i częstotliwości są równie ważne. Celem jest wskazanie impulsowości i zachowań cyklicznych z takim samym udziałem (nawet jeśli  $I_{SE}$  i  $I_{SES}$  mają różne skale). Znalezienie uniwersalnych wag jest jednak trudnym zagadnieniem, co zostało poruszone w [45].

W pracy [A2] zaproponowano rozszerzenie klasycznego infogramu, tj. znormalizowany infogram (norm-infogram). Jest on skonstruowany w następujący sposób. Po obliczeniu macierzy  $I_{SE}$  i  $I_{SES}$ , każda z nich jest normalizowana przy użyciu ich maksymalnych wartości,  $m_{SE}$  i  $m_{SES}$ . Następnie norm-infogram  $\Delta I_{norm}(f, \Delta f)$  jest średnią arytmetyczną znormalizowanych macierzy  $I_{SE}$  i  $I_{SES}$ . Norm-infogram jest związany z infogramem ważonym, w pracy [A2] wykazano, że zachodzi następująca zależność:

$$\Delta I_{norm}(f, \Delta f) = \frac{m_{SE} + m_{SES}}{2m_{SE}m_{SES}} \Delta I_{norm}(f, \Delta f), \quad (12)$$

gdzie  $\rho = m_{SES}/(m_{SE} + m_{SES})$ .

Jako inne możliwe rozszerzenie klasycznego infogramu zaproponowano infogram logarytmiczny (log-infogram). Średnia logarytmiczna dwóch składowych  $y_1$  i  $y_2$  zdefiniowana jest następująco:

$$M_{ln}(y_1, y_2) = \lim_{(a,b) \rightarrow (y_1, y_2)} \frac{a - b}{\ln a - \ln b} = \begin{cases} y_1, & \text{for } y_1 = y_2 \\ \frac{y_1 - y_2}{\ln(y_1) - \ln(y_2)}, & \text{otherwise.} \end{cases} \quad (13)$$

Średnia logarytmiczna jest lepszą miarą tendencji centralnej niż klasyczna średnia arytmetyczna - daje bardziej wiarygodne wyniki w przypadku występowania wartości odstających.

Kolejną propozycją rozszerzenia klasycznego infogramu jest infogram geometryczny (g-infogram). Średnia geometryczna dwóch dodatnich składowych  $y_1$  i  $y_2$  jest zdefiniowana jako:

$$M_{geo}(y_1, y_2) = \sqrt{y_1 y_2}. \quad (14)$$

Średnia geometryczna jest często stosowana, gdy porównywane są elementy o różnych zakresach liczbowych. Średnia geometryczna jest bardziej odpowiednia niż średnia

arytmetyczna do opisywania wzrostu proporcjonalnego, zarówno wzrostu wykładniczego (stałego wzrostu proporcjonalnego), jak i wzrostu zmiennego.

Zdefiniowane nowe infogramy tj. infogram logarytmiczny i znormalizowany infogram logarytmiczny (log-infogram)  $\Delta I_{ln-norm}(f, \Delta f)$ , infogram geometryczny i znormalizowany infogram geometryczny (g-norm-infogram)  $\Delta I_{g-norm}(f, \Delta f)$  oraz infogram znormalizowany (norm-infogram) wykazały większą skuteczność w szczególności w przypadku danych z niegaussowskim szumem. Tab. 1 zawiera podsumowanie notacji proponowanych rozszerzeń klasycznego infogramu.

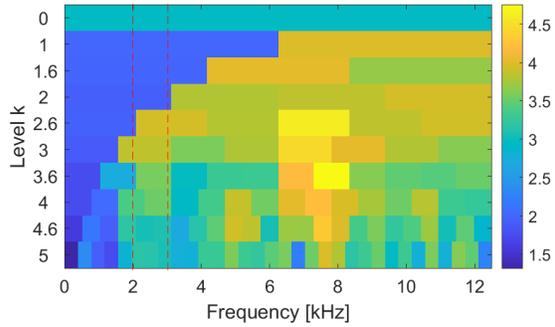
Porównanie wyników  $\Delta I_{1/2}(f, \Delta f)$  z  $\Delta I_{norm}(f, \Delta f)$ ,  $\Delta I_{ln}(f, \Delta f)$ ,  $\Delta I_{ln-norm}(f, \Delta f)$ ,  $\Delta I_g$  oraz z  $\Delta I_{g-norm}$  zostało przedstawione na Rys. 11. Otrzymane wyniki wykazały lepszą wydajność proponowanych nowych infogramów, zastosowanych dla sygnału s4. Informacje umieszczone w tytule widocznym nad każdym z infogramów na Rys. 11 wskazują jaką wartość maksymalną przyjął dany infogram, a dokładnie statystyka testowa jaką jest negentropia (max.value), na jakim poziomie dekompozycji maksymalna wartość została osiągnięta (level), na jakiej szerokości pasma częstotliwości (bw) i dla jakiej częstotliwości środkowej ( $f_c$ ). Klasyczny infogram błędnie wskazał pasmo częstotliwości lokalnego uszkodzenia, sugerując jego występowanie w okolicy częstotliwości nośnej 6-8 kHz, gdzie w rzeczywistości występują impulsy niecykliczne.

Klasyczny infogram, jak i jego zaproponowane rozszerzenia spełniają zasadę nieoznaczoności. Mianowicie, sygnał nie może być arbitralnie impulsowy w obu domenach (czas i częstotliwość) jednocześnie. Górna granica jest osiągnięta przez grzebień Diraca (ang. Dirac comb) tj. szereg impulsów Diraca rozmieszczonych w równych odstępach czasu, co jest idealistyczną reprezentacją sygnału uszkodzenia. W badaniach wykazano również, że zaproponowane nowe infogramy (podobnie jak klasyczny infogram) zwracają wynik, ograniczony z góry przez  $0.5 \ln N$ , który rośnie wraz z długością sygnału (dowód jest przedstawiony w załączniku do artykułu [A2]).

Tabela 1: Proponowane rozszerzenia klasycznego infogramu

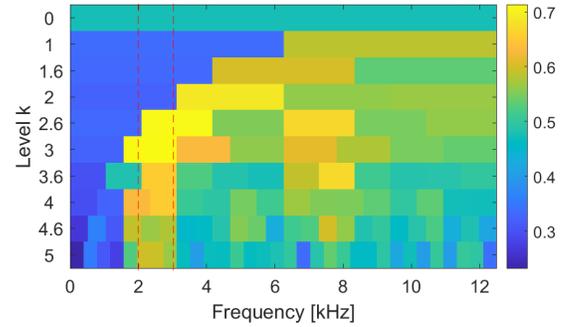
	Rodzaj średniej		
	średnia arytmetyczna	logarytmiczna (log/ln)	geometryczna (g)
$I_{SE}, I_{SES}$	klasyczny infogram $\Delta I_{1/2}(f, \Delta f)$	log-infogram $\Delta I_{ln}(f, \Delta f)$	g-infogram $\Delta I_{geo}(f, \Delta f)$
unormowane $I_{SE}$ oraz $I_{SES}$	norm-infogram $\Delta I_{norm}(f, \Delta f)$	ln-norm-infogram $\Delta I_{ln-norm}(f, \Delta f)$	g-norm-infogram $\Delta I_{geo-norm}(f, \Delta f)$

$\Delta I_{1/2}$ : max.value=4.8, level 3.6, bw= 1041.7Hz,  $f_c$  =7812.5Hz



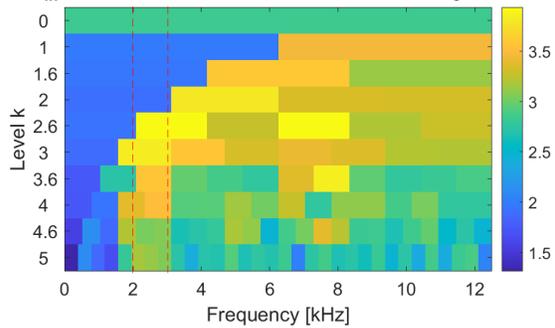
(a)

$\Delta I_{norm}$ : max.value=0.7, level 3, bw= 1562.5Hz,  $f_c$  =2343.8Hz



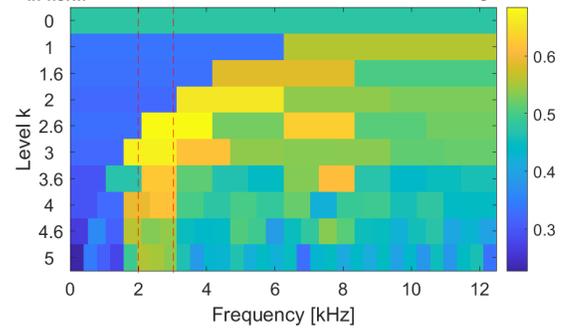
(b)

$\Delta I_{ln}$ : max.value=3.9, level 2.6, bw= 2083.3Hz,  $f_c$  =3125Hz



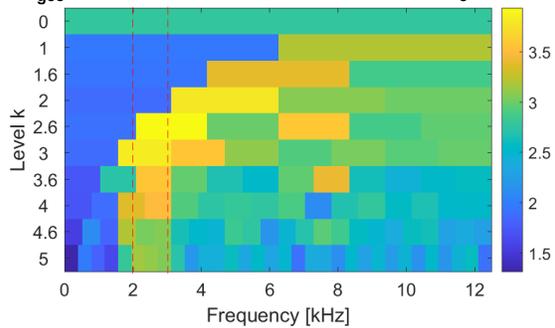
(c)

$\Delta I_{ln-norm}$ : max.value=0.7, level 2.6, bw= 2083.3Hz,  $f_c$  =3125Hz



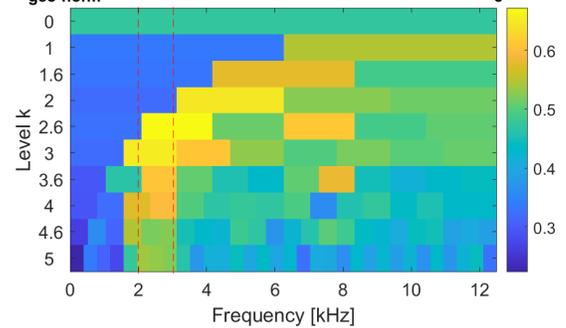
(d)

$\Delta I_{geo}$ : max.value=3.9, level 2.6, bw= 2083.3Hz,  $f_c$  =3125Hz



(e)

$\Delta I_{geo-norm}$ : max.value=0.7, level 2.6, bw= 2083.3Hz,  $f_c$  =3125Hz



(f)

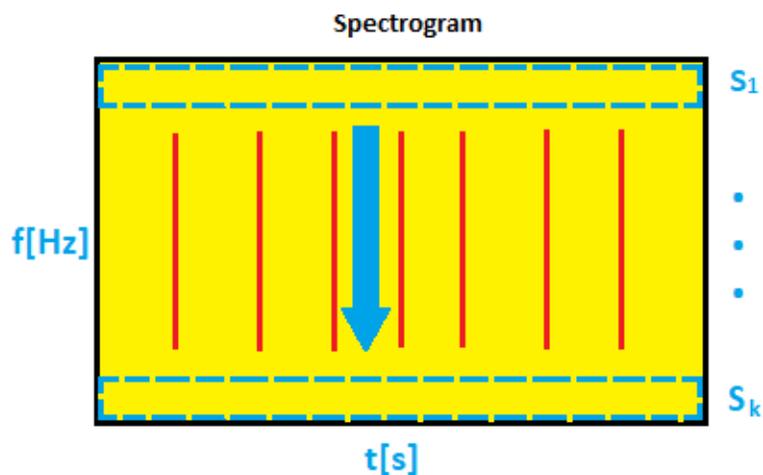
Rysunek 11: Podsumowanie wyników selekcji IFB dla sygnału symulowanego s4, z wykorzystaniem klasycznego infogramu (a) i jego rozszerzonych wersji: log-infogram (b), g-infogram (c), norm-infogram (d), ln-norm-infogram (e), g-norm-infogram (f) [A2]

#### 4.1.6 Alternatywne miary zależności

W kolejnych badaniach szczególną uwagę poświęcono cykliczności - charakterystyce uszkodzenia, która niejednokrotnie jest wystarczająca do identyfikacji lokalnego uszkodzenia w maszynach [29, 131].

W artykule [A8] przedstawiono wykorzystanie miar zależności tj. korelacja Pearsona, Spearmana oraz korelacja Kendalla do stworzenia map korelacji - narzędzia informującego o występujących cyklicznych zależnościach w sygnale, bazując na jego czasowo-częstotliwościowej reprezentacji. Idea mapy zależności polega na pomiarze "podobieństwa" podsygnałów spektrogramu w parach, dla różnych pasm częstotliwości. Zaproponowane miary tj. korelacja Spearmana oraz korelacja Kendalla nie były dotychczas wykorzystywane w diagnostyce maszyn.

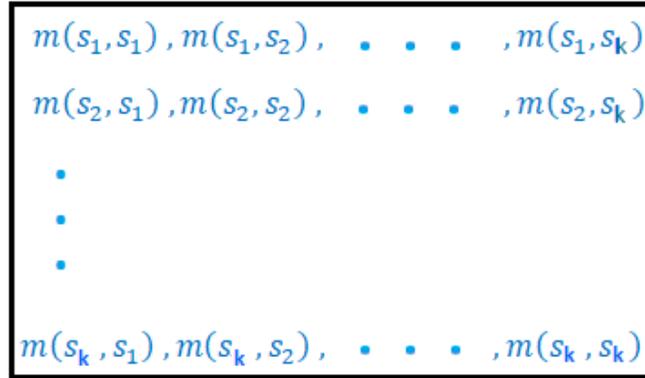
W algorytmie liczenia map korelacji na podstawie spektrogramu sygnału  $S(t, f)$  (zdefiniowanego w równaniu (2), w rozdziale 4.1.1), którego uproszczona wersja została przedstawiona na Rys. 12, wszystkie pasma częstotliwości, zwane podsygnałami  $s_i$ , dla  $i = 1, 2, \dots, k$  oraz  $t = t_1, \dots, t_l$  są testowane pod kątem podobieństwa. Każdy z



Rysunek 12: Uproszczona reprezentacja spektrogramu  $S(t, f)$  [A8]

podsygnałów jest porównywany ze sobą przy użyciu miar zależności. W efekcie powstaje symetryczna mapa zależności, przedstawiona na Rys. 13. W badaniach założono, że jeżeli podsygnał  $s_i$  w paśmie częstotliwości  $f_i$  wykazuje podobne zachowanie jak podsygnał  $s_j$  w paśmie częstotliwości  $f_j$ , dla  $i \neq j$ , oznacza to, że powinny być one traktowane jako to samo źródło informacji. Można oczekiwać, że najsilniejsze podobieństwo wystąpi dla

Dependency map



Rysunek 13: Struktura mapy zależności dla podsygnałów  $s_i$  ze spektrogramu i dla zadanej miary zależności  $m(\cdot, \cdot)$  [A8]

podsygnałów związanych z lokalnymi uszkodzeniami, które charakteryzują się takimi samymi właściwościami cyklicznymi (cykliczna impulsowość o podobnej energii). W przypadku losowej zawartości sygnału należy się spodziewać najmniejszej korelacji podsygnałów  $s_i$  z  $s_j$ , dla  $i \neq j$ , bliskiej zera (tj.  $m(s_i, s_j) \rightarrow 0$ ).

Powszechnie wiadomo, że na estymację korelacji mogą mieć wpływ wartości odstające występujące w sygnale np. niecykliczne impulsy związane z technologią pracy maszyn w kopalni. W związku z tym, zaproponowano wykorzystanie trzech miar korelacji, o różnej wrażliwości na wartości odstające, w celu sprawdzenia ich skuteczności. Poniżej przedstawione zostały definicje korelacji Pearsona, Spearmana i Kendalla.

### Korelacja Pearsona

Niech  $(x_1, y_1), \dots, (x_N, y_N)$  będzie dwuwymiarową próbką wektora losowego  $(X, Y)$ , gdzie  $N$  jest długością próbki. Korelację Pearsona wektora  $(X, Y)$  definiuje się następująco [132]:

$$\rho_{XY} = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}, \tag{15}$$

gdzie  $\text{cov}(\cdot, \cdot)$  jest funkcją kowariancji,  $\sigma_X$  jest odchyleniem standardowym  $X$  i  $\sigma_Y$  is jest odchyleniem standardowym  $Y$ . Korelacja Pearsona bada liniową zależność w sygnale. Wartości współczynnika korelacji Pearsona mieszczą się w przedziale  $[-1, 1]$ . Wartości bliskie

1 i  $-1$  wskazują na silną zależność (odpowiednio dodatnią i ujemną). Wartość 0 oznacza brak zależności.

Empiryczny odpowiednik  $\rho_{XY}$  dla  $(x_1, y_1), \dots, (x_N, y_N)$ , oznaczany jako  $\rho_{xy}$  jest zdefiniowany następująco [132]:

$$\rho_{xy} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}}, \quad (16)$$

gdzie  $\bar{x}$ ,  $\bar{y}$  są średnimi arytmetycznymi wektorów  $x$  i  $y$ .

Kiedy współczynnik korelacji Pearsona jest zastosowany do podsygnałów spektrogramu, wówczas pary  $(x_i, y_j)$  w równaniu (16) są zastąpione podsygnałami  $s_i, s_j$ . Równanie (16) przyjmuje wówczas następującą postać:

$$\rho = \frac{\sum_{i=1}^l (s_{i,a} - \bar{s}_i)(s_{j,a} - \bar{s}_j)}{\sqrt{\sum_{i=1}^l (s_{i,a} - \bar{s}_i)^2} \sqrt{\sum_{i=1}^l (s_{i,b} - \bar{s}_i)^2}}, \quad i, j = 1, 2, \dots, k, \quad (17)$$

gdzie  $s_{i,a}$  jest komponentem wektora  $s_i$ , a  $s_{j,a}$  jest komponentem wektora  $s_j$ , gdzie  $a, b = 1, 2, \dots, l$  ( $s_i$  reprezentuje przepływ energii w czasie  $t = t_1, \dots, t_l$  dla pewnego wąskiego pasma częstotliwości, Rys. 12).  $\bar{s}_i$  oraz  $\bar{s}_j$  to średnie empiryczne wektorów  $s_i$  i  $s_j$ .

## Korelacja Spearmana

Rozważmy losową dwuwymiarową próbę  $(x_1, y_1), \dots, (x_N, y_N)$  odpowiadającą wektorowi losowemu  $(X, Y)$ . Każda para  $(X, Y)$  i jej empiryczny odpowiednik  $(x_i, y_i)$  odpowiada parze  $(Q, W)$ , oraz  $(q_i, w_i)$ , gdzie  $q_i$  jest rangą obserwacji  $x_i$  w próbie  $x_1, \dots, x_N$ , a  $w_i$  jest rangą obserwacji  $y_i$  w próbie  $y_1, \dots, y_N$ . Współczynnik korelacji rang Spearmana dla wektora  $(X, Y)$  definiuje się następująco [133]:

$$r_{XY} = \frac{\text{cov}(Q, W)}{\sigma_Q \sigma_W}, \quad (18)$$

gdzie  $\text{cov}(\cdot, \cdot)$  jest funkcją kowariancji,  $\sigma_Q$  i  $\sigma_W$  są odchyleniami standardowymi zmiennych rangowych. Korelacja Spearmana przyjmuje wartości z przedziału  $[-1, 1]$  i bada zależność monotoniczną, w przeciwieństwie do korelacji Pearsona, która analizuje zależność liniową.

Empiryczny odpowiednik współczynnika korelacji Spearmana zdefiniowany jest następująco:

$$r_{xy} = \frac{\frac{1}{N-1} \sum_{i=1}^N (q_i - \bar{q})(w_i - \bar{w})}{\left[ \frac{1}{N-1} \sum_{i=1}^N (q_i - \bar{q})^2 \frac{1}{N-1} \sum_{i=1}^N (w_i - \bar{w})^2 \right]^{1/2}}, \quad (19)$$

gdzie  $\bar{q}$  i  $\bar{w}$  są średnimi prób w odpowiednich wektorach rangowych.

Kiedy współczynnik korelacji Spearmana jest zastosowany do podsygnałów ze spektrogramu, wówczas  $q_i$  w równaniu (19) jest rangą obserwacji  $s_{i,a}$  w wektorze  $s_i$  i  $w_i$  w równaniu (19) jest rangą obserwacji  $s_{j,b}$  w wektorze  $s_j$ , gdzie  $a, b = 1, 2, \dots, l$ .

### Korelacja Kendalla

Niech  $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$  będą próbami losowymi z rozkładu pary zmiennych losowych  $(X, Y)$ . Wtedy wzór na współczynnik Kendalla  $\tau$  można zapisać następująco [134]:

$$\tau = \frac{2}{N(N-1)} \sum_{1 \leq i < j \leq n} J((x_i, y_i), (x_j, y_j)), \quad (20)$$

gdzie  $J((x_i, y_i), (x_j, y_j)) = \text{sgn}(x_i - x_j) \text{sgn}(y_i - y_j)$  i  $J((x_i, y_i), (x_j, y_j)) = 1$ , jeśli para  $(x_i, y_i)$  jest zgodna z parą  $(x_j, y_j)$ , tzn. jeśli  $(x_i - x_j)(y_i - y_j) > 0$ ;  $J((x_i, y_i), (x_j, y_j)) = -1$ , jeśli para  $(x_i, y_i)$  jest niezgodna z parą  $(x_j, y_j)$ , tzn. jeśli  $(x_i - x_j)(y_i - y_j) < 0$ .

Jeśli współczynnik korelacji Kendalla jest zastosowany do podsygnałów ze spektrogramu, to pary  $(x_i, y_j)$  z równania (20) są zastąpione elementami podsygnałów  $s_i, s_j$ . Wówczas równanie (20) przyjmuje następującą postać:

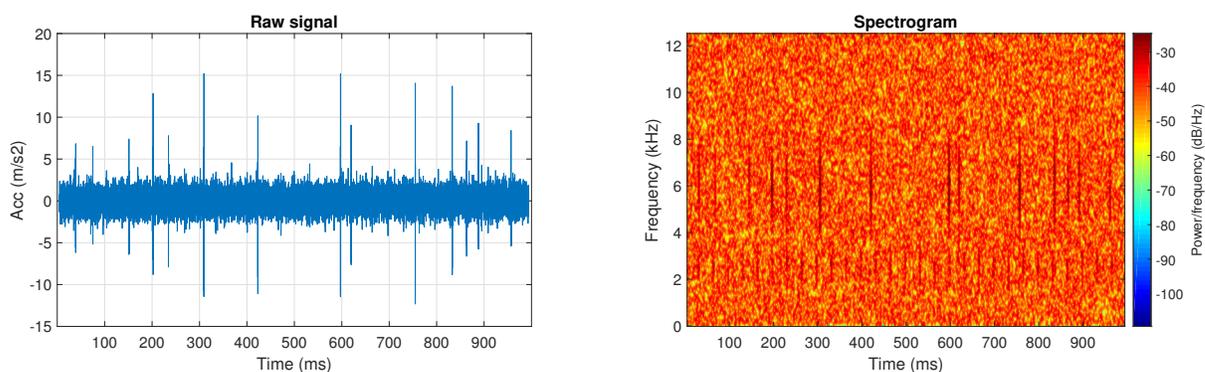
$$\tau = \frac{2}{k(k-1)} \sum_{1 \leq i < j \leq l} J((s_{i,a}, s_{j,a}), (s_{i,b}, s_{j,b})), \quad (21)$$

gdzie  $s_{i,a}$  są komponentami wektora  $s_i$  i  $s_{j,b}$  są komponentami wektora  $s_j$ , gdzie  $a, b = 1, 2, \dots, l$  (Rys. 12).

Korelacje Kendalla i Spearmana są mniej wrażliwe na wartości odstające niż korelacja Pearsona, co zostało zauważone w literaturze [135–139] oraz poparte otrzymanymi wynikami dotyczącymi analizy sygnałów symulowanych, jak również analizą rzeczywistego sygnału drganiowego pochodzącego z kruszarki rudy miedzi [A8].

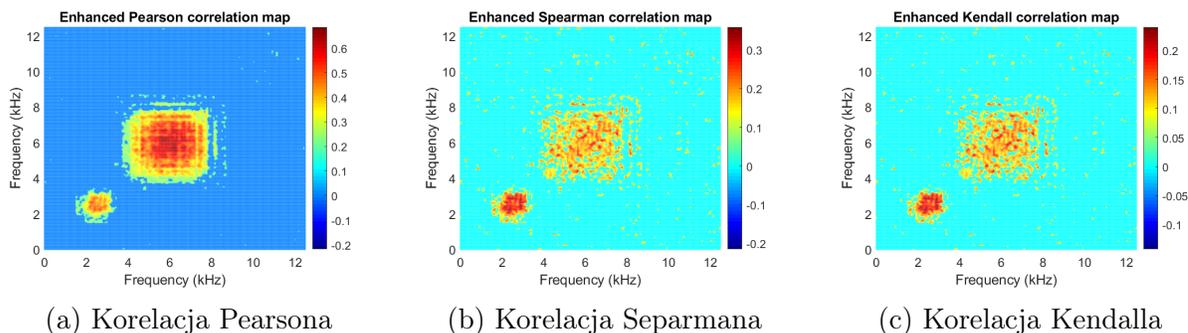
Sygnał symulowany oraz jego reprezentacja czasowo-częstotliwościowa w formie spektrogramu została zaprezentowana na Rys. 14. Sposób symulacji sygnału odpowiada

opisowi sygnału s4, przedstawionemu w rozdziale 4.1.2. Częstotliwość modulująca amplitudę uszkodzenia wynosi 30 Hz, a jego częstotliwość nośna to 2.5 kHz. Częstotliwość niecyklicznych impulsów wynosi 6 kHz.



Rysunek 14: Sygnał symulowany odpowiadający sygnałowi drganiowemu z łożyska kruszarki rudy miedzi i jego spektrogram [A8]

Na Rys. 15 przedstawiono mapy zależności zastosowane dla danych symulowanych.



(a) Korelacja Pearsona

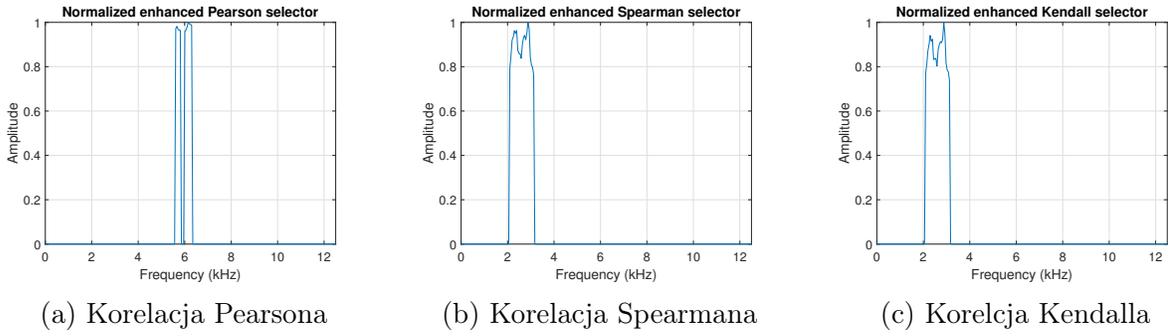
(b) Korelacja Separmana

(c) Korelacja Kendalla

Rysunek 15: Mapy zależności dla symulowanych danych z kruszarki rudy miedzi wykorzystujące różne miary zależności [A8]

Jak można zauważyć, miara Spearmana i Kendalla wykazały większą odporność na występujące niecykliczne impulsy w paśmie częstotliwości 6 kHz niż miara Pearsona. W pracy [A8] zaproponowano również agregację informacji zawartych w mapie zależności do postaci jednowymiarowego wektora - selektora IFB. Przykładowy wynik selektorów stworzonych na podstawie map zależności (Rys. 15) został pokazany na Rys.16. Wartości selektorów, po normalizacji, mogą stanowić charakterystykę filtra, co szczegółowo opisano w artykule [A8].

W kolejnych badaniach [A7] zaproponowano nowe zastosowanie miary Quadrant, dotychczas niestosowanej w diagnostyce maszyn. Co więcej, znane w literaturze korelacje



Rysunek 16: Znormalizowane ulepszone selektory IFB dla danych symulowanych powstałe z map zależności wykorzystujących różne miary zależności [A8]

Pearsona, Spearmana, Kendalla oraz mniej popularna korelacja Quadrant są stosowane jako miary współzależności dwóch zmiennych, natomiast w przeprowadzonych badaniach wykazano ich użyteczność w badaniu autokorelacji w sygnale. Przeformułowanie wyżej wymienionych miar w miary autopodobieństwa zostało szczegółowo opisane w artykule [A7]. W badaniach przedstawiono również ogólną procedurę obliczania mapy autopodobieństwa.

Każdy podsygnał  $s_i$ , dla  $i = 1, 2, \dots, k$  mapy czasowo-częstotliwościowej  $S(t, f)$  zawiera przepływ energii sygnału  $x = x_1, \dots, x_N$  dla zadanej częstotliwości  $f_i$ , w przedziale czasowym  $t$  i jest on badany w kierunku autopodobieństwa w czasie. W konsekwencji tworzona jest mapa autopodobieństwa  $map(i, h)$  dla opóźnienia czasowego  $h = 1, \dots, l$ , gdzie  $automiara(\cdot, \cdot)$  jest zastępowana daną miarą zależności. Algorytm tworzenia mapy autopodobieństwa przedstawia Algorytm 1.

---

**Algorithm 1:** Obliczanie mapy autopodobieństwa [A7]

---

**Data:** Sygnał wejściowy  $X_t$  dla  $t = 1, 2, \dots, N$

**Oblicz spektrogram:**  $S(t, f) = |STFT_x(t, f)|^2$ ,

**Oblicz automiarę:**

$k$  - liczba wierszy w macierzy  $S$

$l$  - liczba kolumn w macierzy  $S$

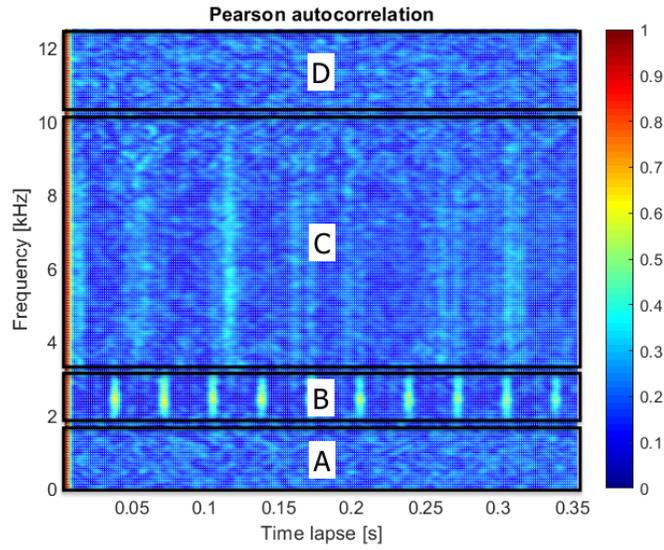
$automiara(s_i, h)$  - funkcja do obliczania wartości miary dla podsygnałów  $s_i$  oraz przesunięcia czasowego  $h$

**for**  $i \leftarrow 1$  **to**  $k$  **do**

**for**  $h \leftarrow 1$  **to**  $l$  **do**  
|  $map(i, h) = automiara(s_i(1:l), h)$

---

Przykładowy wynik mapy autopodobieństwa wykorzystującej popularną autokorelację Pearsona został przedstawiony na Rys. 17.



Rysunek 17: Mapa autopodobieństwa Pearsona z wyróżnionymi czterema obszarami o charakterystycznym zachowaniu [A7]

Uniwersalny algorytm obliczenia mapy autopodobieństwa pozwala na zastosowanie różnych - nieuwzględnionych w dotychczas przeprowadzonych badaniach - miar zależności i tworzyć mapy autopodobieństwa na podstawie miary dostosowanej do potrzeb rozważanego problemu. W przeprowadzonych badaniach przedstawiono szczegółową analizę działania map autopodobieństwa dla wyżej wymienionych miar zależności oraz zaproponowano kryteria ich porównania. Przedstawione mapy autopodobieństwa mogą stanowić etap pośredni dla wielu znanych metod wykrywania uszkodzeń lokalnych.

Poniżej przedstawiono definicje korelacji Spearmana, Kendalla i miary Quadrant przeformułowane na miary autokorelacji.

### Autokorelacja Spearmana

Autokorelacja Spearmana dla szeregu czasowego  $\{X_t\}$  i opóźnienia czasowego  $h$  jest dana wzorem:

$$\rho_x(h) = \frac{\text{cov}(R_t, R_{t+h})}{\sigma_R^2},$$

gdzie  $R_t$  jest wektorem rang odpowiadającym szeregowi czasowemu  $\{X_t\}$ , a  $\sigma_R$  jest odchyleniem standardowym wektora  $R_t$ .

Estymator autokorelacji Spearmana jest dany przez [A7]:

$$\hat{\rho}_x(h) = \frac{\sum_{t=1}^{N-h} (r_t - \bar{r})(r_{t+h} - \bar{r})}{\sum_{t=1}^N (r_t - \bar{r})^2}, \quad (22)$$

gdzie  $r_1, \dots, r_N$  jest rangą obserwacji z próby  $x_1, \dots, x_N$ , a  $\bar{r}$  jest średnią arytmetyczną wektora rang. Autokorelacja Spearmana przyjmuje wartości z przedziału  $[-1, 1]$  i bada monotoniczną zależność wektora danych w zależności od zmieniającego się opóźnienia czasowego  $h$ .

### Autokorelacja Kendalla

Autokorelacja Kendalla wykorzystuje pary obserwacji i określa siłę związku na podstawie wzoru zgodności i niezgodności między tymi parami. Obliczanie korelacji Kendalla wymaga, aby proces mógł być uporządkowany (zmienne muszą być mierzone co najmniej na skali porządkowej).

Estymator autokorelacji Kendalla ma następującą postać [A7]:

$$\hat{\tau}_x(h) = \frac{2}{N(N-1)} \sum_{t>j} \text{sgn}((x_t - x_j)(x_{t+h} - x_{j+h})), \quad (23)$$

gdzie  $x_1, \dots, x_N$  są obserwacjami odpowiadającymi szeregowi czasowemu  $\{X_t\}$ .

### Autokorelacja Quadrant

Definicję autokorelacji Quadrant dla szeregu czasowego  $\{X_t\}$  i opóźnienia czasowego  $h$  można zapisać jako [140]:

$$q_x(h) = \mathbb{E}[\text{sgn}(X_t - \mu_X)(\text{sgn}(X_{t+h} - \mu_X))].$$

Estymatorem autokorelacji Quadrant jest [A7]:

$$\hat{q}_x(h) = \frac{1}{N-h} \sum_{t=1}^N \text{sgn}((x_t - \text{med}(x))(x_{t+h} - \text{med}(x))) \quad (24)$$

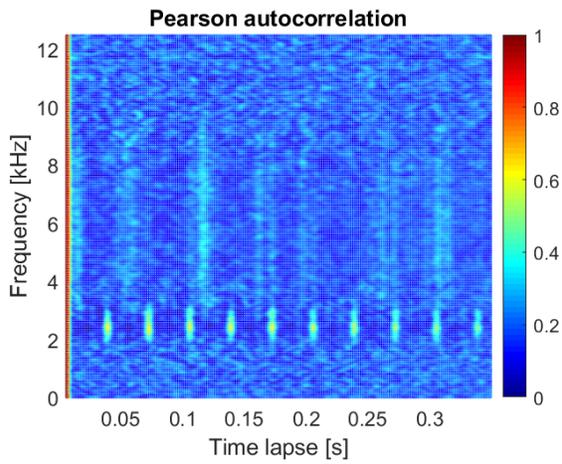
gdzie  $\text{med}(x)$  jest medianą próby  $x_1, \dots, x_N$ . Korelacja Quadrant jest równa 1 dla silnej korelacji dodatniej,  $-1$  dla silnej korelacji ujemnej i 0 dla braku korelacji. To samo zachodzi dla korelacji Spearmana i Kendalla. Proponowane miary korelacji mierzą zależność między

rangami. W konsekwencji nie mają na nie wpływu żadne wzrosty między obserwacjami odpowiadającymi  $x_t$  a  $x_{t+h}$ .

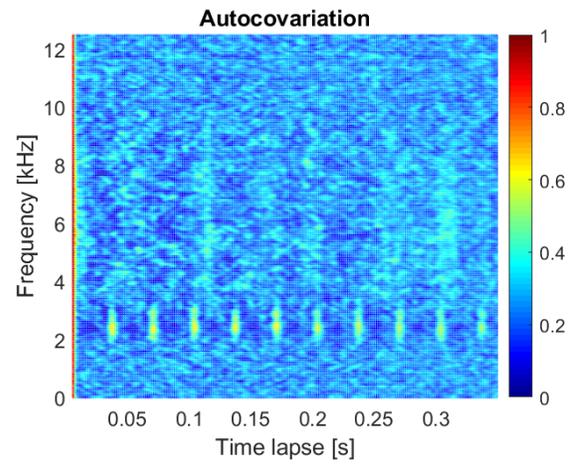
Działania map korelacji wykorzystujących automiary Spearmana, Kendalla oraz Quadrant zostało zaprezentowane na Rys. 18. Definicja map autopodobieństwa wykorzystujących inne, znane w diagnostyce maszyn miary zależności została przedstawiona w pracy [A7] (mapa autokorelacji Pearsona, mapa autokowariancji, mapa autokodyferencji). Wspólną cechą wszystkich map autopodobieństwa jest właściwe reagowanie na impulsy cykliczne - na mapie autopodobieństwa można zaobserwować wyższe wartości autokorelacji (jasnoniebieskiej oraz zielone, cykliczne pasma), powtarzające się w paśmie częstotliwości 2.5 kHz. Natomiast główną różnicą w działaniu map jest ich reagowanie na impulsy niecykliczne. Mapa autokorelacji Pearsona przyjmuje wysokie wartości w zakresie częstotliwości 3 kHz – 10 kHz (jasnoniebieskie, szerokopasmowe, powtarzające się pasma), podobnie jak mapa autokowariancji (Rys. 18b). Jest to konsekwencją wrażliwości tych miar autokorelacji na impulsowy szum - wysokie wartości w danych zniekształcają wyniki. Na mapie autokodyferencji (Rys. 18c) można zauważyć zwiększone wartości w zakresie częstotliwości 3 kHz – 10 kHz, ale tylko dla niewielkiego odcinka czasu (0 – 0,06 s). Na pozostałych mapach autokorelacji, tj. na mapach Spearmana (Rys. 18d), Kendalla (Rys. 18e) i Quadrant (Rys. 18f), impulsy niecykliczne o dużej amplitudzie nie są widoczne, a wartości w zakresie 3 – 10 kHz są podobne do wartości dla szumu gaussowskiego występującego w zakresie 0 – 2 kHz i 10 – 12 kHz, co jest porządaną własnością.

W pracy [A7] szczegółowo omówiono działanie map bazujących na zdefiniowanych automiarach w zależności od zmieniających się parametrów sygnału, takich jak liczba i amplituda niecyklicznych impulsów występujących w sygnale. W badaniach wykazano, iż zaproponowane rozwiązania wykorzystujące alternatywne miary zależności są szczególnie wartościowe w przypadku analizy sygnałów z szumem niegaussowskim.

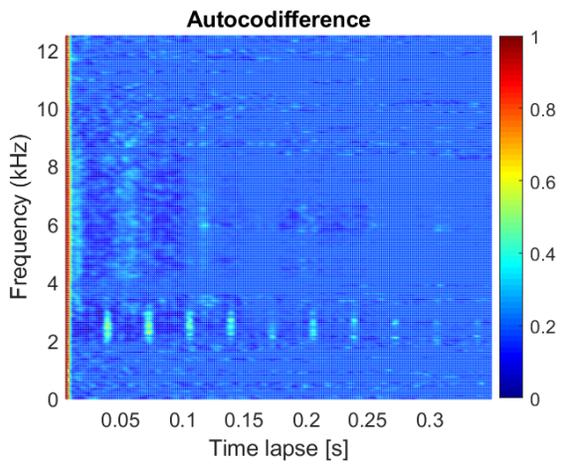
W pracy [A4] przedstawiono również problem spektralnego nakładania się informacyjnych i nieinformacyjnych składowych impulsowych (zbliżona wartość częstotliwości nośnej impulsów cyklicznych, pochodzących z uszkodzenia oraz impulsów niecyklicznych, związanych z technologią pracy maszyny). Występujące impulsy (pobudzenia) mogą nakładać się na siebie spektralnie w sposób całkowity, częściowy lub w niektórych przypadkach mogą zajmować różne pasma częstotliwości, co zostało zaprezentowane na Rys. 19. Przeprowadzona analiza wykazała jak problem ten wpływa na skuteczność wybranych popularnych procedur diagnostycznych tj. selektor CVB, Alfa selektor, selektor Spearmana. Problem ten nie był



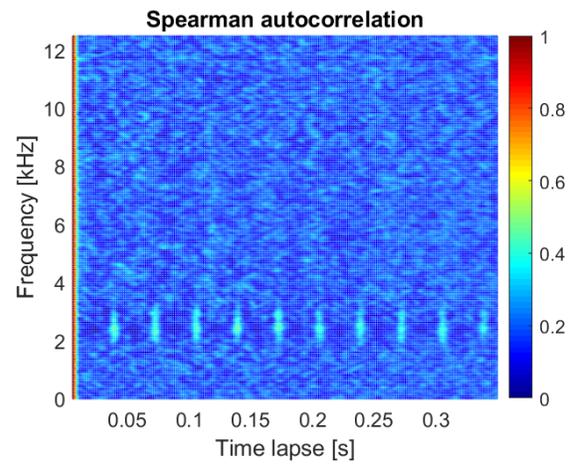
(a) Autokorelacji Pearsona



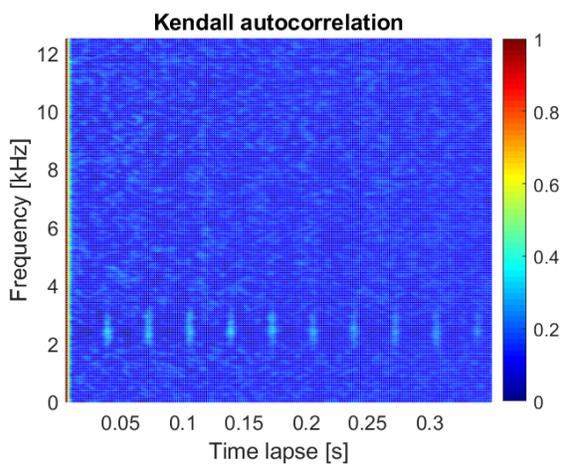
(b) Autokowariancja



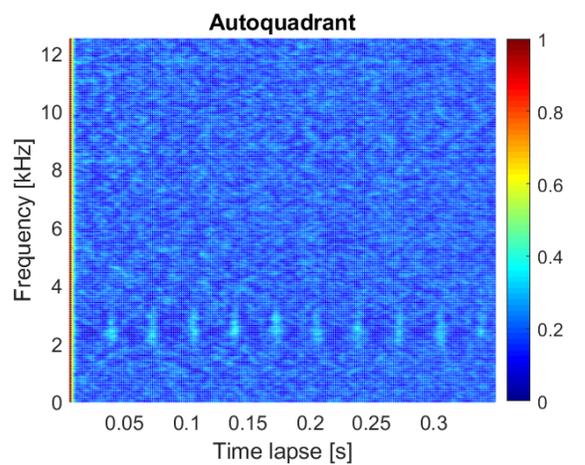
(c) Autokodyferencja



(d) Autokorelacja Spearmana

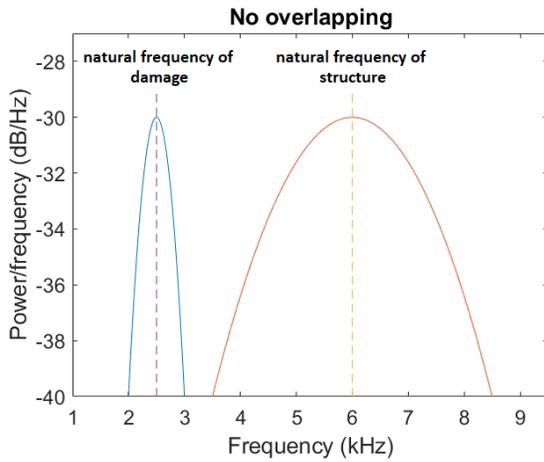


(e) Autokorelacja Kendalla

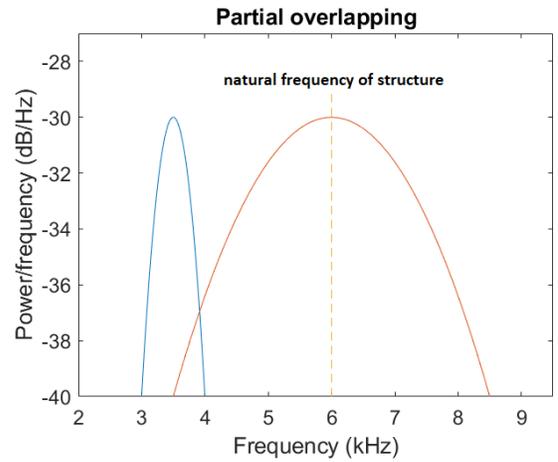


(f) Autokorelacja Quadrant

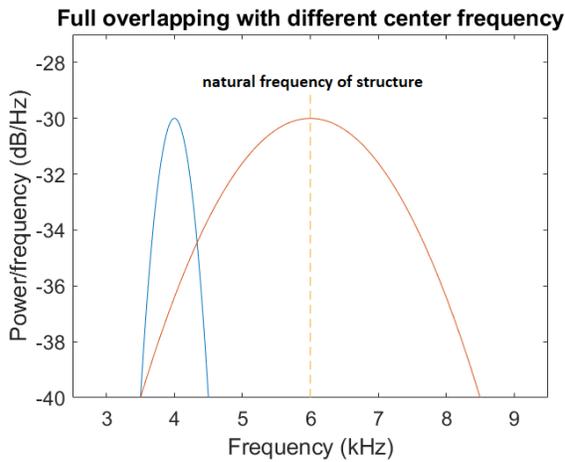
Rysunek 18: Mapy autopodobieństwa dla sygnału s4 dla różnych miar zależności [A7]



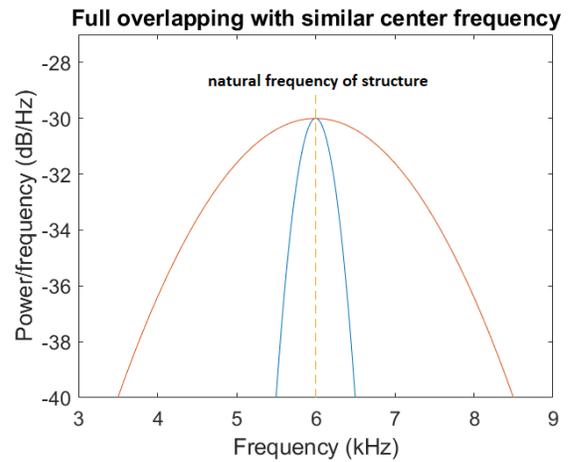
(a)



(b)



(c)



(d)

Rysunek 19: Różne przypadki częstotliwości nośnej lokalnego uszkodzenia: bez nakładających się pasm częstotliwości nośnej impulsów cyklicznych i niecyklicznych (a), z częściowym nakładaniem się (b) i z pełnym nakładaniem się (c)-(d) [A4]

dotychczas rozważany w literaturze. Zaproponowano eksperyment numeryczny dla czterech różnych przypadków (różnych poziomów) nakładania się widm, a jako miarę skuteczności wybranych metod diagnostycznych zastosowano indykator ENVSI (szczegółowo opisany w artykule [A8]). Jak wspomiano, selektor o najwyższej wartości indykatora ENVSI jest najbardziej skuteczny.

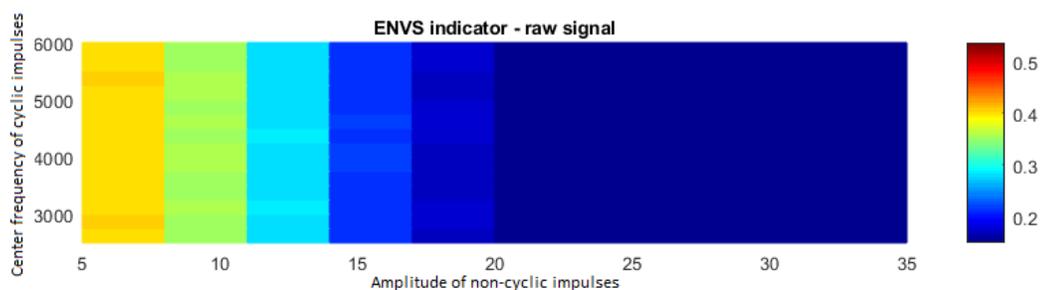
Plan eksperymentu obejmuje symulacje i analizę sygnałów o amplitudach impulsów niecyklicznych ze zbioru [5 : 3 : 35] i częstotliwościach środkowych impulsów okresowych należących do zbioru [2500 : 250 : 6000] Hz. Częstotliwość środkowa impulsów niecyklicznych wynosi  $f_c = 6000$  Hz, a amplituda impulsów cyklicznych 3. Więcej szczegółów dotyczących symulowanych sygnałów zostało przedstawionych w pracy [A1]. Wskaźnik ENVSI został obliczony dla przefiltrowanych sygnałów (przy użyciu trzech rozważanych metod) w celu oceny efektywności selekcji IFB.

Na Rys. 20 przedstawiono wyniki przeprowadzonych symulacji, bazujących na metodzie Monte Carlo. Na rysunku umieszczono również wartości ENVSI dla surowego sygnału symulowanego. Wartości ENVSI dla symulowanych sygnałów, o różnych parametrach (przed filtracją), są niskie, niższe niż dla sygnałów przefiltrowanych testowanymi selektorami, co świadczy o tym, iż każdy z testowanych selektorów skutecznie poprawia SNR. Intuicyjnym wynikiem jest również fakt, że wraz ze zwiększającą się amplitudą impulsów niecyklicznych wartość indykatora ENVSI maleje.

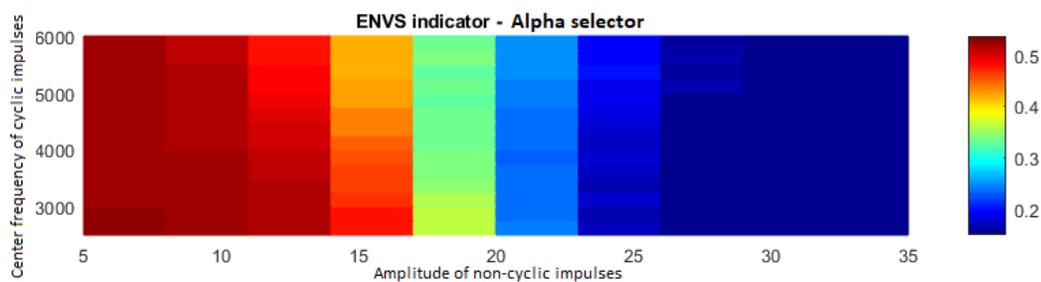
Jak przedstawiono na Rys. 20 stopień nakładania się impulsów nie ma wpływu na wartość wskaźnika ENVSI dla Alfa selektora, Rys. 20a. W pozostałych przypadkach, im mniejszy stopień nakładania się impulsów okresowych i nieokresowych, tym wolniejszy spadek wartości ENVSI wraz ze wzrostem amplitudy (Rys. 20b, 20c).

Filtrowanie za pomocą selektorów Spearmana i CVB okazało się najbardziej efektywne, dlatego w artykule przedstawiono dokładne porównanie tych metod [A4].

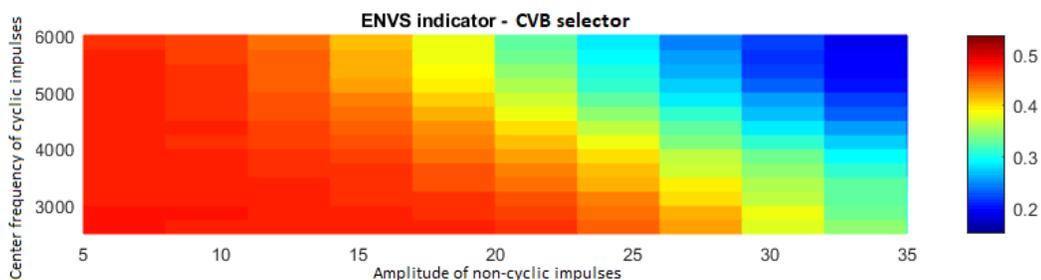
Przeprowadzone badania w zakresie diagnostyki maszyn są podstawą do wdrożenia nowych, bardziej efektywnych procedur wykrywania uszkodzeń lokalnych (we wczesnym stadium) - pozwala to na zaplanowanie konserwacji maszyny we właściwym czasie, uniknięcie jej przestoju i awarii innych komponentów, oszczędności czasu, kapitału i zwiększenie bezpieczeństwa pracy.



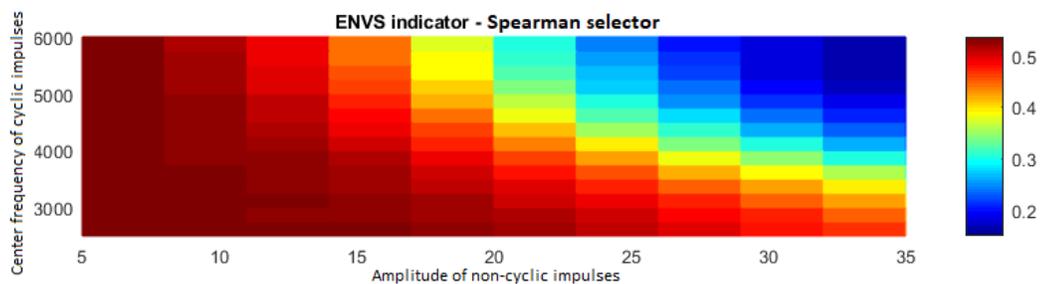
(a) Wartości ENVSI dla sygnału symulowanego



(b) Wartości ENVSI dla Alfa selektora



(c) Wartości ENVSI dla selektora CVB



(d) Wartości ENVSI dla selektora Spearmana

Rysunek 20: Mapy ze średnimi wartościami wskaźnika ENVSI uzyskanymi w wyniku symulacji Monte Carlo [A4]

## 4.2 Obszar: wentylacja i zagrożenia gazowe

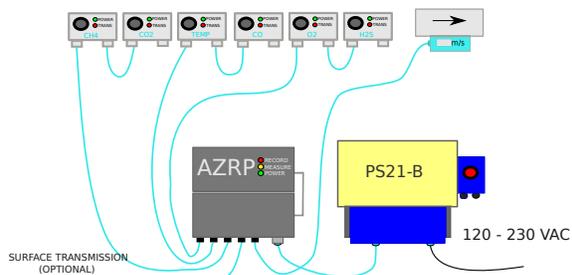
Jakość powietrza i jego zmienność w głębokiej kopalni podziemnej to proces zmienny w czasie i zależy od wielu czynników. Jak wspomniano, w szczególności wpływają na to procesy technologiczne, takie jak wykorzystanie materiałów wybuchowych, praca maszyn dołowych, a także gaz uwalniany przez górotwór (siarkowódor, metan). W rozważanej kopalni rudy miedzi KGHM P.M. S.A O/ZG "Polkowice-Sieroszowice" metan odnotowano w śladowych ilościach. Groźnym gazem który uwalnia się z górotworu jest tutaj siarkowódor ( $H_2S$ ). Gaz ten występuje naturalnie, a jego stężenie w powietrzu jest związane z warunkami geologicznymi. Inżynierowie odpowiedzialni za bezpieczeństwo górników monitorują stężenie tego gazu poprzez mobilne czujniki, w które są wyposażeni i na tej podstawie podejmują decyzję, czy aktualne warunki pracy są bezpieczne. Do tej pory nie analizowano długoterminowych danych dot. stężenia tego gazu, a jego zmienność w ciągu dnia nie była znana.

Dane dot. stężenia siarkowodoru pochodzą z okresu 28.10.2014 - 28.12.2014. System monitoringu zastosowany w tym eksperymencie jest w stanie mierzyć takie parametry powietrza jak: tlenek węgla - CO, dwutlenek węgla -  $CO_2$ , siarkowódor -  $H_2S$ , metan -  $CH_4$  oraz inne zmienne fizyczne, takie jak wilgotność, temperatura i prędkość strumienia powietrza. Celem przeprowadzonych badań było wykorzystanie zebranych danych dotyczących stężenia CO i  $H_2S$  - jako najgroźniejszych gazów w rozważanej kopalni. Częstotliwość próbkowania danych wynosi 1 sekundę. W tym konkretnym miejscu w kopalni nie ma infrastruktury elektrycznej, dlatego raz w miesiącu pomiar był zatrzymywany, a dane były przenoszone z urządzenia do komputera za pomocą karty SD. Strukturę systemu monitoringu przedstawiono na Rys. 21a, a instalację odpowiednich czujników w rozpatrywanej kopalni na Rys. 21b.

Poniżej przedstawione zostaną najważniejsze wyniki dotyczące analizy danych stężenia siarkowodoru [A3], a następnie wyniki dotyczące analizy danych stężenia tlenu węgla [A5]. Dane pochodzą z tego samego eksperymentu i zostały udostępnione dzięki współpracy z firmą KGHM.

### 4.2.1 Zmienność stężenia siarkowodoru ( $H_2S$ )

W przeprowadzonych badaniach dotyczących stężenia  $H_2S$  w kopani rudy miedzi ujętych w pracy [A3] zaproponowano uniwersalną procedurę analizy danych, która pozwoliła określić charakter zmienności stężenia  $H_2S$ , istnienie deterministycznych komponentów oraz



(a) System pomiarowy - schemat czujników

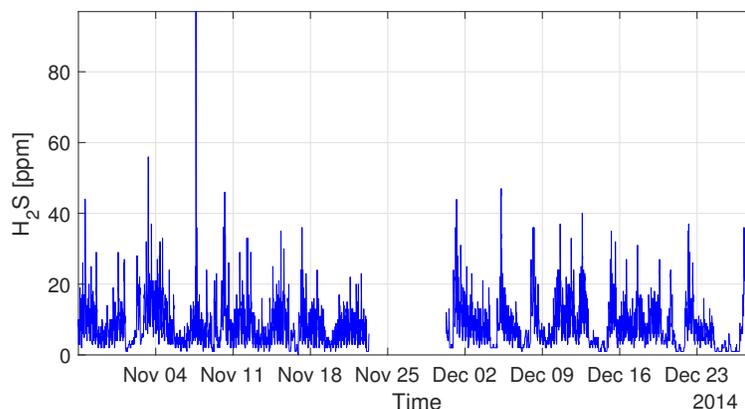


(b) Czujniki zainstalowane w kopalni

Rysunek 21: System pomiarowy wykorzystany do monitorowania jakości powietrza w kopalni [A5]

wpływu procesów technologicznych na zmiany stężenia tego gazu. Dzięki zaproponowanym algorytmom analiza ta może być automatycznie powtarzana w momencie zaktualizowana danych pomiarowych.

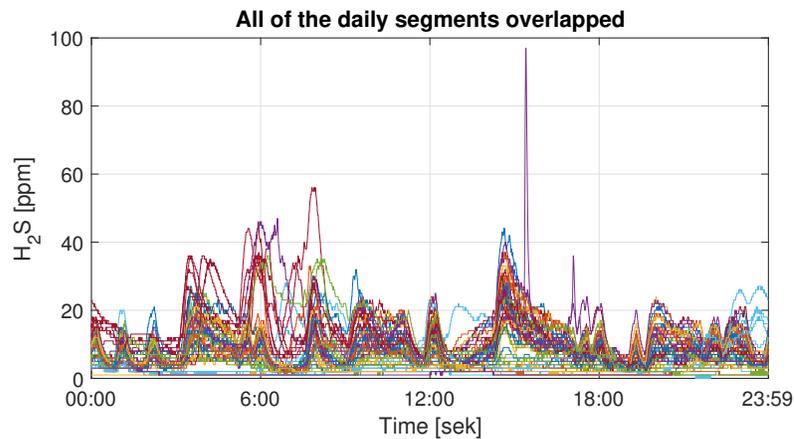
Surowy sygnał opisujący zmienność stężenia  $H_2S$  przedstawiono na Rys. 22. W pierwszym



Rysunek 22: Dane stężenia  $H_2S$  w kopalni podziemnej rud miedzi [A3]

kroku analizy wyodrębnione zostały segmenty danych dotyczące pojedynczych dni (54 dni - 54 dobowe segmenty). Dobowe segmenty (trajektorie) zostały zsynchronizowane i nałożone na siebie, co zostało przedstawione na Rys. 23. Dzięki temu możliwe było zaobserwowanie powtarzalnej zmienności w wartościach stężenia  $H_2S$  w ciągu doby. Obserwacja ta była podstawą hipotezy H5 opowiadającej za tym, iż ze względu na wykorzystywaną technologię

wentylacji wyrobisk zmienność stężenia siarkowodoru nie jest wyłącznie losowa i występuje powtarzający się determinizm, który da się zamodelować.



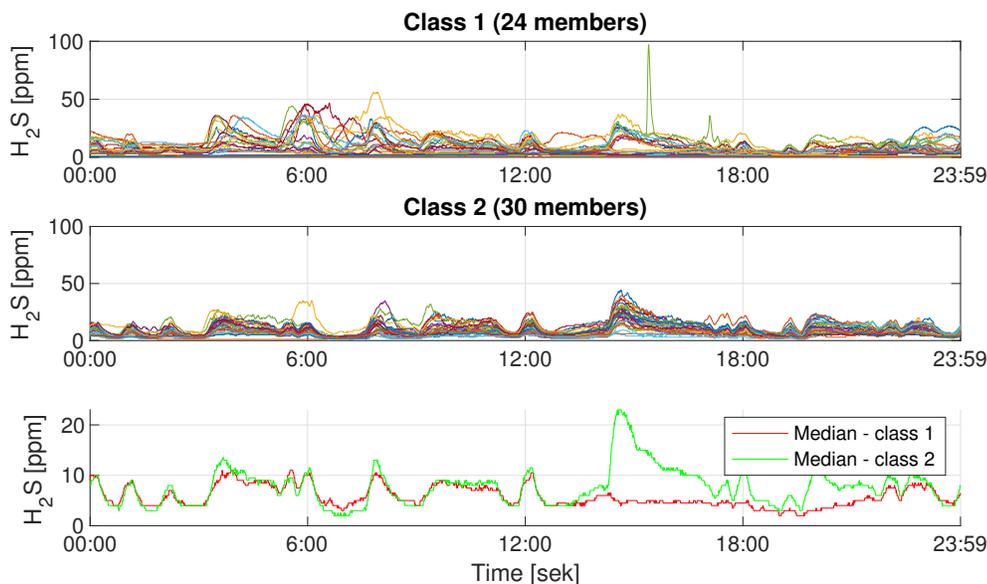
Rysunek 23: Dobowa zmienność stężenia H<sub>2</sub>S - 54 nakładające się na siebie segmenty dobowe [A3]

Aby stworzyć model dobowej zmiany stężenia siarkowodoru segmenty zostały porównane i sklasyfikowane na podstawie podobieństwa do siebie. Do przeprowadzenia klasyfikacji zaproponowano wykorzystanie trzech niezależnych technik, następnie porównano ich wyniki (dobowe wzorce zachowań stężenia H<sub>2</sub>S). Wykorzystane metody to: metoda grupowania k-średnich (ang. k-means) oraz dwie techniki statystyczne, jedna oparta na konstrukcji przedziałów ufności (ang. conditional intervals - CI) i druga wykorzystująca współczynnik korelacji Spearmana (Spearman correlation coefficient - SCC). Poniżej omówiono każde z tych podejść, szczegółowe opisy zostały przedstawione w artykule [A3].

### Metoda 1

W algorytmie k-means przypisanie do danej klasy opiera się na minimalizacji kryterium, które w każdym klastrze (dobowa zmienność) polega na obliczeniu średniej odległości euklidesowej pomiędzy punktami w tym klastrze, a obserwacjami ze średniej klastrowej (uśredniona dobowo zmienność). Optymalna liczba klas została wybrana za pomocą algorytmu Silhouette [141]. W analizie danych rzeczywistych klasyfikacja została przeprowadzona na dobowych segmentach stężenia H<sub>2</sub>S. Algorytm Silhouette wskazał 2 klasy podobnych zachowań wśród analizowanych 54-ech dobowych segmentach, a klasa zawierająca najwięcej dziennych segmentów, o najbardziej zbliżonym zachowaniu została wybrana jako reprezentatywna (klasa numer 2, Rys. 24). Wybrana klasa posłużyła do obliczenia wzorca dobowego. Wykorzystano

do tego medianę, jako miarę bardziej odporną na występowanie skrajnych wartości, które mogą pojawić się w danych. Graficzna ilustracja wyselekcjonowanych klas oraz ostateczny wzorzec dobowy (mediana z 30 segmentów należących do klasy numer 2) został pokazany na Rys. 24.

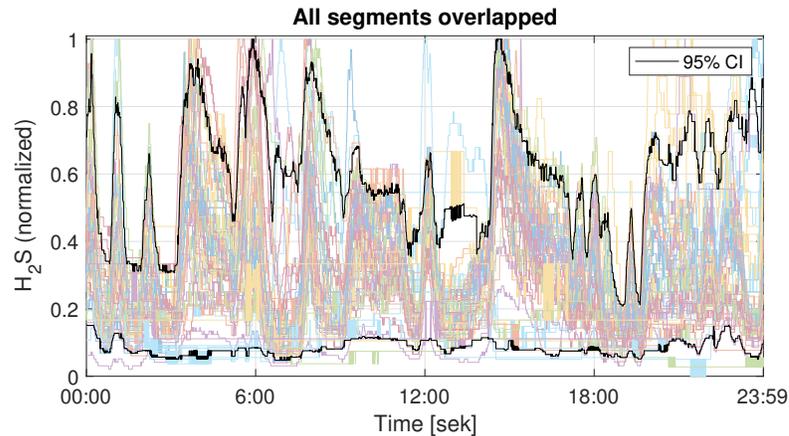


Rysunek 24: Klasyfikacja - metoda nr 1 [A3]

## Metoda 2

Metoda wykorzystująca przedziały ufności (CI) może dostarczyć informacji o pewności (procentowej) otrzymanego wyniku i zwykle jest konstruowana na poziomie ufności równym 5%. Poziom ufności równy 5% oznacza, że istnieje prawdopodobieństwo co najmniej 95%, że wynik jest wiarygodny lub innymi słowy, że jest 5% szans na to, że wynik jest fałszywy. Do obliczenia przedziałów ufności wykorzystuje się kwantyle szeregów czasowych, w tym przypadku kwantyle dziennych segmentów. Zbiór szeregów czasowych stanowił bazę danych do obliczenia kwantyli dla każdej próbki czasu w ciągu jednej doby. W przeprowadzonej analizie uwzględniono przedział ufności na poziomie 95% z dwoma różnymi progami odcięcia: cot 5% i cot 10% (ang. cut-off thresholds - cot). Progi odcięcia oznaczają, że dany procent danych dla każdej trajektorii nie mieści się w rozważanym przedziale ufności. Zaproponowane podejście, uwzględniające 5% lub 10%-owe progi odcięcia pozwala zachować trajektorie dla których większość tj. 95% lub 90% danych mieści się w przedziale ufności. W przeciwnym

wypadku wykroczenie poza CI chociaż jednej próbki generowałoby odrzucenie tej trajektorii z rozważanego CI. Rozważany 95% przedział ufności wraz ze wszystkimi analizowanymi dobowymi segmentami został wyszczególniony na Rys. 25.



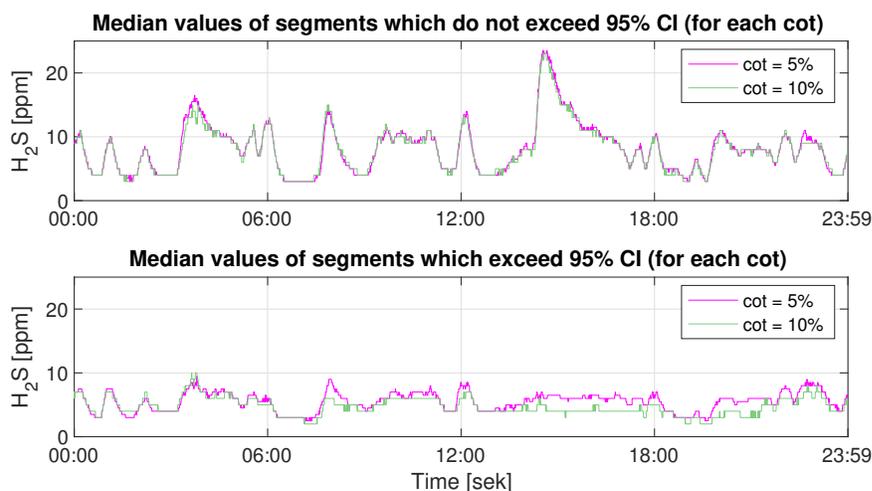
Rysunek 25: Dobowe segmenty (54) wraz z zaznaczonym 95%-owym przedziałem ufności [A3]

Klasyfikację przeprowadza się w następujący sposób. Sprawdzamy, czy szereg czasowy odpowiadający danemu segmentowi mieści się w rozważanym przedziale ufności. Jeśli do 5% (cot 5%) danych z tego szeregu czasowego nie mieści się w 95% CI to segment ten jest klasyfikowany jako klasa 1. Jeśli do 10% (cot 10%) danych z tego segmentu nie mieści się w CI to należy on do klasy 2. W przeciwnym razie mamy klasę numer 3.

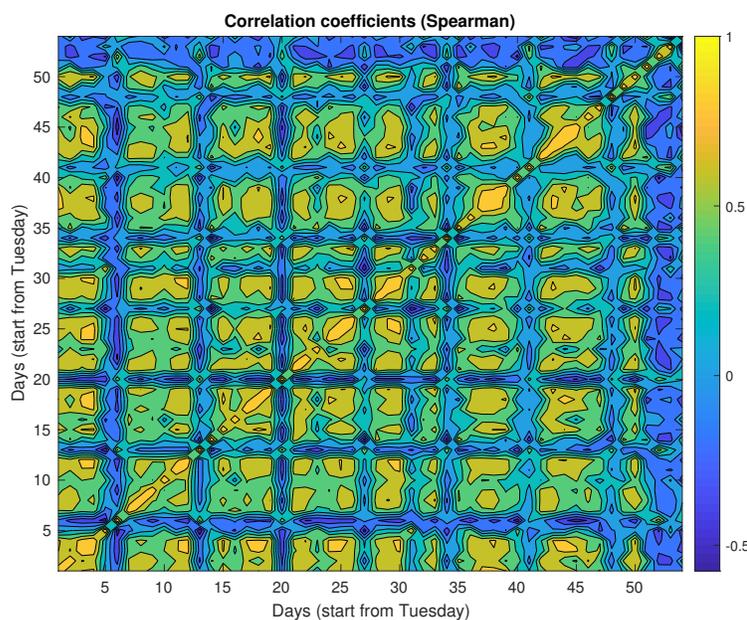
Podobnie jak w poprzednim przypadku klasą reprezentatywną zostaje wybrana ta, która ma najwięcej segmentów najbardziej podobnych do siebie. Wartość mediany z segmentów klasy reprezentatywnej została ustalona jako wzorzec zachowań danych. Wynik klasyfikacji i uśrednienia został przedstawiony na Rys 26.

### Metoda 3

W ostatniej metodzie do wyodrębnienia wzorca dobowego zaproponowano wykorzystanie korelacji Spearmana. Analiza polega na utworzeniu symetrycznej macierzy korelacji Spearmana (ang. Spearman correlation matrix - SCM), szczegółowo opisanej w artykule [A3]. Analogiczna macierz korelacji Spearmana była wykorzystana do zdefiniowania macierzy zależności na potrzeby wykrywania uszkodzeń w łożysku kruszarki rudy miedzi, co zostało opisane w rozdziale 4.1.6 oraz w pracy [A8]. Dla rozważanych segmentów powstała macierz korelacji o rozmiarze  $54 \times 54$ , co zostało przedstawione na Rys. 27.



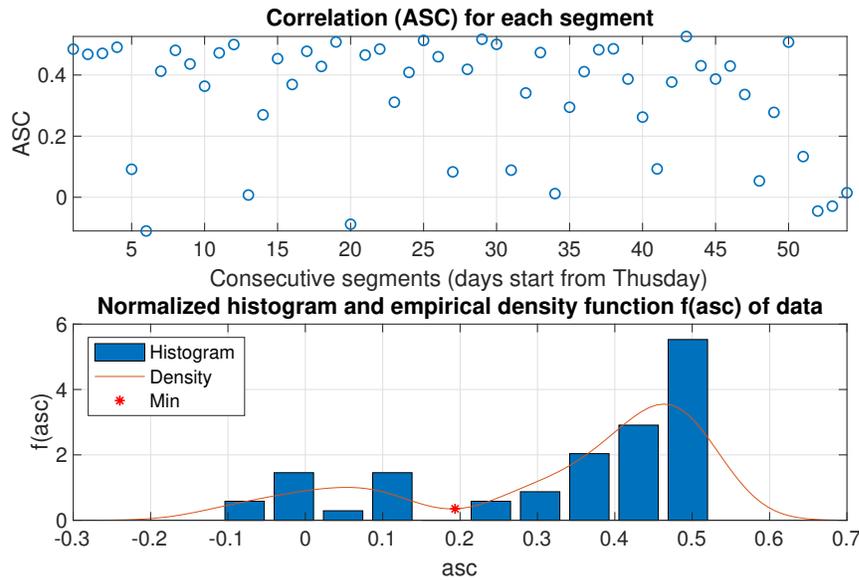
Rysunek 26: Przedział ufności przy różnych wartościach progów odcięcia (ang. cut-off thresholds - cot) - podsumowanie [A3]



Rysunek 27: Macierz korelacji Spearmana dla rozważanych dobowych segmentów [A3]

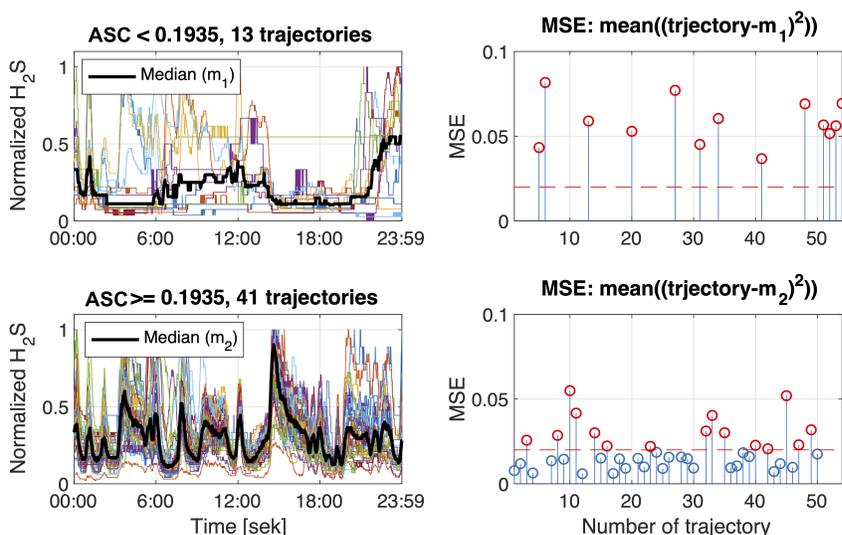
Pierwsza kolumna macierzy zawiera korelacje pierwszego dobowego segmentu tj. wtorku (28.10.2014) ze wszystkimi 54 dniami, kolejna to korelacja środy (29.10.2014) ze wszystkimi 54 dniami i tak dalej. Jak widać na Rys. 27, widoczna jest silna korelacja (korelacja bliska 1 - żółte wartości) i słaba (bliska 0 - niebieskie wartości). Aby skondensować informacje przedstawione na macierzy, wyniki dla każdego segmentu z macierzy SCM zostały uśrednione

do wektora średnich wartości korelacji Spearmana ASC (ang. averaged Spearman correlation - ASC), szczegółowy opis procedury został przestawiony w artykule [A3]. Wektor ASC został przedstawiony na Rys. 28 wraz z unormowanym histogramem wartości ASC.



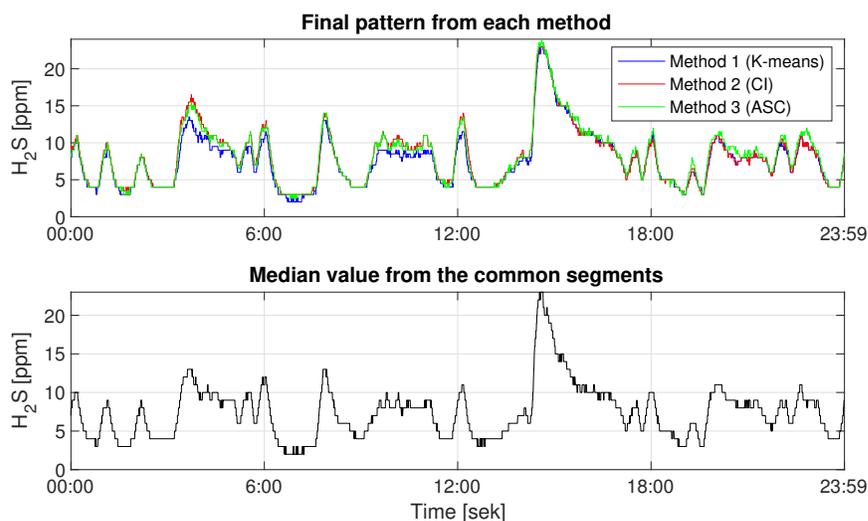
Rysunek 28: Wektor ASC dla rozważanych dobowych segmentów wraz z unormowanym histogramem wartości ASC [A3]

Jak widać na Rys. 28 (górny panel), istnieją dni, które są słabo skorelowane z innymi dniami tygodnia (korelacja bliska 0). Na Rys. 28 (dolny panel) przedstawiono unormowany histogram wraz z empiryczną gęstością. Wyszczególniony punkt przegięcia (Min - wartość minimalna) równy 0.1935 został wykorzystany do podziału segmentów na dwie klasy, z czego jedna klasa, najliczniejsza (41 segmentów) odpowiadająca występującym najsilniejszym korelacjom została wybrana jako klasa reprezentatywna. Za wzorec dobowy z metody 3 uważana jest mediana z segmentów klasy reprezentatywnej bez segmentów z błędem średniokwadratowym MSE (ang. Mean Square Error - MSE) większym niż 2%. Segmenty obu klas wraz z klasyfikacją wykorzystującą MSE oraz medianą zostały przedstawione na Rys. 29 (poziom 2% został zaznaczony na Rys. 29 czerwoną, przerywaną linią). Trajektoria zaznaczona na czarno to wartość mediany wszystkich segmentów w danej klasie. Prawe panele pokazują wartości błędu średniokwadratowego dla wyniku różnicy mediany obliczonej z segmentów danej klasy z każdym segmentem tej klasy. Dokładne wyjaśnienie zostało zawarte w pracy [A3].



Rysunek 29: Klasyfikacja dobowych segmentów wykorzystująca wartości ASC i MSE [A3]

Na Rys. 30 przedstawiono ostateczne wzorce dobowej zmienności  $H_2S$  każdej z trzech zaproponowanych metod. Jak widać wyniki zwrócone przez 3 niezależne metody pokrywają się, co potwierdza występowanie determinizmu w dobowej zmienności wartości stężenia siarkowodoru. Potwierdza to słuszność hipotezy o istnieniu determinizmu w zmienności

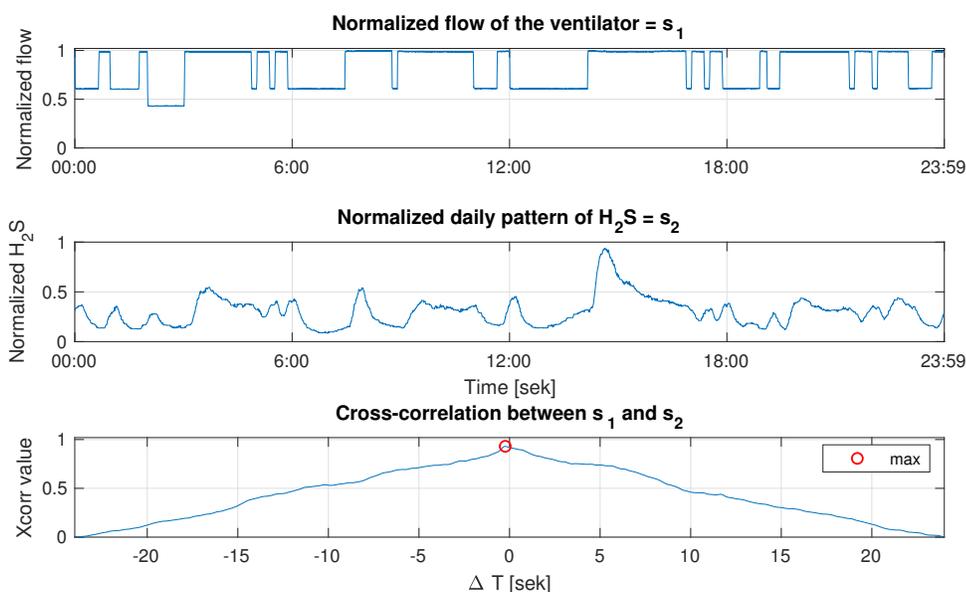


Rysunek 30: Wzorce dobowe zmienności wartości stężenia  $H_2S$  uzyskane przez trzy niezależne metody wykorzystując m.in metodę k-means, przedziały ufności oraz macierz korelacji Spearmana [A3]

stężenia tego gazu, który można zamodelować wykorzystując m.in metodę k-means,

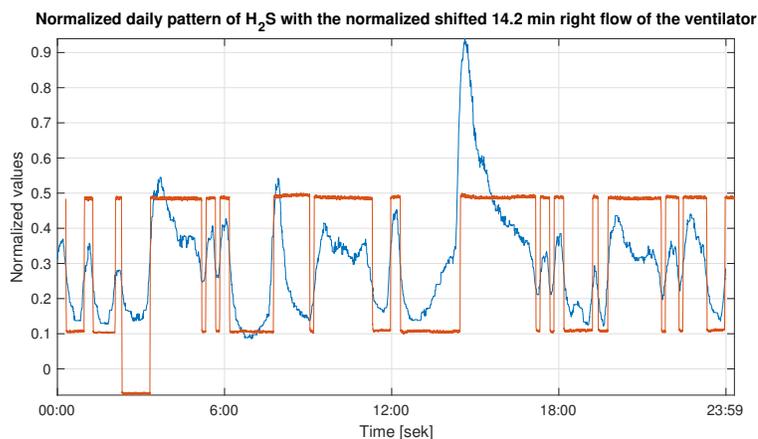
przedziały ufności lub macierz korelacji Spearmana - wszystkie metody zwróciły zbliżony wynik informujący o dokładnych wysokościach stężenia w ciągu doby. Oszacowanie wzorca dobowego pozwala na bieżące określanie anomalii zmian stężenia  $H_2S$  (anomalía wyrażona jest w residuum między analizowanym stężeniem dobowym, a wzorcem dobowym).

Występowanie determinizmu w danych dot. stężenia  $H_2S$  postawiło kolejne wyzwanie związane ze znalezieniem przyczyny pojawiającej się powtarzalności w zmienności wartości stężenia tego gazu w kopalni, w której jego występowanie jest naturalne. Na tej podstawie postanowiono zweryfikować zależność między dobową zmiennością stężenia siarkowodoru, a pracą wentylatorów. Unormowany, dobowy przebieg stężenia  $H_2S$  został porównany z reżimem operacyjnym stacji wentylacyjnej za pomocą metody korelacji krzyżowej, co zostało przedstawione na Rys. 31. Korelacja krzyżowa przyjmuje największą wartość, bliską 1, dla opóźnienia równego -14.2 minut. Oznacza to, że przesunięcie strumienia powietrza przez wentylatory w czasie o 14.2 minut spowoduje wysoką korelację między analizowanymi wektorami danych. Wykryte opóźnienie związane jest z odległością pomiędzy przodkiem wydobywczym, czujnikiem i szybem wentylacyjnym.



Rysunek 31: Znormalizowany przepływ wentylacyjny powietrza (panel górny), znormalizowane stężenie  $H_2S$  (panel środkowy) oraz korelacja krzyżowa między wzorcem  $H_2S$  a przepływem wentylacyjnym (panel dolny) [A3]

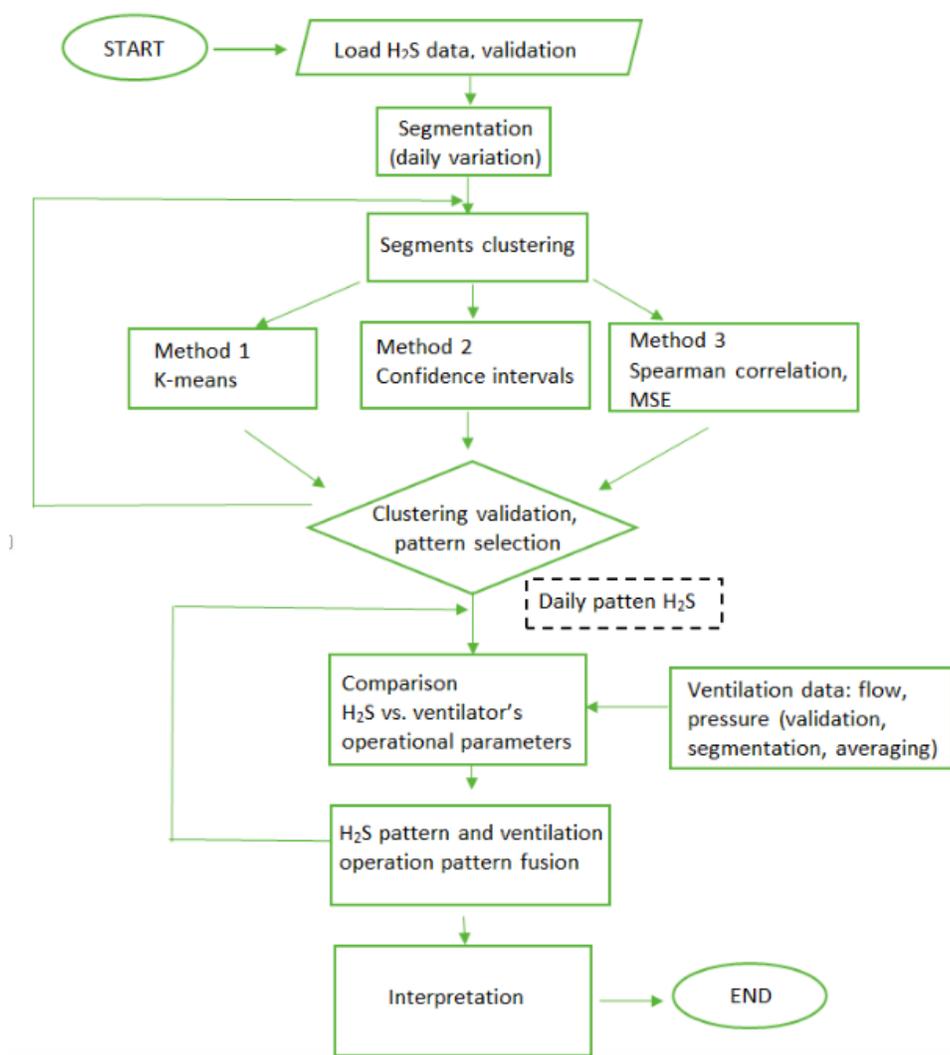
Wzorzec stężenia  $H_2S$  i dane przepływu powietrza w wentylatorach, unormowane do tej samej skali w celu umożliwienia szczegółowego porównania, zostały przesunięte zgodnie z wykrytym opóźnieniem i przedstawione na Rys. 32. Jak widać na Rys. 32, punkty wzrostu obu funkcji w większości pokrywają się ze sobą.



Rysunek 32: Dobowy wzorzec stężenia  $H_2S$  i przesunięty, znormalizowany przepływ powietrza - porównanie [A3]

Jak wspomniano  $H_2S$  występuje naturalnie i nie jest bezpośrednio związany z żadnym procesem technologicznym, a jego stężenie powinno zależeć od lokalnych właściwości złóż. Jednak przeprowadzona analiza wyodrębniła model/wzorzec zachowań stężenia  $H_2S$  co potwierdza występowanie determinizmu. Na podstawie uzyskanych wyników można stwierdzić, że harmonogram prac wentylacyjnych w głębokiej podziemnej kopalni rudy istotnie wpływa na poziom stężenia  $H_2S$ . Jak się okazuje, zwiększenie pracy wentylatorów powoduje (przy opóźnieniu bliskim 14 minut) podwyższenie wartości stężenia  $H_2S$ , po czym następuje jego monotoniczne zmniejszanie się. Zatem, co zaskakujące, wentylacja wpływa na chwilowy wzrost tego niebezpiecznego związku chemicznego w powietrzu kopalni podziemnej. Stężenie  $H_2S$  jest w pewnym stopniu uwarunkowane procesem technologicznym jakim jest wentylacja, co potwierdza hipotezę, iż zmienność stężenia siarkowodoru nie jest wyłącznie losowa ze względu na wykorzystywaną technologię wentylacji. Włączenie wentylatorów powoduje powstanie podciśnienia co prowadzi do nadmiernego uwalniania się tego związku chemicznego z górotworu.

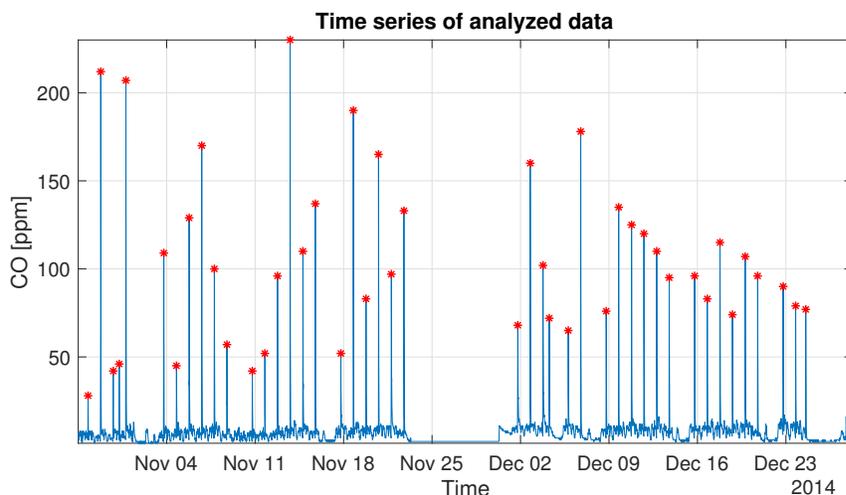
Przeprowadzona analiza stanowi podstawę do efektywnego kontrolowania zagrożenia gazowego stężeniem siarkowodoru w kopalni rudy miedzi. Uproszczony algorytm dotyczący analizy danych rzeczywistych został przedstawiony na Rys. 33.



Rysunek 33: Schemat blokowany dotyczący analizy danych stężenia H<sub>2</sub>S [A3]

#### 4.2.2 Zmienność stężenia tlenku węgla (CO)

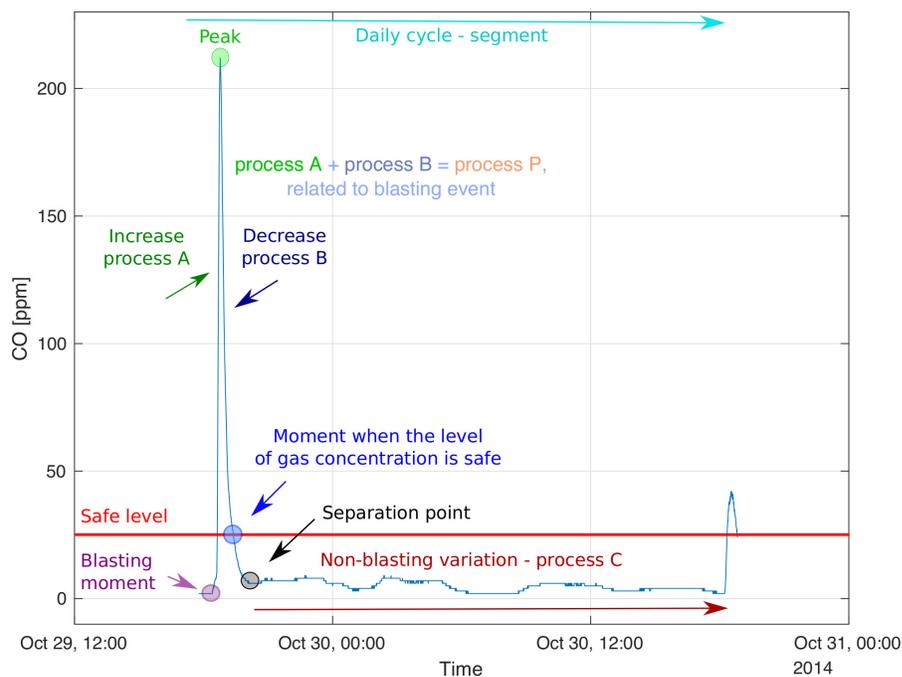
Innym krytycznym parametrem jakości powietrza w kopalni jest stężenie tlenku węgla (CO). Jego obecność wynika głównie z procesów technologicznych przeprowadzanych w kopalni tj. stosowanie materiałów wybuchowych do fragmentacji złoża. W artykule [A5] dotyczącej stężenia CO w kopalni rudy miedzi zaproponowano, między innymi, uniwersalną metodę segmentacji i analizę statystyczną sygnału oraz automatyczną procedurę lokalizowania momentów wybuchu – momenty wysokich skoków stężenia CO. Surowy sygnał opisujący zmienność stężenia CO wraz z lokalnymi maksymalnymi wartościami jego stężenia (czerwone punkty) przedstawiono na Rys. 34. W analizowanych danych zidentyfikowano 44 lokalne



Rysunek 34: Dane stężenia CO w kopalni podziemnej rud miedzi [A5]

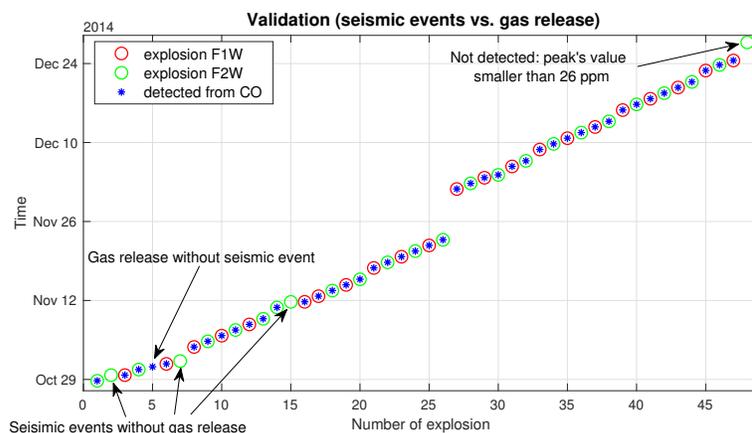
maksymalne wartości (maksima) stężeń w ciągu doby (wyższe niż przyjęty bezpieczny poziom stężenia, wynoszący 26 ppm). W tym celu wykorzystano funkcję lokalnego maksimum, znajdującą maksymalną wartość stężenia w zadanym oknie czasowym. W rozważanym problemie za szerokość okna przyjęto 7 godzin (długość jednej zmiany roboczej górników, podczas której dokonywana jest jedna detonacja złoża rudy miedzi).

Lokalne skoki wartości stężenia CO różnią się między sobą amplitudą, jednak wykazują podobne zachowanie związane ze wzrostem stężenia, osiągnięciem maksymalnej wartości oraz wygaszeniem. Przykładowy dobowy przebieg zmienności stężenia CO został pokazany na Rys. 35, gdzie zostały wyszczególnione najważniejsze punkty zmiany stężenia CO, które pełnią kluczową rolę w modelowaniu tego procesu. Do zweryfikowania poprawności wykrywania czasu rozpoczęcia wzrostu stężenia, które osiągają lokalne maksymalne wartości,



Rysunek 35: Schemat opisujący zmienność stężenia gazu CO [A13]

zapropozowano porównanie wyników z danymi z systemu monitoringu sejsmicznego używanego w kopalni (każda sesja robót strzałowych jest rejestrowana przez system sejsmiczny), co zostało przedstawione na Rys. 36. Większość wykrytych maksimów pokrywa



Rysunek 36: Walidacja wykrytych lokalnych maksimów stężenia CO, porównanie z danymi z systemu monitoringu sejsmicznego [A5]

się ze wstrząsami sejsmicznymi, jednak jeden z nich, nie został zarejestrowany przez system

monitoringu sejsmicznego. Natomiast cztery drgania sejsmiczne wystąpiły bez ulatniania się tlenku węgla, pierwsze trzy są związane z typowymi drganiami sejsmicznymi górotworu. Ostatni z nich nie został wykryty jako lokalne maksimum, ponieważ jego wartość nie przekroczyła bezpiecznego poziomu stężenia tlenku węgla, co było jednym z warunków funkcji znajdującej lokalne maksimum.

W pracy zbadano również rozkład prawdopodobieństwa procesu odpowiedzialnego za wysokość stężeń CO tj. rozkład amplitud wykrytych maksimów. W celu znalezienia odpowiedniej klasy rozkładu prawdopodobieństwa odpowiadającego wartościom wykrytych lokalnych wartości maksymalnych stężenia CO, zaproponowano analizę zachowania ich ogona empirycznego (Rys. 37). Empiryczny ogon (ang. empirical tail) rozkładu zdefiniowany jest następująco:

$$ET(x) = 1 - \hat{F}_N(x) = 1 - \frac{1}{N} \sum_{i=1}^N 1_{\{a_i \leq x\}}, \quad (25)$$

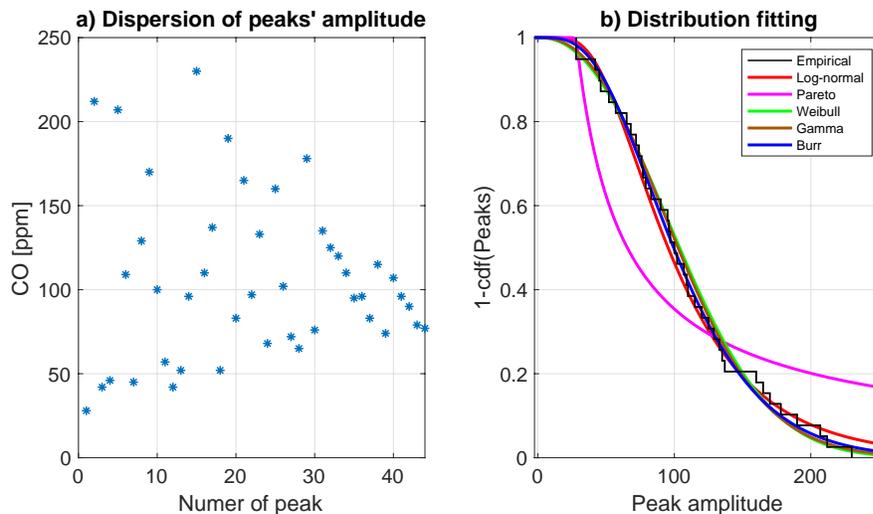
gdzie  $x$  jest argumentem funkcji empirycznego ogona,  $1_{\{A\}}$  jest indykatozem zbioru  $A$ , natomiast  $a_1, a_2, \dots, a_N$  jest wektorem wykrytych maksymalnych wartości stężenia tlenku węgla.  $\hat{F}_N(\cdot)$  jest empiryczną funkcją dystrybuanty wektora  $a_1, a_2, \dots, a_N$ .

W celu rozpoznania klasy rozkładu odpowiadającego wektorowi  $a_1, a_2, \dots, a_N$  dopasowano teoretyczne ogony znanych rozkładów do ogona empirycznego. Do estymacji parametrów rozkładów zastosowano estymator oparty na metodzie największej wiarygodności.

Jako wskaźnik wyboru najlepiej dopasowanego rozkładu prawdopodobieństwa, spośród 5 rozważanych (wspomniane na Rys. 37, zdefiniowane w artykule [A5]), wykorzystano test graficzny ogonów rozkładu oraz test Kołmogorowa-Smirnowa (KS test). Rozkład Burra został wybrany jako najlepiej dopasowany. Wartości parametrów dopasowanego rozkładu Burra są następujące:

- Parametr skali  $\alpha = 284.77$ ;
- Parametr kształtu  $c = 2.42$  i  $k = 8.49$ .

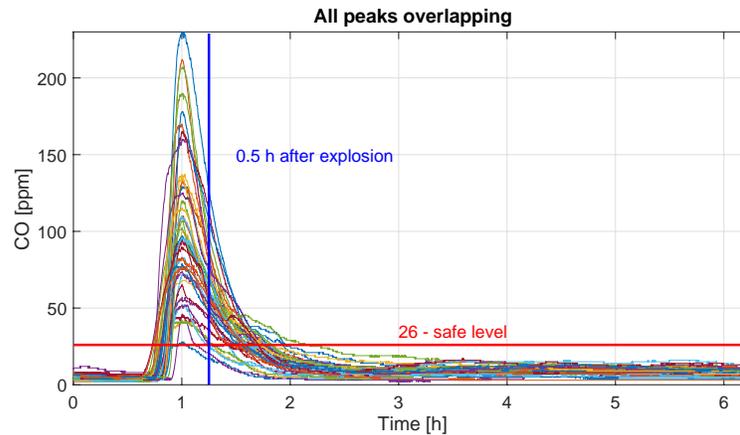
Dystrybuanta rozkładu Burra ma następującą postać  $F(x; c, k, \alpha) = 1 - \left[1 + \left(\frac{x}{\alpha}\right)^c\right]^{-k}$ . Znajomość rozkładów amplitud pików pozwala na określenie oczekiwanej wartości stężenia CO spowodowanego zdarzeniem strzałowym, co może być pomocne przy planowaniu eksploatacji kopalni i wentylacji.



Rysunek 37: Rozproszenie amplitud wykrytych pików (panel a); ogon rozkładu empirycznego dla wielkości pików oraz ogon teoretyczny kilku dopasowanych rozkładów (panel b) [A5]

W pracy badawczej skupiono się również na analizie procesów A i B (zaznaczonych na Rys. 35, jako proces wzrostu i wygaszania, ang. increase and decrease processes). Proces A rozpoczyna się momentem nagłego skoku wartości stężenia - zazwyczaj jest to moment wybuchu (ang. blasting moment) materiałów wybuchowych, związanym z robotami strzałowymi i odpowiada monotonicznemu wzrostowi wartości stężenia. Natomiast proces B odpowiada monotonicznemu zmniejszaniu się wartości stężenia do bezpiecznej wartości 26 ppm i osiągnięcia tak zwanego punktu separacji (ang. separation point). Punkt separacji rozumiany jest jako moment, w którym wartość stężenia CO wróciła do swojego standardowego poziomu, sprzed nagłego wzrostu wartości stężenia. Innymi słowy, jest to punkt załamania funkcji wygaszania wartości stężenia CO i pojawienia się nowego, niewielkiego wzrostu stężenia CO, bezpiecznego dla ludzi. Do wyznaczenia punktów zmiany stanu (moment wybuchu, punkt separacji) wykorzystano funkcję pochodnej oraz lokalne minimum funkcji (zaproponowane funkcje pozwalają zachować automatyczność działania proponowanych procedur). Procedura lokalizowania nagłych wzrostów stężenia CO może być wykorzystywana do alarmowania górników o niebezpieczeństwie.

Na Rys. 38 przedstawiono wszystkie lokalne maksima posegmentowane i nałożone na siebie zgodnie z lokalizacją maksymalnej wartości stężenia, uwzględniając 1 godzinę przed i około 5 godzin po osiągniętym maksimum. W przeprowadzonych badaniach [A5], wykorzystując kryterium Silhouette i klasteryzację k-średnich (ang. k-means) pokazano, że istnieją dwa klastry (dwie klasy) zachowań procesu odpowiedzialnego za wygaszanie

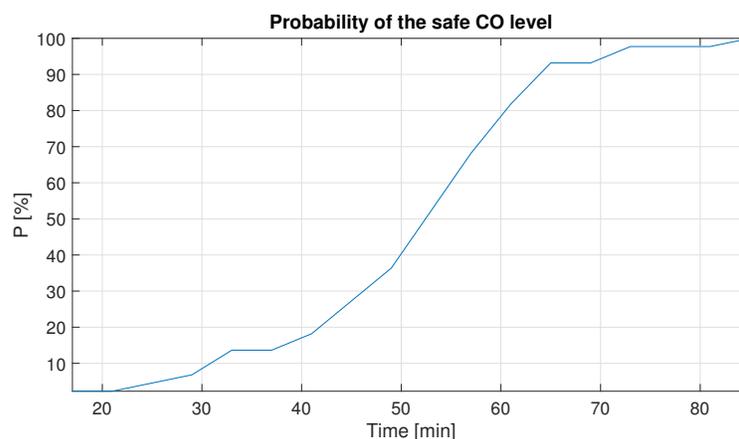


Rysunek 38: Zarejestrowane piki nakładające się na siebie zgodnie z ustalonymi ramami czasowymi. Żółta pionowa linia wskazuje 30-minutowy czas oczekiwania po robotach strzałowych, a czerwona linia pozioma - bezpieczny poziom stężenia gazu [A5]

maksimów. Oba można opisać funkcją wykładniczą o różnych parametrach  $a$ ,  $b$  i  $c$  w zależności od klasy. Główna różnica między klasami występuje pomiędzy amplitudami osiągniętych maksymalnych wartości - parametr skali  $a$  funkcji wykładniczej reprezentuje tę własność. W pracy [2] zaproponowano model procesu A i B (proces P) w formie jednej funkcji będącej sumą funkcji Gaussa i stałej  $d$  odpowiadającej poziomowi stężenia CO, na poziomie której oscyluje stężenie CO poza okresem podwyższonej wartości związanej z procedurą strzałową (proces C, Rys. 35). Do oszacowania odpowiednich parametrów zaproponowanej funkcji zastosowano metodę najmniejszych kwadratów. Jakość dopasowania funkcji deterministycznej sprawdzono za pomocą współczynnika determinacji  $R^2$ , która w każdym z dopasowań przyjęła wartość większą niż 90%, co świadczy o dobrym dopasowaniu modelu. Dopasowaną funkcję można wykorzystać do przewidywania czasu potrzebnego do osiągnięcia bezpiecznego poziomu CO podczas robót strzałowych. W praktyce, w rozważanej kopalni czas równy 30 minut był najczęstszym czasem oczekiwania po zakończeniu robót strzałowych na zezwolenie pracy górnikom w tym obszarze.

Podsumowując przeprowadzona analiza pozwoliła wskazać wysokie wzrosty stężeń o pochodzeniu innym niż proces technologiczny. Procedura lokalizowania nagłych wzrostów stężenia CO może być wykorzystywana do alarmowania górników o niebezpieczeństwie. Przeprowadzona analiza pokazała, że dzienne wzorce zmienności stężenia CO różnią się (pomimo faktu, że prace strzałowe dokonywane są każdego dnia o zbliżonych godzinach), a wartości stężenia CO osiągają bezpieczny poziom w innym czasie po detonacji

ładunków podczas robót strzałowych. Na podstawie danych historycznych wyliczono (z pewnym prawdopodobieństwem) czas do osiągnięcia bezpiecznego poziomu stężenia CO po zakończeniu prac strzałowych, co przedstawiono na Rys. 39. Obliczono optymalny czas

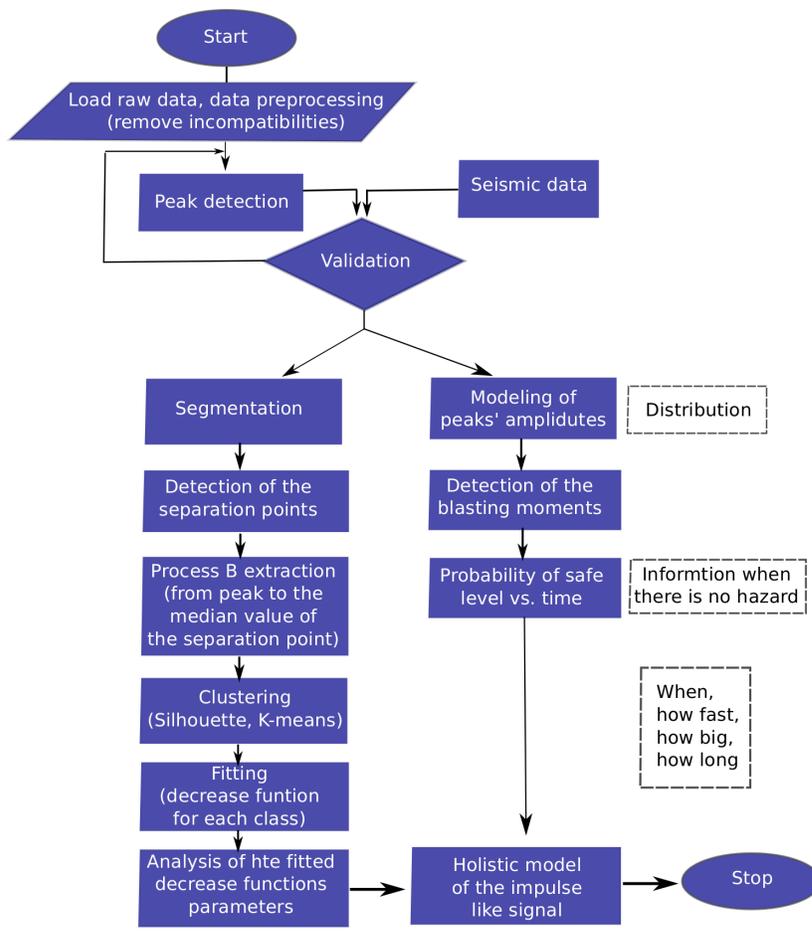


Rysunek 39: Empiryczne rozkład prawdopodobieństwa czasu potrzebnego do zapewnienia bezpiecznego poziomu CO po zakończeniu robót strzałowych [A5]

oczekiwania, który zapewnia wysokie prawdopodobieństwo (93%) bezpiecznego poziomu stężenia CO. Czas ten to 65 min.

Zaproponowana metoda analizy danych stężenia CO jest automatyczna i może być aktualizowana o nowe dane, dzięki czemu wspomniany bezpieczny czas oczekiwania może się zmieniać (być aktualizowany). Ogólny schemat analizy danych tlenku węgla przedstawiono na Rys. 40.

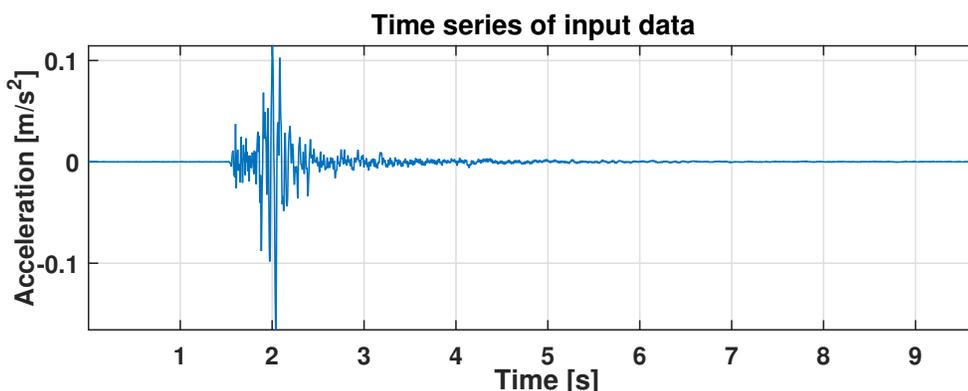
Wiedza o naturze zmienności oraz źródłach występowania niebezpiecznych gazów występujących w rozważanej kopalni, takich jak tlenku węgla i siarkowodór może być pomocna przy tworzeniu modeli prognostycznych, a także przy planowaniu działalności górniczej. Zaproponowana metodologia ma charakter innowacyjny i jest analizowana przez służby wentylacyjne w kopalni (jeden ze współautorów jest głównym inżynierem ds. wentylacji).



Rysunek 40: Schemat blokowany dot. analizy danych stężenia CO [A5]

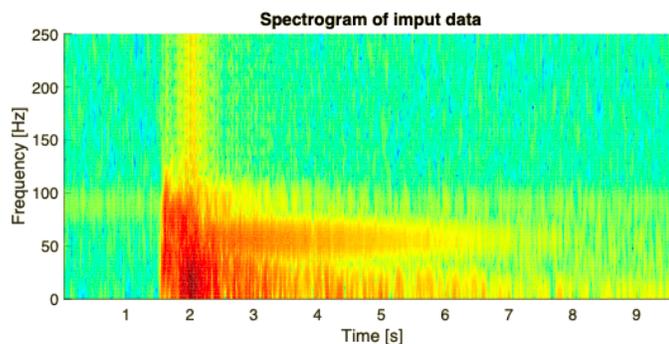
### 4.3 Obszar: sejsmika

Zdarzenia sejsmiczne to zjawiska powszechnie występujące w górnictwie. Mogą być one wywołane zjawiskami o charakterze naturalnym (trzęsienia ziemi) lub indukowane są przez działalność górnictw. Ze względu na niebezpieczny charakter analizowanego problemu, informacja o występowaniu wstrząsu o wysokiej energii oraz jego lokalizacja są kluczowe w rozpoznaniu zdarzenia, lokalizacji ogniska i ewentualnym rozpoczęciu akcji ewakuacyjnej. Zdobywanie tych informacji jest prawie niemożliwe bez wykrycia momentu nadejścia fali P do czujnika. Głównym celem algorytmów znajdowania fali P (najszybsza fala sejsmiczna, tzw. zapowiadająca - moment rozpoczęcia zdarzenia sejsmicznego) jest wysoka dokładność i automatyczność metody. W przeprowadzonych badaniach [A9] zaproponowano innowacyjną metodę, która obejmuje analizę sygnału sejsmicznego, opartą na analizie głównych składowych (ang. Principal Component Analysis - PCA) z wykorzystaniem czasowo-częstotliwościowej reprezentacji sygnału. Sygnał sejsmiczny został przedstawiony na Rys. 41.



Rysunek 41: Sygnał rzeczywisty - dane sejsmiczne [A9]

W przeprowadzonej analizie wykorzystano czasowo-częstotliwościową reprezentację sygnału (spektrogram, zdefiniowany w równaniu (1), rozdział 5.1.1), która pozwala na lepszą dokładność wykrywania zmian struktury sygnału. Na Rys. 42 przedstawiono spektrogram analizowanych danych sejsmicznych, pochodzących z systemu monitoringu sejsmicznego ELOGOR-C, który jest wykorzystywany do obserwacji górotworu w podziemnej kopalni rudy miedzi O/ZG "Rudna". Jak wspomniano zaletą reprezentacji czasowo-częstotliwościowej jest możliwość jednoczesnej obserwacji zachowania się sygnału w dziedzinie czasu oraz w dziedzinie częstotliwości. Jednak zmiana reprezentacji sygnału do czasowo-częstotliwościowej

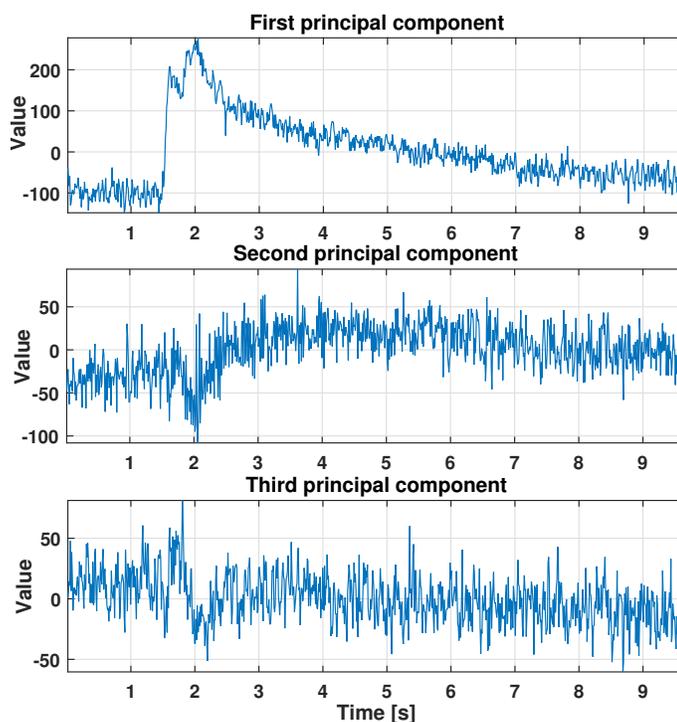


Rysunek 42: Spektrogram danych sejsmicznych [A9]

mapy powoduje wzrost złożoności obliczeniowej. Przybywa informacji na temat przepływu energii w sygnale, ale pojawia się problem z wybraniem tej informacji, która jest istotna z punktu widzenia detekcji fali P (gwałtowna zmiana wartości w sygnale drganiowym - zmiana reżimu). Dlatego zaproponowano wykorzystanie PCA, które jest znane z wysokiej efektywności w redukcji wymiarów danych przy zachowaniu największej zmienności w danych.

Analiza składowych głównych jest powszechnie znana w analizie statystycznej [142]. Zakłada ona, że zbiór danych składający się z  $N$  obserwacji, z których każda obejmuje  $M$  zmiennych, może być interpretowana jako chmura punktów w przestrzeni  $M$ -wymiarowej. Celem PCA jest rotacja lokalnego układu współrzędnych w kierunku maksymalizacji wariancji w nowym zbiorze wymiarów, takim że pierwszy wymiar charakteryzuje się największą wariancją, drugi wymiar drugą co do wielkości wariancją itd. Taki przekształcony układ składa się z nowych wartości danych, w nowym zestawie wymiarów. Wektory danych w nowym układzie współrzędnych nazywamy składowymi głównymi. Nowo utworzona przestrzeń cech opisuje oryginalny zbiór danych głównie w obrębie kilku pierwszych składowych głównych, które niosą najwięcej oryginalnej informacji. Zazwyczaj informacja zawarta w niewielkiej liczbie pierwszych składowych jest wystarczająca, ponieważ ich zawartość informacyjna (zmienność wartości) jest bardzo wysoka. Na Rys. 43 przedstawiono pierwsze trzy składowe PCA analizowanego sygnału, które zawierają 87%, 4% i 2% zmienności analizowanych danych.

Jak wspomniano, PCA jest uważana za metodę redukcji wymiarowości. Biorąc pod uwagę  $N$  obserwacji danych  $M$ -wymiarowych ułożonych w macierz  $X \in \mathbb{R}^{N \times M}$ , składowe główne można obliczyć za pomocą rozkładu według wartości osobliwych (ang. Singular Value



Rysunek 43: Pierwsze trzy składowe PCA, przedstawiające 87%, 4% i 2% zmienności danych sejsmicznych [A9]

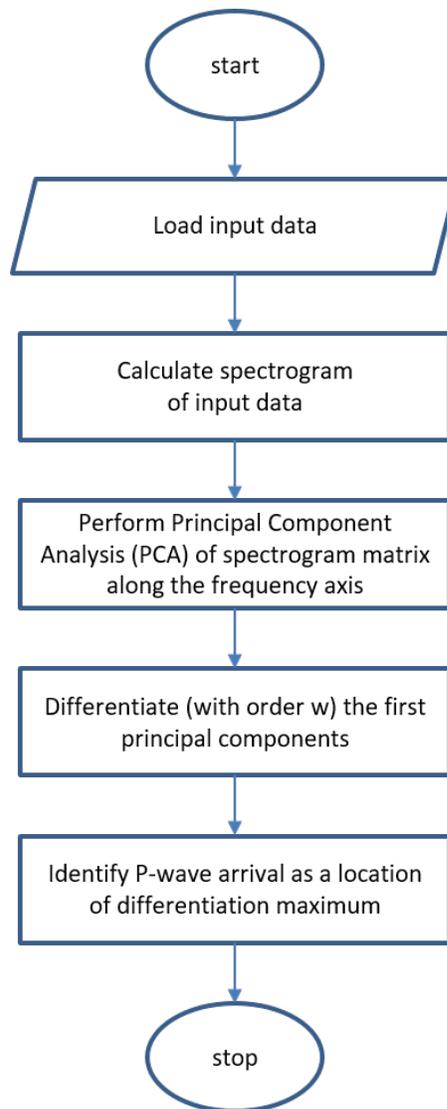
Decomposition - SVD):

$$\frac{1}{\sqrt{N-1}}\mathbf{X} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T, \quad (26)$$

gdzie  $U \in \mathbb{R}^{N \times N}$  i  $V \in \mathbb{R}^{M \times M}$  są macierzami jednostkowymi i  $\Sigma \in \mathbb{R}^{N \times M}$  zawiera nieujemną liczbę rzeczywistą wartości osobliwych (ang. singular values) o nierosnącej wielkości ( $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_M \geq 0$ ). Składowe główne są ortonormalnymi wektorami kolumnowymi macierzy  $\mathbf{V}$ , a wariancja  $i$ -tego komponentu jest równa  $\sigma_i^2$ .

W przeprowadzonych badaniach, po transformacji PCA, pierwszy składnik PCA1 został wykorzystywany jako najbardziej informacyjny, z punktu widzenia zmienności analizowanych danych, co jest szczególnie widoczne w skali wartości PC1, w porównaniu do skali wartości oryginalnych danych. Założono, że w związku z nadejściem fali P pojawi się znacząca, gwałtowna zmiana wariancji. W związku z tym zaproponowano obliczyć pochodną (różnicowanie) z wektora danych PCA1 do wyznaczenia zmiany reżimu, oznaczającego czas nadejścia fali P. Wielkość okna różnicowania została szczegółowo omówiona w artykule [A9].

Podsumowując, w analizie danych sejsmicznych zastosowano analizę czasowo-częstotliwościową STFT do surowego sygnału sejsmicznego (jednokanałowego).



Rysunek 44: Schemat blokowy analizy danych sejsmicznych [A9]

Następnie dla wielowymiarowej macierzy danych (zbiór podsygnałów dla każdego zbioru częstotliwości  $\Delta f$ ) zastosowano algorytm PCA w celu wyodrębnienia największej zmienności w danych. Następnie dla PCA1 zastosowano technikę detekcji fali P opartą na zasadzie: znajdź maksymalną wartość na pochodnej funkcji pierwszej składowej PCA, niosącej "informację" mówiącą o największej zmienności w danych, co interpretujemy jako moment nadejścia fali P.

W artykule [A9] opisano szczegółowo metodologię proponowanej procedury. Ogólny zarys algorytmu przedstawiono na Rys. 44. Zaproponowana metoda jest skuteczna, intuicyjna

i automatyczna. Została ona przetestowana na danych rzeczywistych pochodzących z systemu monitoringu stosowanego w podziemnej kopalni. Jej skuteczność jest lepsza niż skuteczność popularnej metody LTA/STA (ang. Short-Term Average/Long-Term Average), co zostało pokazane w artykule [A9]. W literaturze nie znaleziono podobnego podejścia, łączącego czasowo-częstotliwościową reprezentację sygnału z metodą PCA i różnicowaniem w zastosowaniu dla sygnału sejsmicznego, co świadczy o innowacyjności proponowanego algorytmu.

## 4.4 Obszar: zarządzanie efektywnością pracy samojezdnych maszyn dołowych

### Opis maszyny

Maszyną wykorzystaną w eksperymencie jest wóz odstawczy CB4-20TB wyprodukowany przez KGHM ZANAM. Podstawowe parametry wozu to: 10300 mm długości, 3350 mm szerokości, 1900/2000/2100 mm wysokości (w zależności od ruchomej kabiny). Masa całkowita: 26000 kg, pojemność skrzyni załadunkowej: 11.1 m<sup>3</sup>, ładowność nominalna: 20 t, moc znamionowa: 149 kW, prędkość jazdy: do 20 km/h. Zdjęcie maszyny przedstawiono na Rys. 45.



Rysunek 45: Zdjęcie maszyny - wóz odstawczy CB4-20TB wykorzystywany w kopalni rudy miedzi KGHM [A10]

### Opis systemu monitorującego

Zgodnie ze standardem monitorowania danych opracowanym w ramach wewnętrznego projektu Grupy KGHM, istnieje lista parametrów mierzonych na maszynie. W zależności od typu maszyny lista ta może zawierać różne parametry. Są one związane z różnymi komponentami, mają różną dynamikę (procesy o niskiej częstotliwości, np. temperatura, procesy o wysokiej częstotliwości, np. ciśnienie, itp.) i różną odporność na zakłócenia. W przeprowadzonych badaniach wykorzystano tylko niektóre z dostępnych danych. Większość danych jest próbkowana z częstotliwością 1 Hz. Tab. 2 przedstawia wykaz monitorowanych parametrów dla analizowanego wozu odstawczego.

#### 4.4.1 Selekcja informacyjnych parametrów monitorowania maszyny

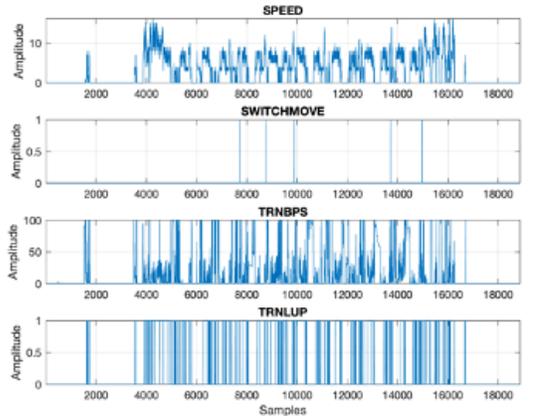
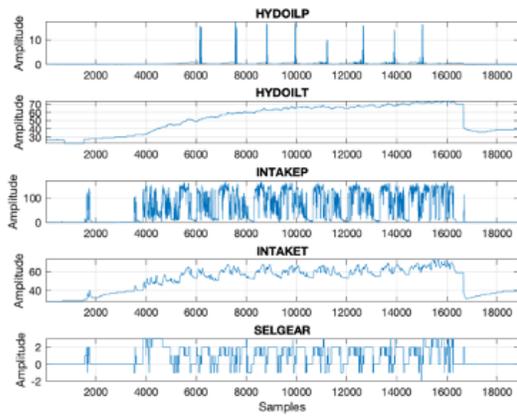
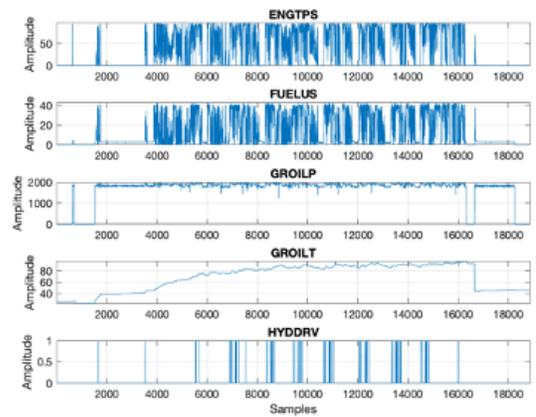
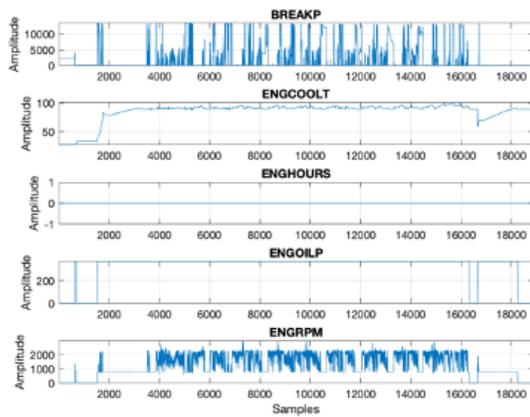
Samojezdne Maszyny Górnicze - SMG są podstawowym zasobem technicznym stosowanym w kopalniach rud miedzi w KGHM P.M S.A. Koszty eksploatacji maszyn: amortyzacja, serwis, materiały eksploatacyjne, wynagrodzenie operatorów itp. stanowią ponad 30% kosztów

Nazwa zmiennej	Opis
BREAKP	ciśnienie w układzie hamowania
ENGCOOLT	temperatura oleju chłodzącego silnika spalinowego
ENGHOURS	liczba godzin pracy silnika spalinowego w ujęciu skumulowanym
ENGOILP	ciśnienie oleju w silniku spalinowym
ENGRPM	prędkość obrotowa silnika
ENGTPS	odchylenie pedału gazu
FUELUS	chwilowe zużycie paliwa
GROILP	ciśnienie oleju w skrzyni biegów
GROILT	temperatura oleju w przekładni i konwerterze momentu obrotowego
HYDDRIV	dołączony dodatkowy napęd hubowy
HYDOILP	ciśnienie w instalacji hydraulicznej
HYDOILT	temperatura oleju hydraulicznego
INTAKEP	ciśnienie doładowania silnika
INTAKET	temperatura powietrza na wlocie do silnika
SELGEAR	kierunek i bieżący bieg
SPEED	średnia prędkość co 1 sekundę
SWITCHMOVE	przełączanie kierunku jazdy pod obciążeniem
TRNBPS	położenie pedału hamulca; 0-100%
TRNLUP	system lock-up (włączony/wyłączony)

Tabela 2: Lista monitorowanych parametrów dla wozu odstawczego [A10]

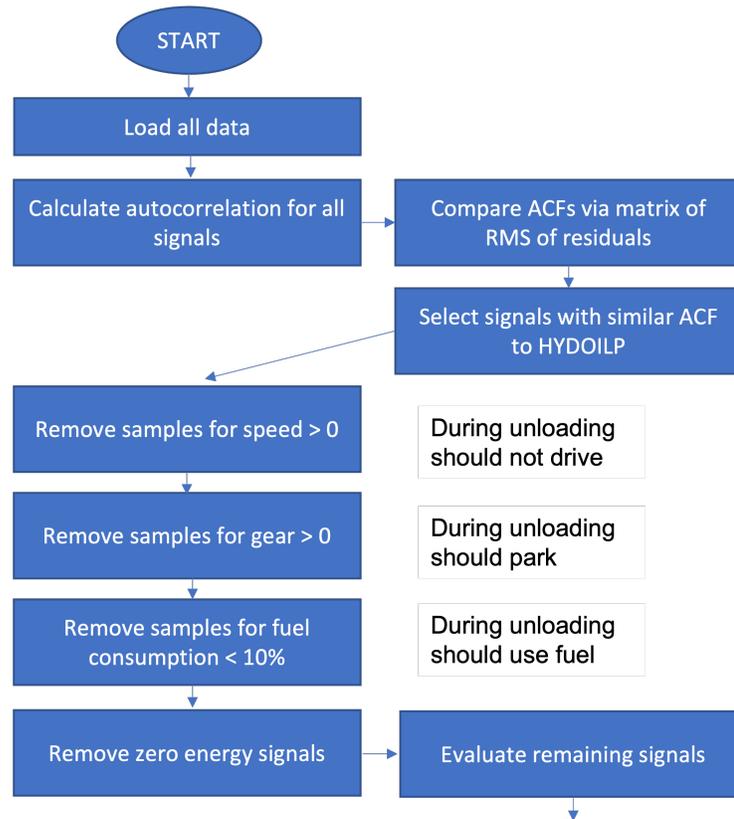
technicznych produkcji rud miedzi [A11]. W celu optymalizacji kosztów, maszyny i procesy są monitorowane.

W przeprowadzonych badaniach wykorzystano dane pochodzące z pokładowego systemu monitorowania wozu odstawczego (opisanego w rozdziale 4.4) do identyfikacji reżimów pracy (cykli roboczych). Przykładowe dane zostały zaprezentowane na Rys. 46. Opracowanie wskaźników oceny organizacji pracy w procesie produkcyjnym, np. liczba cykli wykonanych przez maszynę, średni czas cyklu, odchylenia od średniego czasu cyklu, rozpoczęcie/zakończenie pracy maszyny na zmianę roboczą itp. można uznać za pierwszy krok do optymalizacji kosztów tego procesu. W literaturze [120] opracowano metodę zliczania cykli roboczych dla ładowarek, wykorzystującą sygnał ciśnienia z siłownika w układzie hydraulicznym. Jednak w przypadku wozu odstawczego charakter danych różni się i potrzebny jest nowy algorytm, wykorzystujący inne parametry maszyny. Ponadto, w praktyce istnieją ograniczenia w stosowaniu wskaźnika opartego na ciśnieniu, ze względu na utratę danych spowodowaną podatnością czujnika ciśnienia na uszkodzenia mechaniczne. Na podstawie tych doświadczeń, w artykule [A11], zaproponowano nową metodologię



Rysunek 46: Przykład danych rzeczywistych pochodzących z wozu odstawczego z jednej zmiany roboczej [A11]

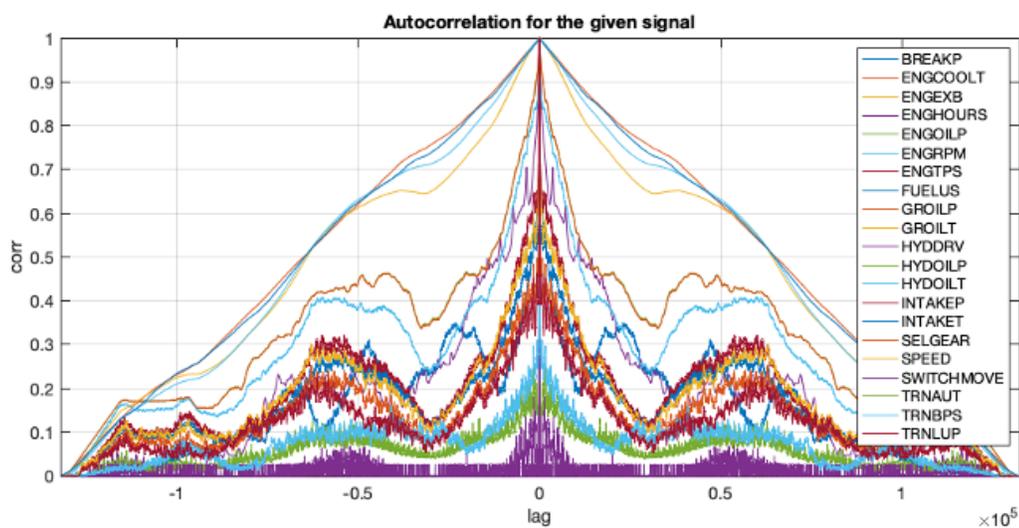
wykorzystującą inne rejestrowane zmienne fizyczne tj. obroty silnika, numer biegu, chwilowe zużycie paliwa, prędkość, jak również ciśnienie w układzie hamulcowym do wyznaczania cykli pracy wozu odstawczego. Zaproponowane zmienne są znacznie bardziej niezawodne i odporne na zakłócenia. Ogólny zarys algorytmu przedstawiono na Rys. 47.



Rysunek 47: Schemat blokowy analizy danych z pokładowego systemu monitorowania wozu odstawczego [A11]

W pracy [A11] zaproponowano uniwersalną procedurę doboru zmiennych do identyfikacji cykli operacyjnych. Główne założenie to cykliczność procesu. Spodziewamy się powtarzającego wzorca zachowań w obserwowanych danych. Jest to wyraźnie widoczne w danych dotyczących ciśnienia oleju hydraulicznego (HYDOILP, Tab. 2). Jednak jak wspomniano, ze względu na bardzo trudne warunki panujące w kopalni, ten kanał pomiarowy jest często uszkodzony i istnieje potrzeba zastąpienia tej zmiennej. W związku z tym, aby znaleźć oczekiwany wzorec cykliczny, który mógłby skutecznie zastąpić dotychczas wykorzystywany wskaźnik HYDOILP zaproponowano wykorzystanie funkcji autokorelacji (ang. autocorrelation function - ACF) do zbadania zależności w danych z pokładowego

systemu monitorującego. Oceniono podobieństwa w zmienności funkcjach autokorelacji dla wszystkich zmiennych i na podstawie zaproponowanego kryterium energetycznego (błąd średniokwadratowy residuów HYDOILP i pozostałych danych) dokonano wstępnej selekcji zmiennych. Przykładowy wynik funkcji dla rozważanych zmiennych został zaprezentowany na Rys. 48. Na tej podstawie wyselekcjonowano 11 zmiennych o podobnej charakterystyce



Rysunek 48: Znormalizowane funkcje autokorelacji (ACF) dla wszystkich rozważanych sygnałów [A11]

funkcji ACF. Należy podkreślić, że podobna zmienność funkcji ACF nie oznacza dokładnego podobieństwa sygnału - mogą być one przesunięte w czasie i mieć ten sam cykliczny charakter. W związku z tym zaproponowano kolejny etap przetwarzania. Drugi etap procedury opiera się na pewnych założeniach inżynierskich związanych z wiedzą o procesie pracy maszyny. Założono, że proces rozładunku wymaga maszyny o nieruchomej pozycji (zerowa prędkość jazdy) i jest to (ze względów bezpieczeństwa) związane z wykorzystaniem biegu neutralnego (parametr SELGEAR = 0). Aby rozładować wóz odstawczy, należy rozładować rudę ze skrzyni wozu odstawczego, więc można się spodziewać pewnego zużycia paliwa (przyjęto je jako  $>10\%$  maksymalnego zużycia paliwa podczas zmiany). Te trzy założenia pozwoliły na dokładniejszą selektywność co pozwoliło zaobserwować że ciśnienie hamowania i położenie pedału hamulca (BREAKP i TRNBPS) oraz chwilowe zużycie paliwa, odchylenie pedału gazu i ciśnienie doładowania silnika (FUELUS, ENGTPS, INTAKEP) są od siebie zależne i wykazują podobną zmienność. Wydaje się oczywiste, że ciśnienie hamowania i położenie pedału hamulca są liniowo zależne, podobnie jak zużycie paliwa, ciśnienie doładowania silnika

i wychylenie pedału gazu. Ostatecznie do identyfikacji reżimów pracy wozu odstawczego zaproponowano wykorzystanie następujących zmiennych: prędkość, numer biegu oraz jeden ze wskaźników: (BREAKP, TRNBPS, FUELUS, ENGTSP, INTAKEP).

Przeprowadzone badania skutecznie zidentyfikowały alternatywne parametry (zmiennie) z pokładowego systemu monitorowania maszyn do wyznaczania cykli pracy wozu odstawczego. Algorytm doboru zmiennych jest uniwersalny i może być ponownie wykorzystany w sytuacji kiedy rejestrowanych zmiennych fizycznych będzie więcej.

#### **4.4.2 Analiza drgań maszyny podczas eksploatacji w kopalni głębinowej**

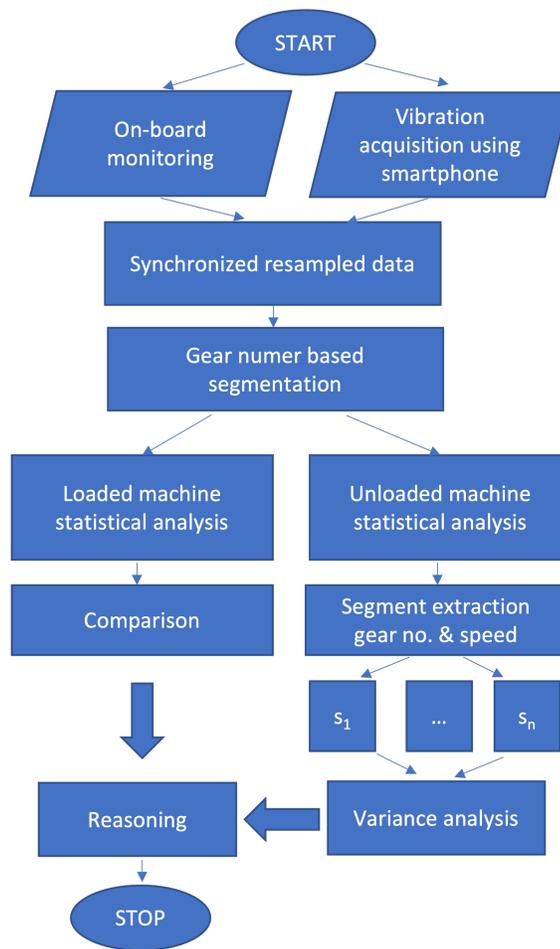
Jednym z celów przeprowadzonych badań było zbadanie jakości dróg w kopalni podziemnej. W przeprowadzonych badaniach ujętych w artykułach [A10, A12] podjęto próbę identyfikacji zmiany jakości nawierzchni jezdnej w kopalni podziemnej na podstawie wzbudzenia zewnętrznego maszyny. Wzbudzenie zewnętrzne może być również związane z ładunkiem (masa materiału przewożonego przez wozy odstawcze), parametrami pracy (prędkość, obroty, bieg), czynnikami środowiskowymi (błoto, woda), a także geometrią korytarza (wzniesienia, spadki, zakręty, skrzyżowania), jak również z umiejętnościami operatora. W związku z tym ocena jakości dróg jest utrudniona.

Na potrzeby przeprowadzenia analizy drgań w jednej z maszyn tj. wozie odstawczym, opisanym w rozdziale 4.5.1, zainstalowano przenośne urządzenie z systemem IMU (ang. inertial measurement unit) do akwizycji drgań, aby sprawdzić, czy możliwe jest doświadczalne określenie jakości nawierzchni dróg transportowych w kopalni.

W pierwszym kroku, w celu uproszczenia analizy wpływu jakości nawierzchni dróg transportowych na zewnętrzne wzbudzenia maszyny, zaproponowano wprowadzenie kontekstu numeru biegu - analizie poddano tylko dane uzyskane podczas jazdy na biegu numer 2 - najczęściej używanym biegu, co w znacznym stopniu uprościło analizę. Wykorzystanie innych zmiennych (prędkość, zużycie paliwa) jest skomplikowane ze względu na charakter zmienności tych parametrów, co zostało szczegółowo przedstawione w artykule [A10]. Ogólny zarys algorytmu przedstawiono na Rys. 49.

Szczegółowa analiza drgań (przyspieszenie mierzone w trzech kierunkach XYZ) pozwoliła na identyfikację pewnych podobieństw w zależności od lokalizacji. Przykładowe dane zostały zaprezentowane na Rys. 50.

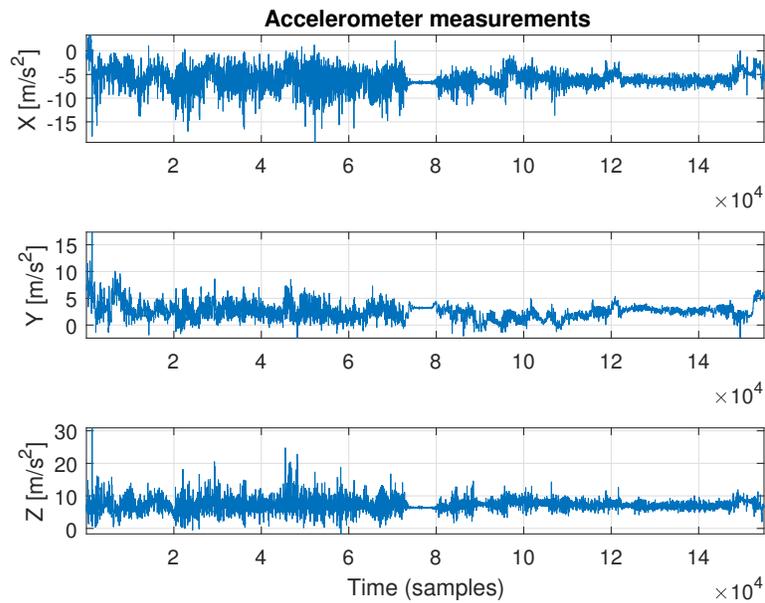
W badaniach ujętych w artykule [A10] wykazano, że w pobliżu przesiewacza górniczego drgania rejestrowane przez czujniki są mniejsze (w sensie wariancji drgań), natomiast w



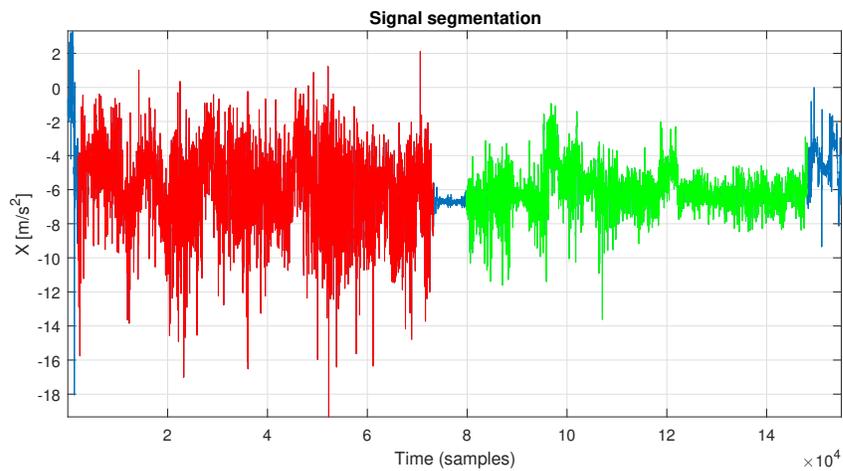
Rysunek 49: Schemat blokowy analizy danych z pokładowego systemu monitorowania wozu odstawczego [A10]

poblizu przodka górniczego są one znacznie intensywniejsze. Jest to związane z jakością drogi (bliżej przodka - gorsza jakość drogi). Badania wykazały również, że podstawowa analiza statystyczna nie jest w stanie rozpoznać różnic pomiędzy drganiami dla maszyny obciążonej i nieobciążonej.

Przeprowadzone badania [A10, A12] pokazały, że rozróżnienie jakości nawierzchni dróg transportowych w kopalni jest możliwe na podstawie analizy drgań obudowy maszyny wykorzystując analizę miar zróżnicowania drgań (tj. wariancję, rozstęp międzykwartyłowy - IQR). Przykładowy wynik dla drgań zaprezentowanych na Rys. 51 został przedstawiony na Rys. 52. W szczególności przedstawiono użyteczność wykresu pudełkowego (ang. box-plot) oraz gęstości empirycznej. Narzędzia te pozwalają ująć na jednym rysunku wiadomości dotyczące położenia, rozproszenia i kształtu rozkładu empirycznego badanej cechy.

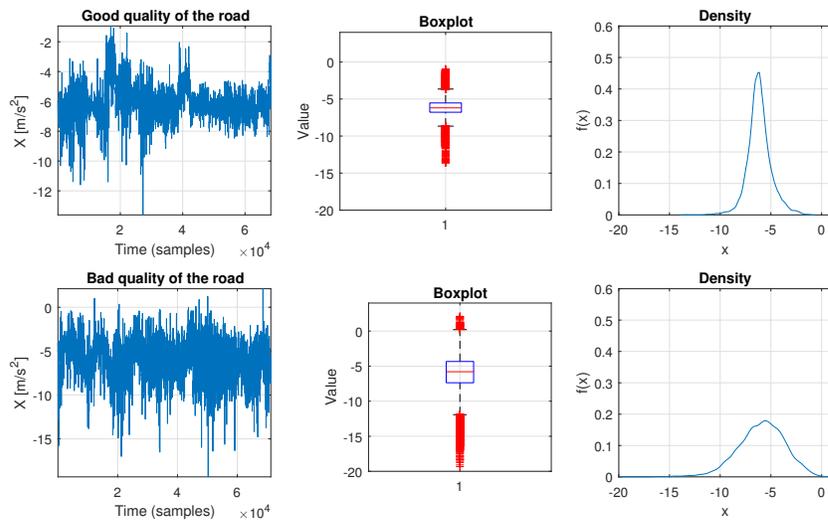


Rysunek 50: Przykład danych wibracyjnych z zewnętrznej obudowy maszyny, zmierzonych na wozie odstawczym w kopalni podziemnej KGHM [A12]



Rysunek 51: Przykład danych wibracyjnych z zewnętrznej obudowy maszyny, zmierzonych na wozie odstawczym w kopalni podziemnej KGHM [A12]

Informacja dotycząca jakości drogi jest ważna z punktu widzenia planowania utrzymania dróg w kopalni podziemnej oraz wykorzystania jej do innych analiz, np. zużycia paliwa przez SMG.



Rysunek 52: Przykład parametryzacji wybranych segmentów odpowiadającym różnej jakości nawierzchni dróg transportowych w kopalni [A12]

## 5 Wnioski

W ramach pracy badawczej przeprowadzono analizę danych kilku kluczowych obszarów górnictwa tj. diagnostyka wybranych elementów maszyn górniczych oraz monitorowanie efektywności pracy maszyn dołowych, wentylacja i zagrożenia gazowe oraz zagrożenia naturalne związane z aktywnością sejsmiczną. Każdy z wymienionych obszarów ma swoją niepowtarzalną specyfikę, ale wspólnym mianownikiem działań było zastosowanie zaawansowanych metod matematycznych (w szczególności statystycznych) do opisu procesów w górnictwie. Główna hipoteza badawcza została potwierdzona. **Procesy stochastyczne zostały z powodzeniem wykorzystane do opisu zjawisk zachodzących w górnictwie i geologii.** W szczególności zostały one wykorzystane w poprawie skuteczności wykrywania uszkodzeń w łóżysku w kruszarce rudy miedzi tj.:

1. Wykorzystanie warunkowej wariancji w algorytmie wykrywania uszkodzeń lokalnych w maszynach wykazało lepszą skuteczność od popularnych metod diagnostycznych, w szczególności dla sygnałów z niegaussowskim szumem co potwierdza hipotezę H1.
2. Zmodyfikowanie infogramu, poprzez zastosowanie alternatywnych miar uśredniania, poprawiło jego skuteczność diagnostyczną, w szczególności dla sygnałów z niegaussowskim szumem, co potwierdza hipotezę H2.
3. Alternatywne miary zależności (korelacja Spearmana, Kendalla oraz korelacja Quadrant) zostały skutecznie wykorzystywane do opracowania metody wskazującej informacyjne pasmo częstotliwości (mapy korelacji, mapy autopodobieństwa), co potwierdza hipotezę H3.
4. W badaniach wykazano, że spektralne nakładanie się pasm impulsów cyklicznych oraz niecyklicznych wpływa negatywnie na skuteczność wybranych procedur diagnostycznych (tj. selektor CVB, selektor Spearmana). W przypadku Alfa selektora nakładanie się pasm nie pogarsza jego skuteczności. Jednak ten selektor ma dużo mniejszą skuteczność w porównaniu do wyżej wspomnianych selektorów dla sygnałów w których impulsy niecykliczne mają wysoką energię. W badaniach szczegółowo przedstawiono dla jakich parametrów sygnału spektralne nakładanie się pasm impulsów informacyjnych i nieinformacyjnych zmienia skuteczność wybranych procedur diagnostycznych - co potwierdza hipotezę H4.

Główna hipoteza została również potwierdzona wynikami z przeprowadzonej analizy danych opisujących występujące zagrożenia gazowe w rozważanej kopalni podziemnej KGHM P.M S.A, oddział Polkowice-Sieroszowice. Analiza danych stężenia siarkowodoru umożliwiła zidentyfikowanie zależności pomiędzy pracą wentylatorów, a wielkością stężeń tego gazu. W badaniach wykazano, iż praca wentylatorów powoduje wytworzenie podciśnienia w wyrobiskach, co prowadzi do zwiększonego uwalniania siarkowodoru z górotworu i chwilowych skoków stężenia tego gazu, co potwierdza hipotezę H5. W badaniach zaproponowano dokładny model zmienności dobowego stężenia siarkowodoru, jak i dokładny model zmienności stężenia tlenu węgla związanego z procedurą strzałową. Co więcej, dzięki korelacji krzyżowej danych pochodzących z monitoringu zdarzeń sejsmicznych oraz danych dotyczących zmienności stężenia tlenu węgla wykazano, iż wykryte skoki stężenia CO (powyżej dopuszczalnego poziomu 26 ppm) są w większości związane z robotami strzałowymi, wykonanymi w tym czasie, w analizowanej kopalni rudy miedzi, co potwierdza hipotezę H6. Dzięki analizie statystycznej obliczono optymalny czas oczekiwania, który z prawdopodobieństwem 93% zapewnia bezpieczny poziom stężenia CO.

Założenie przedstawione w głównej hipotezie znalazło również potwierdzenie w uzyskanych wynikach badań w obszarze sejsmiki, w poprawie skuteczności wykrywania fal sejsmicznych rozchodzących się w kopalni. Kombinacja czasowo-częstotliwościowej reprezentacji sygnału i algorytmu PCA pozwoliła na bardziej precyzyjne wykrycie najszybszej fali sejsmicznej - fali P, w porównaniu do klasycznej metody LTA/STA, co potwierdza hipotezę H7.

W przypadku zarządzania efektywnością pracy samojezdnych maszyn dołowych analiza sygnału drganiowego z zewnętrznych komponentów wozu odstawczego, w zestawieniu z innymi parametrami pochodzącymi z pokładowego systemu monitorującego (tj. numer biegu), pozwoliła oszacować zmianę jakości nawierzchni, po której porusza się maszyna, co potwierdza hipotezę H8. Natomiast podstawowa analiza wskaźników dostępnych z pokładowego systemu monitorującego wozu odstawczego dostarczyła nowych kryteriów do wyznaczania cykli pracy wozu odstawczego, co potwierdza hipotezę H9. Do identyfikacji reżimów pracy wozu odstawczego zaproponowano wykorzystanie następujących zmiennych: prędkość, numer biegu oraz jeden z wskaźników: (BREAKP, TRNBPS, FUELUS, ENGTSP, INTAKEP), jako alternatywnych dla dotychczas stosowanej zmiennej HYDOILP.

Wszystkie przeprowadzone badania dają większą kontrolę nad trudnymi warunkami jakie panują w kopalniach co prowadzi do bezpieczniejszych warunków pracy i oszczędniejszego

trybu pracy. Jednakże aby wykorzystanie proponowanych algorytmów i modeli było możliwe w sposób w pełni zautomatyzowany, wymagane są dalsze badania, które pozwolą na bardziej złożone walidacje uwzględniające dużą zmienność warunków pracy panujących w kopalni.

Temat pracy badawczej umożliwił podjęcie współpracy z KGHM P.M. S.A. Dzięki temu, zdefiniowane problemy mają swoje źródło w realnych potrzebach górniczych. Interdyscyplinarność badań wymagała przede wszystkim zrozumienia istoty problemu i realiów pracy w kopalni, doboru odpowiednich technik analitycznych, modelowania procesów, przetwarzania danych, stanowiących mieszaninę procesów losowych i deterministyczny oraz interpretacji uzyskanych wyników. Przeprowadzone badania nie miały charakteru teoretycznego, metody badawcze zawsze odnosiły się do realnych problemów, danych rzeczywistych z kopalni, a wyniki badań wiążą się z możliwością ich wdrażania w kolejnych latach.

# Literatura

- [1] Tomasz Kaniewski, Paweł Śliwiński, Justyna Hebda-Sobkowicz, and Radosław Zimroz. Comprehensive, experimental verification of the effects of the lock-up function implementation in lhd haul trucks in the deep underground mine. In *Mining Goes Digital*, pages 506–514. CRC Press, 2019.
- [2] Justyna Hebda-Sobkowicz, Radosław Zimroz, Agnieszka Wyłomańska, and Sebastian Gola. Identification and statistical analysis of impulse-like patterns of carbon monoxide variation in deep underground mine. In *AIP Conference Proceedings*, volume 2209, page 020005. AIP Publishing LLC, 2020.
- [3] Piotr Kruczek, Norbert Gomolla, Justyna Hebda-Sobkowicz, Anna Michalak, Paweł Śliwiński, Jacek Wodecki, Paweł Stefaniak, Agnieszka Wyłomańska, and Radosław Zimroz. Predictive maintenance of mining machines using advanced data analysis system based on the cloud technology. In *Proceedings of the 27th International Symposium on Mine Planning and Equipment Selection-MPES 2018*, pages 459–470. Springer, 2019.
- [4] Jacek Wodecki, Justyna Hebda-Sobkowicz, Agnieszka Wyłomańska, Radosław Zimroz, and Konstantinos Gryllias. Application of principal component analysis of time-frequency representation for gearbox fault detection. *Vibroengineering Procedia*, 19:82–85, 2018.
- [5] Jacek Wodecki, Piotr Kruczek, Justyna Hebda-Sobkowicz, Agnieszka Wyłomańska, Radosław Zimroz, and Konstantinos Gryllias. Informative frequency band identification method using bi-frequency map clustering for fault detection in rotating machines. *Vibroengineering Procedia*, 19:86–90, 2018.

- [6] Ankit Singh, Dheeraj Kumar, and Jürgen Hötzel. Iot based information and communication system for enhancing underground mines safety and productivity: Genesis, taxonomy and open issues. *Ad Hoc Networks*, 78:115–129, 2018.
- [7] Franziska Günther, Helmut Mischo, Robert Lösch, Steve Grehl, and Frederic Güth. Increased safety in deep mining with iot and autonomous robots. In *Mining Goes Digital*, pages 603–611. CRC Press, 2019.
- [8] Byung Wan Jo and Rana Muhammad Asad Khan. An event reporting and early-warning safety system based on the internet of things for underground coal mines: A case study. *Applied Sciences*, 7(9):925, 2017.
- [9] Agnieszka Wyłomańska. How to identify the proper model. *Acta Physica Polonica B*, 43(5):1241–1253, 2012.
- [10] Tadeusz Andrzej Przylibski, Agnieszka Wyłomańska, Radosław Zimroz, and Lidia Fijałkowska-Lichwa. Application of spectral decomposition of  $^{222}\text{Rn}$  activity concentration signal series measured in niedźwiedzia cave to identification of mechanisms responsible for different time-period variations. *Applied Radiation and Isotopes*, 104:74–86, 2015.
- [11] Robert Hossa, Ryszard Makowski, and Radosław Zimroz. Automatic segmentation of seismic signal with support of innovative filtering. *International Journal of Rock Mechanics and Mining Sciences*, 91:29–39, 2017.
- [12] Andrzej Szczurek, Monika Maciejewska, Agnieszka Wyłomańska, Radosław Zimroz, Grzegorz Żak, and Anna Dolega. Detection of occupancy profile based on carbon dioxide concentration pattern matching. *Measurement*, 93:265–271, 2016.
- [13] Andrzej Szczurek, Monika Maciejewska, Rafał Połoczański, Marek Teuerle, and Agnieszka Wyłomańska. Dynamics of carbon dioxide concentration in indoor air. *Stochastic environmental research and risk assessment*, 29(8):2193–2199, 2015.
- [14] Andrzej Szczurek, Monika Maciejewska, Agnieszka Wyłomańska, Grzegorz Sikora, Michał Balcerek, and Marek Teuerle. Normal and anomalous diffusion in fluctuations of dust concentration nearby emission source. *Physica A: Statistical Mechanics and its Applications*, 491:619–631, 2018.

- [15] Gaofeng Song and Shengli Yang. Probability and reliability analysis of pillar stability in south africa. *International Journal of Mining Science and Technology*, 28(4):715–719, 2018.
- [16] Liu Cheng, Li Shugang, and Yang Shouguo. Gas emission quantity prediction and drainage technology of steeply inclined and extremely thick coal seams. *International Journal of Mining Science and Technology*, 28(3):415–422, 2018.
- [17] Zongchang Yang and Shaowu Zhou. Modeling and prediction of daily gas concentration variation at a mining face based on the elliptic orbit model: A case study. *International Journal of Mining Science and Technology*, 25(6):1045–1052, 2015.
- [18] Hongqing Zhu, Mingran Chang, and Haiyan Wang. Study on primal CO gas generation and emission of coal seam. *International Journal of Mining Science and Technology*, 27(6):973–979, 2017.
- [19] Jiabo Geng, Jiang Xu, Wen Nie, Shoujian Peng, Chaolin Zhang, and Xiaohang Luo. Regression analysis of major parameters affecting the intensity of coal and gas outbursts in laboratory. *International Journal of Mining Science and Technology*, 27(2):327–332, 2017.
- [20] Shulei Shi, Bingyou Jiang, and Xiangrui Meng. Assessment of gas and dust explosion in coal mines by means of fuzzy fault tree analysis. *International Journal of Mining Science and Technology*, 2018.
- [21] Joao Felipe Costa and Roussos Dimitrakopoulos. A conditional fractal (fbm) simulation approach for orebody modelling. *International Journal of Surface Mining, Reclamation and Environment*, 12(4):197–202, 1998.
- [22] Andrew Darnell, Richard Wise, and John Quaranta. Probabilistic modeling of shale gas containment pits for environmental and safety management. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 38(4):503–511, 2016.
- [23] Robert R Britton. Using the general linear procedures model in blasting research. *International Journal of Surface Mining, Reclamation and Environment*, 2(4):227–236, 1988.

- [24] Robert Bond Randall and Jerome Antoni. Rolling element bearing diagnostics – a tutorial. *Mechanical Systems and Signal Processing*, 25(2):485–520, 2011.
- [25] Andrew KS Jardine, Daming Lin, and Dragan Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7):1483–1510, 2006.
- [26] Yanxue Wang, Jiawei Xiang, Richard Markert, and Ming Liang. Spectral kurtosis for fault detection, diagnosis and prognostics of rotating machines: A review with applications. *Mechanical Systems and Signal Processing*, 66:679–698, 2016.
- [27] Agnieszka Wyłomańska, Radosław Zimroz, Joanna Janczura, and Jakub Obuchowski. Impulsive noise cancellation method for copper ore crusher vibration signals enhancement. *IEEE Transactions on Industrial Electronics*, 63(9):5612–5621, 2016.
- [28] Jakub Obuchowski, Radosław Zimroz, and Agnieszka Wyłomańska. Identification of cyclic components in presence of non-gaussian noise—application to crusher bearings damage detection. *Journal of Vibroengineering*, 17(3), 2015.
- [29] Grzegorz Żak, Marek Teuerle, Agnieszka Wyłomańska, and Radosław Zimroz. Measures of dependence for  $\alpha$ -stable distributed processes and its application to diagnostics of local damage in presence of impulsive noise. *Shock and Vibration*, 2017:1963769, 2017.
- [30] Grzegorz Żak, Agnieszka Wyłomańska, and Radosław Zimroz. Application of alpha-stable distribution approach for local damage detection in rotating machines. *Journal of Vibroengineering*, 17(6):2987–3002, 2015.
- [31] Jerome Antoni and Robert Bond Randall. The spectral kurtosis: application to the vibratory surveillance and diagnostics of rotating machines. *Mechanical Systems and Signal Processing*, 20(2):308–331, 2006.
- [32] Robert Bond Randall, Jerome Antoni, and S Chobsaard. The relationship between spectral correlation and envelope analysis in the diagnostics of bearing faults and other cyclostationary machine signals. *Mechanical Systems and Signal Processing*, 15(5): 945–962, 2001.

- [33] Tomasz Barszcz and Adam Jabłoński. A novel method for the optimal band selection for vibration signal demodulation and comparison with the kurtogram. *Mechanical Systems and Signal Processing*, 25(1):431 – 451, 2011. ISSN 0888-3270.
- [34] Tomasz Figlus and Marcin Stańczyk. A method for detecting damage to rolling bearings in toothed gears of processing lines. *Metalurgija*, 55(1):75–78, 2016.
- [35] Pietro Borghesani and Md Rifat Shahriar. Cyclostationary analysis with logarithmic variance stabilisation. *Mechanical Systems and Signal Processing*, 70:51–72, 2016.
- [36] ZK Peng and FL Chu. Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. *Mechanical systems and signal processing*, 18(2):199–221, 2004.
- [37] Ruqiang Yan, Robert X Gao, and Xuefeng Chen. Wavelets for fault diagnosis of rotary machines: A review with applications. *Signal processing*, 96:1–15, 2014.
- [38] Tomasz Figlus, Štefan Liščák, Andrzej Wilk, and Bogusław Łazarz. Condition monitoring of engine timing system by using wavelet packet decomposition of a acoustic signal. *Journal of mechanical science and technology*, 28(5):1663–1671, 2014.
- [39] Piotr Czech, Grzegorz Wojnar, Rafał Burdzik, Łukasz Konieczny, and Jan Warczek. Application of the discrete wavelet transform and probabilistic neural networks in ic engine fault diagnostics. *Journal of Vibroengineering*, 16(4):1619–1639, 2014.
- [40] Rafał Burdzik, Łukasz Konieczny, and Tomasz Figlus. Concept of on-board comfort vibration monitoring system for vehicles. In *International Conference on Transport Systems Telematics*, pages 418–425. Springer, 2013.
- [41] Christian Pachaud, R Salvetat, and C Fray. Crest factor and kurtosis contributions to identify defects inducing periodical impulsive forces. *Mechanical Systems and Signal Processing*, 11(6):903–916, 1997.
- [42] Jakub Obuchowski, Agnieszka Wylomańska, and Radosław Zimroz. Selection of informative frequency band in local damage detection in rotating machinery. *Mechanical Systems and Signal Processing*, 48(1-2):138–152, 2014.

- [43] Dong Wang. Some further thoughts about spectral kurtosis, spectral l2/l1 norm, spectral smoothness index and spectral gini index for characterizing repetitive transients. *Mechanical Systems and Signal Processing*, 108:360–368, 2018.
- [44] Yonghao Miao, Ming Zhao, and Jing Lin. Improvement of kurtosis-guided-grams via gini index for bearing fault feature identification. *Measurement Science and Technology*, 28(12):125001, 2017.
- [45] Jerome Antoni. The infogram: Entropic evidence of the signature of repetitive transients. *Mechanical Systems and Signal Processing*, 74:73–94, 2016.
- [46] Chuan Li, Diego Cabrera, José Valente de Oliveira, René-Vinicio Sanchez, Mariela Cerrada, and Grover Zurita. Extracting repetitive transients for rotating machinery diagnosis using multiscale clustered grey infogram. *Mechanical Systems and Signal Processing*, 76:157–173, 2016.
- [47] Zhiliang Liu, Yaqiang Jin, Ming J Zuo, and Dandan Peng. Accugram: A novel approach based on classification to frequency band selection for rotating machinery fault diagnosis. *ISA transactions*, 95:346–357, 2019.
- [48] Giacinto Gelli, Luciano Izzo, and Luigi Paura. Cyclostationarity-based signal detection and source location in non-gaussian noise. *IEEE Transactions on Communications*, 44(3):368–376, 1996.
- [49] Gang Yu, Changning Li, and Jianfeng Zhang. A new statistical modeling and detection method for rolling element bearing faults based on alpha-stable distribution. *Mechanical Systems and Signal Processing*, 41(1-2):155–175, 2013.
- [50] Jacek Wodecki, Anna Michalak, and Radosław Zimroz. Optimal filter design with progressive genetic algorithm for local damage detection in rolling bearings. *Mechanical Systems and Signal Processing*, 102:102–116, 2018.
- [51] Piotr Kruczek, Radosław Zimroz, and Agnieszka Wyłomańska. How to detect the cyclostationarity in heavy-tailed distributed signals. *Signal Processing*, page 107514, 2020.
- [52] Fakher Chaari, Jacek Leskow, Antonio Napolitane, Radosław Zimroz, and Agnieszka Wyłomańska. *Cyclostationarity: Theory and Methods–IV*. Springer, 2020.

- [53] Pietro Borghesani and Jerome Antoni. Cs2 analysis in presence of non-gaussian background noise—effect on traditional estimators and resilience of log-envelope indicators. *Mechanical Systems and Signal Processing*, 90:378–398, 2017.
- [54] Jarmo Lundén, Saleem A Kassam, and Visa Koivunen. Robust nonparametric cyclic correlation-based spectrum sensing for cognitive radio. *IEEE Transactions on Signal Processing*, 58(1):38–52, 2009.
- [55] Victor Girondin, Komi Midzodzi Pekpe, Herve Morel, and Jean-Philippe Cassar. Bearings fault detection in helicopters using frequency readjustment and cyclostationary analysis. *Mechanical Systems and Signal Processing*, 38(2):499–514, 2013.
- [56] Antonio Napolitano. Cyclostationarity: New trends and applications. *Signal Processing*, 120:385–408, 2016.
- [57] Jerome Antoni. Cyclostationarity by examples. *Mechanical Systems and Signal Processing*, 23(4):987–1036, 2009.
- [58] Piotr Kruczek, Radosław Zimroz, and Agnieszka Wyłomańska. How to detect the cyclostationarity in heavy-tailed distributed signals. *Signal Processing*, page 107514, 2020.
- [59] Udit Satija, Madhusmita Mohanty, and Barathram Ramkumar. Cyclostationary features based modulation classification in presence of non gaussian noise using sparse signal decomposition. *Wireless Personal Communications*, 96(4):5723–5741, 2017.
- [60] Yang Liu, Qiong Wu, Yinghui Zhang, Jing Gao, and Tianshuang Qiu. Cyclostationarity-based doa estimation algorithms for coherent signals in impulsive noise environments. *EURASIP Journal on Wireless Communications and Networking*, 2019(1):81, 2019.
- [61] Yang Liu, Tianshuang Qiu, and Hu Sheng. Time-difference-of-arrival estimation algorithms for cyclostationary signals in impulsive noise. *Signal Processing*, 92(9): 2238–2247, 2012.

- [62] ZS Chen, YM Yang, Z Hu, and GJ Shen. Detecting and predicting early faults of complex rotating machinery based on cyclostationary time series model. *Vibration and acoustics*, 128(5), 2006.
- [63] Xuejun Zhao, Yong Qin, Changbo He, Limin Jia, and Linlin Kou. Rolling element bearing fault diagnosis under impulsive noise environment based on cyclic correntropy spectrum. *Entropy*, 21(1):50, 2019.
- [64] Thomas E Biedka, Lamine Mili, and Jeffrey H Reed. Robust estimation of cyclic correlation in contaminated gaussian noise. In *Conference Record of the Twenty-Ninth Asilomar Conference on Signals, Systems and Computers*, volume 1, pages 511–515. IEEE, 1996.
- [65] Xinyu Ma and Chrysostomos L Nikias. Joint estimation of time delay and frequency delay in impulsive noise using fractional lower order statistics. *IEEE Transactions on Signal Processing*, 44(11):2669–2687, 1996.
- [66] Vladimir Katkovnik. Robust m-periodogram. *IEEE Transactions on Signal processing*, 46(11):3104–3109, 1998.
- [67] Jong-Hoon Jeon and Yang-Hann Kim. Localization of moving periodic impulsive source in a noisy environment. *Mechanical Systems and Signal Processing*, 22(3):753–759, 2008.
- [68] Ruonan Liu, Boyuan Yang, Enrico Zio, and Xuefeng Chen. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 108:33–47, 2018.
- [69] Yang Zhao, Tingting Li, Xuejun Zhang, and Chaobo Zhang. Artificial intelligence-based fault detection and diagnosis methods for building energy systems: Advantages, challenges and the future. *Renewable and Sustainable Energy Reviews*, 109:85–101, 2019.
- [70] Mateusz Kudasik and Norbert Skoczylas. Analyzer for measuring gas contained in the pore space of rocks. *Measurement Science and Technology*, 28(10):105–901, 2017.
- [71] Mirosław Wierzbicki and Mariusz Młynarczuk. Structural aspects of gas and dolomite outburst in rudna copper mine, poland. *International Journal of Rock Mechanics and Mining Sciences*, (57):113–118, 2013.

- [72] Anna Pajdak, Katarzyna Godyń, Mateusz Kudasik, and Tomasz Murzyn. The use of selected research methods to describe the pore space of dolomite from copper ore mine, poland. *Environmental Earth Sciences*, 76(11):389, 2017.
- [73] Norbert Skoczylas. Estimating gas and rock outburst risk on the basis of knowledge and experience—the expert system based on fuzzy logic. *Archives of Mining Sciences*, 59(1):41–52, 2014.
- [74] Byung Wan Jo and Rana Muhammad Asad Khan. An internet of things system for underground mine air quality pollutant prediction based on azure machine learning. *Sensors*, 18(4):930, 2018.
- [75] Magdalena Tutak, Jarosław Brodny, Dawid Szurgacz, Leszek Sobik, and Sergey Zhironkin. The impact of the ventilation system on the methane release hazard and spontaneous combustion of coal in the area of exploitation—a case study. *Energies*, 13(18):4891, 2020.
- [76] Bogusław Ptaszyński. Carbon dioxide concentration in mine workings. *Górnictwo i Geoinżynieria*, 30:47–59, 2006.
- [77] Jan Wachowicz. Analysis of underground fires in polish hard coal mines. *Journal of China University of Mining and Technology*, 18(3):332–336, 2008.
- [78] Leszek Les W Lunarzewski. Gas emission prediction and recovery in underground coal mines. *International Journal of Coal Geology*, 35(1-4):117–145, 1998.
- [79] Antoni Tajduś, Marek Cała, and Krzysztof Tajduś. Seismicity and rock burst hazard assessment in fault zones: a case study. *Archives of Mining Sciences*, 63(3):747–765, 2018.
- [80] Grzegorz Mutke, Józef Dubiński, and Adam Lurka. New criteria to assess seismic and rock burst hazard in coal mines. *Archives of Mining Sciences*, 60(3):743–760, 2015.
- [81] Dariusz Chlebowski, Zbigniew Burtan, and Andrzej Zorychta. Evaluation of rockburst hazard under abandoned mine workings. *Archives of Mining Sciences*, 2018.
- [82] Anna Gogolewska and Piotr Junik. Seismic hazard related to rate of face advance in lubin copper ore mine. *Mining Science*, 20:87–99, 2013. doi: 10.5277/gig132007. URL <http://dx.doi.org/10.5277/gig132007>.

- [83] Mark Leonard. Comparison of manual and automatic onset time picking. *Bulletin of the Seismological Society of America*, 90(6):1384–1390, 2000.
- [84] Haijiang Zhang, Clifford Thurber, and Charlotte Rowe. Automatic p-wave arrival detection and picking with multiscale wavelet analysis for single-component recordings. *Bulletin of the Seismological Society of America*, 93(5):1904–1912, 2003.
- [85] Stefania Gentili and Alberto Michelini. Automatic picking of p and s phases using a neural tree. *Journal of Seismology*, 10(1):39–63, 2006.
- [86] Costas Panagiotakis, Eleni Kokinou, and Filippos Vallianatos. Automatic p-phase picking based on local-maxima distribution. *IEEE Transactions on Geoscience and Remote Sensing*, 46(8):2280–2287, 2008.
- [87] Es-Saïd Akhouayri, Dris Agliz, Abderrahman Atmani, et al. Automatic detection and picking of p-wave arrival in locally stationary noise using cross-correlation. *Digital Signal Processing*, 26:87–100, 2014.
- [88] Rex V Allen. Automatic earthquake recognition and timing from single traces. *Bulletin of the Seismological Society of America*, 68(5):1521–1532, 1978.
- [89] Jin Wang and Ta-Liang Teng. Artificial neural network-based seismic detector. *Bulletin of the Seismological Society of America*, 85(1):308–319, 1995.
- [90] Reinoud Sleeman and Torild van Eck. Robust automatic p-phase picking: an on-line implementation in the analysis of broadband seismogram recordings. *Physics of the earth and planetary interiors*, 113(1):265–275, 1999.
- [91] Mark Leonard and Brian Kennett. Multi-component autoregressive techniques for the analysis of seismograms. *Physics of the Earth and Planetary Interiors*, 113(1):247–263, 1999.
- [92] Mitchell Withers, Richard Aster, Christopher Young, Judy Beiriger, Mark Harris, Susan Moore, and Julian Trujillo. A comparison of select trigger algorithms for automated global seismic phase and event detection. *Bulletin of the Seismological Society of America*, 88(1):95–106, 1998.

- [93] Jakub Sokołowski, Jakub Obuchowski, Radosław Zimroz, and Agnieszka Wyłomańska. Comparison of recent p-wave arrival picking methods. In *16th International Multidisciplinary Scientific GeoConference SGEM 2016*, volume 2, pages 133–140. SGEM2016 Conference Proceedings, 2016.
- [94] Jiangjing Zhang, Yalei Tang, and Hongjie Li. Sta/lta fractal dimension algorithm of detecting the p-wave arrival. *Bulletin of the Seismological Society of America*, 108(1):230–237, 2018.
- [95] Choi Hun. Automatic seismic p-wave detection algorithm using variations of impact momentum. *The Transactions of The Korean Institute of Electrical Engineers*, 67(7): 884–891, Jul 2018. doi: 10.5370/KIEE. URL <http://dx.doi.org/10.5370/KIEE>.
- [96] Junhyeon Kwon, Taemin Heo, Jae Kwan Kim, and Hee-Seok Oh. A new p-wave detector via moving empirical cumulative distribution function. *Bulletin of the Seismological Society of America*, 108(4):2080–2089, 2018.
- [97] Meng Li, Huifeng Li, Guo Tao, Mohammed Ali, and Yuhua Guo. Microseismic event location using multi-scale time reversed imaging. *Journal of Petroleum Science and Engineering*, 174:144–160, 2019.
- [98] Yijun Zhang, Qiang Chen, Xianwen Liu, Jingjing Zhao, Qian Xu, Yinghui Yang, and Guoxiang Liu. Adaptive and automatic p-and s-phase pickers based on frequency spectrum variation of sliding time windows. *Geophysical Journal International*, 215(3): 2172–2182, 2018.
- [99] Xu Wang, Jihua Fu, Chengpei Tang, Zhitao Li, and Jianjun Wang. Ap waves’ automatic picking by detecting the changes of seismic signals’ stationary random process through similarity analysis. *Soil Dynamics and Earthquake Engineering*, 115:225–231, 2018.
- [100] Nurhaida, Subanar, Abdurakhman, and Agus Maman Abadi. Detecting p and s-wave of mt. rinjani seismic based on a locally stationary autoregressive (lsar) model. In *AIP Conference Proceedings*, volume 1868, page 040006. AIP Publishing, 2017.
- [101] Jakub Sokołowski, Jakub Obuchowski, Radosław Zimroz, Agnieszka Wyłomańska, and Eugeniusz Koziarz. Algorithm indicating moment of p-wave arrival based

on second-moment characteristic. *Shock and Vibration*, 2016:1–6, 2016. URL <https://doi.org/10.1155/2016/4051701>. Art. ID 4051701.

- [102] Gou Xiantai, Li Zhimin, Qin Na, and Jin Weidong. Adaptive picking of microseismic event arrival using a power spectrum envelope. *Computers & geosciences*, 37(2): 158–164, 2011.
- [103] CH Chen. On a segmentation algorithm for seismic signal analysis. *Geoexploration*, 23 (1):35–40, 1984.
- [104] Robert Hossa, Ryszard Makowski, and Radosław Zimroz. Automatic segmentation of seismic signal with support of innovative filtering. *International Journal of Rock Mechanics and Mining Sciences*, 91:29–39, 2017.
- [105] Radosław Zimroz, Maciej Madziarz, Grzegorz Żak, Agnieszka Wyłomańska, and Jakub Obuchowski. Seismic signal segmentation procedure using time-frequency decomposition and statistical modelling. *Journal of VibroEngineering*, 17(6):3111–3121, 2015.
- [106] Daniel Kucharczyk, Agnieszka Wyłomańska, Jakub Obuchowski, Radosław Zimroz, and Maciej Madziarz. Stochastic modelling as a tool for seismic signals segmentation. *Shock and Vibration*, 2016:1–13, 2016. Art. ID 8453426.
- [107] Theodor D Popescu. Signal segmentation using changing regression models with application in seismic engineering. *Digital Signal Processing*, 24:14–26, 2014.
- [108] Theodor D Popescu and Dorel Aiordachioaie. Signal segmentation in time-frequency plane using renyi entropy-application in seismic signal processing. In *Control and Fault-Tolerant Systems (SysTol), 2013 Conference on*, pages 312–317. IEEE, 2013.
- [109] Erion-Vasilis Pikoulis and Emmanouil Z Psarakis. A new automatic method for seismic signals segmentation. In *Acoustics, Speech and Signal Processing (ICASSP), 2012 IEEE International Conference on*, pages 3973–3976. IEEE, 2012.
- [110] Daniel Kucharczyk, Agnieszka Wyłomańska, and Radosław Zimroz. Structural break detection method based on the adaptive regression splines technique. *Physica A: Statistical Mechanics and its Applications*, 471:499–511, 2017.

- [111] Hamed Azami, Saeid Sanei, Karim Mohammadi, and Hamid Hassanpour. A hybrid evolutionary approach to segmentation of non-stationary signals. *Digital Signal Processing*, 23(4):1103–1114, 2013.
- [112] Janusz Gajda, Grzegorz Sikora, and Agnieszka Wyłomańska. Regime variance testing—a quantile approach. *Acta Phys. Polon B*, 44(5):1015–1035, 2013.
- [113] Agnieszka Wyłomańska and Radosław Zimroz. Signal segmentation for operational regimes detection of heavy duty mining mobile machines—a statistical approach. *Diagnostyka*, 15(2):33–42, 2014.
- [114] Dawid Szurgacz and Jarosław Brodny. Innovative visualization system designed to monitor parameters of mining systems operation. *Multidisciplinary Aspects of Production Engineering*, 1, 2018.
- [115] Jordan McBain and Markus Timusk. Software architecture for condition monitoring of mobile underground mining machinery: A framework extensible to intelligent signal processing and analysis. In *2012 IEEE Conference on Prognostics and Health Management*, pages 1–12. IEEE, 2012.
- [116] J Kicki and Artur Dyczko. The concept of automation and monitoring of the production process in an underground mine. *New Techniques and Technologies in Mining—Proceedings of the School of Underground Mining*, R. Dychkovskyy (eds.), Taylor & Francis, London, pages 245–253, 2010.
- [117] Anna Gustafson, Håkan Schunnesson, Diego Galar, and Uday Kumar. The influence of the operating environment on manual and automated load-haul-dump machines: a fault tree analysis. *International Journal of Mining, Reclamation and Environment*, 27(2):75–87, 2013.
- [118] Radosław Zimroz, Jacek Wodecki, Robert Król, Marek Andrzejewski, Paweł Śliwiński, and Paweł Stefaniak. Self-propelled mining machine monitoring system—data validation, processing and analysis. In *Mine planning and equipment selection*, pages 1285–1294. Springer, 2014.
- [119] Paweł Kępski and Tomasz Barszcz. Validation of vibration signals for diagnostics of mining machinery. *Diagnostyka*, pages 25–30, 2012.

- [120] Paweł Stefaniak, Radosław Zimroz, Jakub Obuchowski, Paweł Śliwiński, and Marek Andrzejewski. An effectiveness indicator for a mining loader based on the pressure signal measured at a bucket's hydraulic cylinder. *Procedia Earth and Planetary Science*, 15:797–805, 2015.
- [121] RJ Thompson, AT Visser, PS Heyns, and D Hugo. Mine road maintenance management using haul truck response measurements. *Mining Technology*, 115(4):123–128, 2006.
- [122] Huaijun Wang, Na Huo, Junhuai Li, Kan Wang, and Zhixiao Wang. A road quality detection method based on the mahalanobis-taguchi system. *IEEE Access*, 6:29078–29087, 2018.
- [123] Jakob Eriksson, Lewis Girod, Bret Hull, Ryan Newton, Samuel Madden, and Hari Balakrishnan. The pothole patrol: using a mobile sensor network for road surface monitoring. In *Proceedings of the 6th international conference on Mobile systems, applications, and services*, pages 29–39, 2008.
- [124] Gang Yu, Changning Li, and Jianfeng Zhang. A new statistical modeling and detection method for rolling element bearing faults based on alpha-stable distribution. *Mechanical Systems and Signal Processing*, 41(1-2):155–175, 2013.
- [125] Jerome Antoni. The spectral kurtosis: a useful tool for characterising non-stationary signals. *Mechanical Systems and Signal Processing*, 20(2):282–307, 2006.
- [126] Jerome Antoni. Fast computation of the kurtogram for the detection of transient faults. *Mechanical Systems and Signal Processing*, 21(1):108–124, 2007.
- [127] Boualem Boashash. *Time-frequency signal analysis and processing: a comprehensive reference*. Academic Press, 2015.
- [128] Jacek Wodecki, Piotr Kruczek, Anna Bartkowiak, Radosław Zimroz, and Agnieszka Wyłomańska. Novel method of informative frequency band selection for vibration signal using nonnegative matrix factorization of spectrogram matrix. *Mechanical Systems and Signal Processing*, 130:585–596, 2019.
- [129] Damian Jelito and Marcin Pitera. New fat-tail normality test based on conditional second moments with applications to finance. *Available at SSRN 3303132*, 2018.

- [130] Piotr Jaworski and Marcin Pitera. The 20-60-20 rule. *Discrete & Continuous Dynamical Systems-Series B*, 21(4), 2016.
- [131] Ali Moshrefzadeh and Alessandro Fasana. The autogram: An effective approach for selecting the optimal demodulation band in rolling element bearings diagnosis. *Mechanical Systems and Signal Processing*, 105:294–318, 2018.
- [132] Olive Jean Dunn and Virginia A Clark. *Basic statistics: a primer for the biomedical sciences*. John Wiley & Sons, 2009.
- [133] Maurice G. Kendall and Jean Dickinson Gibbons. *Rank Correlation Methods*. Charles Griffin Book Series (5th ed.). Oxford: Oxford University Press, 1990.
- [134] Maurice G Kendall. A new measure of rank correlation. *Biometrika*, 30(1/2):81–93, 1938.
- [135] Joost CF de Winter, Samuel D Gosling, and Jeff Potter. Comparing the pearson and spearman correlation coefficients across distributions and sample sizes: A tutorial using simulations and empirical data. *Psychological methods*, 21(3):273, 2016.
- [136] Anthony J Bishara and James B Hittner. Testing the significance of a correlation with nonnormal data: comparison of pearson, spearman, transformation, and resampling approaches. *Psychological methods*, 17(3):399, 2012.
- [137] Sorana-Daniela Bolboaca and Lorentz Jäntschi. Pearson versus spearman, kendall’s tau correlation analysis on structure-activity relationships of biologic active compounds. *Leonardo Journal of Sciences*, 5(9):179–200, 2006.
- [138] Christophe Croux and Catherine Dehon. Influence functions of the spearman and kendall correlation measures. *Statistical methods & applications*, 19(4):497–515, 2010.
- [139] Marie-Therese Puth, Markus Neuhäuser, and Graeme D Ruxton. Effective use of spearman’s and kendall’s correlation coefficients for association between two measured traits. *Animal Behaviour*, 102:77–84, 2015.
- [140] Alexander Dürre, Roland Fried, and Tobias Liboschik. Robust estimation of (partial) autocorrelation. *Wiley Interdisciplinary Reviews: Computational Statistics*, 7(3): 205–222, 2015.

- [141] Renato Cordeiro de Amorim and Christian Hennig. Recovering the number of clusters in data sets with noise features using feature rescaling factors. *Information Sciences*, 324:126–145, 2015.
- [142] Bruce Moore. Principal component analysis in linear systems: Controllability, observability, and model reduction. *IEEE transactions on automatic control*, 26(1): 17–32, 1981.

# Spis rysunków

1	Symulowane sygnały drganiowe z łożyska kruszarki rudy miedzi [A6] . . . . .	21
2	Kruszarka młotkowa rudy miedzi [A2] . . . . .	22
3	Sygnał drganiowy z łożyska kruszarki rudy miedzi z dodanym lokalnym uszkodzeniem [A6] . . . . .	23
4	Spektrogram sygnału rzeczywistego [A6] . . . . .	24
5	Gęstość standardowego rozkładu gaussowskiego z zaznaczonymi podziałami odpowiadającymi Regule 20/60/20 [A1] . . . . .	25
6	Funkcja rozkładu prawdopodobieństwa dla rozkładu gaussowskiego $N(0, 1)$ z zaznaczonym podziałem na 7 podzbiorów [A1] . . . . .	27
7	Wyniki selekcji informacyjnego pasma częstotliwości dla sygnału s4 przez wybrane metody diagnostyczne tj. kurtoza widmowa, Alfa selektor, selektor CVB, kurtogram, spectral smoothenss selektor, Gini selektor, infogram [A6] .	29
8	Wyniki selekcji informacyjnego pasma częstotliwości dla rzeczywistego sygnału drganiowego przez wybrane metody diagnostyczne tj. kurtoza widmowa, Alfa selektor, selektor CVB, kurtogram, spectral smoothenss selektor, Gini selektor, infogram [A6] . . . . .	30
9	Symulacje Monte Carlo wartości indykatora ENVSI dla różnych wartości współczynnika CNI . . . . .	32
10	Symulacje Monte Carlo wartości indykatora ENVSI dla różnych wartości amplitudy ( $ANCI$ ), jak również dla zmiennej wartości współczynnika $\overline{FIM}_2/FIM_1$ . . . . .	33
11	Podsumowanie wyników selekcji IFB dla sygnału symulowanego s4, z wykorzystaniem klasycznego infogramu (a) i jego rozszerzonych wersji: log-infogram (b), g-infogram (c), norm-infogram (d), ln-norm-infogram (e), g-norm-infogram (f) [A2] . . . . .	37

12	Uproszczona reprezentacja spektrogramu $S(t, f)$ [A8] . . . . .	38
13	Struktura mapy zależności dla podsygnałów $s_i$ ze spektrogramu i dla zadanej miary zależności $m(\cdot, \cdot)$ [A8] . . . . .	39
14	Sygnał symulowany odpowiadający sygnałowi drganiowemu z łożyska kruszarki rudy miedzi i jego spektrogram [A8] . . . . .	42
15	Mapy zależności dla symulowanych danych z kruszarki rudy miedzi wykorzystujące różne miary zależności [A8] . . . . .	42
16	Znormalizowane ulepszone selektory IFB dla danych symulowanych powstałe z map zależności wykorzystujących różne miary zależności [A8] . . . . .	43
17	Mapa autopodobieństwa Pearsona z wyróżnionymi czterema obszarami o charakterystycznym zachowaniu [A7] . . . . .	44
18	Mapy autopodobieństwa dla sygnału $s_4$ dla różnych miar zależności [A7] . .	47
19	Różne przypadki częstotliwości nośnej lokalnego uszkodzenia: bez nakładających się pasm częstotliwości nośnej impulsów cyklicznych i niecyklicznych (a), z częściowym nakładaniem się (b) i z pełnym nakładaniem się (c)-(d) [A4] . . . . .	48
20	Mapy ze średnimi wartościami wskaźnika ENVSI uzyskanymi w wyniku symulacji Monte Carlo [A4] . . . . .	50
21	System pomiarowy wykorzystany do monitorowania jakości powietrza w kopalni [A5] . . . . .	52
22	Dane stężenia $H_2S$ w kopalni podziemnej rud miedzi [A3] . . . . .	52
23	Dobowa zmienność stężenia $H_2S$ - 54 nakładające się na siebie segmenty dobowe [A3] . . . . .	53
24	Klasyfikacja - metoda nr 1 [A3] . . . . .	54
25	Dobowe segmenty (54) wraz z zaznaczonym 95%-owym przedziałem ufności [A3]	55
26	Przedział ufności przy różnych wartościach progów odcięcia (ang. cut-off thresholds - cot) - podsumowanie [A3] . . . . .	56
27	Macierz korelacji Spearmana dla rozważanych dobowych segmentów [A3] . .	56
28	Wektor ASC dla rozważanych dobowych segmentów wraz z unormowanym histogramem wartości ASC [A3] . . . . .	57
29	Klasyfikacja dobowych segmentów wykorzystująca wartości ASC i MSE [A3]	58

30	Wzorce dobowe zmienności wartości stężenia H <sub>2</sub> S uzyskane przez trzy niezależne metody wykorzystując m.in metodę k-means, przedziały ufności oraz macierz korelacji Spearmana [A3] . . . . .	58
31	Znormalizowany przepływ wentylacyjny powietrza (panel górny), znormalizowane stężenie H <sub>2</sub> S (panel środkowy) oraz korelacja krzyżowa między wzorcem H <sub>2</sub> S a przepływem wentylacyjnym (panel dolny) [A3] . . . .	59
32	Dobowy wzorec stężenia H <sub>2</sub> S i przesunięty, znormalizowany przepływ powietrza - porównanie [A3] . . . . .	60
33	Schemat blokowany dotyczący analizy danych stężenia H <sub>2</sub> S [A3] . . . . .	61
34	Dane stężenia CO w kopalni podziemnej rud miedzi [A5] . . . . .	62
35	Schemat opisujący zmienność stężenia gazu CO [A13] . . . . .	63
36	Walidacja wykrytych lokalnych maksimów stężenia CO, porównanie z danymi z systemu monitoringu sejsmicznego [A5] . . . . .	63
37	Rozproszenie amplitud wykrytych pików (panel a); ogon rozkładu empirycznego dla wielkości pików oraz ogon teoretyczny kilku dopasowanych rozkładów (panel b) [A5] . . . . .	65
38	Zarejestrowane piki nakładające się na siebie zgodnie z ustalonymi ramami czasowymi. Żółta pionowa linia wskazuje 30-minutowy czas oczekiwania po robotach strzałowych, a czerwona linia pozioma - bezpieczny poziom stężenia gazu [A5] . . . . .	66
39	Empiryczne rozkład prawdopodobieństwa czasu potrzebnego do zapewnienia bezpiecznego poziomu CO po zakończeniu robót strzałowych [A5] . . . . .	67
40	Schemat blokowany dot. analizy danych stężenia CO [A5] . . . . .	68
41	Sygnal rzeczywisty - dane sejsmiczne [A9] . . . . .	69
42	Spektrogram danych sejsmicznych [A9] . . . . .	70
43	Pierwsze trzy składowe PCA, przedstawiające 87%, 4% i 2% zmienności danych sejsmicznych [A9] . . . . .	71
44	Schemat blokowy analizy danych sejsmicznych [A9] . . . . .	72
45	Zdjęcie maszyny - wóz odstawczy CB4-20TB wykorzystywany w kopalni rudy miedzi KGHM [A10] . . . . .	74
46	Przykład danych rzeczywistych pochodzących z wozu odstawczego z jednej zmiany roboczej [A11] . . . . .	76

47	Schemat blokowy analizy danych z pokładowego systemu monitorowania wozu odstawczego [A11] . . . . .	77
48	Znormalizowane funkcje autokorelacji (ACF) dla wszystkich rozważanych sygnałów [A11] . . . . .	78
49	Schemat blokowy analizy danych z pokładowego systemu monitorowania wozu odstawczego [A10] . . . . .	80
50	Przykład danych wibracyjnych z zewnętrznej obudowy maszyny, zmierzonych na wozie odstawczym w kopalni podziemnej KGHM [A12] . . . . .	81
51	Przykład danych wibracyjnych z zewnętrznej obudowy maszyny, zmierzonych na wozie odstawczym w kopalni podziemnej KGHM [A12] . . . . .	81
52	Przykład parametryzacji wybranych segmentów odpowiadającym różnej jakości nawierzchni dróg transportowych w kopalni [A12] . . . . .	82

# Spis tabel

1	Proponowane rozszerzenia klasycznego infogramu . . . . .	36
2	Lista monitorowanych parametrów dla wozu odstawczego [A10] . . . . .	75