

AUTOREFERAT

1. Imię i nazwisko

Agnieszka Wyłomańska

2. Posiadane dyplomy, stopnie naukowe — z podaniem nazwy, miejsca i roku ich uzyskania oraz tytułu rozprawy doktorskiej

- Dyplom magistra inżyniera matematyki, specjalność: Matematyka Finansowa i Ubezpieczeniowa, Wydział Podstawowych Problemów Techniki, Politechnika Wrocławska, 06.06.2002, tytuł pracy magisterskiej: „Metody liczenia składek i rezerw na podstawie tablic dla dowolnego wieku”.
- Stopień doktora nauk matematycznych, Instytut Matematyki i Informatyki, Wydział Podstawowych Problemów Techniki, Politechnika Wrocławska, 20.09.2006, tytuł rozprawy: „Analiza modeli ARMA ze zmiennymi współczynnikami”.

3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych

6.10.2006–30.09.2007, asystent, Instytut Matematyki i Informatyki, Wydział Podstawowych Problemów Techniki, Politechnika Wrocławska

1.10.2007–obecnie, adiunkt, Instytut Matematyki i Informatyki, Wydział Podstawowych Problemów Techniki, Politechnika Wrocławska

4. Wskazanie osiągnięcia wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 r. o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz. U. nr 65, poz. 595 ze zm.):

a) Tytuł osiągnięcia naukowego:

"Metody statystyczne w zakresie przetwarzania, modelowania i analizy szeregów czasowych w zastosowaniu do diagnostyki technicznej"

b) Lista prac składających się na osiągnięcie naukowe:

- H1. Obuchowski J., **Wyłomańska A.**, Zimroz R., 2014. Selection of informative frequency band in local damage detection in rotating machinery, *Mechanical Systems and Signal Processing* 48, 138-152.
- H2. Obuchowski J., **Wyłomańska A.**, Zimroz R., 2014. The local maxima method for enhancement of time-frequency map and its application to local damage detection in rotating machines, *Mechanical Systems and Signal Processing* 46, 389-405.
- H3. Obuchowski J., **Wyłomańska A.**, Zimroz R., 2014. The local maxima method for enhancement of time-frequency map, *Advances in Condition Monitoring of Machinery in Non-Stationary Operations, Lecture Notes in Mechanical Engineering*, G. Dalpiaz et al. (eds.), 325-334.
- H4. Obuchowski J., **Wyłomańska A.**, Zimroz R., 2013. Stochastic modeling of time series with application to local damage detection in rotating machinery, *Damage Assessment of Structures in: Key Engineering Materials* 569, 441-449.
- H5. **Wyłomańska A.**, Obuchowski J., Zimroz R., Hurd H., 2014. Periodic autoregressive modeling of vibration time series from planetary gearbox used in bucket wheel excavator, in *Cyclostationarity: Theory and Methods Lecture Notes in Mechanical Engineering*, Fakher Chaari et al. (eds.), Springer, 171-186.
- H6. **Wyłomańska A.**, 2008. Spectral measures of PARMA sequences, *Journal of Time Series Analysis* 29(1), 1-13.
- H7. Nowicka-Zagrajek J., **Wyłomańska A.**, 2006. The dependence structure for PARMA models with α -stable innovations, *Acta Physica Polonica B* 37(1), 3071-3081.
- H8. Nowicka-Zagrajek J., **Wyłomańska A.**, 2008. Measures of dependence for stable AR(1) models with time-varying coefficients, *Stochastic Models* 24(1), 58-70.
- H9. Stefaniak P., **Wyłomańska A.**, Obuchowski J., Zimroz R., 2014. Procedures for decision thresholds finding in maintenance management of belt conveyor system-statistical modeling of diagnostic data, *praca przyjęta do Lecture Notes in Production Engineering*, Springer.
- H10. Burnecki K., **Wyłomańska A.**, Beletskii A., Gonchar V., Chechkin A., 2012. Recognition of stable distribution with Lévy index alpha close to 2, *Physical Review E* 85, 056711.
- H11. **Wyłomańska A.**, 2012. How to identify the proper model?, *Acta Physica Polonica B* 43(5), 1241-1253.
- H12. **Wyłomańska A.**, Zimroz R., 2014. Signal segmentation for operational regimes detection of heavy duty mining mobile machines- a statistical approach, *Diagnostyka* 15(2), 33-42.
- H13. Gajda J., Sikora G., **Wyłomańska A.**, 2013. Regime variance testing - a quantile approach, *Acta Physica Polonica B* 44(5), 1015-1035.
- H14. **Wyłomańska A.**, 2012. Arithmetic Brownian motion subordinated by tempered stable and inverse tempered stable processes, *Physica A* 391(22), 5685-5696.

- c) Omówienie celu wyżej wymienionych prac i osiągniętych wyników.

Wstęp

Cykl przedstawionych prac jest podsumowaniem kilkuletnich badań, w których opracowano nowe metody matematyczne oraz zastosowano autorskie i istniejące, zaawansowane techniki modelowania matematycznego do diagnostyki technicznej maszyn górniczych. Badania te można podzielić na cztery istotne grupy. Pierwsza z nich, to badania dotyczące **detekcji uszkodzeń lokalnych w maszynach górniczych**. Tego typu problem od lat jest analizowany w różnym kontekście i w literaturze światowej coraz częściej spotyka się niekonwencjonalne metody, które umożliwiają detekcję uszkodzeń dla maszyn, których sygnały są bardzo skomplikowane i dla których klasyczne metody nie dają pożądanych wyników. W prowadzonych przeze mnie badaniach staram się udowodnić, iż wykorzystując własności statystyczne analizowanych sygnałów można dokonać detekcji uszkodzeń w maszynach górniczych przy dużym poziomie zakłóceń o różnym charakterze.

Podstawowe założenie proponowanego podejścia bazuje na dekompozycji złożonych sygnałów na sub-sygnały o prostszej strukturze.

Nowatorskie metody opracowane do detekcji uszkodzeń wykorzystują fakt, iż dla uzyskanych sub-sygnałów dla maszyn nieuszkodzonych rozkład prawdopodobieństwa jest zbliżony do rozkładu gaussowskiego, podczas gdy w przypadku maszyny uszkodzonej taka własność nie występuje. Dzięki tej własności zaproponowano kilka miar impulsowości (tzw. selektorów) na podstawie których możliwe było dokonanie detekcji uszkodzeń także dla takich sygnałów, dla których klasyczna metoda oparta na kurtozie (w szczególności widmowej) nie dawała pożądanych efektów. Selektory te oparte są na statystykach wykorzystywanych do testowania, czy analizowane dane rzeczywiste pochodzą z rozkładu gaussowskiego. Kolejną własnością sub-sygnałów dla analizowanych maszyn jest fakt, iż dla maszyn uszkodzonych w sub-sygnałach obserwujemy lokalne maksima związane z szerokopasmowymi wzbudzeniami (co odpowiada impulsom w dziedzinie czasu). Na tej podstawie skonstruowano kolejny selektor oraz skonstruowano ulepszoną mapę czasowo-częstotliwościową (ang. *enhanced spectrogram*), która w lepszy sposób niż dotychczas stosowany spektrogram oddaje charakter sygnału. Na podstawie wspomnianych selektorów możliwe było wyznaczenie informacyjnych pasm częstotliwościowych danych sygnałów. Selektory te umożliwiły także dokonanie filtracji sygnałów, po adaptacji metody filtracji wykorzystującej kurtozę widmową.

Druga grupa badań opiera się na wykorzystaniu metod szeregów czasowych do **modelowania sygnałów drganiowych w zmiennych warunkach eksploatacyjnych**. Sygnały w tym przypadku są zmodulowane amplitudowo i częstotliwościowo i nie mają stałej struktury widma, dlatego też klasyczne modele typu ARMA (ang. *autoregressive moving average*) nie mogą być tutaj zastosowane. W badaniach skupiłam się przede wszystkim na modelach typu ARMA, w których współczynniki są zmienne w czasie. Systemy takie są rozszerzeniem klasycznych modeli ARMA (ze stałymi współczynnikami), które były wykorzystywane do modelowania drgań dla maszyn pracujących w stałych warunkach eksploatacyjnych. Szczególną uwagę poświęciłam modelom ARMA, w których współczynniki są okresowe (tzw. modele

PARMA). Pokazałam, że modele takie oddają charakter analizowanych sygnałów drganiowych, jakie obserwujemy na przykład w układzie napędowym koła czerpakowego koparki kołowej. Dodatkowo na podstawie filtrów odwrotnych tych modeli możliwe było także dokonanie detekcji uszkodzeń bazując na residuach modelu. Dodatkowo w moich badaniach przeanalizowałam także modele PARMA w kontekście ich miary spektralnej i na jej podstawie zaproponowałam innowacyjną metodę estymacji parametrów modelu. Zająłam się także problemem struktury zależności w modelach PARMA, w których innowacje gaussowskie zastąpiono inną klasą rozkładów, np. α -stabilnych. Pokazałam, iż wykorzystując alternatywne miary zależności (w stosunku do klasycznej autokorelacji) w takich modelach można uzyskać asymptotycznie parametr stabilności. Wyniki te są punktem wyjścia do zaproponowania estymatora tego parametru. Podobny problem przeanalizowałam także dla modeli AR(1) z α -stabilnym szumem i współczynnikami, które są dowolnymi funkcjami. Modele takie znalazły swoje zastosowanie do opisu różnego rodzaju danych rzeczywistych, także sygnałów uzyskanych z maszyn górniczych.

Kolejnym obszarem moich zainteresowań jest **modelowanie rozkładów cech diagnostycznych na potrzeby ustalenia progów decyzyjnych**. Do opisu rozkładów takich cech zaproponowano tutaj inne rozkłady niż gaussowskie. Powodem tego jest fakt, iż w lepszy sposób oddają one charakter analizowanych danych. Takim rozkładem są np. rozkłady Pareto czy Weibulla. Na podstawie wyestymowanych parametrów tych rozkładów dla danej cechy diagnostycznej oraz charakterystyk prędkości obrotowych możliwe było wyznaczenie progów decyzyjnych umożliwiających klasyfikację stanu danej maszyny. W tym obszarze zaproponowałam zastosowanie także innego rozkładu, wspomnianego już wcześniej α -stabilnego, który znakomicie oddaje charakter różnych zjawisk fizycznych, w tym także związanych z diagnostyką maszyn. Zaproponowałam tutaj procedurę rozróżniania takich rozkładów od rozkładu gaussowskiego, która jest przydatna także w przypadku niewielkich różnic pomiędzy tymi rozkładami. Ponadto w tym obszarze zaproponowałam prosty sposób doboru odpowiedniego modelu do danych rzeczywistych, także w przypadku modeli o różnych rozkładach pobudzeń. Jako przykład zastosowania tej procedury przeanalizowałam dane opisujące jeden z parametrów jakości powietrza wewnętrznego, mianowicie stężenie CO₂, wskazując na inne możliwe zastosowania do danych dotyczących diagnostyki technicznej.

Ostatnim obszarem moich zainteresowań w kontekście diagnostyki technicznej są **metody segmentacji sygnału w celu wykrywania stanów pracy maszyny**. Zaproponowałam tutaj dwie metody bazujące na własnościach statystycznych sygnału, które umożliwiły dokonanie segmentacji danych opisujących prędkość obrotową maszyny. Dodatkowo zaproponowałam także test, który umożliwia testowanie sygnałów, w których obserwuje się zmianę jego własności statystycznych. Zachowania takie obserwujemy np. we względnych fluktuacjach prędkości obrotowej. Ponadto zająłam się także problemem opisu danych, w których występują tzw. zachowania "pułapkowe", tzn. przedziały czasu, w który dany sygnał pozostaje na tym samym poziomie. Takie zachowania obserwujemy np. w prędkości obrotowej gdy maszyna pracuje na biegu jałowym. Zaproponowałam tutaj model, znany z fizyki statystycznej, zwany ogólnie modelem subdyfuzyjnym, który wykazuje podobne własności. Ponadto zaproponowałam nowatorską metodę estymacji parametrów takiego mode-

lu.

Głównymi celami moich badań w zakresie diagnostyki technicznej było:

- a) pokazanie, iż metody statystyczne i stochastyczne mogą być użyte w celu adaptacji dotychczas stosowanych technik w analizie sygnałów drganiowych,
- b) udowodnienie, iż zaproponowane kryteria selekcji wykazują bardzo dobre własności i mogą być alternatywą dla szeroko stosowanej kurtozy widmowej, a w niektórych przypadkach dają one lepsze wyniki,
- c) pokazanie, iż klasyczne modele szeregów czasowych są niewystarczające do opisu sygnałów dla maszyn pracujących w zmiennych warunkach eksploatacyjnych, dlatego też konieczne jest zaproponowanie bardziej zaawansowanych modeli,
- d) wskazanie, iż popularnie stosowane rozkłady gaussowskie są niewystarczające do opisu danych związanych z pracą maszyn górniczych, dlatego też konieczne jest zastosowanie innych rozkładów,
- e) określenie metod segmentacji sygnałów na potrzeby wykrywania pracy maszyny z wykorzystaniem własności statystycznych danych.

Wykorzystanie metod statystycznych do detekcji uszkodzeń lokalnych w maszynach górniczych (prace H1, H2, H3, H4)

Wykrywanie uszkodzeń lokalnych jest jednym z najczęstszych problemów poruszanych w literaturze w przypadku diagnostyki maszyn górniczych. Istnieją przynajmniej dwa powody występowania tego typu problemów. Po pierwsze, wykrywanie takich uszkodzeń w warunkach rzeczywistych może być bardzo trudne ze względu na niski stosunek sygnału do szumu (ang. *signal to noise ratio*) oraz specyficzne własności sygnału informacyjnego. Po drugie, amplituda drgań związanych z uszkodzeniem jest o wiele niższa niż amplituda sygnałów uzyskanych przy normalnej pracy maszyny. Niekorzystna relacja amplitud uniemożliwia wykrycie uszkodzeń we wczesnym stadium. Przyspiesza to degradację maszyny i może być przyczyną awarii. Analiza drgań wydaje się być tutaj najbardziej skutecznym podejściem do tego problemu [1, 36, 44, 47]. Lokalne uszkodzenia powodują pojawienie się sygnału impulsowego. Ze względu na ruch obrotowy maszyny sygnał ten powinien być cykliczny. W prostych przypadkach impulsy te mogą być obserwowane w dziedzinie czasu. W takich przypadkach klasyczne metody umożliwiają wykrycie uszkodzeń lokalnych. Kolejnym krokiem po wykryciu uszkodzenia jest jego zlokalizowanie i przypisanie go określonym elementom maszyny na podstawie tzw. charakterystycznych częstotliwości. Motywacją do zastosowania bardziej zaawansowanych metod umożliwiających detekcję uszkodzeń lokalnych w maszynach przemysłowych jest wczesna faza rozwoju uszkodzenia i fakt, że impulsy w dziedzinie czasu są nieobserwowalne. W tych przypadkach wspomniane cykliczne impulsy mogą być trudno zauważalne i istnieje potrzeba oddzielenia sygnału informacyjnego od zakłóceń pochodzących z różnych źródeł. Najbardziej rozsądnym podejściem jest w tym wypadku zaprojektowanie filtra, który umożliwiłby wydzielenie sygnału informacyjnego (SOI, ang. *signal of interest*). Na szczególną uwagę zasługują tutaj filtry bazujące na charakterystykach analizowanych danych. Filtr można określić poprzez jego odpowiedź impulsową w dziedzinie czasu lub jako charakterystykę częstotliwościową. W drugim z przedstawionych podejść konstrukcja filtra bazuje na informacji, które częstotliwości są

informacyjne (powinny być filtrowane bez zmian), a które są nieinformacyjne (filtracja powinna je usunąć). Wiedza na temat lokalizacji pasm informacyjnych pozwala na stosowanie filtru pasmowo-przepustowego bądź filtru liniowego o charakterystyce amplitudowej proporcjonalnej do informacyjności poszczególnych pasm [41, 50].

W pracy [H1] zaproponowano szereg statystyk, zwanych selektorami, które umożliwiają znalezienie sygnału informacyjnego oraz informacyjnego pasma częstotliwościowego (IFB, ang. *informative frequency band*) danego sygnału. Zaproponowane metody zastosowano zarówno do sygnałów symulowanych jak i rzeczywistych pochodzących z maszyn przemysłowych. We wszystkich zaproponowanych metodach w pierwszym kroku wyznacza się krótkookresową transformatę Fouriera (ang. *short time Fourier transform*), która dla sygnału $X(t)$, czasu $t \in T$ oraz częstotliwości $f \in F$ zdefiniowana jest następująco:

$$STFT(t, f) = \int_{-\infty}^{\infty} w(t - \tau)X(\tau)e^{2j\pi f\tau} d\tau, \quad (1)$$

gdzie $w(t - \tau)$ jest odpowiednim oknem. Dyskretna wersja powyższego równania dla wektora obserwacji X_1, X_2, \dots, X_n czasu $t \in T$ oraz częstotliwości $f \in F$ przyjmuje postać:

$$STFT(t, f) = \sum_{k=0}^{n-1} X_k w(t - k) e^{2j\pi f k/n}. \quad (2)$$

Najbardziej znanym selektorem, który do tej pory był używany do wyznaczenia informacyjnego pasma częstotliwościowego jest kurtoza widmowa (SK, ang. *spectral kurtosis*) zdefiniowana następująco [2]:

$$SK(f) = \#T \frac{\sum_{t \in T} |STFT(t, f)|^4}{(\sum_{t \in T} |STFT(t, f)|^2)^2} - 2, \quad (3)$$

gdzie $\#T$ oznacza liczbę elementów zbioru T , tzn. liczbę punktów czasowych, dla których jest wyznaczona STFT.

Kolejnym selektorem, który został zaproponowany w pracy [H1] jest statystyka Jacque-Bera (JB), która używana jest do testowania czy dany wektor obserwacji posiada własności charakterystyczne dla rozkładu gaussowskiego. Selektor JB dla częstotliwości f zdefiniowany jest następująco:

$$JB(f) = \frac{\#T}{6} \left(S(f)^2 + \frac{(K(f) - 3)^2}{4} \right), \quad (4)$$

gdzie $S(f)$ i $K(f)$ są odpowiednio empirycznymi skośnością i kurtozą wyznaczonymi dla sub-sygnału odpowiadającego częstotliwości f .

Kolejną grupą selektorów są selektory bazujące na odległościach pomiędzy dystrybucją empiryczną odpowiadającą danemu sub-sygnałowi dla odpowiedniej częstotliwości i teoretyczną dla rozkładu gaussowskiego. Do stworzenia selektora wykorzystano tutaj ciekawe własności sygnałów dla maszyn uszkodzonych i nieuszkodzonych. Mianowicie, sygnał pochodzący z maszyny nieuszkodzonej ma rozkład zbliżony do rozkładu gaussowskiego, inaczej niż w przypadku sygnału pochodzącego z maszyny uszkodzonej. Jednym z takich selektorów bazujących na tej własności jest statystyka Kolmogorova-Smirnova (KS), która dla danej częstotliwości f zdefiniowana jest następująco [30]:

$$KSS(f) = \sup_x |ECDF(f, x) - \Phi(f, x)|, \quad (5)$$

gdzie $\Phi(f, \cdot)$ jest dystrybuantą rozkładu gaussowskiego z parametrami wyestymowanymi dla sub-sygnału odpowiadającego częstotliwości f , natomiast $ECDF$ jest jego dystrybuantą empiryczną. Kolejnym analizowanym selektorem jest statystyka Andersona-Darlinga (AD), która należy do rodziny statystyk Cramera-von Misesa zdefiniowanych następująco [12]:

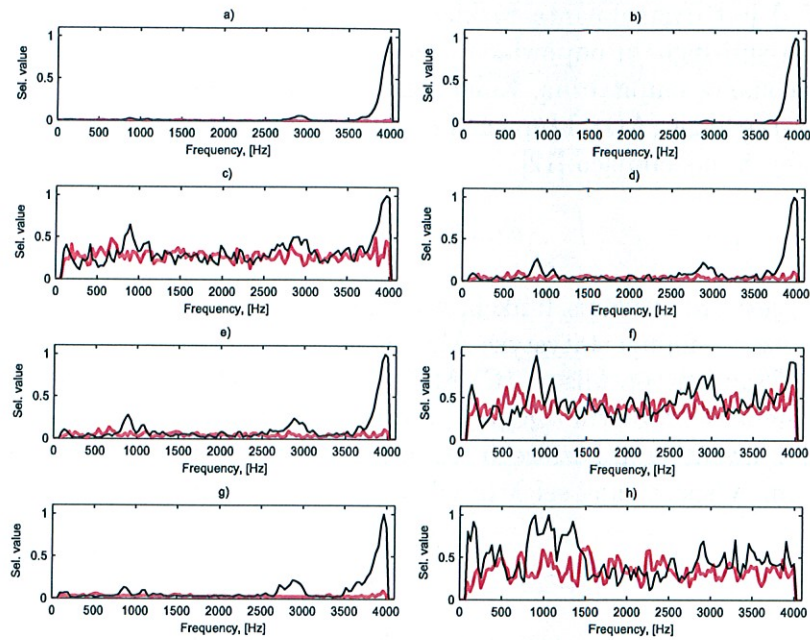
$$Q(f) = \#T \int_{-\infty}^{\infty} (ECDF(f, x) - \Phi(f, x))^2 \phi(x) dx, \quad (6)$$

gdzie $\phi(x)$ jest odpowiednią funkcją wagową. Dla $\phi(x) = [\Phi(f, x)(1 - \Phi(f, x))]^{-1}$ powyższy wzór definiuje statystykę AD. Dla $\phi(x) = 1$, statystyka (6) nazywana jest statystyką Cramera-von Misesa (CVM). Kolejnym selektorem jest statystyka bazująca wykresie kwantylowym (QQplot) porównującego kwantyle empiryczne wektora obserwacji z kwantylami bazowego rozkładu, który w tym wypadku jest rozkładem gaussowskim. Wspomniany selektor zdefiniowany jest następująco:

$$H_{max}(f) = \max_{1 \leq k \leq \#T} \left| \Phi^{-1} \left(f, \frac{2k-1}{2\#T} \right) - aS(k, f) - b \right|, \quad (7)$$

gdzie $\Phi^{-1}(f, \cdot)$ jest funkcją odwrotną do $\Phi(f, \cdot)$ dla $\mu = 0$ i $\sigma = 1$, $S(k, f)$ jest k -tą wartością posortowanego sub-sygnału $\{|STFT(t, f)|\}_{t \in T}$, $a = \frac{\Phi^{-1}(f, 0.75) - \Phi^{-1}(f, 0.25)}{q(f, 0.75) - q(f, 0.25)}$, $b = \Phi^{-1}(f, 0.75) - aq(f, 0.75)$ oraz $q(f, p)$ jest p -tym kwantylem tego sub-sygnału. Wzór na średnią odległość jest analogiczny do (7), gdzie \max zastąpiono średnią arytmetyczną. Odpowiednią charakterystykę oznaczamy jako H_{aver} . Selektory bazujące na statystyce KS, AD oraz H_{max} i H_{aver} zostały opisane także w pracy [H4], gdzie po raz pierwszy zastosowano je do danych rzeczywistych opisujących sygnał z łożyska używanego w bębnach napędowych przenośników taśmowych. W pracy [H1] porównano uzyskane w [H4] wyniki dla innych selektorów stąd też jest ona rozszerzeniem badań przedstawionych w [H4]. Ostatnim zaproponowanym selektorem w pracy [H1] jest selektor bazujący na metodzie lokalnych maksimów (LM). Ponieważ metoda lokalnych maksimów jest szczegółowo opisana w pracy [H2] dlatego też opis tego selektora podany będzie przy okazji omawiania tej pracy. Jak wspomniano wcześniej, przedstawione selektory zastosowano najpierw do sygnału symulowanego odpowiadającego maszynie nieuszkodzonej i uszkodzonej. Pokazano, iż w przypadku maszyny uszkodzonej zaproponowane selektory przyjmują większe wartości dla pasm, w których pojawiają się wzbudzenia związane z uszkodzeniem lokalnym, dlatego też bazując na wspomnianych miarach impulsowości można w łatwy sposób wyznaczyć pasmo informacyjne i zaproponować odpowiedni filtr. W kolejnej części pracy [H1] przeanalizowano dwa rodzaje sygnałów rzeczywistych: jeden odpowiadający łożysku w bębnie napędowym oraz drugi z przekładni dwustopniowej pracujących w układzie napędowym przenośnika taśmowego. Dla pierwszego sygnału opisane selektory dały podobne wyniki jednoznacznie wskazując na informacyjne pasmo częstotliwościowe. Dla drugiego bardziej skomplikowanego sygnału z przekładni dwustopniowej, w którym występują trzy informacyjne pasma częstotliwościowe oraz artefakt, zaproponowane selektory dały różne wyniki. Niektóre jednoznacznie wskazały na wspomniane trzy pasma informacyjne jak np. H_{aver} czy LM, niektóre wyodrębniły jedynie występujący w danych artefakt, jak SK. Wykresy wspomnianych miar impulsowości dla tego sygnału przedstawione są na Rys. 1.

Zaproponowane techniki są rozszerzeniem metod wykorzystywanych dotychczas, a uzyskane w pracy [H1] wyniki wskazują na ich potencjalne zastosowania do wy-



Rysunek 1: Selektory wyznaczone dla sygnału z przekładni dwustopniowej w maszynie uszkodzonej (czarna linia) i nieuszkodzonej (czerwona linia): *SK* (a), *JB* (b), *KSS* (c), *CVM* (d), *AD* (e), *H_{aver}* (f), *H_{max}* (g) oraz *LM* (h).

krywania uszkodzeń lokalnych dla maszyn dla których rejestrowane sygnały mają skomplikowaną strukturę. Przykłady innych selektorów, które służą do detekcji uszkodzeń w maszynach górniczych są przedstawione w pracach [P15, P16].

W pracach [H2] i [H3] została zaproponowana nowa metoda służąca do detekcji uszkodzeń w maszynach górniczych (metoda lokalnych maksimum). Polega ona na wyeksponowaniu informacji na mapie czasowo-częstotliwościowej. Jest to kontynuacja badań nad nowatorskimi metodami bazującymi na własnościach statystycznych analizowanych sygnałów, które umożliwiają wykrywanie uszkodzeń w maszynach, których sygnały drganiowe są skomplikowane. W zaproponowanej metodzie w pierwszym kroku, podobnie jak w pracy [H1], szereg drganiowy jest dekomponowany poprzez krótkookresową transformatę Fouriera zgodnie z wzorem (2). Wówczas mapa czasowo-częstotliwościowa może być traktowana jako macierz ($m \times n$) zawierająca m sub-sygnałów o długości n . Takie samo podejście było rozpatrywane w pracy [H1], gdzie mapa czasowo-częstotliwościowa była punktem wyjścia do wyznaczania wartości selektorów dla każdej z częstotliwości. Każdy taki sub-sygnał jest traktowany jako szereg czasowy i może być interpretowany jako zmiana energii w czasie dla wąskich pasm częstotliwościowych. Do każdego sub-sygnału zastosowano nową metodę, zwaną metodą lokalnych maksimum (ang. *local maxima method*). W analizowanych sygnałach szukanie lokalnych maksimum w wąskim oknie dla odpowiednich sub-sygnałów jest uzasadnione, ze względu na fakt, iż w sygnale odpowiadającym maszynie uszkodzonej (łożysku bądź przekładni) lokalne maksima o dużym zasięgu są związane z szerokopasmowymi wzbudzeniami oznaczającymi impulsy w dziedzinie czasu. Informacje otrzymane dla każdego sub-sygnału są zagregowane do jednego wymiaru w celu potwierdzenia impulsowego charakteru sygnału. Ze wzglę-

du na losowy charakter każdego analizowanego sub-sygnału, konieczne jest tutaj sprawdzenie istnienia lokalnego maksimum oraz jego istotność. Jeśli istnieją punkty w czasie, dla których średnia liczba lokalnych maksimum jest znacznie większa niż dla innych punktów czasowych, wówczas istotność tych maksimum jest większa i nadaje się im większą wagę. Ta statystyka, zwana wektorem wag (ang. *vector of weights*) może stanowić punkt wyjścia do stworzenia ulepszanego spektrogramu. Gdy na podstawie wektora wag utworzy się mapę czasowo-częstotliwościową uwzględniającą miejsca występowania lokalnych maksimum, wówczas nieinformacyjne pasma częstotliwościowe są tłumione, a pasma informacyjne - wzmacniane. Jeśli rozkład lokalnych maksimum na spektrogramie tworzy szerokopasmowy cykliczny wzrost energii istnieje podejrzenie, że maszyna jest uszkodzona. Dla sygnału pochodzącego z dobrej maszyny wektor średniej liczby maksimum dla każdego punktu w czasie nie powinien mieć obserwacji odstających, agregacja informacji dla wszystkich sub-sygnałów ma charakter losowy i nie posiada cykli. Kompletna procedura tworzenia mapy czasowo-częstotliwościowej na podstawie tak utworzonego wektora wag została opisana w pracy [H3]. Praca [H2] jest rozszerzeniem pracy [H3] dlatego wyniki tych prac zostaną omówione jednocześnie.

W pracach [H2] i [H3] została opisana metoda znajdowania lokalnych maksimum. Procedura ta przebiega następująco: w pierwszym kroku dla sygnału X_1, X_2, \dots, X_n wyznacza się krótkookresową transformatę Fouriera zgodnie z wzorem (2). Następnie dla danej częstotliwości analizuje się odpowiadający jej szereg czasowy i tworzy się binarny szereg czasowy określający miejsca występowania lokalnych maksimum (o zasięgu r) w danym szeregu. Oznacza to, że dla danej częstotliwości $f \in F$ tworzymy szereg $M(t_i, f)$, który zdefiniowany jest następująco: $M(t_i, f) = 1$ jeśli $|STFT(t_i, f)| = \max\{|STFT(t_k, f)| : i - r \leq k \leq i + r\}$ oraz $M(t_i, f) = 0$ w przeciwnym wypadku. Procedura znajdowania wielkości r została opisana w pracy [H2]. Następnym krokiem jest wyznaczenie wektora wag, który jest średnią liczbą lokalnych maksimum odpowiadających danemu punktowi w czasie. Wektor wag zdefiniowany jest następująco:

$$W(t_i) = \frac{1}{\#F} \sum_{f \in F} M(t_i, f). \quad (8)$$

Na podstawie wektora wag tworzy się mapę czasowo-częstotliwościową, na podstawie której można dokonać detekcji, czy dany sygnał pochodzi z maszyny uszkodzonej czy nieuszkodzonej. Ulepszony spektrogram definiujemy następująco:

$$ENH(t_i, f_j) = W(t_i)M(t_i, f_j). \quad (9)$$

Na podstawie tak skonstruowanego spektrogramu można w łatwy sposób wyznaczyć pasma częstotliwościowe odpowiadające uszkodzeniom także w przypadkach, gdzie na podstawie tradycyjnego spektrogramu ta informacja jest zakłócona. Zaproponowana metoda wyznaczenia mapy czasowo-częstotliwościowej na podstawie wektora wag daje lepsze rezultaty w przypadku problemu wykrywania uszkodzeń lokalnych niż zwykły spektrogram. Dodatkowo, w pracy [H3] przeanalizowano zachowanie wektora wag zdefiniowanego w (8) traktując go jako szereg czasowy. Okazuje się, że w przypadku maszyny nieuszkodzonej wektor wag zachowuje się losowo, a funkcja autokorelacji zachowuje się podobnie jak dla szeregu nieskorelowanych zmiennych losowych (jest bliska zeru dla opóźnień większych niż zero). W przypadku maszyny uszkodzonej obserwujemy cykliczne zachowanie wektora wag, funkcji

jego autokorelacji czy widma obwiedni. W pracy [H3] zilustrowano przedstawioną procedurę zarówno dla danych symulowanych jak i rzeczywistych sygnałów pochodzących z łożyska. W pracy [H2] ulepszono opisaną w [H3] metodę i w kolejnym kroku po wyznaczeniu mapy czasowo-częstotliwościowej $ENH(t, f)$ zdefiniowanej w (9) zaproponowano wyznaczenie ulepszonej wersji wektora wag w następujący sposób:

$$V(t_i) = \frac{1}{\#F} \sum_{f \in F} ENH(t_i, f). \quad (10)$$


Powyższa formuła redukuje szum obserwowany w wektorze wag $W(t)$ nadając większe wartości tym punktom w czasie, dla których na ulepszonym spektrogramie $ENH(t, f)$ obserwujemy szerokopasmowe wzbudzenia. W kolejnym kroku analizy obserwuje się zachowanie funkcji autokorelacji. Przypomnijmy, że funkcja autokorelacji (ACF, ang. *autocorrelation function*) dla wektora X_1, X_2, \dots, X_n pochodzącego z modelu stacjonarnego przyjmuje następującą postać:

$$ACF(k) = \frac{\sum_{i=1}^{n-|k|} (X_i - \bar{X})(X_{i+|k|} - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2}, \quad (11)$$

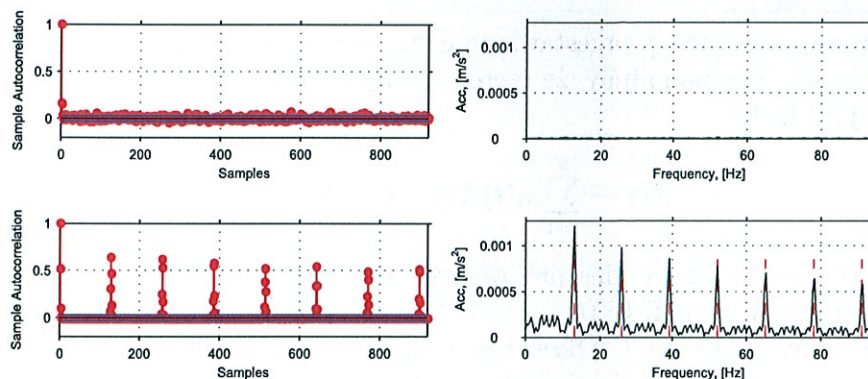
gdzie \bar{X} jest średnią empiryczną z próby. W zaproponowanej metodzie, ACF stosujemy do wektora $V(t)$. Podobnie jak dla wektora wag $W(t)$ również dla $V(t)$ odpowiadającego maszynie uszkodzonej w zachowaniu ACF obserwujemy cykliczność, podczas gdy dla maszyny nieuszkodzonej funkcja ta przyjmuje wartość bliską zeru dla opóźnień większych niż zero. W pracy [H2] proponuje się także obserwacje widma obwiedni dla wektora $V(t)$. Również ta statystyka dla maszyny uszkodzonej wykazuje cykliczność, podczas gdy dla nieuszkodzonej - zachowuje się losowo. Dodatkowo na jej podstawie dla sygnału z maszyny uszkodzonej możemy wyznaczyć te częstotliwości, przy których obserwowane jest uszkodzenie.

W pracy [H2] przeanalizowano sygnał pochodzący z łożyska używanego w bębnach napędowych oraz sygnał pochodzący z łożyska używanego w bębnach napinających przenośnika taśmowego. Dla obydwu przypadków przeanalizowano zarówno sygnał pochodzący z maszyny uszkodzonej jak i nieuszkodzonej. Dla rozpatrywanych przykładów pokazano, iż zaproponowana metoda oparta na metodzie lokalnych maksimów jest przydatna w przypadku detekcji uszkodzeń lokalnych. Zarówno wektor wag $V(t)$ zdefiniowany w (10), jak i ulepszony spektrogram jednoznacznie wskazują na uszkodzenia lokalne. Dodatkowo charakterystyki wektora $V(t)$ takie jak funkcja autokorelacji czy widmo obwiedni mogą również być kryterium do detekcji uszkodzeń w rozpatrywanych maszynach. Na Rys. 2 przedstawiono ulepszone spektrogramy dla dla sygnału rzeczywistego z łożyska nieuszkodzonego jak i uszkodzonego (uszkodzenie bieżni wewnętrznej lub zewnętrznej). Na Rys. 3 przedstawiono widmo obwiedni jak i funkcję autokorelacji dla wektora wag.

Uzyskane w pracach [H1-H4] wyniki wskazują, iż bazując na własnościach statystycznych analizowanych sygnałów i wykorzystując zaawansowane metody matematyczne można dokonać detekcji uszkodzeń lokalnych w maszynach górniczych, których sygnały drganiowe są bardzo skomplikowane i w przypadku których detekcja uszkodzeń z wykorzystaniem klasycznych metod nie daje pożądaných wyników.



Rysunek 2: Ulepszone spektrogramy dla sygnału z łożyska nieuszkodzonego (lewy panel) oraz uszkodzonego (prawy panel).



Rysunek 3: Funkcja autokorelacji (lewy panel) oraz widmo obwiedni (prawy panel) dla wektora wag dla sygnału z łożyska nieuszkodzonego (górny panel) oraz uszkodzonego (dolny panel).

Wykorzystanie szeregów czasowych (ze szczególnym uwzględnieniem systemów typu ARMA ze zmiennymi współczynnikami) do modelowania sygnału drganiowego w zmiennych warunkach eksploatacyjnych (prace H5, H6, H7, H8)

Sygnały drganiowe uzyskane z maszyn działających w zmiennych warunkach obciążenia eksploatacyjnego są trudne do przetwarzania w związku z ich zmienną w czasie charakterystyką widmową, skomplikowanymi własnościami statystycznymi, czy zmiennym stosunkiem sygnału do szumu. W przypadku analizy drgań uszkodzonej maszyny w klasycznym podejściu dokonuje się separacji danych na sygnał informacyjny (ang. *informative*) i nieinformacyjny (ang. *non-informative*). Takiej separacji można dokonać na wiele sposobów. Jednym z nich jest podejście bazujące na dopasowaniu odpowiedniego modelu do danego sygnału [5, 20, 34, 43, 54, 57, 58]. Najbardziej znanym modelem wykorzystywanym do opisu sygnału drganiowego uzyskanego z maszyn działających w stałych warunkach eksploatacyjnych jest system autoregresyjny (AR, ang. *autoregressive*) [5, 20, 35], za pomocą którego modeluje się wysokoenergetyczne komponenty deterministyczne w takich sygnałach. Separacja na część informacyjną i nieinformacyjną bazująca na danym modelu (np. autoregresyjnym) polega na dobraniu odpowiedniego modelu do sygnału, a następnie na filtracji,

która prowadzi do uzyskania reszt modelu (residuum). W kolejnym kroku analizuje się uzyskane reszty. W przypadku drgań analizowanych w pracy [H5] klasyczne podejście bazujące na modelowaniu sygnału z wykorzystaniem systemu AR okazało się niewystarczające. Jest to związane z tym, iż analizie poddano sygnał uzyskany z przekładni planetarnej działającej w zmiennych warunkach eksploatacyjnych. W wyniku procesu urabiania, przekładnia planetarna w koparkach kołowych poddawana jest cyklicznym obciążeniom, w związku z tym uzasadnione wydaje się zastosowanie do tego typu sygnału modeli, które wykazują własności cykliczne. Jednym z takich systemów jest okresowy model AR (PAR, ang. *periodic autoregressive*), który jest rozszerzeniem klasycznego modelu autoregresyjnego. W pracy [H5] wykorzystano model PAR do modelowania wysokoenergetycznych składowych deterministycznych sygnału uzyskanego z przekładni planetarnej (działającej w zmiennych warunkach eksploatacyjnych).


W pierwszej części pracy przedstawiono definicję modelu PAR oraz jego najważniejsze własności. Przypomnijmy, że szereg czasowy PAR z rzędem p zdefiniowany jest następująco [21]:

$$X(t) - \sum_{i=1}^p a_i(t)X(t-i) = b(t)Z(t). \quad (12)$$

gdzie $Z(t)$ jest szeregiem nieskorelowanych zmiennych losowych o tym samym rozkładzie, a współczynniki $\{a_i(t), i = 1, 2, \dots, p\}$ oraz $b(t)$ są okresowe ze względu na t z tym samym okresem T . Okres ten związany jest z cykliczną pracą koła czerpakowego koparki kołowej. Warto wspomnieć, że modele PAR i ich rozszerzona wersja PARMA (ang. *periodic autoregressive moving average*) były stosowane do opisu wielu zjawisk wykazujących własności cykliczności czy okresowości, takich jak dane hydrologiczne [52], meteorologiczne [7] czy ekonomiczne [P1]. Model typu PARMA (czy PAR) jest jednym z systemów wykazujących własności procesów cyklostacjonarnych, szeroko stosowanych w diagnostyce technicznej [3].

W kolejnej części pracy [H5] przedstawiono procedurę estymacji parametrów modelu PAR z wykorzystaniem tzw. metody Yule-Walkera. Zajęto się tutaj także problemem doboru optymalnego rzędu p . Kolejna część pracy poświęcona była zastosowaniu modelu PAR do sygnału symulowanego mającego identyczne własności jak sygnał drganiowy uzyskany z przekładni planetarnej. Wymulowano tutaj dwa sygnały. Jeden odpowiadający maszynie nieuszkodzonej, a drugi - z lokalnym uszkodzeniem. Wymulowany sygnał zawierał część deterministyczną reprezentowaną przez sumę czterech funkcji sinusoidalnych zmodyfikowanych częstotliwościowo z dodanym szumem gaussowskim. W przypadku maszyny z uszkodzeniem lokalnym szum był dodatkowo zmodulowany amplitudowo poprzez ciąg impulsów. Uszkodzenie takie nie jest obserwowane w dziedzinie czasowej, gdyż deterministyczna część ma dużo większą energię niż część losowa. Jednak najbardziej istotną sprawą związaną z drganiami przekładni planetarnej działającej w zmiennych warunkach eksploatacyjnych jest dodatkowa modulacja częstotliwościowa komponentów deterministycznych, co związane jest z cykliczną pracą maszyny. Zarówno modulacja częstotliwościowa części deterministycznej (dla obydwu sygnałów) i amplitudowa modulacja szumu (dla sygnału odpowiadającej maszynie uszkodzonej) są obserwowalne na spektrogramach, na których widoczne są cztery okresowe składowe deterministyczne (linie pionowe) oraz impulsy (linie poziome) dla uszkodzonej maszyny, Rys. 4.

Dla obydwu typu wymulowanych sygnałów (odpowiadających drganiom maszy-



Rysunek 4: Spektrogramy dla sygnału odpowiadającego maszynie nieuszkodzonej (lewy panel) oraz uszkodzonej (prawy panel).

ny uszkodzonej i nieuszkodzonej) zaproponowano optymalny model PAR, który w tym wypadku ma rząd 15. Następnie w obydwu przypadkach zastosowano odwrotny filtr bazujący na dopasowanym modelu i zajęto się analizą uzyskanych reszt. W przypadku obu sygnałów reszty nie zawierają już żadnych składowych deterministycznych, co jest widoczne zarówno w dziedzinie czasowej jak i częstotliwościowej (spektrogram). W przypadku maszyny uszkodzonej sygnał residualny wykazuje jedynie zaburzenia szerokopasmowe i podobnie jak dla sygnału z maszyny nieuszkodzonej wszystkie składowe deterministyczne zostały usunięte poprzez zastosowanie odwrotnego filtra PAR. Na koniec przeanalizowano także charakterystyki sygnałów residualnych takie jak autokorelację, widmo obwiedni czy wyestymowane odchylenie standardowe. Dla sygnału odpowiadającego maszynie nieuszkodzonej żadne wymienione charakterystyki nie wykazywały składowych harmonicznych związanych z modulacją komponentów deterministycznych. W przypadku sygnału z maszyny uszkodzonej wszystkie charakterystyki uwzględniały jedynie modulację amplitudową szumu.

Aby pokazać, jak ogromne znaczenie ma dobranie odpowiedniego modelu, w pracy [H5] do wysymulowanych sygnałów dobrano także optymalny klasyczny model AR. Po dokonaniu filtracji odwrotnej dla dopasowanego modelu przeanalizowano reszty obydwu sygnałów. W przypadku modelu AR zarówno dla sygnału odpowiadającego maszynie uszkodzonej jak i nieuszkodzonej w sygnałach residualnych obserwuje się pewne składowe deterministyczne, a dodatkowo w sygnale dla maszyny uszkodzonej szeroko pasmowe wzbudzenia. Również widmo obwiedni sygnałów residualnych wskazuje na niepożądane składowe harmoniczne. Uzyskane wyniki dla obydwu sygnałów jednoznacznie pokazują, iż dla sygnałów drganiowych pochodzących z maszyn działających w zmiennych warunkach eksploatacyjnych konieczne jest zastosowanie bardziej zaawansowanych modeli od tych klasycznych wykorzystywanych do drgań maszyn działających w stałych warunkach eksploatacyjnych.

W pracy [H6] przeanalizowano wspomniane modele PARMA w kontekście ich miary spektralnej. Wyznaczenie tej miary pozwoliło na zaproponowanie nowego estymatora parametrów modelu, a tym samym na nową metodę analizy sygnałów, w których obserwuje się własności charakterystyczne dla tego typu systemów, np. sygnałów uzyskanych z maszyn górniczych pracujących w zmiennych warunkach eksploatacyjnych. Warto wspomnieć, że model PARMA jest procesem wykazującym własności cyklostacjonarności. Proces $X(t)$ jest cyklostacjonarny lub okresowo skorelowany

(PC, ang. *periodically correlated*) z okresem T jeśli spełnione są dwa warunki [21]:

$$\begin{aligned} E(X(t)) &= E(X(t+T)) \\ \text{cov}(X(t), X(t+s)) &= \text{cov}(X(t+T), X(t+s+T)), \end{aligned} \quad (13)$$

gdzie $E(X)$ jest wartością oczekiwaną zmiennej losowej X , a $\text{cov}(X, Y)$ oznacza kowariancję zmiennych X oraz Y .

Ponieważ każdy proces cyklostacjonarny $X(t)$ jest silnie harmonizowalny [P13], a do takich zaliczają się modele typu PARMA, zatem ich miara spektralna F na $[0, 2\pi] \times [0, 2\pi]$ jest wyrażona następującym wzorem [26]:

$$\text{corr}(X(n), X(m)) = \int_0^{2\pi} \int_0^{2\pi} e^{i(sn-mt)} F(ds, dt), \quad (14)$$

gdzie $\text{corr}(X, Y)$ jest korelacją zmiennych losowych X i Y . Dodatkowo dla procesów PC z okresem T miara spektralna przyjmuje postać [16]:

$$F(ds, dt) = \sum_{n=0}^{T-1} \Gamma_n(ds, dt), \quad (15)$$

gdzie miary Γ_n są określone na zbiorach $L_n = \{(s, t) \in [0, 2\pi] \times [0, 2\pi] : t = s + \frac{2n\pi}{T}\}$ dla $n = 0, 1, \dots, n-1$.

W pracy [H6] podano postać rozwiązania dla ogólnych modeli PARMA oraz warunki na istnienie jednoznacznego PC rozwiązania takich modeli (Twierdzenie 1), co pozwala na opis stochastyczny sygnałów o własnościach cyklostacjonarnych. Dodatkowo podano postać funkcji kowariancji dla takich systemów oraz udowodniono, że miary Γ_n w (15) są absolutnie ciągłe ze względu na miarę Lebesgue'a na odcinku $[0, 2\pi]$ oraz pokazano ich postać (Twierdzenie 2). Jako szczególne przypadki rozpatrzono klasyczny model AR(1), wykorzystywany do opisu sygnałów o stałej strukturze widma oraz PAR(1), który może być wykorzystany dla sygnałów o widmie zmiennym w czasie.

Ponieważ dla wielu sygnałów rzeczywistych rozkład gaussowski wydaje się być niewystarczający do opisu badanego zjawiska, dlatego też coraz częściej odchodzi się od założenia, że analizowany wektor obserwacji może być opisany jednym z modeli gaussowskich. Takim przykładem są dane finansowe opisujące ceny akcji analizowane w [P14], gdzie do opisu zaproponowano ciągły model AR(1) (zwany procesem Ornsteina-Uhlenbecka) z innymi niż szumy o charakterze gaussowskim. Korzystając z zaawansowanych metod statystycznych pokazano tutaj, iż znacznie bardziej do analizowanych danych pasują modele oparte na innych rozkładach. Ma to również miejsce w przypadku diagnostyki technicznej, gdzie często klasyczny model pobudzony jest niegaussowskim szumem. Przykładem są tutaj sygnały łożyska tocznego, do opisu których zaproponowano rozkłady α -stabilne, będące rozszerzeniem rozkładu gaussowskiego [51]. Rozkłady te znalazły także wiele innych zastosowań w różnych dziedzinach, takich jak procesy sygnałowe [40], ekonomia [39], fizyka [23, 28] oraz elektrotechnika [49]. W pracy [H7] analizie poddano modele PARMA i ich szczególny przypadek modele PAR dane równaniem (12), w których residua gaussowskie $Z(t)$ zastąpiono szumami pochodzącymi z symetrycznego rozkładu α -stabilnego. Zmienna losowa X o symetrycznym rozkładzie α -stabilnym z parametrami $0 < \alpha \leq 2$

oraz $\sigma > 0$ zdefiniowana jest jednoznacznie poprzez funkcję charakterystyczną w następujący sposób [45]:

$$E(e^{izX}) = e^{-|z|^\alpha \sigma^\alpha}. \quad (16)$$

Warto wspomnieć, iż dla $\alpha = 2$ symetryczny rozkład α -stabilny jest rozkładem gaussowskim.

Mimo wielu zastosowań, rozkłady α -stabilne posiadają jedną istotną wadę. Dla $\alpha \neq 2$ nie posiadają one drugiego momentu, co z kolei uniemożliwia zastosowanie klasycznych metod do ich analizy, w których to bardzo często bazuje się na funkcji autokowariancji, czy autokorelacji. W przypadku rozkładów α -stabilnych żadna z tych miar nie jest zdefiniowana, dlatego też konieczne jest zastosowanie innych, alternatywnych miar zależności, które mogą być zamiennikami klasycznych miar w przypadku rozkładów z nieskończoną wariancją. W pracy [H7] przeanalizowano dwie miary poprawnie zdefiniowane dla rozkładów α -stabilnych, kowariację (CV, ang. *covariation*) oraz kodyferencję (CD, ang. *codifference*). Miary te dla zmiennych X, Y α -stabilnych zdefiniowane są następująco [45]:

$$CV(X, Y) = \int_S s_1 s_2^{\alpha-2} \bar{s}_2 \Gamma(ds_1, ds_2), \quad 1 < \alpha \leq 2, \quad (17)$$

gdzie Γ jest gęstością spektralną wektora (X, Y) , a S jest sferą jednostkową w R^2 . Oraz

$$CD(X, Y) = \ln(E(e^{i(X-Y)})) - \ln(E(e^{iX})) - \ln(E(e^{-iY})), \quad 0 < \alpha \leq 2. \quad (18)$$

W pracy [H7] szczególnie przeanalizowano model PAR(1) dany równaniem (12) z $p = 1$ (w pracy określony jako PARMA(1,1) zgodnie z przyjętą definicją), dla którego szumy pochodziły z symetrycznego rozkładu α -stabilnego z $1 < \alpha \leq 2$. Pokazano postać jednoznacznego rozwiązania dla analizowanego modelu $X(t)$ oraz warunki gwarantujące jego istnienie. Ponadto zajęto się problemem asymptotycznego zachowania wspomnianych miar zależności i pokazano, że zachodzi:

$$\lim_{h \rightarrow \infty} \frac{CD(X(t), X(t-h))}{CV(X(t), X(t-h))} = \lim_{h \rightarrow \infty} \frac{CD(X(t+h), X(t))}{CV(X(t+h), X(t))} = \alpha. \quad (19)$$

Uzyskany wynik może być wykorzystany do estymacji nieznanego parametru α w modelu PAR(1) bazując na empirycznych odpowiednikach miar CV oraz CD. Dodatkowo w pracy [H7] przeanalizowano szczególne przypadki analizowanego systemu i pokazano zachowanie asymptotyczne wspomnianych miar.

Kolejną pracą, w której analizuje się modele szeregów czasowych wykorzystywanych do opisu drgań maszyn górniczych, jest praca [H8], która jest rozszerzeniem pracy [H7]. Rozszerzenie polega na tym, iż analizie poddano modele AR(1) z symetrycznym α -stabilnym szumem o funkcji charakterystycznej (16), w którym współczynniki są dowolnymi funkcjami. Szczególnym przypadkiem takich systemów jest model PAR(1) analizowany w [H7], czyli model, w którym współczynniki są funkcjami okresowymi. Modele ARMA z dowolnymi zmiennymi w czasie współczynnikami zmiennymi w czasie były analizowane dla danych technicznych np. w [43, 48], z kolei problem estymacji w takich modelach z niegaussowskim szumem był omówiony

w [25]. Modele takie mają zastosowanie do skomplikowanych sygnałów, w których klasyczne systemy są niewystarczające.

W pracy [H8] przeanalizowano modele AR(1) z szumem symetrycznym α -stabilnym w kontekście miar zależności: kowariacji oraz kodyferencji zdefiniowanych odpowiednio w (17) oraz (18). Pokazano tutaj warunki, przy których jednoznaczne rozwiązanie takich systemów istnieje, a także formuły na odpowiednie miary przy podanych warunkach gwarantujących istnienie rozwiązania (Propozycja 3.1 i Propozycja 4.1). Kolejnym wynikiem pracy są twierdzenia, które mówią o asymptotycznym zachowaniu danych miar przy odpowiednich warunkach (Twierdzenie 3.1 i Twierdzenie 4.1). To asymptotyczne zachowanie jest rozszerzeniem równości (19) dla przypadku modeli AR(1) z dowolnymi zmiennymi w czasie współczynnikami. Pokazano, że przy pierwszym ze zdefiniowanych warunków na istnienie jednoznacznego rozwiązania (condition (I)) dla $1 < \alpha \leq 2$ zachodzi:

$$\lim_{h \rightarrow \infty} \frac{CD(X(t), X(t-h))}{CV(X(t), X(t-h))} = \alpha, \quad \lim_{h \rightarrow \infty} \frac{CD(X(t-h), X(t))}{CV(X(t-h), X(t))} = 0. \quad (20)$$

Podczas, gdy przy drugim warunku (condition(II)) dla $1 < \alpha \leq 2$ mamy:

$$\lim_{h \rightarrow \infty} \frac{CD(X(t), X(t+h))}{CV(X(t), X(t+h))} = \alpha, \quad \lim_{h \rightarrow \infty} \frac{CD(X(t+h), X(t))}{CV(X(t+h), X(t))} = 0. \quad (21)$$

Dodatkowo w pracy [H8] przeanalizowano szczególne przypadki omawianego modelu AR(1) ze zmiennymi w czasie współczynnikami i symetrycznym α -stabilnym szumem i wskazano na ich związek z klasycznymi modelami AR, szeroko stosowanymi do opisu sygnałów drganiowych.

Modelowanie rozkładów cech diagnostycznych na potrzeby ustalenia progów decyzyjnych (prace H9, H10, H11)

Przenośniki taśmowe stanowią kluczowe ogniwo transportowe zarówno w polskich kopalniach odkrywkowych węgla brunatnego jak i podziemnych kopalniach rud miedzi. Niezależnie od struktury kopalni, problem związany z utrzymaniem ruchu przenośników taśmowych z punktu widzenia całego procesu technologicznego kopalni ma istotne znaczenie z wielu powodów, np.: (a) przenośniki są rozproszone przestrzennie na stosunkowo rozległym obszarze, (b) tworzą logicznie powiązaną sieć transportową złożoną z ciężkich i wielkogabarytowych podzespołów, (c) są eksploatowane w skomplikowanych, kopalnianych warunkach środowiskowych, (d) awaria któregośkolwiek przenośnika skutkuje przestojem całej linii produkcyjnej lub jej większej części. Artykuł [H9] dotyczy problematyki utrzymania przekładni zębatych stosowanych w układach napędowych odstawy taśmowej. Autorzy przedstawili system klasy CMMS w technologii GIS do wspomaganie zarządzania eksploatacją sieci przenośników. Jego zasadniczą rolą jest podejmowanie właściwych decyzji eksploatacyjnych dotyczących wymiany komponentów przekładni lub dopuszczenia ich do dalszej pracy. Tak zdefiniowane zadanie wymaga określenia złożonych reguł decyzyjnych oraz wyznaczenia właściwych wartości progowych parametrów diagnostycznych. W artykule [H9] przedstawiono procedury określania progów decyzyjnych bazujące na statystycznym modelowaniu danych diagnostycznych oraz ich wielowymiarowym grupowaniu. Wybór właściwego rozkładu danych, selekcja odpowiednich

parametrów statystycznych cechy diagnostycznej i przeprowadzenie wielowymiarowej analizy pozwala określić optymalne wartości progowe na potrzeby efektywnego określania stanu technicznego podzespołów maszyn oraz szacowania optymalnego czasu ich bezpiecznej eksploatacji.

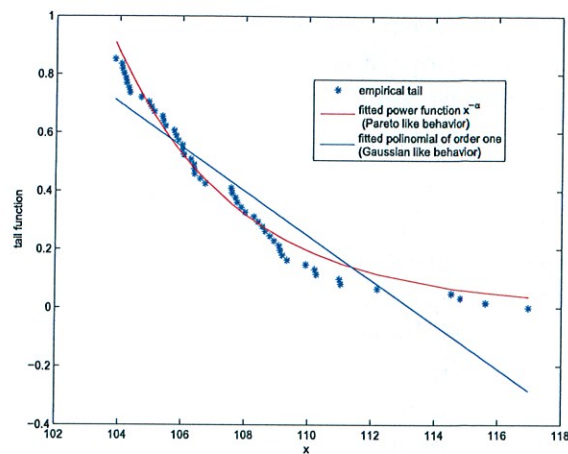
Oprócz wspomnianego opisu systemu klasy CMMS do zarządzania eksploatacją sieci przenośników, zajęto się problemem ustalenia wartości progowych, przy których dana cecha diagnostyczna będzie mogła być zaliczona do jednego z dwóch stanów: prawidłowego bądź nieprawidłowego. W przypadku maszyn górniczych, takich jak przenośniki taśmowe, podejmowanie decyzji diagnostycznych na podstawie porównania widma jednego sygnału może być nieuzasadnione z uwagi na obecność licznych zakłóceń w tych złożonych systemach maszynowych. Z tego też względu podczas definiowania progów decyzyjnych, wydaje się uzasadnione wykorzystanie dużej populacji pomiarów i przeprowadzenie na ich zbiorze analizy statystycznej w celu określenia jego podstawowych parametrów [8]. Statystyczne podejście w rozpoznawaniu dwustanowym (stan prawidłowy – stan nieprawidłowy) bazuje na wyznaczeniu funkcji gęstości prawdopodobieństwa dla danej cechy. Następnie na ich podstawie wyznacza się wartość poziomu alarmowego. Niestety, w pewnych przypadkach maszyn niemożliwa jest separacja stanów ze względu na efekt nakładania się funkcji gęstości. Problem nakładania się charakterystyk jest związany głównie z silną zależnością cech diagnostycznych bazujących na widmie sygnału od wartości obciążenia eksploatacyjnego maszyny. Z tego też względu proponuje się uwzględnienie w procesie wnioskowania wartości cech diagnostycznych oraz warunków eksploatacyjnych, dla jakich wykonano pomiar [11, 14, 27].

W celu ustalenia progów decyzyjnych badanej cechy diagnostycznej w pracy [H9] wykorzystano jej szczególne własności statystyczne. Mianowicie pokazano iż szeregi czasowe opisujące daną cechę diagnostyczną nie mogą być modelowane z wykorzystaniem popularnego rozkładu gaussowskiego. Rozkładem, który bardziej oddaje charakter analizowanej cechy jest przesunięty rozkład Pareto, dla którego funkcja gęstości zdefiniowana jest następująco [4]:

$$f(x) = \frac{\alpha \lambda^\alpha}{x^{\alpha+1}}, \quad x \geq \lambda, \quad (22)$$

gdzie $\alpha > 0$ jest parametrem kształtu, podczas gdy $\lambda > 0$ jest parametrem skali. Rozkład Pareto jest wykorzystywany w wielu różnych zastosowaniach, takich jak ubezpieczenia czy monitorowanie procesów produkcyjnych [31]. Na Rys. 5 pokazano empiryczny "ogon" (1 – *dystybuanta*, ang. *tail*) dla przykładowych danych opisujących daną cechę diagnostyczną wraz z "ogonem" rozkładu Pareto oraz "ogonem" rozkładu gaussowskiego. Parametry obydwu rozkładów zostały wyestymowane na podstawie analizowanego wektora obserwacji. Łatwo zauważyć tutaj, że rozkład Pareto bardziej oddaje charakter analizowanych danych.

W pracy [H9] dla każdego z analizowanych 119 zbiorów danych dotyczących cechy diagnostycznej wyestymowano parametry α i λ wykorzystując metodę największej wiarygodności. Następnie utworzono zestaw danych i poddano je grupowaniu w celu znalezienia miar podobieństwa. Do grupowania zastosowano procedurę klasteryzacji zwaną k-średnich (ang. *k-means*). W procedurze k-średnich grupowanie polega na wstępnym podzieleniu populacji na z góry założoną liczbę klas. Następnie,



Rysunek 5: Empiryczny "ogon" dla przykładowych danych opisujących daną cechę diagnostyczną wraz z "ogonem" rozkładu Pareto (z wyestymowanymi parametrami) oraz ogonem rozkładu gaussowskiego.

uzyskany podział jest poprawiany w ten sposób, że niektóre elementy są przenieszone do innych klas, tak, aby uzyskać minimalną wariancję wewnątrz uzyskanych klas. Metoda ta wykorzystywana jest do wstępnej analizy danych. Pozwala ona na wyodrębnienie jednorodnych grup (subpopulacji), które podlegają osobnej dalszej analizie statystycznej. Metoda k-średnich służy także do eksploracji danych, gdzie grupowanie używane jest do podziału analizowanych czynników na podgrupy [24]. W analizowanym przypadku procedurę k-średnich zastosowano do następujących parametrów: wyestymowanych wartości α i λ z danych opisujących daną cechę diagnostyczną oraz wartości średniej (μ) i odchylenia standardowego (σ) dla odpowiednich prędkości obrotowych. Następnie przeprowadzono wielowymiarową analizę grupowania k-średnich dla czterech wymienionych zmiennych. Na tej podstawie wyznaczono wartości progowe odpowiednio dla stanów prawidłowego, ostrzegawczego oraz nieprawidłowego. Wartości progowe wyznaczono jako krzywe zależności danej cechy diagnostycznej od prędkości obrotowej. Uzyskane rezultaty bazujące na własnościach statystycznych cechy diagnostycznej potwierdzają tezę, zgodnie z którą w maszynach górniczych obserwuje się silny wpływ obciążenia eksploatacyjnego na wartość cech diagnostycznych. Co więcej, wpływ ten narasta w miarę wzrostu procesu degradacji układu napędowego i w przypadku maszyn ze stanem alarmowym ma on charakter silnie nieliniowy [8]. Uzyskane wyniki porównano z wynikami klasteryzacji (również metodą k-średnich) przy założeniu, iż badana cecha ma rozkład gaussowski. W tym wypadku rezultaty nie potwierdziły nieliniowego charakteru progów decyzyjnych w przypadku stanu alarmowego. Przeprowadzone badania pokazują, że powszechnie stosowany rozkład gaussowski nie może być wykorzystany do opisu rozkładu prawdopodobieństwa cech diagnostycznych. Podobnej tematyki dotyczy praca [P24].

Innym rozkładem, który może być alternatywą dla rozkładu gaussowskiego jest wspomniany rozkład α -stabilny, który znalazł zastosowanie np. do modelowania sygnału pochodzącego z łożyska tocznego [51]. Zmienna losowa X ma ogólny roz-

kład α -stabilny z parametrami $0 < \alpha \leq 2$, $\sigma > 0$, $-1 \leq \beta \leq 1$ oraz $\mu \in R$ jeśli jej funkcja charakterystyczna zdefiniowana jest w następujący sposób [45]:

$$E(e^{izX}) = \begin{cases} \exp\{-\sigma^\alpha |z|^\alpha (1 - i\beta \operatorname{sgn}(z) \operatorname{tg} \frac{\pi\alpha}{2}) + iz\mu\} & \text{dla } \alpha \neq 1, \\ \exp\{-\sigma |z| (1 - i\beta \frac{2}{\pi} \operatorname{sgn}(z) \ln |z|) + iz\mu\} & \text{dla } \alpha = 1. \end{cases} \quad (23)$$

W powyższej definicji α jest zwane parametrem stabilności, σ - parametrem skali, β -parametrem skośności, a μ reprezentuje parametr przesunięcia. Szczególnym przypadkiem rozkładu α -stabilnego jest symetryczny rozkład α -stabilny zdefiniowany w (16). Przypomnijmy, że dla $\alpha = 2$ rozkład α -stabilny jest rozkładem gaussowskim. O różnych możliwych zastosowaniach tego rozkładu wspomniano wcześniej. Głównym problemem poruszonym w pracy [H10] jest problem rozróżnienia danych pochodzących z rozkładu gaussowskiego od danych, które mają rozkład zbliżony do gaussowskiego, mianowicie α -stabilny z parametrem α bliskim 2. W przypadku takich rozkładów tradycyjne metody wykorzystywane do testowania różnic pomiędzy rozkładami dwóch wektorów obserwacji wskazują, iż rozkłady te są identyczne. Problem rozróżnienia takich rozkładów obserwujemy dla wielu zjawisk fizycznych, także w przypadku danych technicznych takich jak względna fluktuacja prędkości obrotowej czy sygnał drganiowy (przyspieszenie) omawianych w [8, 15]. Aby rozróżnić wspomniane dwa rozkłady w pracy [H10] zaproponowano procedurę bazującą na własnościach statystycznych analizowanego sygnału. W pierwszym kroku tej procedury proponuje się zastosowanie testu wizualnego bazującego na skumulowanym empirycznym czwartym momencie, czyli obserwację statystyki $C(k)$, która dla wektora obserwacji X_1, X_2, \dots, X_n zdefiniowana jest następująco:

$$C(k) = \frac{1}{k} \sum_{i=1}^k (X_i - \bar{X})^4, \quad k = 1, 2, \dots, n, \quad (24)$$

gdzie \bar{X} jest średnią empiryczną danych. Dla sygnałów, które mogą być opisane rozkładem gaussowskim statystyka $C(k)$ stabilizuje się, natomiast dla sygnałów opisanych rozkładem α -stabilnym ta statystyka zachowuje się bardzo chaotycznie. Potwierdziły to symulacje komputerowe, których wyniki pokazane są w pracy [H10]. Jednakże stabilizowanie się statystyki $C(k)$ nie gwarantuje, że dane mogą być opisane rozkładem gaussowskim, dlatego w kolejnym kroku zaproponowanej metody proponuje się wykorzystanie testów statystycznych służących do testowania rozkładu gaussowskiego i rozkładu α -stabilnego. Testy, które zostały tutaj wykorzystane bazują odpowiednio na statystykach JB, KS oraz AD przedstawionych powyżej. Statystyki te znalazły zastosowanie w problemie wykrywania uszkodzeń lokalnych w maszynach górniczych i mogą być traktowane jako miary impulsowości sygnału. Zatem w kolejnym kroku przedstawionej procedury dla danych, w których statystyka $C(k)$ stabilizuje się dokonuje się procedury testowania rozkładu gaussowskiego z wykorzystaniem testu JB. Jeśli uzyskana p -wartość (ang. p -value) przekracza z góry zadany poziom ufności, wówczas nie ma podstaw do odrzucenia hipotezy, że dane pochodzą z rozkładu gaussowskiego. Natomiast jeśli test JB odrzuca hipotezę o rozkładzie gaussowskim sygnału konieczne jest zastosowanie testu statystycznego, który umożliwi testowanie rozkładu α -stabilnego. W tym wypadku proponuje się dwa testy KS oraz AD, dla których rozkładem bazowym był rozkład α -stabilny. Jeśli p -wartości przekraczają z góry podany poziom ufności, wówczas nie ma podstaw do odrzucenia hipotezy o rozkładzie α -stabilnym, w przeciwnym wypadku konieczne test zastosowanie testów dotyczących innych rozkładów. W przypadku zachowania chaotycznego statystyki $C(k)$ w kolejnym kroku testuje się rozkład α -stabilny.

Chaotyczne zachowanie tej statystyki wskazuje, iż rozkład gaussowski jest nieodpowiedni dla analizowanego sygnału

W pracy [H10] wykorzystując wspomnianą procedurę przeanalizowano zarówno dane symulowane pochodzące z rozkładów odpowiednio gaussowskiego oraz α -stabilnego z parametrem α bliskim 2 jak i dane rzeczywiste opisujące turbulencje w płazmie ziemi [23]. Zaproponowana procedura może być wykorzystana do innych danych rzeczywistych, także sygnałów pochodzących z maszyn górniczych.

Kolejną pracą, która porusza problem analizy innych rozkładów niż gaussowskie, bardziej oddających charakter analizowanych sygnałów jest pozycja [H11]. Oprócz problemu doboru odpowiedniego rozkładu poruszony tutaj został szerszy problem doboru odpowiedniego modelu do danych. W przypadku różnego rodzaju sygnałów istotną sprawą jest dopasowanie odpowiedniego modelu, czyli odpowiedni opis stochastyczny danych. Pokazują to wyniki pracy [H5], gdzie nieodpowiedni klasyczny model AR został dobrany do sygnału zmodulowanego amplitudowo i częstotliwościowo. Po filtracji z wykorzystaniem nieodpowiedniego modelu uzyskano residua, w których obserwowano nadal modulację częstotliwościową, co jest niepożądanym efektem. W pracy [H11] zaproponowano prostą metodę bazującą na obserwacji funkcji autokorelacji (ACF) danego sygnału. Pokazano tutaj, że bazując jedynie na funkcji autokorelacji można wyciągnąć błędne wnioski co do poprawności modelu. Dlatego też zaproponowano metodę, która oprócz analizy ACF dla danego sygnału bazuje na analizie ACF dla kwadratów danych. Poprzez liczne przykłady różnych modeli pokazano, iż zaproponowana procedura może być użyteczna przy doborze modelu. Wyniki teoretyczne poparto symulacjami. Dodatkowo w ostatniej części pracy przeanalizowano dane dotyczące stężenia CO₂ w powietrzu wewnętrznym w pomieszczeniu typu *open space*. Pokazano, że w danych po usunięciu trendu deterministycznego można zauważyć zachowania odpowiednie dla modeli typu autoregresyjnego. Zaproponowana procedura potwierdziła wcześniejsze założenie. Zatem do danych dobrano odpowiedni model AR oraz przeanalizowano reszty modelu. Ponieważ nie wykazywały one własności charakterystycznych dla rozkładu gaussowskiego, do ich opisu zaproponowano bardziej odpowiedni rozkład, mianowicie, rozkład NIG (ang. *normal inverse Gaussian*). Rozkład ten zdefiniowany jest poprzez jego funkcję gęstości w następujący sposób [6, 55]:

$$f(x) = \frac{\alpha\delta}{\pi} e^{\delta\sqrt{\alpha^2-\beta^2}+\beta(x-\mu)} \frac{K_1(\alpha\sqrt{\delta^2+(x-\mu)^2})}{\sqrt{\delta^2+(x-\mu)^2}}, \quad (25)$$

gdzie K_1 jest zmodyfikowaną funkcją Bessela trzeciego rodzaju oraz $\delta > 0$, $0 \leq |\beta| < \alpha$, $\mu \in R$ są parametrami rozkładu.

W pracy [H11] pokazano, że ten rozkład znacznie bardziej opisuje reszty wybranego modelu niż standardowy rozkład gaussowski. Przedstawiona procedura może być wykorzystana do różnych sygnałów, także tych, które pochodzą z maszyn górniczych, których modele pobudzone są szumami niegaussowskimi. Przykład wykorzystania innych niż gaussowskie rozkładów do opisu danych rzeczywistych przedstawiony jest także w pracach [P14, P33].

Segmentacja sygnału w celu wykrywania stanów pracy maszyny (prace H12, H13, H14)

W artykule [H12] przedstawiono procedury umożliwiające segmentację sygnałów drganiowych. Opracowane techniki pozwoliły na detekcję oraz identyfikację fragmentów sygnału (segmentów) które związane są z różnymi trybami pracy maszyny, jak na przykład bieg jałowy czy przeciążenie. Detekcja i parametryzacja różnych segmentów umożliwia poprawienie efektywności pracy maszyny, co związane jest z minimalizowaniem czasu pracy na biegu jałowym czy zapobieganiem przyspieszonym procesom degradacji, które wynikają z nieprawidłowego użytkowania maszyny. W pracy [H12] zaproponowano dwie metody, które pozwalają na wyznaczenie tych punktów sygnału, w których zmieniają się odpowiednie własności statystyczne analizowanych danych, co z kolei prowadzi do wyznaczenia segmentów sygnału związanych z różnymi trybami pracy danej maszyny. Walidację zaproponowanych technik przeprowadzono dla danych symulowanych, w których obserwowane były momenty zatrzymań (tzw. "pułapki"). Ponadto jako główną część pracy podane metody zastosowano do danych opisujących prędkość obrotową silnika. Poniżej zostaną omówione główne wyniki pracy [H12].

Pierwsza ze statystyk (statystyka R), która zaproponowana została do detekcji i identyfikacji segmentów sygnału bazuje na drugim empirycznym momencie analizowanego sygnału w oknie o długości k . Statystyka ta dla wektora obserwacji X_1, X_2, \dots, X_n w segmencie $j = 0, 1, \dots, n - k$ zdefiniowana jest następująco:

$$R_j = \sum_{i=j+1}^{j+k} X_i^2, \quad i = 0, 1, \dots, n - k. \quad (26)$$

Tak zdefiniowana statystyka $R = (R_0, R_1, \dots, R_{n-k})$ była wcześniej zaproponowana w pracy [H13] do analizy danych niestacjonarnych wykazujących różne własności statystyczne (wyrażone w języku drugiego momentu) oraz do testowania punktu krytycznego wskazującego na moment zmiany tych własności dla analizowanych danych rzeczywistych. Szerzej wyniki dotyczącej pracy [H13] zostaną omówione poniżej.

W problemie znajdowania momentów zmiany własności statystycznych danego sygnału (segmentacji związanej z różnymi trybami pracy maszyny) wykorzystuje się ciekawą własność statystyki R . Mianowicie jeśli l jest punktem, w którym zmieniają się własności statystyczne analizowanego sygnału, a k jest oknem, wówczas dla $k < l$ wartość średnia zmiennej losowej R_j jest stała dla wszystkich $j \leq l - k$ i $j > l - 1$. Dla $l - k < j \leq l - 1$ zmienna losowa R_j ma wartość oczekiwaną, która jest liniowa ze względu na j . Bazując na tych własnościach można łatwo znaleźć punkt krytyczny, który wskazuje na miejsce zmiany własności statystycznych sygnału wyrażonych w języku jego drugiego momentu empirycznego. Warto wspomnieć, iż statystyka R może być wykorzystana do danych, gdzie punkty zmiany własności statystycznych sygnału łatwo zauważyć (jak w danych opisujących prędkość obrotową silnika), ale także w danych, gdzie zmiana własności statystycznych nie jest łatwo obserwowalna (jak w danych laboratoryjnych opisujących turbulencje w płazmie ziemi opisanych w [H13]).

Druga statystyka, funkcja C również bazuje na drugim momencie empirycznym analizowanego sygnału, jednakże w jej definicji nie bazujemy na oknie o danej długości, a na skumulowanym empirycznym drugim momencie. Statystyka $C = (C_1, C_2, \dots, C_n)$

dla wektora obserwacji X_1, X_2, \dots, X_n zdefiniowana jest następująco:

$$C_j = \sum_{i=1}^j X_i^2, \quad j = 1, 2, \dots, n. \quad (27)$$

Podobnie jak statystyka R , zmienna losowa C wykorzystywana była w [H13] do detekcji punktu krytycznego wskazującego na moment zmiany własności statystycznych analizowanych danych oraz do testowania czy wektor obserwacji ma tzw. własność zmiany reżimu, co związane jest z testowaniem pewnego rodzaju niestacjonarności w analizowanym sygnale. Procedura znajdowania segmentów sygnału związanych z różnymi trybami pracy maszyny bazująca na statystyce C wykorzystuje własności tej statystyki. Mianowicie, jeśli l jest punktem krytycznym zmiany własności statystycznych sygnału, to dla $j \leq l$ statystyka C_j ma wartość oczekiwaną, która jest funkcją liniową aj dla pewnego parametru $a > 0$, podczas gdy dla $j > l$ wartość oczekiwana (czyli de facto statystyka) zachowuje się jak $bj + c$ dla pewnych parametrów $b, c > 0$. Własność ta pozwala na znajdowanie punktu krytycznego analizowanych danych, który znajduje się w momencie zmiany charakterystyki statystyki C . Statystyki bazujące na skumulowanych empirycznych momentach (szczególnie o rzędach parzystych) są bardzo użyteczne w problemach badania różnych własności statystycznych obserwowanych danych. Takim przykładem może być praca [H10], gdzie statystyka bazująca na skumulowanym 4 momencie była wykorzystywana do detekcji czy dwa wektory danych rzeczywistych pochodzą z tego samego rozkładu. W pracy [H12] zaprezentowana została procedura znajdowania momentów różnych segmentów sygnału odpowiedzialnych za różne tryby pracy maszyny z wykorzystaniem wspomnianych statystyk.

W pracy [H12] przedstawiona procedura została najpierw sprawdzona dla danych symulowanych, w których zdefiniowano "pułapki", czyli momenty zatrzymań, na różnych poziomach i o różnej długości. Obydwie statystyki dały bardzo dobre rezultaty. Warto jednak wspomnieć, że metoda bazująca na statystyce R nie wykrywa momentów zatrzymań mniejszych niż długość okna k , dlatego też postuluje się, aby ten parametr był jak najmniejszy. Dodatkowo, ponieważ bazujemy na zróżnicowanych wartościach sygnału wykryte długości momentów zatrzymań są zawsze o jeden mniejsze niż prawdziwe "pułapki".

Jeśli chodzi o metodę bazującą na statystyce C , tutaj także bazując na zróżnicowanym sygnale otrzymujemy długości "pułapek" pomniejszone o jeden. A z kolei fakt, że działamy na zróżnicowanych wartościach tej statystyki wpływa na przesunięcie miejsca rozpoczęcia kolejnego segmentu. Wszystkie te własności obydwu metod zostały uwzględnione w detekcji segmentów dla rzeczywistego sygnału dotyczącego prędkości obrotowej silnika.

Aplikacyjna część pracy [H12] została poświęcona analizie danych rzeczywistych opisujących prędkość obrotową silnika w samojezdnych maszynach górniczych (ładowarki), w których wykryto segmenty związane z różnymi trybami pracy maszyny. Obydwie metody dały podobne wyniki, które zostały uzasadnione w konkluzjach. Na koniec zaproponowano metodę, która bazuje na obydwu statystykach. Mianowicie, technika ta uwzględnia jedynie momenty zatrzymań wykryte przed obydwie statystyki, a długość tych momentów zdefiniowana jest jako średnia długości "pułapek" wyznaczonych przy obydwu metodach.

Kolejną pracą, w której przedstawione zostały metody do segmentacji sygnałów (danych rzeczywistych) jest [H13]. W pracy tej, wykorzystane zostały statystyki R oraz C zdefiniowane odpowiednio w (26) i (27) pierwotnie do detekcji pewnego rodzaju niestacjonarności w analizowanym sygnale. Niestacjonarność ta związana jest ze zmianą własności statystycznych analizowanego sygnału wyrażonych w języku drugiego momentu. Zachowania takie obserwujemy np. we względnych fluktuacjach prędkości obrotowej [15] oraz w sygnale drganiowym (przyspieszeniu) [8]. W klasycznej analizie statystycznej danych rzeczywistych badanie stacjonarności (bądź niestacjonarności) związane jest przede wszystkim z tzw. problemem pierwiastka jednostkowego (ang. *unit root*) bądź występowania trendów deterministycznych (ang. *trend nonstationarity*). Istnieje wiele testów, które pozwalają na detekcję tego rodzaju niestacjonarności w danych. Warto tutaj wspomnieć o teście Dickeya-Fullera i jego uogólnieniach [17, 18, 46], teście Phillipsa-Perrona [42] czy teście Kwiatkowskiego, Phillipsa, Schmidta i Shina (test KPSS) [32].

Jednakże w przypadku wielu danych rzeczywistych, także tych związanych z diagnostyką techniczną, obserwuje się inny rodzaj niestacjonarności, mianowicie obserwujemy zmianę pewnych własności statystycznych analizowanego szeregu. Dlatego też konieczne jest wprowadzenie innych niż standardowe testy na wykrywanie tego rodzaju niestacjonarności, które jest silnie związane ze wspomnianą wcześniej segmentacją danego sygnału. Zauważmy, że jeśli pewne własności statystyczne danego wektora obserwacji zmieniają się w czasie, to wektor ten można podzielić na reżimy o takich samych własnościach, czyli dokonać jego segmentacji. Dlatego też statystyki wykorzystane w pracy [H13] stały się użyteczne do segmentacji sygnału opisującego prędkość obrotową silnika analizowaną w [H12]. W [H13] zmieniające się własności statystyczne wektora obserwacji wyrażono w języku empirycznego drugiego momentu i zajęto się tutaj problemem testowania czy dany sygnał X_1, X_2, \dots, X_n spełnia następującą własność:

$$X_i \stackrel{d}{=} \begin{cases} Y & \text{dla } i \leq l \\ Z & \text{dla } i > l, \end{cases} \quad (28)$$

gdzie Y i Z są niezależnymi zmiennymi losowymi o różnych własnościach statystycznych, wyrażonych jako kwantyle $q_\alpha, q_{1-\alpha}$ kwadratów dla danego poziomu istotności α . W pracy [H13] zaproponowano dwa testy wizualne, które umożliwiają obserwacje punktu zmiany własności statystycznych sygnału. Bazują one na wspomnianych statystykach R oraz C i umożliwiają wykrycie punktu krytycznego l . Wspomniane testy wizualne zastosowano do symulowanych danych, w których punkt krytyczny był widoczny, ale także dla takich danych, dla których, różnica pomiędzy rozkładem zmiennej Z i Y w równaniu (28) nie była łatwo obserwowalna. Testy wizualne zastosowano do rozkładów gaussowskiego i α -stabilnego, gdyż są one na tyle ogólne, że mogą być wykorzystane do różnego typu danych, także związanych z sygnałami dotyczącymi pracy maszyn.

Poza testami wizualnymi służącymi do detekcji czy w sygnale występuje zachowanie dane równaniem (28), w pracy [H13] zaproponowano metodę wykrywania punktu krytycznego l . Algorytm bazuje na własnościach statystyki C opisanej w (27). Warto podkreślić, że przedstawiona procedura jest uniwersalna i nie zależy od rozkładu analizowanych danych rzeczywistych. Z powodzeniem była stosowana do różnych zjawisk, np. do danych opisujących parametry jakości powietrza wewnętrznego [P12].

Kolejna część pracy zawiera opis zaproponowanego testu statystycznego dotyczącego reżimowej wariancji. Hipoteza zerowa w tym teście brzmi następująco: \mathcal{H}_0 analizowany szereg nie spełnia równania (28), podczas gdy \mathcal{H}_1 : analizowany szereg ma przynajmniej jeden punkt krytyczny l taki jak w równaniu (28). Przy hipotezie \mathcal{H}_0 kwantyle kwadratów danych nie zmieniają się w czasie, co może być spełnione np. w przypadku danych niezależnych o tym samym rozkładzie (ang. *independent identically distributed, i.i.d.*). Przy hipotezie alternatywnej \mathcal{H}_1 kwantyle kwadratów danych zmieniają się w czasie i istnieje co najmniej jeden punkt krytyczny l .

Podobnie jak w przypadku testów wizualnych walidację opisanego testu statystycznego przeprowadzono dla danych symulowanych, dla których punkt zmiany reżimu był widoczny, ale także dla danych, dla których nie był łatwo obserwowalny. Na koniec wspomniany test zastosowano do przykładowych danych opisujących turbulencje w płazmie ziemi. Zaproponowana procedura może być wykorzystana także do innych sygnałów, w których obserwuje się segmenty odpowiadające różnym własnościom statystycznym danych, takich jak względna fluktuacja prędkości obrotowej czy sygnał drganiowy (przyspieszenie) analizowanymi odpowiednio w [15] oraz [P24].

W pracy [H14] zaproponowany został model stochastyczny do opisu danych, w których obserwuje się momenty zatrzymań ("pułapki"), tzn. takie miejsca w szeregu, dla których wektor następujących po sobie obserwacji ma wartości na tym samym poziomie. Tego typu sygnał opisujący prędkość obrotową silnika był analizowany w pracy [H12]. W pracy [H14] podjęto się próby modelowania tego typu danych, czyli rozpoznania procesu stochastycznego, który ma podobne własności jak analizowany sygnał. W wielu innych dziedzinach życia obserwuje się także dane z widocznymi momentami zatrzymań. Takim przykładem mogą być procesy obserwowane na rynkach finansowych [P2, P3, P8, P17], w fizyce [13, 22, 37], biologii [29, 53] oraz w technice [38]. Systemy służące do opisu wspomnianych zachowań przedstawiane są najczęściej w języku ułamkowych równań Fokkera-Plancka, będących uogólnieniem równań Fokkera-Plancka. Równania te opisują gęstość danego procesu i w wielu dziedzinach właśnie w ten sposób podaje się reprezentacje systemów stochastycznych [56]. Stochastyczną reprezentacją ułamkowych równań Fokkera-Plancka jest tzw. proces subordynowany. Idea subordynacji była wprowadzona w roku 1949 przez Bochnera [9] i kontynuowana w późniejszych jego publikacjach [10]. Ogólnie proces subordynowany zdefiniowany jest jako złożenie dwóch procesów: procesu zewnętrznego $X(t)$ oraz subordynatora $T(t)$, który niejako zastępuje czas w procesie zewnętrznym. Zatem proces subordynowany $Y_T(t)$ zdefiniowany jest następująco:

$$Y_T(t) = X(T(t)). \quad (29)$$

Procesy subordynowane były wykorzystywane do wielu różnych danych rzeczywistych. Ta różnorodność zastosowań wynika z możliwości wykorzystania różnych procesów zewnętrznych $X(t)$ oraz szerokiej gamy subordynatorów $T(t)$. Najbardziej popularnymi procesami subordynowanymi są np. proces variance gamma [33], w którym procesem zewnętrznym jest standardowy ruch Browna $B(t)$, a subordynatorem - proces gamma, czy proces NIG [6], w którym standardowy ruch Browna był subordynowany poprzez tzw. odwrotny proces gaussowski. Obydwa wspomniane procesy subordynowane znalazły szerokie zastosowanie w finansach do opisu np. zwrotów

cen akcji [H11] czy modelowania cen opcji [33]. W pracy [H14] rozpatrywane są dwa szczególne przykłady procesów subordynowanych. Mianowicie jako zewnętrzny proces proponuje się tzw. arytmetyczny ruch Browna, czyli standardowy ruch Browna z dryfem, który zdefiniowany jest następująco:

$$dX(t) = \beta dt + dB(t), \quad (30)$$

gdzie $B(t)$ jest standardowym ruchem Browna, natomiast subordynatorem jest proces temperowany stabilny w jednym przypadku i odwrotny proces temperowany stabilny - w drugim.

Przypomnijmy, że proces temperowany stabilny $T(t)$ z parametrami $0 < \alpha < 1$ i $\lambda > 0$ to proces o stacjonarnych niezależnych przyrostach z rozkładu temperowanego stabilnego, którego jednoznacznie charakteryzuje transformata Laplace'a:

$$E(e^{-zT(t)}) = e^{t(\lambda^\alpha - (\lambda+z)^\alpha)}, \quad \lambda > 0, 0 < \alpha < 1. \quad (31)$$

Proces odwrotny do procesu temperowanego stabilnego zdefiniowany jest następująco:

$$S(\tau) = \inf\{t > 0 : T(t) > \tau\}. \quad (32)$$

Praca [H14] została podzielona na dwie części. W jednej rozpatrywany jest proces $Y_T(t) = X(T(t))$, gdzie odpowiednie procesy zdefiniowane są w równaniach (30) i (31), podczas gdy w drugiej analizowany jest proces $Y_S(\tau) = X(S(\tau))$, gdzie odpowiednie procesy zdefiniowane są w (30) i (32). W pierwszej części pracy podane są najważniejsze własności procesu $Y_T(t)$, takie jak jego gęstość, zachowanie momentów czy kowariancja, a także procedura jego symulacji. Zaproponowana została także tutaj procedura estymacji procesu bazująca na nowym pomysle, w którym parametry β, α i λ estymowane są poprzez porównanie empirycznej funkcji charakterystycznej dla przyrostów procesu i teoretycznej, która została wyprowadzona w pracy. Dodatkowo wykorzystując metodę Monte Carlo sprawdzono poprawność metody estymacji. Metoda testowania bazująca na odległościach pomiędzy empiryczną i teoretyczną funkcją charakterystyczną została później także wykorzystana w pracy [P3] także w kontekście procesów subordynowanych. W drugiej części pracy [H14], gdzie analizowano proces $Y_S(\tau)$ zajęto się własnościami asymptotycznymi nie tylko procesu subordynowanego, ale także procesu $S(\tau)$ zdefiniowanego w (32). Pokazano związek funkcji gęstości tego procesu i procesu $T(t)$, a także jej asymptotyczne zachowanie. Dodatkowo zajęto się także problemem opisu podstawowych charakterystyk procesu $Y_S(\tau)$ takich jak gęstość, czy odpowiednie momenty. Zaproponowano tutaj także procedurę estymacji dla tego procesu, która bazuje na segmentacji wektora obserwacji na część związaną z momentami zatrzymań i część, w której nie obserwujemy danych "pułapkowych". Jest to standardowa procedura bazująca na zależności procesu subordynowanego z odwrotnym subordynatorem i tzw. błędzenia losowego z czasem ciągłym. Procedura ta była wykorzystywana wielokrotnie w kontekście procesów subordynowanych dla różnych typów procesów zewnętrznych i różnych subordynatorów [P2, P8, P17, P3, P5].

W ostatniej części pracy [H14] analizie poddano dane rzeczywiste opisujące dwa najważniejsze parametry powietrza wewnętrznego: wilgotność i temperaturę. Na podstawie charakterystyk dopasowanych procesów i ich empirycznych odpowiedników

udowodniono, że analizowane procesy subordynowane odzwierciedlają własności danych rzeczywistych. Przedstawiona procedura może być wykorzystana dla różnych rodzajów danych, także danych dotyczących diagnostyki technicznej, jak prędkość obrotowa silnika, gdzie zachowania "pułapkowe" związane są z różnymi trybami pracy danej maszyny, np. przy biegu jałowym. Procesy subordynowane są także rozpatrywane w pracach [P2, P3, P4, P5, P6, P12, P8, P17, P25, P32].

5. Omówienie pozostałych osiągnięć naukowo - badawczych (artystycznych)

Analiza zmienności fizycznych i chemicznych parametrów jako źródło informacji dotyczących jakości powietrza wewnętrznego

Obecnie jestem głównym wykonawcą w projekcie "Analiza zmienności fizycznych i chemicznych parametrów jako źródło informacji dotyczących jakości powietrza wewnętrznego" nr umowy *UMO* – 2012/07/*B/ST8/03031*. Projekt ten jest wynikiem mojej współpracy z Wydziałem Inżynierii Środowiska Politechniki Wrocławskiej. Badania prowadzone w ramach projektu dotyczą rozpoznania źródeł informacji, które umożliwią charakteryzowanie powietrza wewnątrz pomieszczeń budynków użyteczności publicznej w sposób kompleksowy, a są dotychczas wykorzystywane sporadycznie oraz opracowania koncepcji metod i narzędzi (obliczeniowych i aparaturowych) pozwalających poprawić dokładność oceny jakości powietrza wewnętrznego. Bezpośrednim wynikiem mojego uczestnictwa w projekcie są prace [P12, P32]. Praca [P12] dotyczy modelu anomalnej dyfuzji wykorzystanego do opisu jednego z parametrów powietrza wewnętrznego, temperatury. Praca [P32] traktuje o procesie anomalnej dyfuzji opartym o proces temperowany stabilny z odwrotnym nieskończone podzielonym subordynatorem.

Czujniki i sensory

W latach 2009-2013 byłem jednym z wykonawców projektu "Czujniki i sensory do pomiarów czynników stanowiących zagrożenia w środowisku – modelowanie i monitoring zagrożeń" nr projektu *POIG.01.03.01 – 02 – 002/08*. Bezpośrednim wynikiem mojego uczestnictwa w tym projekcie są prace: [P7, P11] oraz praca [H11]. W pracy [P7] do opisu danych dotyczących jakości powietrza wewnętrznego zaproponowano wielowymiarowy model ARMA, na podstawie którego dokonano predykcji danych. W pracy [P11] zajęto się problemem opisu parametrów jakości powietrza wewnętrznego z wykorzystaniem procesów stochastycznych. Praca [H11] dotyczy problemu doboru optymalnego modelu do danych rzeczywistych. Jestem również współautorką raportów z realizacji zadań badawczych projektu.

Strategia rozwoju energetyki na Dolnym Śląsku metodami foresightowymi

W latach 2009-2011 byłem głównym wykonawcą projektu "Strategia rozwoju energetyki na Dolnym Śląsku metodami foresightowymi" nr projektu *POIG.01.01.01 –*

00 – 005/08. Głównym celem projektu było opracowanie strategii rozwoju energetyki na Dolnym Śląsku z wykorzystaniem metod badań ankietowych oraz statystycznych. Bezpośrednim wynikiem mojego uczestnictwa w tym projekcie są prace [P18, P19, P20, P21, P22, P26]. W pracach tych poruszany jest problem rozwoju rynku energii elektrycznej na Dolnym Śląsku i analiza tego rynku z wykorzystaniem metod statystycznych oraz stochastycznych. Dodatkowo jestem współautorką czterech rozdziałów w pracy "Strategia rozwoju energetyki na Dolnym Śląsku na podstawie metody foresightowej Delphi" : praca zbiorowa / pod red. E. Ropuszyńskiej-Surmy i Z. Szalbierza. Wrocław : Oficyna Wydawnicza Politechniki Wrocławskiej oraz współautorką raportów z realizacji zadań badawczych projektu.

Procesy anomalnej dyfuzji

W swojej pracy badawczej zajęłam się także procesami anomalnej dyfuzji, stosowanymi przede wszystkim w fizyce statystycznej. Jednakże ostatnimi laty znalazły one różne inne liczne zastosowania, także w diagnostyce technicznej. W mojej pracy badawczej skupiłam się nie tylko na teoretycznych zagadnieniach związanych z tymi procesami, ale także na możliwościach ich praktycznego zastosowania. Podjęłam się także problemu estymacji i testowania modeli, które wykazują własności anomalnej dyfuzji. Procesy anomalnej dyfuzji są także klasą modeli do opisu danych, w których obserwuje się tzw. momenty zatrzymań. Takie zachowania także obserwujemy w sygnałach drganiowych, np. w prędkości obrotowej silnika. W mojej pracy badawczej skupiłam się na szczególnej klasie modeli anomalnych dyfuzji, mianowicie procesach subordynowanych przez tzw. odwrotny subordynator. Ogólna definicja takiego procesu podana jest w (29). W ramach tych badań powstał szereg prac obejmujących wspomniane zagadnienia, np. [P6, P12, P25]. Procesom subordynowanym poświęcona jest także praca [H14] szerzej opisana powyżej. W pracy [P6] podjęto się tematu porównania procesu subordynowanego z trzema typami odwrotnych subordynatorów: α -stabilnym, temperowanym stabilnym oraz gamma. W pracy [P12] do opisu danych dotyczących jakości powietrza wewnętrznego zaproponowano model subordynowany, uwzględniający okresowość analizowanych danych oraz występujące w nich momenty zatrzymań. Opisano procedurę estymacji oraz sprawdzono poprawność modelu. W pracy [P25] przeanalizowano ułamkowy ruch stabilny z temperowanym stabilnym subordynatorem. Podano najważniejsze własności takiego procesu oraz procedurę estymacji.

Ułamkowe równania Fokkera-Plancka

Swoje badania naukowe poświęciłam także ułamkowym równaniom Fokkera-Plancka, które opisują gęstości procesów anomalnej dyfuzji. W ramach tych badań opublikowane zostały prace [P3, P4, P32]. W [P3] przedstawiono proces subordynowany bazujący na procesie temperowanym stabilnym (jako modelu zewnętrznym) i α -stabilnym odwrotnym subordynatorze. Pokazano postać odpowiadającego ułamkowego równania Fokkera-Plancka, które opisuje gęstość procesu. Zajęto się także problemem estymacji oraz testowania omawianego systemu. Wyniki teoretyczne zastosowano do opisu danych rzeczywistych. W pracy [P4] wyznaczono ułamkowe równanie Fokkera-Plancka dla ułamkowego ruchu Browna z dowolnym nieskończenie podzielnym subordynatorem. Pokazano tutaj także procedurę symulacji takich

modeli oraz w szczególnych przypadkach udowodniono własność tzw. przejściowej subdyfuzji (ang. *transient subdiffusion*). Praca [P32] poświęcona jest procesowi temperowanemu stabilnemu z dowolnym nieskończenie podzielny subordynatorem. Pokazano tutaj odpowiadające ułamkowe równanie Fokkera-Plancka dla analizowanego procesu oraz przeanalizowano szczególne przypadki subordynatorów.

Inżynieria finansowa

Obszar moich zainteresowań związany jest także z zagadnieniami inżynierii finansowej. W tym zakresie skupiłam się na problemie modelowania danych finansowych z wykorzystaniem różnych typów modeli. Tego typu zagadnieniom poświęcone są prace [P2, P5, P8, P17]. W pracy [P2] opisano proces subordynowany $Y(t)$ dany wzorem (29), w którym zewnętrznym procesem jest geometryczny ruch Browna, natomiast subordynator jest procesem temperowanym stabilnym o transformacie Laplace'a (31). Przedstawiono tutaj najważniejsze własności analizowanego procesu oraz zajęto się problemem estymacji. Omawiany model zastosowano do opisu finansowych danych rzeczywistych. W pracy [P5] omówiono model anomalnej dyfuzji, w którym proces zewnętrzny jest ruchem Browna, a proces wewnętrzny jest α -stabilny. Omówiono najważniejsze własności takich systemów oraz podano szereg metod do estymacji parametru stabilności α . Wyniki teoretyczne zastosowano do opisu danych finansowych. W pracy [P8] badaniu poddano α -stabilny proces Ornsteina-Uhlenbecka (który jest ciągłym odpowiednikiem modelu AR) ze stabilnym subordynatorem. Podano tutaj procedurę estymacji w takim modelu oraz zastosowano go do trzech rodzajów danych finansowych z widocznymi momentami zatrzymań. W pracy [P17] omówiono arytmetyczny ruch Browna z odwrotnym temperowanym stabilnym subordynatorem. Podano tutaj, jak estymować parametry takiego procesu. System ten zastosowano do opisu danych pochodzących z rynku finansowego. Problemem opisu finansowych danych rzeczywistych z wykorzystaniem modeli błędzenia losowego z czasem ciągłym (będących dyskretnym odpowiednikiem procesów subordynowanych) zajęto się także w pracach [P9, P10].

Rynek energii elektrycznej

Kolejnym obszarem moich zainteresowań jest rynek energii elektrycznej ze szczególnym uwzględnieniem optymalnych strategii wytwórców energii. Badania koncentrują się na zastosowaniu metod teorii gier do badania zachowań graczy na rynku energii. W ramach tych badań powstały prace dotyczące wspomnianych zagadnień [P23, P27, P28, P29, P30, P31].

Narzędzia statystyczne i algorytmy

W czasie mojej działalności badawczej konstruowałam narzędzia statystyczne oraz algorytmy, które miały służyć przede wszystkim do estymacji oraz testowania procesów anomalnej dyfuzji bazujących na procesach subordynowanych z odwrotnym subordynatorem. Procedury estymacji oraz testowania takich systemów dla różnych procesów subordynowanych są przedstawione w pracach [P2, P3, P5, P8, P12, P17, P25] oraz [H14]. Wyniki tych prac omówione są powyżej.

Prace dla przemysłu i gospodarki

Jestem autorką raportu "Opracowanie procedury do identyfikacji i segmentacji sygnałów z systemu monitorowania", który wykonałam na zlecenie KGHM CUPRUM spółka z o.o. Centrum Badawczo-Rozwojowe, 2013.

Brałam udział w zleceniu "Analiza czynników ryzyka oraz opracowanie założeń optymalnej struktury umożliwiającej efektywne zarządzanie ryzykiem w Holdingu BOT" finansowanego przez BOT Górnictwo i Energetyka S.A., 2005-2006. Wynikami tych badań są nieopublikowane raporty.

Jestem współautorką opracowania "Analiza sytuacji rynkowej w zakresie regularnego przewozu osób na linii komunikacji autobusowej nr 31 Wałbrzych – Świebodzice – Świdnica", CBF CREATOR (na podstawie umowy z Województwem Dolnośląskim nr DU-z. 081 – 081 – 537/08 z dnia 19 czerwca 2008), 2009.

W ramach badań naukowych współpracuję: z Wydziałem Geoinżynierii, Górnictwa i Geologii w zakresie modelowania danych dotyczących promieniowania radonu w Jaskini Niedźwiedzia (prof. T. Przylibski) oraz z Zakładem Górnictwa KGHM Cuprum w zakresie modelowania sygnałów sejsmicznych (dr. inż. M. Madziarz).

Literatura

- [P1] Broszkiewicz-Suwaj E., Makagon A., Weron R., Wyłomańska A., 2004. On detecting and modeling periodic correlation in financial data. *Physica A* 336, 196-205.
- [P2] Gajda, J., Wyłomańska A., 2012. Geometric Brownian motion with tempered stable waiting times, *J. Stat. Phys.* 148, 296-3.
- [P3] Gajda J., Wyłomańska A., 2013. Tempered stable Lévy motion driven by stable subordinator, *Physica A* 392, 3168-3176.
- [P4] Gajda J., Wyłomańska A., 2014. Fokker-Planck type equations associated with fractional Brownian motion controlled by infinitely divisible processes, *Physica A* 405, 104-113.
- [P5] Janczura J., Wyłomańska A., 2009. Subdynamics of financial data from fractional Fokker-Planck equation, *Acta Phys. Polon. B* 40(5), 1341-1351.
- [P6] Janczura J., Wyłomańska A., 2012. Anomalous diffusion models: different types of subordinator distribution, *Acta Phys. Polon. B* 43(5), 1001-1016.
- [P7] Janczura J., Teuerle M., Wyłomańska A., 2013. Analiza jakości powietrza wewnętrznego z wykorzystaniem metod szeregów czasowych, w *Czujniki i Sensory do Pomiaru Czynniki Stanowiących Zagrożenia w Środowisku*, część 2. red. W. Grzebyk, Wrocław.
- [P8] Janczura J., Orzeł S., Wyłomańska A., 2011. Subordinated alpha-stable Ornstein-Uhlenbeck process as a tool of financial data description, *Physica A* 390, 4379-4387.
- [P9] Jurlewicz A., Wyłomańska A., Żebrowski P., 2008. Financial Data Analysis by means of Coupled Continuous-Time Random Walk in Rachev-Ruschendorf Model, *Acta Phys. Polon. A* 114(3), 629-634.
- [P10] Jurlewicz A., Wyłomańska A., Żebrowski P., 2009. Coupled continuous-time random walk approach to the Rachev-Ruschendorf model for financial data, *Physica A* 388, 407-418.

- [P11] Maciejewska M., Szczurek A., Sikora G., Wyłomańska A., 2012. Diffusive and sub-diffusive dynamics of indoor microclimate. A time series modeling, *Phys. Rev. E* 86, 031128.
- [P12] Maciejewska M., Szczurek A., Janczura J., Wyłomańska A., 2013. Stochastic modeling of indoor air temperature, *J. Stat. Phys.* 152, 979-994.
- [P13] Makagon A., Wyłomańska A., 2008. On the support of the spectral measure of a harmonizable sequence, *Proceedings of the American Mathematical Society* 136, . 2609-2613.
- [P14] Obuchowski J., Wyłomańska A., 2013. The Ornstein-Uhlenbeck process with non-Gaussian structure, *Acta Phys. Polon B* 44(5), 1123-1136.
- [P15] Obuchowski J., Wyłomańska A., Zimroz R., 2013. Quantile-based risk measures as a tool for local damage detection in rotating mining machinery, in: *Interdyscyplinarne Zagadnienia w Górnictwie i Geologii*, red. J. Drzymała, W. Ciężkowski, 159-164.
- [P16] Obuchowski J., Wyłomańska A., Zimroz R., 2013. Selection of informative frequency band based on the local maxima method in application to bearing diagnostics, 12th International Technical Systems Degradation Conference (Liptovský Mikuláš, Slovakia, 3-6.04 2013).
- [P17] Orzeł S., Wyłomańska A., 2011. Calibration of the subdiffusive arithmetic Brownian motion with tempered stable waiting-times, *J. Stat. Phys.* 143(3), 447-454.
- [P18] Ropuszyńska-Surma E., Węglarz M., Wyłomańska A., 2011. Badania typu foresight w planowaniu kierunków rozwoju energetyki regionalnej, *Przegląd Elektrotechniczny R.* 87, 9a, 226-229.
- [P19] Ropuszyńska-Surma E., Szalbierz Z., Węglarz M., Wyłomańska A., 2011. Regionalna strategia energetyczna na bazie badań foresightowych, *Rynek Energii* 2, 151-156.
- [P20] Ropuszyńska-Surma E., Węglarz M., Wyłomańska A., 2011. Bariery rozwoju technologii przyczyniających się do wzrostu bezpieczeństwa energetycznego Dolnego Śląska - wyniki badań foresightowych, *Rynek Energii* 1, 152-157.
- [P21] Ropuszyńska-Surma E., Węglarz M., Wyłomańska A., 2010. Strategia rozwoju energetyki na Dolnym Śląsku metodami foresightowymi, *Rynek Energii* 6, 105-107.
- [P22] Ropuszyńska-Surma E., Wyłomańska A., 2009. Cele i założenia projektu strategia rozwoju energetyki na Dolnym Śląsku metodami foresightowymi, *Energetyka* 12, 856-857.
- [P23] Sapio S., Wyłomańska A., 2008. The impact of forward trading on the spot power price volatility with Cournot competition, 5th International Conference on the European Electricity Market, EEM 2008, [Lisbon, Portugal, 28-30 May 2008. Piscataway, NJ : IEEE], 1-6.
- [P24] Stefaniak P., Wyłomańska A., Zimroz R., 2014. Procedury wyznaczania progów decyzyjnych w zarządzaniu eksploatacją układów napędowych przenośników taśmowych - statystyczne modelowanie danych diagnostycznych. XXIII Szkoła Eksploatacji Podziemnej: materiały konferencyjne (Kraków, 24-28 lutego 2014), Instytut Gospodarki Surowcami Mineralnymi i Energią Polskiej Akademii Nauk, Katedra Górnictwa Podziemnego. Akademia Górniczo-Hutnicza. Kraków : Szkoła Eksploatacji Podziemnej.
- [P25] Teuerle M., Wyłomańska A., Sikora G., 2013. Modelling anomalous diffusion by subordinated fractional Levy-stable process, *J. Stat. Mech.* P05016.
- [P26] Weron A., Wyłomańska A., 2011. Prognoza dla sektora energetycznego Dolnego Śląska na lata 2010-2020, *Strategia rozwoju energetyki na Dolnym Śląsku na podstawie*

- metody foresightowej Delphi : praca zbiorowa / pod red. Edyty Ropuszyńskiej-Surmy i Zdzisława Szalbierza. Wrocław : Oficyna Wydawnicza Politechniki Wrocławskiej, 91-106.
- [P27] Węglarz M. Wyłomańska A., 2010. Optimal bidding strategies on the power market based on the stochastic models, stochastic models, Modern Electric Power Systems, MEPS '10 , September, 20-22, 2010, Wrocław, Poland. Wrocław : Institute of Electrical Power Engineering. Wrocław University of Technology, 1-6.
- [P28] Węglarz M. Wyłomańska A., 2009. Jak modelować dane elektroenergetyczne przy wykorzystaniu szeregów czasowych?, Aktualne problemy w elektroenergetyce, APE '09 : XIV Międzynarodowa konferencja naukowa, Gdańsk-Jurata, 3-5 czerwca 2009. T. 1, Systemy elektroenergetyczne : eksploatacja, stabilność, niezawodność, awarie i restytucje, modelowanie i symulacje. [Gdańsk] : Politechnika Gdańska. Katedra Elektroenergetyki, 239-246.
- [P29] Węglarz M. Weron A., Wyłomańska A., 2008. Stochastic models for bidding strategies on oligopoly electricity market, Math. Methods Oper. Res. 69, 579-592.
- [P30] Węglarz M., Wyłomańska A., 2008. Modele gry producentów energii elektrycznej na rynku spotowym, Systems: Journal of Transdisciplinary Systems Science 13, 141-147.
- [P31] Węglarz M., Wyłomańska A., 2008. Financial engineering as a tool of power producers' strategies optimization, The European electricity market. Challenge of the unification. EEM-07. 4th Conference, Cracow, Poland, May 23-25, 2007. Łódź : Instytut Elektroenergetyki PŁódz. : SEP, 159-165.
- [P32] Wyłomańska A. 2013. Tempered stable process with infinitely divisible inverse subordinators, J. Stat. Mech. P10011.
- [P33] Wyłomańska A., 2011. Measures of dependence for Ornstein-Uhlenbeck processes with tempered stable distribution, Acta Phys. Polon. B 42, 2049-2062.
-
- [1] Antoni J., Bonnardot F., Raad A., El Badaoui A. M., 2004. Cyclostationary modeling of rotating machine vibration signals, Mech. Syst. Signal Process. 18 (6), 1285-1314.
- [2] Antoni J., Randall R., 2006., The spectral kurtosis: application to the vibratory surveillance and diagnostics of rotating machines, Mech. Syst. Signal Process. 20 (2), 308-331.
- [3] Antoni J., 2009, Cyclostationarity by examples, Mech. Syst. Signal Process. 23 (4), 987-1036.
- [4] Arnold B.C., 2004. Pareto Distributions. John Wiley & Sons, Inc. All.
- [5] Baillie D.C, Mathew J., 1996. A comparison of autoregressive modeling techniques for fault diagnosis of rolling element bearings, Mech. Syst. Signal Process. 10, 1-17.
- [6] Barndorff-Nielsen O., 1997. Normal inverse Gaussian distributions and stochastic volatility modelling. Scand. J. Statist. 24, 1-13.
- [7] Bloomfield P., Hurd H.L., Lund R.B., 1994. Periodic correlation in stratospheric ozone data, J. Time Ser. Anal. 12, 127-150.
- [8] Bartelmus W., Zimroz R., 2009. A new feature for monitoring the condition of gearboxes in non-stationary operating conditions, Mech. Syst. Signal Process. 2, 1528-1534.
- [9] Bochner S., 1949. Diffusion equation and stochastic processes, Proc. Natl. Acad. Sci. USA 35, 368-370.
- [10] Bochner S., 1955. Harmonic Analysis and the Theory of Probability, Unif. California Press.

- [11] Brooks R., Thorpe R., Wilson J., 2004. A new method for defining and managing process alarms and for correcting process operation when an alarm occurs, *Journal of Hazardous Materials* 115, 169-174.
- [12] Burnecki K. Janczura J., Weron R., 2011. Building loss models, in *Statistical Tools for Finance and Insurance*, ed. P. Cizek, W.H Hardle, R. Weron, Springer.
- [13] Caspi A., Granek R., Elbaum M., 2000. Enhanced diffusion in active intracellular transport, *Phys. Rev. Lett.* 85, 5655-5658.
- [14] Cempel C., 1990. Limit value in practice of vibration diagnosis, *Mech. Syst. Signal Process.* 4, 483-493.
- [15] Combet F., Zimroz R., 2009. A new method for the estimation of the instantaneous speed relative fluctuation in a vibration signal based on the short time scale transform, *Mech. Syst. Signal Process.* 23, 1382-1397.
- [16] Dehay D., Hurd H., (1994. Representation and estimation for PC and almost PC random processes, In *Cyclostationarity in Communications and Signal Processing* (ed. W. Gardner). New York: IEEE Press, 295-329.
- [17] Dickey D., Fuller W., 1979. Distribution of the estimators for autoregressive time series with a unit root, *Journal of the American Statistical Association* 74, 427-431.
- [18] Dickey D., Fuller W., 1981. Likelihood ratio statistics for autoregressive time series with a unit root, *Econometrica* 49, 1057-1072.
- [19] Draper N.R., Smith H., 1988. *Applied Regression Analysis*, Wiley Series in Probability and Statistics.
- [20] Endo H., Randall R.B., 2007. Enhancement of autoregressive model based gear tooth fault detection technique by the use of minimum entropy deconvolution filter, *Mech. Syst. Signal Process.* 21, 906-919.
- [21] Gladyshev E.G., 1961. Periodically correlated random sequences, *Sov. Math.* 2, 385-388.
- [22] Golding I., Cox E.C., 2006. Physical nature of bacterial cytoplasm, *Phys. Rev. Lett.* 96, 098102.
- [23] Gonchar V.Yu., Chechkin A.V. , Sorokovoy E.L. , Chechkin V.V., Grigor'eva L.I., Volkov E.D., 2003. Stable Lévy distributions of the density and potential fluctuations in the edge plasma of the U-3M torsatron, *Plasma Physics Reports* 29(5), 380-390.
- [24] Gordon A. D., 1999. *Classification*. Chapman & Hall.
- [25] Huang R., Zheng H., Kuruoglu E.E., 2013. Time-varying ARMA stable process estimation using sequential Monte Carlo, *Signal Image and Video Processing* 7(5), 951-958.
- [26] Hurd H., 1989. Representation of strongly harmonizable periodically correlated processes and their covariance, *Journal of Multivariate Analysis* 29, 53-67.
- [27] Jablonski A., Barszcz T., Bielecka M., Breuhaus P., 2013. Modeling of probability distribution functions for automatic threshold calculation in condition monitoring systems, *Measurement* 46/1, 727-738.
- [28] Janicki A., Weron A., 1994. Can one see α -stable variables and processes? *Stat.Sci.* 9, 109-126.
- [29] Jeon J.-H., Tejedor V., Burov S., Barkai E., Selhuber-Unkel Ch., Berg-Srensen K., Odderhede L., Metzler, R., 2011. In vivo anomalous diffusion and weak ergodicity breaking of lipid granules, *Phys. Rev. Lett.* 106, 048103.

- [30] Justel A., Pen D., Zamar R., 1997. A multivariate Kolmogorov–Smirnov test of goodness of fit, *Statistics & Probability Letters* 35(3), 251–259.
- [31] Kleiber C., Kotz S., 2003. *Statistical Size Distributions in Economics and Actuarial Sciences*. Wiley.
- [32] Kwiatkowski D., Phillips P.C.B., Schmidt P., Shin Y., 1992. Testing the null hypothesis of stationarity against the alternative of a unit root?: How sure are we that economic time series have a unit root? *Journal of Econometrics* 54, 159–178.
- [33] Madan D.B., Carr P.P., Chang E.C., 1998. The variance gamma process and option pricing, *Eur. Finance Rev.* 2, 79–105.
- [34] Makowski R.A., Zimroz R., 2011. Adaptive bearings vibration modelling for diagnosis, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 6943, 248–259.
- [35] Makowski R.A., Zimroz R., 2013. A procedure for weighted summation of the derivatives of reflection coefficients in adaptive Schur filter with application to fault detection in rolling element bearings, *Mech. Syst. Signal Process.* 38, 65–77.
- [36] McFadden P.D., Smith J.D., 1984. Vibration monitoring of rolling element bearings by the high frequency resonance technique – a review, *Tribology International* 17, 3–10.
- [37] Metzler R., Klafter J., 2000. The random walk’s guide to anomalous diffusion: a fractional dynamics approach, *Phys. Rep.* 339, 1–77.
- [38] Mitkowski W., Kacprzyk J., Baranowski J., 2013. *Advances in the Theory and Applications of Non-integer Order Systems*, Springer.
- [39] Mittnik S., Ratchev S.T., 2000. *Stable Paretian Models in Finance*. Wiley, New York.
- [40] Nikias C.L., Shao M., 1995. *Signal Processing with Alpha-Stable Distributions and Applications (Adaptive and Learning Systems for Signal Processing, Communications and Control Series)*. Wiley-Interscience.
- [41] Nikolaou N.G., Antoniadis I.A., 2002. Demodulation of vibration signals generated by defects in rolling element bearings using complex shifted Morlet wavelets, *Mech. Syst. Signal Process.* 16 (4), 677–694.
- [42] Phillips P.C.B., Perron P., 1988. Testing for a unit-root in time series regression, *Biometrika* 75, 335–346.
- [43] Poulimenos A.G., Fassois S.D., 2006. Parametric time-domain methods for non-stationary random vibration modeling and analysis - A critical survey and comparison, *Mech. Syst. Signal Pr.* 20, 763–816.
- [44] Randall R., Antoni J., 2011. Rolling element bearing diagnostics – A tutorial, *Mech. Syst. Signal Process.* 25 (2), 485–520.
- [45] Samorodnitsky G., Taqqu M.S., 1994. *Stable Non-Gaussian random processes*, Chapman & Hall, New York.
- [46] Said S.E., Dickey D., 1984. Testing for unit roots in autoregressive-moving average models of unknown order, *Biometrika* 71, 599–607.
- [47] Samuel P.D., Pines D.J., 2005. A review of vibration-based techniques for helicopter transmission diagnostics, *Journal of Sound and Vibration* 282 (1–2), 475–508.
- [48] Spiridonakos, M.D., Poulimenos A.G., Fassois S.D., 2010. Output-only identification and dynamic analysis of time-varying mechanical structures under random excitation: A comparative assessment of parametric methods, *Journal of Sound and Vibration* 329, 768–785.

- [49] Stuck B. W., Kleiner B., 1974. A statistical analysis of telephone noise, Bell. Syst. Tech. J. 53, 1263-1320.
- [50] Tse P.W., Yang W.X., Tam H.Y., 2004. Machine fault diagnosis through an effective exact wavelet analysis, Journal of Sound and Vibration 277 (4-5), 1005-1024.
- [51] Yu G., Li Ch., Zhang J., 2013. A new statistical modeling and detection method for rolling element bearings faults based on alpha-stable distribution, Mech. Syst. Signal Process. 41, 155-175.
- [52] Vecchia A.V., 1985. Periodic autoregressive-moving average (PARMA) modeling with applications to water resources, Water Resour. Bull. 21, 21-730.
- [53] Wong I.Y., Gardel M.L., Reichman D.R., Weeks E., Valentine M.T., Bausch A.R., Weitz D.A., 2004. Anomalous diffusion probes microstructure dynamics of entangled F-actin networks, Phys. Rev. Lett. 92, 178101.
- [54] Wang W., Wong A.K., 2002. Autoregressive model-based gear fault diagnosis, J Vib. Acoust. 124, 172-179.
- [55] Weron R., 2004. Computationally Intensive Value at Risk Calculations (in: Handbook of Computational Statistics: Concepts and Methods), eds. Gentle J.E., Haerdle W., Mori Y. Springer.
- [56] Wyrwas M., Girejko E., Mozyrska D., Pawłuszewicz E., 2013. Stability of Fractional Difference Systems with Two Orders (in: Advances in the Theory and Applications of Non-integer Order Systems), eds. Mitkowski W., Kacprzyk J., Baranowski J., Springer, 41-52.
- [57] Zhan Y., Makis V., Jardine A.K.S., 2006. Adaptive state detection of gearboxes under varying load conditions based on parametric modeling, Mech. Syst. Signal Process. 20, 188-221.
- [58] Zhan Y., Mechefske C.K., 2007. Robust detection of gearbox deterioration using compromised autoregressive modeling and Kolmogorov-Smirnov test statistic-Part I: Compromised autoregressive modeling with the aid of hypothesis tests and simulation analysis, Mech. Syst. Signal Process. 21, 1953-1982.

Agnieszka
Muszko