

POLITECHNIKA ŚLĄSKA
WYDZIAŁ: Mechaniczny Technologiczny
DYSCYPLINA NAUKOWA: Inżynieria Mechaniczna

ROZPRAWA DOKTORSKA

mgr inż. Piotr KILJAN

**METODA OKREŚLANIA SYSTEMU
IDENTYFIKACJI WĘGIEL-SKAŁA**

Promotor:

dr hab. inż. Krzysztof Kalinowski, prof. PŚ

Gliwice, 2024 r.

Składam serdeczne podziękowania promotorowi pracy
Panu Dr hab. inż. Krzysztofowi Kalinowskiemu ,Prof. Pol. Śl
za opiekę nad pracą, wnikliwe uwagi,
które przyczyniły się do powstania pracy.

Dziękuję **Panu prof. dr hab. Wojciechowi Moczulskiemu**
Za opiekę naukową, przeprowadzenia badań literaturowych,
wstępnej dyskusji nt. koncepcji pracy w ramach stażu
przemysłowego w firmie SkyTech Research sp. z o.o
(obecnie AuRoVt sp. z o.o.)

Szczególne podziękowania dla mojej siostry **Anny**
za namówienie mnie do realizacji doktoratu.

Spis treści

Spis oznaczeń i symboli	5
1 Wstęp.....	9
2 Cel i zakres pracy	13
3 Charakterystyczne cechy pokładów węgla	14
4 Podział metod nieparametrycznych analizy sygnałów.....	18
4.1 Metody analizy w dziedzinie amplitudy	19
4.2 Metody analizy w dziedzinie czasu.....	20
4.3 Analiza sygnałów niestacjonarnych w dziedzinie częstotliwości.....	21
4.3.1 Analiza oparta na STFT.....	26
4.3.2 Analiza oparta na przekształceniu falkowym.....	27
5 Przegląd metod rozpoznawania granicy warstw węgla i skały.....	33
5.1 Metoda wizyjna	36
5.2 Metoda wykorzystująca georadar	38
5.3 Metoda wykorzystująca występowanie naturalnego promieniowania gamma	40
5.4 Metoda wykorzystująca wibracje.....	43
5.5 Metoda akustyczna.....	46
5.6 Metoda wykorzystująca LIBS.....	47
6 Wybrane metody klasyfikacji	48
6.1 k najbliższych sąsiadów	49
6.2 Maszyny wektorów nośnych.....	51
6.3 Las losowy (ang. Random Forest)	53
6.4 Perceptron wielowarstwowy	53
6.5 Miary jakości klasyfikacji	55
7 Metody normalizacji danych.....	58
8 Opis metody badania	59
8.1 Określenie miejsca i warunków urabiania	60
8.2 Dobór aparatury pomiarowej	63
8.3 Rejestracja dźwięku	70

8.4	Dobór parametrów STFT	72
8.5	Analiza próbek-STFT.....	78
8.6	Przygotowanie bazy danych do programu WEKA	82
8.7	Klasyfikacja k-NN	84
8.8	Klasyfikator SVM	86
8.9	Klasyfikacja Random Forest	88
8.10	Klasyfikacja MLP	91
9	Analiza statystyczna Chi-kwadrat.....	95
10	Wnioski i przyszłe prace	99
11	Bibliografia	102
	Załącznik 1	114
	Załącznik 2	114
	Streszczenie rozprawy doktorskiej w języku polskim:	115
	Streszczenie rozprawy doktorskiej w języku angielskim:.....	116

Spis oznaczeń i symboli

<i>STFT</i>	–	Short Time Fourier Transform
<i>TF</i>	–	Fourier Transform
<i>CWT</i>	–	Continuous Wavelet Transform
<i>EMD</i>	–	Empirical Mode Decomposition
<i>LMD</i>	–	Local Mean Decomposition
<i>MFCC</i>	–	Mel-Frequency Cepstral Coefficients
<i>PCA</i>	–	Principal Component Analysis
<i>LDA</i>	–	Linear Discriminant Analysis
<i>ICA</i>	–	Independent Component Analysis
<i>ANN</i>	–	Artificial Neural Network
<i>GZW</i>	–	Górnosląskie zagłębienie węglowe
IEPE	–	Internal Electronic Piezoelectric
MEMS	–	Mikroelectromechanical System
LTCC	–	Longwall Top Coal Caving
LIBS	–	Laser-Induced Breakdown Spectroscopy
SVM	–	Support Vector Machines
k-NN	–	k-Nearest Neighbor
WEKA	–	Waikato Environment for Knowledge Analysis
GUI	–	Graficzny interfejs użytkownika
CCI	–	Correctly Classified Instances
ICI	–	Incorrectly Classified Instances

Spis rysunków

Rysunek 1. Schemat złoża pokładowego [10].	14
Rysunek 2. Charakterystyczne cechy pokładu [9, 10]	15
Rysunek 3. Główne typy uskoków, a) normalny, b) pionowy, c) odwrócony	16
Rysunek 4. Zaburzenia sedimentacyjne: a) wymycie, b) przerosty w pokładzie, c) żyła klastyczna [17].....	16
Rysunek 5. Wzór cięcia kombajnu w miejscu zaburzenia geologicznego [Opracowanie własne].....	17
Rysunek 6. Przykład wyników analizy opartej na STFT-wykres kaskadowy [opracowanie własne].....	27
Rysunek 7. Przykład wyników analizy opartej na STFT-spektrogram [opracowanie własne]	27
Rysunek 8. Skalogram dla sygnału dwutonowego [33].....	32
Rysunek 9. Podział sieci neuronowych [40]	35
Rysunek 10. Przykład zainstalowania detektora/kamery termowizyjnej na kombajnie ścianowym (opracowanie własne).	36
Rysunek 11. Różnica tekstury węgla i mułowca (zdjęcie własne).	37
Rysunek. 12. Przykładowe miejsce zainstalowania detektora promieniowania gamma na ramieniu kombajnu ścianowego [49].	42
Rysunek 13. Miejsce zainstalowania detektora promieniowania gamma na osłonie zawałowej sekcji obudowy zmechanizowanej [49, 62].....	42
Rysunek 14. Miejsce zainstalowania akcelerometru na ramieniu urabiającym kombajnu ścianowego oraz na osłonie zawałowej sekcji obudowy zmechanizowanej [6, 12].	46
Rysunek 15. Przykład metody SVM w dwuwymiarowej przestrzeni [opracowanie własne].	51
Rysunek. 16. Etapy realizacji metody.....	59
Rysunek 17. Kompleks ścianowy [96].....	62
Rysunek 18. Dookólna charakterystyka mikrofonu [100].	66
Rysunek 19. Kardoidalna charakterystyka mikrofonu [100].	66
Rysunek 20. Hyperkardoidalna charakterystyka mikrofonu [100].....	67
Rysunek 21. Charakterystyka ósemkowa mikrofonu [100].	67
Rysunek 22. mikrofon kierunkowy Synco D-1 [103].	68

Rysunek 23 Rejestrator dźwięku ZOOM H5.	69
Rysunek 24 Schemat lokalizacji mikrofonu w wyrobisku ścianowym.....	70
Rysunek 25 Rozdzielczość czasowa i częstotliwościowa w zależności od dobranego okna [22]	73
Rysunek 26 Wpływ zastosowania okna wąskiego (1024) (opracowanie własne).	74
Rysunek 27. Wpływ zastosowania okna szerokiego (4096) (opracowanie własne).	75
Rysunek 28 Wpływ okienkowania na kształt sygnału [24]	76
Rysunek 29 Przykład zastosowania różnych funkcji okna	77
Rysunek 30 Wykres kaskadowy-węgiel	79
Rysunek 31 Wykres kaskadowy-skała	79
Rysunek 32 Spektrogram-węgiel	79
Rysunek 33 Spektrogram-skała.....	80
Rysunek 34 Wykres średnich amplitud w czasie całego nagrania próbek dźwięku	81
Rysunek 35. Fragment struktury danych wykorzystanych do analizy w programie WEKA.....	83
Rysunek 36 Dobór eksperymentalny wartości k klasyfikacji k-NN	85
Rysunek 37 Poprawnie sklasyfikowane przypadki klasyfikacji SVM.....	88
Rysunek 38 Poprawność klasyfikacji w zależności od liczby drzew oraz liczby cech	90
Rysunek 39 Okno dostosowywania parametrów sieci MLP w programie WEKA	92
Rysunek 40. Wyniki poprawnej klasyfikacji MPL.....	94
Rysunek 41 Model rozpoznawania węgla i skały	100

Spis tabel

Tabela 1 Porównanie wartości wybranych parametrów funkcji okien [22].....	25
Tabela 2 Przekształcenia stosowane do ekstrakcji cech [40].	34
Tabela 3 Właściwości elektryczne niektórych skał [53, 55].	39
Tabela 4 Zakres zmienności aktywności właściwej naturalnych izotopów promieniotwórczych w węglach i skałach [58].	41
Tabela 5 Wartości wytrzymałości skał na ściskanie w rejonie ściany nr 5.....	61
Tabela 6 Dane wejściowe do programu WEKA.	82
Tabela 7 Liczba wykorzystanych atrybutów do analizy k-NN.	84
Tabela 8 Wyniki klasyfikacji k-NN dla $k=21$	85
Tabela 9 Wyniki klasyfikacji dla poszczególnych funkcji jądra oraz parametru C.	87
Tabela 10 Wyniki poprawności metody Random Forest w zależności od liczby drzew i liczby cech.	89
Tabela 11 Wyniki klasyfikacji Random Forest.....	90
Tabela 12 Wyniki klasyfikacji MLP z normalizacją.....	93
Tabela 13 Wyniki klasyfikacji MLP bez normalizacji.....	94
Tabela 14 Wyniki obliczeń statystyki χ^2	97

1 Wstęp

Kopalnie węgla kamiennego w Polsce od kilku lat podlegają procesom restrukturyzacyjnym. Do czasu wybuchu wojny na terenie Ukrainy ceny węgla importowanego z rynków zagranicznych były niższe od cen oferowanych przez producentów krajowych. W roku 2022 w Polsce zanotowano deficyt węgla z powodu sankcji nałożonych na Federację Rosyjską, co spowodowało wstrzymanie importu węgla z tego kraju. Trudności z importem oraz czas potrzebny na transport węgla z innych krajów wymusiło na przedsiębiorstwach górniczych podjęcie działań mających na celu zwiększenie wydobycia węgla kamiennego. Możliwość zwiększenia wydobycia w kopalniach węgla kamiennego ograniczona jest wieloma czynnikami. Jednym z czynników jest ograniczony front robót górniczych, którego nie można rozszerzyć w sposób gwałtowny. Związane jest to z niedoborem osobowym pracowników, wysokim nakładem kosztów oraz czasem potrzebnym do wykonania wyrobisk przygotowawczych. W zależności od warunków geologicznych i technicznych jest możliwe wykonanie ok. 100-250m wyrobiska w skali miesiąca. Około 1,5 roku zajmuje wykonanie ściany o wybiegu 1 km i długości 250m (bez wyrobisk udostępniających), ponieważ w tym celu należy wydrążyć aż 2,5km wyrobisk rozcinających pole ściany. Istotny wpływ na ograniczenie produkcji mają także występujące zagrożenia naturalne, takie jak: wybuch metanu, tąpnięcia. Niestety, zwiększenie wydajności i szybkości prac, może się przełożyć na bezpieczeństwo pracowników.

Przedsiębiorcom może pomóc rozwijająca się idea Przemysłu 4.0, czyli czwartej rewolucji przemysłowej, którą zapoczątkowała rozwijająca się wszechobecna cyfryzacja. W skład Przemysłu 4.0. wchodzi takie obszary jak: Przemysłowy Internet Rzeczy, obliczenia w chmurze, duże zbiory danych i analityka, autonomiczne roboty, pozioma i pionowa integracja softwarowa, poszerzona rzeczywistość, technologie przyrostowe oraz symulacje linii i procesów produkcyjnych, co przekłada się na stworzenie inteligentnej fabryki. Przemysłowy Internet Rzeczy - koncepcja wykorzystania połączenia różnych przedmiotów, które nie tylko kojarzą się bezpośrednio z Internetem, takich jak komputery, laptopy, tablety, smartfony, ale także lodówki, telewizory, linie produkcyjne, maszyny, roboty. Takie połączenie pozwala na wykorzystanie Internetu nie tylko w życiu codziennym, ale także w automatyce

przemysłowej i prowadzi do wzrostu wydajności produkcji. Chmury obliczeniowe to wirtualne przestrzenie, które pozwalają na zbieranie plików tekstowych, notatek czy danych w niemal dowolnej formie. Ich obecność zrewolucjonizowała pracę firm, zapewniając niemal nieograniczony dostęp do przetwarzania i przechowywania danych dla fabryk, przedsiębiorców i innych firm, a także dostęp do danych z każdego miejsca na Ziemi. Inteligentne fabryki - fabryki nowej generacji wykorzystujące różne obszary Przemysłu 4.0 w zależności od popytu i potrzeb. Wyróżnić można cztery rodzaje takich fabryk: Inteligentne zautomatyzowane i zrobotyzowane zakłady, cyfrowe fabryki masowej indywidualizacji tzw. zakłady zorientowane na klienta, mobilne fabryki modułowe, zakłady produkcji ręcznej wspomagane cyfryzacją [1]. Postępująca cyfryzacja w inżynierii mechanicznej a razem z nią, urządzeń w zakładach przemysłowych wydobywających węgiel kamienny, umożliwia pozyskiwanie w czasie rzeczywistym informacji o pracy urządzeń, systemów pomiarowych z zakresu geofizyki, gazometrii oraz jakości węgla kamiennego. Większość danych pozyskiwanych z systemów technicznych jest wykorzystywana głównie do kontroli i monitorowania parametrów pracy urządzeń lub parametrów środowiskowych. Uzyskane dane są archiwizowane i sporadycznie wykorzystywane do wyjaśnienia lub analizy konkretnego zdarzenia. Pozyskane dane przesyłane są na powierzchnię zakładu górniczego za pośrednictwem istniejącej infrastruktury światłowodowej. Stosowany jest głównie w systemach transmisji danych technologicznych, takich jak: transmisja danych ze sterowników maszyn i urządzeń, transmisja danych z systemów ochrony zasilania 6 kV, a także z systemów kamer telewizji dozorowej.

W polskim górnictwie najczęściej stosowanymi metodami wydobycia węgla są systemy ścianowe. Można wyróżnić dwa główne warianty kompleksów ścianowych ze względu na zastosowane w nich maszyny urabiające [2]. Kompleksy ścianowe w których w zależności od warunków górniczo-geologicznych wykorzystano rozwiązania strugowe lub kombajnowe. System strugowy wykorzystywany jest w Lubelskim Zagłębiu Węglowym. Stosowany jest głównie w pokładach niskich o niewielkim stopniu zaburzenia pokładu (przebieg warstwy węgla zbliżony do prostej, brak występowania uskokiów tektonicznych lub występujące uskoki o małym zrzucie warstw, znikome wtrącenia skalne) o stosunkowej niskiej zwięzłości warstwy węgla. Systemu ścianowy różni się tym od strugowego, że jest stosowany przy pokładach o większej miąższości. Niska wysokość pokładów ograniczająca miejsce w przestrzeni roboczej

dla operatora, wysoka prędkość przesuwu struga oraz wysoka szybkość sterowania zestawem sekcji obudowy zmechanizowanej wymusiła zastosowanie automatyki do kontroli i sterowania kompleksem wydobywczym. Praca strugu odbywa się w sposób automatyczny ze względu na ograniczoną przestrzeń dla operatora i związanych z tym zagrożeń, takich jak np. obryw skał stropowych.

System ścianowy wykorzystujący kombajn jest systemem najpowszechniej stosowanym w Górnośląskim Zagłębiu Węglowym. Jest on bardziej elastyczny pod względem występujących warunków geologicznych. Może być stosowany do pokładów, gdzie występują uskoki o wartości zrzutu warstw równej miąższości pokładów (powyżej tej wartości wydobywanie nie jest opłacalne ekonomicznie ze względu na zawartość skały płonnej w urobku), pokładach zawierających przerosty skalne, lekko zafałdowanych, o dużej miąższości. Wysoka złożoność warunków górniczo-geologicznych sprawia, że opracowanie systemu automatycznego urabiania nie jest zagadnieniem łatwym. Trudność polega na odpowiedniej synchronizacji maszyn i urządzeń zainstalowanych w ścianie wydobywczej, od przenośnika ścianowego transportującego urobek, sekcji obudowy zmechanizowanej utrzymującej stateczność wyrobiska i odpowiedzialnej za posuw przenośnika ścianowego w kierunku wydobycia, i kombajnu urabiającego węgiel. W zakładach górniczych stosujących kompleksy ścianowe z kombajnem, podejmowano próby zastosowania zautomatyzowanego systemu wydobycia. Jednym z nich jest system automatycznego sterowania obudową DOH-matic [3]. Sterowanie sekcjami obudowy zmechanizowanej działa nie w pełni automatycznie, lecz pod obserwacją i nadzorem. Nadzór odbywa się ze stanowiska znajdującego się poza wyrobiskiem ścianowym, zlokalizowanym w chodniku podścianowym. Możliwe jest to dzięki zastosowaniu rozbudowanej aparatury pomiarowej dostarczającej niezbędnych informacji z wyrobiska. Informacje przekazywane do operatora to m.in. ciśnienie w strefie podtłokowej stojaków obudowy, położenie przesuwnika przenośnika zgrzeblowego oraz kombajnu ścianowego. Podczas przeprowadzonych testów uzyskane dane wskazały, że czas przestawiania sekcji w trybie automatycznym wynosił średnio 12,2 s, natomiast średni czas przestawienia obudowy przez górnika sekcyjnego w trybie ręcznym wynosił 22,2 s. Zanotowano także wyższe wydobywanie dobowe ściany z zainstalowanym systemem w porównaniu do innych ścian w zakładzie górniczym [4, 5]. W KWK „Pniówek” zastosowano zautomatyzowany system ścianowy, gdzie procesem urabiania steruje dwóch

kombajnistów siedzących przy pulpitych sterowniczych, jeden górnik sekcyjny oraz kablowy. Kombajniści nadzorują pracę kombajnu, mogą przejąć kontrolę na kombajnem w sytuacjach tego wymagających. W tym czasie mogą przejechać odcinek ściany kombajnem bez korekty skrawu wzorcowego lub skorygować parametry skrawu wzorcowego. System monitoringu pracy urządzeń wyświetla na monitorze wszystkie najpotrzebniejsze parametry pracy, a w razie wystąpienia awarii operator powiadamiany jest o jej rodzaju i miejscu. W celu zapewnienia bezpieczeństwa załogi przebywającej w ścianie, sekcje obudowy zmechanizowanej powiadamiają o rozpoczęciu pracy sygnałem dźwiękowym i świetlnym, oprócz tego możliwe jest zablokowanie przez pracownika części sekcji lub wszystkich sekcji. Zautomatyzowany system zainstalowany został w ścianie o wysokim zagrożeniu metanowym należącym do IV kategorii zagrożenia metanowego, w partii zaliczonej do zagrożonych wyrzutami gazów i skał. System pozwolił na ograniczenie liczby zatrudnionej załogi na zmianę z 17 osób do 14. Co pozwoliło na oszczędność 12 osób na dobę przy systemie pracy czterozmianowym [6, 7, 8, 9].

Testowane systemy automatycznej pracy kompleksu ścianowego pozwalają na zwiększenie bezpieczeństwa załogi, ograniczenie jej liczby w danym rejonie prac, gdzie występują zagrożenia naturalne o wysokim stopniu. Automatyzacja, oprócz uzyskiwania większego wydobycia pozwala na natychmiastowe powiadomienie operatora o występującej awarii oraz miejscu jej wystąpienia. Wysoka automatyzacja pracy ma także wpływ na stopień zmęczenia pracowników na danej zmianie, co przekłada się także na efektywność i bezpieczeństwo pracy.

Wykorzystane systemy nie są w pełni zautomatyzowane, a praca urządzeń odbywa się pod nadzorem pracowników. Praca w trybie pod nadzorem pracowników pozwoliła na ograniczenie ich liczby w rejonach zagrożonych. Wpłynęło to na zwiększenie bezpieczeństwa załogi jak i ograniczenie kosztów produkcyjnych. Inwestycja w zwiększenie automatyzacji procesu produkcyjnego przełożyła się także na szybkość wykonywanych pracy związanych z procesem wydobywczym, zwiększając końcowe wyniki produkcyjne. Z tych powodów dalsze badania nad zwiększeniem poziomu automatyzacji pracy kombajnów ścianowych mają bardzo duże znaczenie i są kluczowe przy kształtowaniu konkurencyjnych cen węgla w stosunku do oferowanych na rynkach zagranicznych.

2 Cel i zakres pracy

Głównym celem pracy jest opracowanie metody określania systemu rozpoznawania węgla i skały na podstawie rejestrowanego dźwięku urabiania w ścianie wydobywczej kopalni węgla kamiennego.

W procesie tworzenia systemu identyfikacji węgiel-skała wyszczególniono cztery etapy.

Pierwszy etap obejmował dobór i przygotowanie odpowiedniej aparatury pomiarowej do warunków panujących w miejscu rejestracji dźwięku. Uwzględniono w nim najistotniejsze parametry zapewniające prawidłowy sposób rejestracji dźwięku, uzyskanie odpowiedniej jakości nagrywanego materiału oraz zgodność z przepisami BHP obowiązującymi w Zakładzie Górniczym Janina, Południowego Koncernu Węglowego S.A.


Drugi etap polegał na doborze metody określenia charakterystycznych cech zarejestrowanych próbek dźwiękowych. W tym celu posłużono się metodą analizy czasowo-częstotliwościowej wykorzystującej krótkoczasowe przekształcenie Fouriera (STFT). Na podstawie doboru odpowiednich parametrów analizy STFT sporządzono wykresy kaskadowe oraz spektrogramy w programie Matlab-MathWorks, z których wyznaczono charakterystyczne przedziały częstotliwościowe oraz amplitudy dla poszczególnych rodzajów skał. Na podstawie wyeksportowanych danych z programu Matlab-MathWorks stworzono bazę danych do dalszej analizy w programie Waikato Environment for Knowledge Analysis (WEKA).

Etap trzeci obejmował normalizację danych oraz wykorzystanie wybranych metod klasyfikacji umożliwiających rozpoznanie warstw węgla i skały wraz z doбором odpowiednich wartości parametrów poszczególnych metod.

W etapie czwartym wykorzystano analizę statystyczną Chi-kwadrat Pearsona, w celu zbadania zależności pomiędzy dwoma próbkami węgla i skały, wykorzystując otrzymane w STFT wartości amplitud dla poszczególnych częstotliwości.

3 Charakterystyczne cechy pokładów węgla

Nie każde złożo nadaje się do eksploatacji górniczej. Złoża o znaczeniu gospodarczym i wartości przemysłowej kopalni użytecznej, są to złoża, których wartość rynkowa wydobytej kopaliny pokrywa wszystkie koszty związane z wydobyciem. Złoża takie nazywa się złożami przemysłowymi [2]. Do złożo, których wydobycie nastęrcza wiele trudności można zaliczyć złoża o skomplikowanej budowie geologicznej (uskoki, wymycia, pofałdowania), lub zalegające np. pod dnem morskim. Pokład węgla posiada formę przeważnie ławicową, ograniczoną dwoma równoległymi płaszczyznami. Dolna płaszczyzna nazywana jest spągim, górna stropem (Rys.1).



Rysunek 1. Schemat złoza pokładowego [10].

Budowa pokładów zależy od amplitudy ruchów pionowych. Wyróżnić można pokłady o budowie prostej i złożonej. Pokłady o prostej budowie nie są przedzielone wkładkami utworów niewęglowych, inaczej zwanych skałą płonną. W pokładzie budowy złożonej, występują przerosty utworów skalnych różnej grubości [11, 12].


Pokład charakteryzują następujące elementy (Rys. 1) [13, 14]:

- Rozciągłość - jest to krawędź przecięcia płaszczyzny spągu i stropu z płaszczyzną poziomą. Kąt, jaki tworzy ta krawędź z kierunkiem północnym, przyjętym umownie jako kąt zerowy, liczony zgodnie z ruchem wskazówek zegara, nazwany jest azymutem rozciągłości,
- Upad - jest to kąt dwuścienny zawarty między płaszczyzną spągu lub stropu z płaszczyzną poziomą,
- Kierunek zapadania pokładu,

- Grubość (miąższość) - pokładu jest to najkrótszy odcinek łączący strop ze spągiem.

Ze względu na grubość pokłady węgla dzieli się na [15]:

- **cienkie**, grubości do 1,5 m,
- **średnio grube**, grubości od 1,5÷3,5 m,
- **grube**, 3,5÷7,0m,
- **bardzo grube** >7,0m.




Rysunek 2. Charakterystyczne cechy pokładu [9, 10].

W pokładach węgla mogą występować zaburzenia wpływające na ocenę ich przydatności przemysłowej. Zaburzenia nierozpoznane utrudniają, a niekiedy uniemożliwiają zmechanizowaną eksploatację.

Wyróżnić można zaburzenia wpływające na zmiany [15]:


- parametrów geometrycznych (morfologii), głównie grubości pokładu aż do jego zaniku,
- jakości i własności fizykomechanicznych węgla i skał otaczających pokłady.

Zaburzeniami powodującymi nieciągłość w zaleganiu pokładów węgla są uskoki. Uskokiem nazywa się zaburzenia w pierwotnym ułożeniu warstw, polegające na przerwaniu ich ciągłości i przesunięciu względem siebie wzdłuż szczeliny uskokowej. Na Rys. 3 przedstawiono typowe przebiegi płaszczyzny uskokowej w pokładach.



Rysunek 3. Główne typy uskoków, a) normalny, b) pionowy, c) odwrócony.

Nieciągłości zalegania pokładów mogą być spowodowane przyczynami sedymentacyjnymi i erozyjnymi. Na Rys. 4 przedstawiono zaburzenia sedymentacyjne w formie wymycia, przerostów oraz żyły klastycznej. Wymycie lub zmycie pokładu jest to całkowite lub częściowe zniszczenie pokładu wskutek erozyjnego działania wody w czasie, gdy był on przykryty cienką warstwą materiału luźnego. Przerosty są to warstwy lub wkładki skały płonnej w pokładzie [13, 15]. Kiedy grubość przerostów wzrasta, wówczas pokład rozszczepia się na dwa lub więcej cieńszych pokładów. Żyła klastyczna powstaje podczas wypełnienia spękań piaskiem w tworzących się pokładach węgla [16].



Rysunek 4. Zaburzenia sedymentacyjne: a) wymycie, b) przerosty w pokładzie, c) żyła klastyczna [17].

Znajomość występowania nieciągłości tektonicznych jest szczególnie ważna przy poszukiwaniu złóż, szacowaniu zasobów i projektowaniu eksploatacji. Określenie ekonomicznie opłacalnej eksploatacji możliwe jest za pomocą obliczenia współczynnika nieciągłości. Współczynnik wyrażony jest stosunkiem całkowitej


powierzchni nieciągłości (np. powierzchni wymycia erozyjnego) pokładu (F_d) do całkowitej powierzchni występowania pokładu (F), według wzoru:

$$K_d = \frac{F_d}{F} * 100\% \quad (1)$$

Jeśli:

- $K_d > 10\%$, eksploatacja może być utrudniona
- $K_d > 45\%$, eksploatacja staje się nieekonomiczna

Określenie występowania zaburzeń geologicznych występujących w pokładzie węgla jest ważnym elementem do stworzenia automatycznego systemu eksploatacji węgla. Przewidywana forma występowania zaburzeń oraz jej kierunek częściowo zostaje stwierdzona podczas prowadzenia robót przygotowawczych chodnikami przyścianowymi. Wykonane otwory wiertnicze mogą w wysokim stopniu stwierdzić przebieg uskoków oraz zaburzeń w formie żył klastycznych.



Rysunek 5. Wzór cięcia kombajnu w miejscu zaburzenia geologicznego [Opracowanie własne].

Opracowany (Rys. 5) na tej podstawie teoretyczny przebieg uskoków w ścianie, może usprawnić działanie systemu poprzez określenie wzoru cięcia warstw. Do systemu wprowadzono by pewne odstępstwa w miejscu występującego zaburzenia. Odstępstwa polegałyby na częściowym urabianiu piaskowca obierając optymalną trasę przejazdu. Trasa mogłaby być opracowana na podstawie wcześniejszych doświadczeń z przejazdu podobnych zaburzeń geologicznych.

4 Podział metod nieparametrycznych analizy sygnałów

Nowoczesne zakłady produkcyjne wyposażone są w szereg urządzeń i maszyn, których praca nadzorowana jest przez komputery otrzymujące informacje o procesie produkcji, jaki i o stanie technicznym maszyn z zainstalowanych czujników. Informacje z czujników przekazywane w czasie rzeczywistym w większości przypadków są sygnałami niestacjonarnymi. W pierwszej części niniejszego rozdziału przedstawiono podstawowe pojęcia odnoszące się do sygnału. W kolejnych częściach rozdziału opisano wybrane metody analizy sygnałów w dziedzinie amplitudy, czasu, częstotliwości. W końcowej części rozdziału opisano najczęściej wybierane analizy sygnałów niestacjonarnych w dziedzinie częstotliwości. Pierwszą z nich jest analiza oparta na krótko-czasowej transformacji Fouriera (ang. short-time Fourier transform), która w dalszej części pracy zostanie wykorzystana do analizy dźwięku węgla i skały. Druga opisana analiza oparta jest na przekształceniu falkowym i często wykorzystywana do analizy sygnału, lub diagnostyki maszyn.

Podstawowym pojęciem teorii sygnałów jest sygnał. Sygnałem nazywa się przebieg dowolnej wielkości fizycznej, mogącej być nośnikiem informacji [18]. Sygnały najprościej można podzielić na zdeterminowane (deterministyczne) oraz sygnały losowe (stochastyczne). Sygnały zdeterminowane można opisać jednoznacznie modelami matematycznymi za pomocą funkcji (czasu, częstotliwości lub położenia) o wartościach rzeczywistych lub zespolonych. Aby opisać sygnał losowy należy przyporządkować mu proces stochastyczny. Cechy punktowe i funkcyjne wyznacza się nie dla wszystkich realizacji sygnału, lecz tylko dla skończonego, często nielicznego, zbioru realizacji wybranego z całego zbioru populacji wszystkich jego realizacji. Cechy wyznaczone dla nielicznego zbioru należącego do zbioru wszystkich jego realizacji nazywany jest estymatorem. Dla danego zbioru realizacji sygnału, estymator jest reprezentatywny, jeżeli jest estymatorem nieobciążonym, najefektywniejszym i zgodnym [19, 20, 21].

Cechy sygnałów można podzielić na ilościowe, jakościowe, liczbowe:

- cechy ilościowe -wartość jest liczbą (np. wartość średnia),
- cechy jakościowe -wartość zapisana jest w postaci nazwy lub symbolu,
- cechy liczbowe:

- punktowe, których wartość jest liczbą,
- cechy funkcyjne, których wartość jest funkcją (czasu lub częstotliwości) i zapisana jest w formie macierzowej.

Opis sygnału inaczej zwanym reprezentacją sygnału realizowany jest w trzech dziedzinach:

- czasu,
- amplitudy,
- częstotliwości.

Estymator $\check{\Phi}$ jest estymatorem nieobciążonym cechy Φ , gdy jego wartość oczekiwana jest równa wartości ocenianej cechy:

$$E\{\check{\Phi}\} = \Phi \quad (2)$$

Estymator $\check{\Phi}$ jest estymatorem najefektywniejszym cechy Φ spośród innych estymatorów tej cechy, jeśli błąd średniokwadratowy jest minimalny:

$$E\{(\check{\Phi} - \Phi)^2\} = \min_{i=1,2,\dots} E\{(\check{\Phi}_i - \Phi)^2\} \quad (3)$$

Estymator jest estymatorem zgodnym cechy, jeśli wraz ze wzrostem liczebności próby, z której jest wyznaczony, wartość estymatora dąży z prawdopodobieństwem zmierzającym do jedności do wartości ocenianej cechy.

$$\lim_{n \rightarrow \infty} E\{(\check{\Phi}_i - \Phi)^2\} = 0 \quad (4)$$

gdzie: N-liczność próby.

4.1 Metody analizy w dziedzinie amplitudy

Cechy sygnałów niestacjonarnych w dziedzinie amplitudy najczęściej wyznaczane są za pomocą wartości średniej i średniokwadratowej (wartość skuteczna). Aby wyznaczyć powyższe wartości niezbędne jest wyznaczenie gęstości rozkładu amplitud, służącej do określenia niestacjonarnej gęstości rozkładu amplitud.

Wyraża się ją wzorem:

$$p(x, t) = \lim_{\Delta x \rightarrow 0} \frac{\Pr[x < x(t) \leq x + \Delta x]}{\Delta x} \quad (5)$$

Zmienna w czasie wartość średnia, zapisana jest wzorem:

$$E[\mu_x(t)] = \frac{1}{N} \sum_{i=1}^N E[x_i(t)] = \mu_x(t) \quad (6)$$

gdzie: $x_i(t)$ jest sygnałem, $E[\dots]$ wartością oczekiwaną, $\mu_x(t)$ estymatorem wartości średniej sygnału a N długością realizacji sygnału.

Zmienna w czasie średniokwadratowa, opisywana jest zależnością:

$$E[\Psi_x^2(t)] = \frac{1}{N} \sum_{i=1}^N E[x_i(t)] = \Psi_x^2(t) \quad (7)$$

gdzie: $\Psi_x^2(t)$ jest estymatorem wartości średniokwadratowej sygnału.

Dla sygnałów niestacjonarnych pomiar gęstości prawdopodobieństwa może być bardzo trudny i wymagający analizy bardzo licznego zbioru realizacji procesu losowego. Jednakże w praktyce czasem dysponuje się tylko jedną lub kilkoma realizacjami badanego procesu. W literaturze zaproponowano wykorzystanie metody uśredniania, która w pewnych warunkach daje dobre wyniki. Jednakże w przypadku gęstości prawdopodobieństwa dają na ogół wyniki zniekształcone, uwypuklając małe i duże wartości prawdopodobieństwa amplitud kosztem średnich. Metoda ta daje dobre wyniki przy wyznaczaniu wartości średniej i średniokwadratowej [19, 21].

4.2 Metody analizy w dziedzinie czasu

Najczęściej stosowanymi metodami analizy w dziedzinie czasu są metody korelacyjne, wyznaczane jako współczynniki (cechy punktowe) lub funkcje czasu. W analizie sygnałów niestacjonarnych cechy punktowe nie mają szerokiego zastosowania. Funkcja autokorelacji to cecha funkcyjna sygnału losowego, umożliwiająca identyfikację stopnia zależności wartości sygnału w pewnej określonej chwili czasu od wartości w chwili poprzedzającej o wartość opóźnienia τ [20]. Wartość opóźnienia nazywa się przesunięciem w czasie lub translacją τ i ma stałą wartość, wyrażoną w jednostkach czasu [19].

$$R_x(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)x(t + \tau)dt$$

(8)

gdzie: T jest czasem realizacji sygnału, t określoną chwilą czasu, τ przesunięciem czasowym, $x(t)$ analizowanym sygnałem.

Funkcja autokorelacji stanowi dobre narzędzie do wykrywania procesów zdeterminowanych, które mogą być maskowane przez szum losowy [21].

W przypadku dwóch sygnałów losowych stosuje się funkcję interkorelacji (korelacji wzajemnej). Funkcja ta charakteryzuje wzajemną zależność wartości jednego sygnału losowego od wartości drugiego sygnału losowego [20, 21].

$$R_{xy}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)y(t + \tau)dt$$

(9)

gdzie: T jest czasem realizacji sygnału, t określoną chwilą czasu, τ przesunięciem czasowym, $x(t)$ i $y(t)$ analizowane sygnały.

Funkcję korelacji wzajemnej stosowane są w przypadku pomiaru czasu opóźnienia, wyznaczania toru sygnału, identyfikacji sygnału losowego lub zdeterminowanego, zakłóconego szumem losowym [20, 21].

4.3 Analiza sygnałów niestacjonarnych w dziedzinie częstotliwości

Metody analizy w dziedzinie częstotliwości są najczęściej wykorzystywane do analizy sygnałów oraz diagnostyki maszyn i urządzeń [19, 21]. Spośród dostępnych metod najczęściej stosowanymi są analizy oparte na przekształceniu Fouriera. W analizie sygnałów niestacjonarnych wykorzystuje się głównie krótkoczasowe przekształcenie Fouriera (STFT), oraz analizę falkową opartą na innych przekształceniach. Powyższe dwie metody będą szerzej opisane ze względu na zastosowanie ich w badaniach nad rozpoznawaniem węgla i skały. Ponadto można wyróżnić metodę wykorzystującą analizę Cepstralną będącą anagramem słowa *spectrum*, bazującą na odwrotnej transformacie Fouriera widma sygnału wyrażonego w skali logarytmicznej (decybelowej) [22]. Wykorzystywana głównie jako metoda statystyczna do badania okresowości szeregów czasowych i najczęściej używana do analizowania ludzkiej mowy [23].

Transformacja Fouriera jest podstawą analizy częstotliwościowej sygnałów. Zakłada się, że sygnał jest kombinacją liniową pewnej liczby harmonicznym. Sygnał

harmoniczny może być reprezentowany przez zaledwie trzy zmienne: pulsację ω lub częstotliwość f , amplitudę X_m , oraz fazę początkową ψ_0 . W przypadku sygnałów okresowych stosowany jest szereg Fouriera, dla sygnałów nieokresowych jego uogólnienie, zwane transformacją Fouriera (TF) [20, 22].

Podstawą reprezentacji sygnału w dziedzinie częstotliwości jest przekształcenie Fouriera. Przejście z dziedziny czasu do dziedziny częstotliwości nazywa się przekształceniem Fouriera wyrażonym wzorem [19]:

$$S_{xx}(f) = \int_{-\infty}^{\infty} R_{xx}(\tau) e^{-j2\pi f\tau} d\tau \quad (10)$$

gdzie: $R_{(xx)}$ jest funkcją autokorelacji sygnału.

Wynikiem przekształcenia Fouriera jest częstotliwościowe widmo sygnału. Wyróżnić można cztery zastosowania przekształcenia Fouriera [19, 20, 24]:

- dla sygnałów okresowych i ciągłych widmo wyznaczone jest za pomocą szeregu Fouriera wyrażonego wzorem:

$$G(f) = \sum_{t=-\infty}^{\infty} x_i e^{-j2\pi i\Delta f} \Delta t \quad (11)$$

Odwrotne przekształcenie ma postać:

$$x(t) = \int_{-\frac{1}{2\Delta t}}^{\frac{1}{2\Delta t}} G(f) e^{j2\pi f \Delta t} df \quad (12)$$

gdzie: $-\infty < i < +\infty$,

- przekształcenie całkowe, nazywane ciągłą transformacją Fouriera stosowane w sygnałach nieokresowych i ciągłych, widmo takiego przekształcenia także jest nieokresowe i ciągłe:

$$G(f) = \int_{-\infty}^{+\infty} x(t) e^{-j2\pi f t} dt \quad (13)$$

gdzie: częstotliwość $-\infty < f < +\infty$,

Odwrotne przekształcenie jest definiowane:

$$x(t) = \int_{-\infty}^{+\infty} G(f) e^{j2\pi f t} df \quad (14)$$

gdzie: $-\infty < t < +\infty$, więc także $x(t)$,

- dla sygnałów nieokresowych, lecz dyskretnych, całkowite przekształcenie Fouriera definiowane jest następująco:

$$G(f) = \int_0^T x(t) e^{-j2\pi t \Delta f} dt \quad (15)$$

gdzie: $-\infty \leq k \leq +\infty$,

Przekształcenie odwrotne ma postać:

$$x(t) = \sum_{k=-\infty}^{\infty} G_k e^{-j2\pi t \Delta f} \Delta f \quad (16)$$

gdzie: $0 \leq t \leq T$ jest ciągle i okresowe,

- dla sygnału okresowego i dyskretnego stosowana jest dyskretna transformata Fouriera (DFT) definiowana w postaci szeregu:

$$D(f) = \sum_{t=0}^{N-1} x_i e^{-j \frac{2\pi \Delta f}{N} t} \Delta t \quad (17)$$

gdzie: $0 \leq k \leq N-1$ jest dyskretne i okresowe;

Przekształcenie odwrotne definiuje się w postaci szeregu:

$$x(t) = \sum_{k=0}^{N-1} G_k e^{j \frac{2\pi i \Delta f}{N} t} \Delta f \quad (18)$$

gdzie: $0 \leq i \leq N-1$ jest dyskretne i okresowe;

Transformacje Fouriera obliczona według zależności analitycznej wymaga operacji całkowania lub sumowania w przypadku ciągu dyskretnego w przedziale nieskończonym [22]. W praktyce obserwacja sygnału zwykle realizowana jest w skończonym czasie trwania. Mierzony sygnał można interpretować jako iloczyn sygnału analizowanego oraz funkcji okna pomiarowego, która poza obszarem

obserwacji pomiaru przyjmuje wartość zero. Oknem, które jest zawsze stosowane jest okno prostokątne. Okno prostokątne wprowadza wiele wad widocznych w opisie sygnału w dziedzinie czasu i dziedzinie częstotliwości - związane jest to z własnościami funkcji okna. Charakteryzuje się ono najwęższym listkiem głównym (najkrótsze pasmo 3-decybelowe listka głównego $0,86/T_0$) i najmniejszym tłumieniem listków bocznych (zaledwie 13,2 dB) [22, 25].

Analiza częstotliwościowa sygnałów odbywa się według określonego toru, w którym wykonywane są poszczególne operacje. Każda z wykonywanych operacji może być przyczyną określonych błędów. Podczas analizy sygnałów mogą wystąpić błędy: maskowania częstotliwości, przeciek mocy, efekt palisandrowy. Negatywny wpływ powstałych błędów na wyniki analizy może być zmniejszony, jednakże nie można wyeliminować go całkowicie.

Na etapie próbkowania sygnału może wystąpić pierwszy rodzaj błędu, czyli maskowanie częstotliwości, spowodowane zbyt niską częstotliwością próbkowania sygnału. Zgodnie z twierdzeniem Kotelnikowa-Shanona częstotliwość próbkowania powinna być większa niż podwójna wartość częstotliwości maksymalnej. Próbkowanie w dziedzinie czasu jest operacją mnożenia ciągłego sygnału przez dystrybucję grzebieniową, wynikiem mnożenia są dyskretne wartości sygnału. Próbkowanie w dziedzinie częstotliwości jest operacją splotu widma sygnału i widma dystrybucji grzebieniowej, widmo jest okresowe o okresie równym częstotliwości próbkowania [19, 26, 27]. Maskowanie częstotliwości inaczej aliasingu, jeśli występuje, może mieć dwojaki skutek na wyniki przeprowadzonej transformacji Fouriera. Harmoniczne powyżej częstotliwości Nyquista czyli, maksymalne częstotliwości harmonicznym wracają w zakres częstotliwości dodatnich powodując m.in.: powstawanie fałszywych prążków dla pulsacji znormalizowanych, zmianę wartości harmonicznym istniejących, jeśli po odbiciu trafią na właściwy prążek. Efektem aliasingu jest fałszywy obraz rozkładu harmonicznym sygnału [22, 28]. Częstotliwość próbkowania ma wpływ także na parametr zwany rozdzielczością widma Δf . Między częstotliwością próbkowania, długością realizacji sygnału T oraz rozdzielczością widma istnieją następujące zależności:

$$\Delta t = \frac{1}{f_0}, \quad T = N * \Delta t = \frac{N}{f_0}, \quad \Delta f = \frac{1}{T} = \frac{f_0}{N} \quad (19)$$

gdzie: N-liczba prążków w widmie.

Drugim rodzajem występującego błędu jest przeciek mocy. Obserwacja sygnału realizowana jest w skończonym czasie, związane jest to z operacją mnożenia okna prostokątnego od długości T przez nieskończenie długą, dyskretną i nieokresową realizację sygnału [19]. Widmo prostokątnej funkcji okna jest funkcją typu $(\sin x)/x$. Funkcja ma miejsca zerowe o krotności $(1/T)$. Jeśli długość okna pomiarowego nie spełnia warunku całkowitej wielokrotności sinusoidy, próbkowanie następuje w innych punktach. W efekcie takiego próbkowania zamiast pojedynczego szeregu prążków, wynikiem jest fałszywy sygnał, nieodzwierciedlający rzeczywistego widma amplitudowego. Zmniejszenie efektu przecieku możliwe jest przez zastosowanie okien funkcyjnych różnych od prostokątnego, mających stłumione listki boczne.

Trzecim występującym błędem jest efekt palisadowy (ang. picked-fence effect). Efekt palisadowy jest to przenoszenie mocy sygnału z jednego pasma na dwa sąsiednie pasma. Impulsy w dystrybucji grzebieniowej nie pokrywają się dokładnie ze środkami pasm częstotliwości widma. Operacja korekcji widma pomaga usunąć powstałe zjawisko.

Wyróżnić można kilka rodzajów funkcji okna wykorzystywanych do usunięcia zniekształceń spowodowanych wystąpieniem wstęg bocznych. Opis funkcji okna realizowany jest za pomocą parametrów [22]:

- wysokość listka głównego h_g ,
- stosunek pierwszego listka bocznego do głównego wyrażonego w skali logarytmicznej w dB,
- szerokość 3-decybelowego pasma listka głównego f_{3dB} .

Tabela 1 Porównanie wartości wybranych parametrów funkcji okien [22].

Nazwa okna	h_g	$20\log_{10}\left(\frac{h_b}{h_g}\right)$	f_{3dB}
Prostokątne	T_0	-13,2dB	$0,86/ T_0$
Trójkątne	$0,50T_0$	-26,7dB	$1,27/ T_0$
Hanna	$0,50T_0$	-31,6dB	$1,39/ T_0$
Hamminga	$0,54T_0$	-41,9dB	$1,26/ T_0$
Blackmana	$0,42T_0$	-58,2dB	$1,68/ T_0$

Wszystkie rodzaje okien ze względu na swój kształt tłumią sygnał do zera na początku i końcu czasu pomiarowego. Okno prostokątne charakteryzuje się najmniejszym tłumieniem listków bocznych (13,2dB), jednak zapewnia najkrótsze pasmo 3-decybelowe listka głównego ($0,86/T_0$). Okno Hamminga zapewnia tłumienie listków bocznych na poziomie ponad 40dB i przy stosunkowo niewielkim rozszerzeniu pasma, z tego względu jest najczęściej używane w praktyce [22]. Największe tłumienie listków bocznych zapewnia okno Blackmana prawie 60 dB, jednak posiada najszersze pasmo listka 3-decybelowego.

Tradycyjna analiza Fouriera stosowana jest dla sygnałów stacjonarnych. Funkcje gęstości widmowej mocy nie pokazują zmian częstotliwości i amplitudy w sygnałach niestacjonarnych. Dla sygnałów niestacjonarnych stosowana jest analiza krótkoczasowego przekształcenie Fouriera (STFT) która została zastosowana w analizie dźwięków urabiania węgla i skała w niniejszej pracy.

4.3.1 Analiza oparta na STFT

Analiza oparta na STFT stosowana jest dla sygnałów niestacjonarnych, są to sygnały, których parametry zmieniają się w czasie. Analiza sygnału odbywa się nie w całym okresie pomiarowym, lecz w kolejnych przedziałach czasu. STFT definiuje się jako zwykłą transformatę z zastosowaniem funkcji okna. Wynikiem jest funkcja dwóch zmiennych: czasu i częstotliwości. Metoda realizowana jest w dwóch krokach:

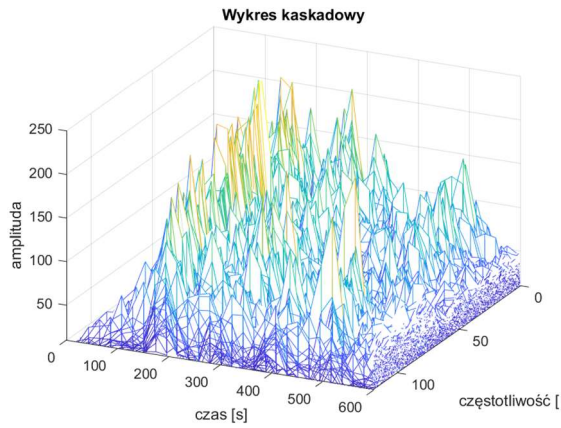
- podziale sygnału na jego stacjonarne podrealizacje,
- wyznaczenie widma podrealizacji.

Definicja tej transformacji zastosowanej dla sygnału $x(t)$ ma postać [19, 22, 29]:

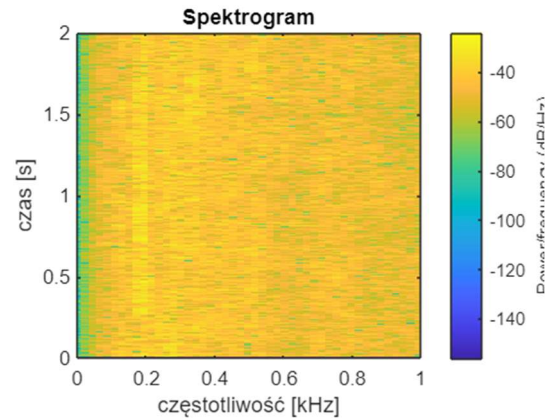
$$STFT_x(t, \omega) = \int_{-\infty}^{\infty} x(\tau)h(\tau - t)e^{-j\omega\tau} d\tau \quad (20)$$

gdzie: $x(t)$ -analizowany sygnał, $h(\tau-t)$ jest funkcja okna, τ -parametr określający przesunięcie okna wzdłuż realizacji sygnału.

Transformacja STFT polega w praktyce na zastosowaniu transformacji Fouriera wykonywanej na kolejnych fragmentach sygnału przez przesuwające się okno w czasie. Wyniki transformaty przedstawiane są jako trójosiowe wykresy kaskadowe lub spektrogramy. Przykładowy wykres kaskadowy (Rys.6) i spektrogram (Rys.7) dla sygnałów niestacjonarnych przedstawiono poniżej.



Rysunek 6. Przykład wyników analizy opartej na STFT-wykres kaskadowy [opracowanie własne]



Rysunek 7. Przykład wyników analizy opartej na STFT-spektrogram [opracowanie własne]

Najważniejszym problemem przy zastosowaniu analizy opartej na STFT jest określenie długości stacjonarnych podrealizacji sygnału. Skracanie długości okna spowodowane wymogiem stacjonarności sygnału prowadzi do pogorszenia rozdzielczości częstotliwościowej. Według zależności Gabora:

$$\Delta t \Delta f \geq \frac{1}{4\pi} \quad (21)$$

rozdzielczość w dziedzinie czasu Δt i częstotliwości nie mogą być dowolnie małe. Długość zastosowanego okna decyduje o rozdzielczości czasowej i częstotliwościowej. Aby uzyskać dobrą rozdzielczość w czasie stosowane jest okno krótkie kosztem gorszej rozdzielczości częstotliwościowej. Okno długie poprawia rozdzielczość częstotliwościową kosztem czasowej. Dobór wielkości okna w przypadku analizy STFT wymaga kompromisu.

4.3.2 Analiza oparta na przekształceniu falkowym

Analiza oparta na przekształceniu falkowym oprócz analizy STFT jest popularną metodą stosowaną w analizie sygnałów niestacjonarnych [22]. Analiza wykorzystywana jest także w celu rozpoznania urabiania węgla i skały [30]. Transformacja falkowa stosuje jądra w postaci falek o skończonym nośniku, spełniające odpowiednie wymagania, umożliwiając ich zastosowanie w analizie wielorozdzielczej. Jądro przekształcenia falkowego reprezentuje przedział częstotliwości o szerokości odwrotnie proporcjonalnej do czasu trwania falki. Transformację falkową określa

macierzysta funkcja falkowa podlegająca skalowaniu i przesunięciu w czasie. Skalowanie przeprowadza się za pomocą parametru skalowania m , zmieniającego wartość zmiennej wejściowej.

$$f(t) \rightarrow f\left(\frac{t}{m}\right) \quad (22)$$

Parametr skalowania zmienia reprezentację częstotliwościową funkcji $F(\omega) \rightarrow F(m\omega)$.

Wpływ współczynnika m w dziedzinie częstotliwości jest odwrotny do tego w dziedzinie czasu. Zawężając dziedzinę częstotliwości, rozszerza się dziedzinę czasu i na odwrót. Do dekompozycji sygnału wykorzystuje się zmianę parametru skali i przesunięcia, tworząc rodzinę falek. Transformacja pozwala na jednoczesne uzyskanie informacji o częstotliwości i lokalizacji szczegółów analizowanego sygnału [22, 31].

Najprostszą funkcją bazową przekształcenia falkowego jest funkcja Haara. Funkcja zdefiniowana jest następująco:

$$\psi(t) = \begin{cases} 1 & \text{dla } 0 \leq t < 0,5 \\ -1 & \text{dla } 0,5 \leq t < 1 \\ 0 & \text{dla innych } t \end{cases} \quad (23)$$

Rozwinięcie funkcji definiuje się następująco:

$$\psi_{mn}(t) = 2^{-m/2} \psi(2^{-m}t - n) \quad (24)$$

dla $m, n = \dots -2, -1, 0, 1, 2, \dots$

gdzie: m -współczynnik skali, n -przesunięcie w czasie nośnika funkcji bazowej.

Współczynnik normalizujący wartości funkcji Haara ($2^{-m/2}$) powoduje, że wartości funkcji wynoszą 1 lub 0. Nośnik funkcji wynosi 2^m , przesunięcie funkcji bazowej zależy od współczynnika skali m i przesunięcia nośnika w czasie n i jest równe $n2^m$. Każda falka o krótszym nośniku odpowiada falce o dłuższym nośniku w przedziale, w którym wartość funkcji się nie zmienia. Funkcje bazowe Harra są ortogonalne, co pozwala na odwracalność przekształcenia falkowego [19, 22, 31, 32].

Wyróżnić można dwa podstawowe przekształcenia falkowe. Przekształcenie ciągle odnoszące się do sygnałów zdefiniowanych dla dowolnej wartości w dziedzinie zmiennej wejściowej oraz transformację dyskretną określoną jedynie w wybranych punktach czasowych.

Ciągła transformacja falkowa (ang. CWT-Continuous Wavelet Transform) zdefiniowana jest dla sygnałów czasu ciągłego, dla których wartości sygnału określone są w dowolnej chwili t . Ciągłe przekształcenie falkowe definiowane jest wzorem [22]:

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi\left(\frac{t-b}{a}\right) x(t) dt \quad (25)$$

gdzie: a -jest skalą, i jest odwrotnością częstotliwości, b -jest przesunięciem w dziedzinie czasu funkcji bazowej, $x(t)$ jest analizowanym sygnałem, $\psi\left(\frac{t-b}{a}\right)$ -funkcja bazowa przekształcenia falkowego;

W zależności od przyjętego współczynnika skali a ma wpływ na rozdzielczość czasową i częstotliwościową dekompozycji falkowej. Przy małej wartości a otrzymuje się wysoką rozdzielczość czasową, kosztem niskiej rozdzielczości częstotliwościowej. Dla dużych wartości a (niska częstotliwość) uzyskuje się niską rozdzielczość w czasie i wysoką w dziedzinie częstotliwości.

Transformacja falkowa jest odwracalna i wyraża się wzorem:

$$x(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \left[\int_{-\infty}^{\infty} W_x(a, b) |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \frac{1}{a^2} db \right] da \quad (26)$$

W powyższym równaniu spełnione muszą być warunki:

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (27)$$

$$\Psi(0) = \int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (28)$$

gdzie: $\Psi(\omega)$ -transformacja Fouriera falki $\psi(t)$.

Przykładami typowych falek stosowanych wyłącznie w transformacji CWT są falka Morleta, kapelusz meksykański (ang. mexican hat), zespolona falka Morleta, falka Gabora, możliwe jest także zastosowanie falek stosowanych w transformacji dyskretnej. Powyższe przykłady falek wyrażone są wzorami:

- Falka Morleta

$$\psi(x) = e^{-\frac{x^2}{2}} \cos(5x) \quad (29)$$

- Falka „kapeluszyk meksykański”

$$\psi(x) = \frac{2}{\sqrt{3}} \pi^{-\frac{1}{4}} (1 - x^2) e^{-\frac{x^2}{2}} \quad (30)$$

- Zespolona falka Morleta

$$\psi(x) = e^{-j\omega_0 t} e^{-\frac{\beta^2 x^2}{2}} \quad (31)$$

- Zespolona falka Gabora

$$\psi(x) = e^{-j\omega_0 t} e^{-\left(x - \frac{x_0}{\sigma}\right)^2} \quad (32)$$

W obecnych czasach większość jak nie wszystkie badania sygnałów prowadzone są za pomocą programów komputerowych, w których wykorzystuje się sygnał zdyskretyzowany. Ze względu na złożoność algorytmu CTW oraz zawartość ogromnej liczby szczegółów, niekiedy istotnych z technicznego punktu widzenia wprowadzono dyskretną transformację falkową (ang. Discrete Wavelet Transform) [22]. Najczęściej wybierane są dyskretne wartości skali a i przesunięcia b w systemie dwójkowym, które wyrażane są w sposób $a=2^{-m}$, $b=2^{-m} \cdot nT$, gdzie wprowadzony został poziom m -ty, przesunięcie n -te, liczone w liczbie okresów T falki na aktualnym poziomie [22].

Falka przeskalowana jest równa:

$$\psi_{m,n}(t) = 2^{\frac{m}{2}} \psi(2^m t - nT) \quad (33)$$

Dyskretna transformacja falkowa określana jest wzorem:

$$W_x(2^m, b) = 2^{-\frac{m}{2}} \int_{-\infty}^{\infty} x(t) \tilde{\psi}(2^{-m}(t - b)) dt \quad (34)$$

wyznaczającym wartości współczynników dekompozycji $W_x(2^m, b)$ dla dyskretnych wartości m i przesunięć b . Sygnał analizowany $x(t)$ jest splatany z funkcją falkową $\tilde{\psi}(t)$.

Przekształcenie dyskretne ma szczególne znaczenie z powodu podobieństwa do filtracji. Funkcje bazowe spełniają rolę układów filtrów górno i dolnoprzepustowych [33, 22].

Transformacja dyskretna jest odwracalna, wyrażona wzorem:

$$x(t) = \sum_m 2^{-\frac{3m}{2}} \int_{-\infty}^{\infty} W_x(2^m, b) \psi(2^{-m}(t-b)) db \quad (35)$$

Powyższy wzór stosowany jest dla ciągłych wartości przesunięcia b , dla wartości dyskretnych $b=b_{m,n}$, rekonstrukcja ogranicza się do sumowania składników rozkładu:

$$x(t) = \sum_{-\infty}^{\infty} \sum_{-\infty}^{\infty} W_x(2^m, 2^m nT) \psi_{m,n}(t) \quad (36)$$


Do uzyskania rekonstrukcji musi być spełniony warunek:

$$\sum_{m=-\infty}^{\infty} \Psi(2^m \omega) \tilde{\Psi}(2^m \omega) = 1 \quad (37)$$

związany z zależnością [22]:

$$\Psi(\omega) = \frac{\tilde{\Psi}(\omega)}{\sum_{m=-\infty}^{\infty} |\tilde{\Psi}(2^m \omega)|^2} \quad (38)$$

Wyniki analizy falkowej prezentowane są najczęściej w postaci wykresów warstwicznych nazywanych skalogramami. Kolorem oznaczona jest miara prawdopodobieństwa podrealizacji sygnału do zastosowanej funkcji bazowej.



Rysunek 8. Skalogram dla sygnału dwutonowego [34]

Rys.8 przedstawia skalogram dla sygnału dwutonowego, na skalogramie żółtym kolorem odznaczają się dwa sygnały o różnej częstotliwości określonej na osi Y wyrażonej w Hz. Sygnały oprócz różnej częstotliwości posiadają różny czas realizacji określony na osi X wyrażonej w sekundach.

5 Przegląd metod rozpoznawania granicy warstw węgla i skały

Rozpoznanie granicy warstw węgla i skały najczęściej przebiega trój etapowo. W pierwszym etapie gromadzone są dane niezbędne do analizy. Drugim etapem jest ekstrakcja cech. W trzecim etapie wykorzystuje się metody klasyfikacyjne odpowiednio dobrane do pozyskanych danych w pierwszym etapie.

Pierwszym etapem jest pozyskiwanie danych, do tego celu wykorzystywane są różnego rodzaju urządzenia lub czujniki takie jak: akcelerometry, kamery, czujniki promieniowania gamma, mikrofony, georadary. Pozyskiwanie danych pierwotnych polega na wykonaniu pomiarów oraz przetworzeniu ich do postaci cyfrowej.

Drugim etapem jest ekstrakcja cech. Cechy oryginalnych wartości pomiarowych przekształca się w inne cechy, które mogą być bardziej efektywne. Ekstrakcja cech może być postrzegana jako pewna forma kompresji danych, może być wbudowana w proces tworzenia modelu, lub być częścią preprocesingu danych. W celu wydobycia ze zbioru danych interesujących nas cech dodatkowych dostarczających nowych informacji stosuje się różnego rodzaju transformacje. Transformację fourierowską (ang. Fourier transform) lub transformację falkową (ang. wavelet transform) stosuje się do uzyskania widma częstotliwościowego lub ekstrakcji charakterystycznych częstotliwości. Połączenie dyskretnej transformaty Fouriera z przekształceniem logarytmicznym pozwala wyznaczyć cepstrum danej cechy. Transformacja Hilberta-Huanga jest techniką analizy sygnału czas-częstotliwość stosowaną w celu wyznaczenia informacji o amplitudzie i fazie z sygnału zmiennego w fazie. Używa metody Empirical Mode Decomposition (EMD) do dekompozycji sygnału na tak zwane funkcje trybu wewnętrznego (IMF-Intrinsic Mode Functions) wraz z trendem i uzyskanie chwilowych danych częstotliwości. Za pomocą metody EMD każdy skomplikowany zbiór danych można rozłożyć na skończoną i często niewielką liczbę elementów. Te komponenty tworzą kompletną i prawie ortogonalną podstawę oryginalnego sygnału. Metoda ta często stosowana przy występowaniu niskiego współczynnika sygnału do szumu (SNR) ograniczającego zdolność do identyfikacji [35, 36, 37]. Rozkład średniej lokalnej - Local Mean Decomposition (LMD) może rozkładać złożone wieloskładnikowe sygnały modulacyjne w liniową kombinację skończonego zbioru funkcji produktu (ang. PF-product function). Podstawowa zasada LMD jest podobna do EMD- głównym celem

jest dekompozycja złożonych wieloskładnikowych sygnałów modulowanych na liniową kombinację sygnałów jednoskładnikowych [38]. Entropia permutacyjna-Permutation Entropy (PE) stosowana do rozkładu wzorców. Wzór na entropię permutacyjną oparty jest na wzorze na entropię Shannona, mierzącą średnią ilość informacji, przypadającą na pojedynczą wiadomość ze źródła informacji. W wersji permutacyjnej używa się prawdopodobieństwa wzorców. Ideą analizy jest rozważenie relacji między wartościami szeregów czasowych, a nie samych wartości. Do ekstrakcji cech stosowana jest także metoda parametryzacji mowy człowieka Mel-Frequency Cepstral Coefficients (MFCC). Są to parametry szeroko stosowane w akustyce mowy oraz w kompresji sygnałów fonicznych. Powstają z cepstrum sygnału przedstawionego w skali melowej (mel-cepstrum). Na bazie skali mel tworzony jest bank filtrów, który dokonuje nieliniowej analizy częstotliwościowej. Filtry mają trójkątne charakterystyki amplitudowe i są równomiernie rozłożone w częstotliwościowej skali mel. Zestaw filtrów naśladuje charakterystykę układu słuchu człowieka [23, 39].

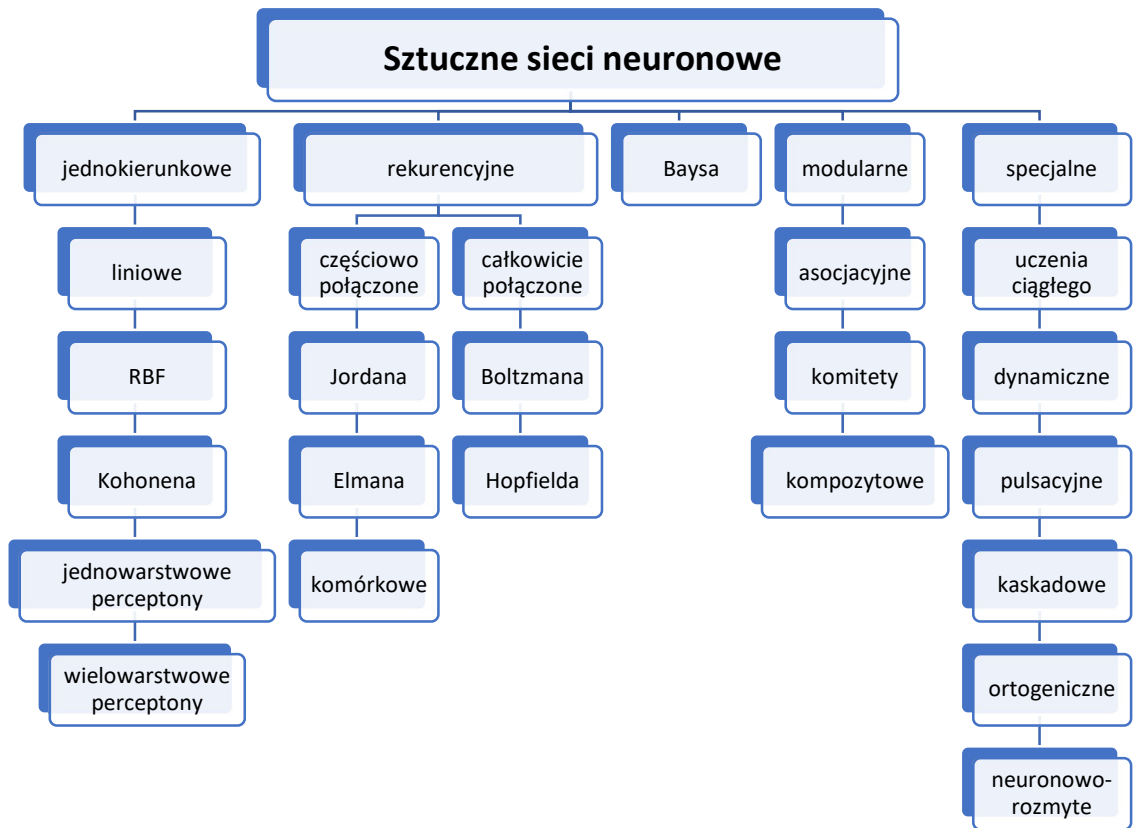
Do ekstrakcji cech najczęściej wykorzystuje się przekształcenia liniowe wykorzystujące nieliniowe funkcje kryterialne jak i funkcje nieliniowe, które przedstawiono w tabeli 2 [40, 41].

Tabela 2 Przekształcenia stosowane do ekstrakcji cech [40].

Liniowe z nieliniowymi funkcjami kryterialnymi	Nieliniowe
<ul style="list-style-type: none"> • Statystyczne testy: Pearsona, chi-kwadrat • Metoda składowych głównych (PCA) • Liniowa Analiza Dyskryminacyjna (LDA) • Analiza Dyskryminacyjna Fishera (FDA) • Metoda składowych niezależnych (ICA) 	<ul style="list-style-type: none"> • liniowe transformacje z funkcjami jądrowymi (np.RBF) • sieci perceptronowe z sigmoidalnymi funkcjami aktywacji • heterogeniczne transformacje • nieliniowa analiza czynnikowa • chi-kwadrat i inne statystyczne testy niezależności • metody wykorzystujące funkcje rozmyte

W trzecim etapie rozpoznawania granicy węgla i skały przeprowadzana jest klasyfikacja, przy użyciu uczenia maszynowego w skład którego wchodzi sieci neuronowe znane również jako sztuczne sieci neuronowe (ang. ANN-Artificial Neural

Network). Istnieje wiele podziałów na typy sieci neuronowych, jeden z nich przedstawiono na Rys.9.



Rysunek 9. Podział sieci neuronowych [40].

Przez topologię sieci neuronowych rozumie się sposób rozmieszczenia neuronów i zbiorów połączeń międzyneuronowych, determinujących jej funkcjonalność i sposób przetwarzania danych. Przepływ informacji w sieci może być jednokierunkowy lub dwukierunkowy. W większości sieci neuronowe są budowy warstwowej, rozróżnić można warstwy wejściowe, ukryte i wyjściowe. W sieciach o typie pamięci skojarzeniowej Kohonena czy Hopfielda warstwa wejściowa jest jednocześnie warstwą wyjściową. Sygnał przechodzi przez warstwę wejściową, warstwę ukrytą następnie trafia do warstwy wyjściowej, gdzie jest odbierany i interpretowany. Każdy sygnał mnożony jest przez wartość liczbową zwaną wagą wpływającą na percepcję, danego układu wejściowego i tworzenie sygnału wyjściowego przez neuron. Wagi mogą mieć wartości dodatnie-pobudzające i ujemne-opóźniające, wartość wagi wynosi zero, kiedy neurony nie są ze sobą połączone. Neurony każdej z warstw oprócz warstwy wejściowej zbierają wartości sygnałów z warstwy poprzedniej z każdego neuronu. Następnie mnożą każdy sygnał przez wagę, sumując otrzymane wartości. Otrzymana suma


przeliczana jest na skończony przedział używając do tego funkcji matematycznych (sigmoidalna, tangensoidalna, funkcji skoku jednostkowego). Uzyskana wartość jest sygnałem neuronu przesyłanym do każdego z neuronów kolejnej warstwy. Sieci neuronowe mogą posiadać połączenia międzywarstwowe, wewnątrzwarstwowe nadwarstwowe oraz typu samosprzężeń [40, 42, 43, 44].

Rodzaj wykorzystywanej sieci neuronowej zależy od kierunku ich zastosowania. Do ważniejszych kierunków zastosowań można zaliczyć predykcje, klasyfikacje i rozpoznawanie, kojarzenie danych, analizę danych, filtracje sygnałów, optymalizacje.

Na Rys. 9 przedstawiono podział sztucznych sieci neuronowych, najczęściej w artykułach naukowych wykorzystywano sieci jednokierunkowe. Ponadto można wyróżnić inne typy sieci neuronowych takie jak: rekurencyjne, Baysa, modułarne oraz specjalne [40].

5.1 Metoda wizyjna


Szeroko stosowane w przedsiębiorstwach produkcyjnych do nadzorowania procesów kamery wizyjne oraz termowizyjne wykorzystuje się do określenia granicy węgla i skały. W metodzie tej rolę czujnika spełnia kamera zainstalowana na kombajnie ścianowym rejestrująca obraz lub temperaturę noży skrawających (Rys.10).



Rysunek 10. Przykład zainstalowania detektora/kamery termowizyjnej na kombajnie ścianowym (opracowanie własne).

Obraz poddany jest analizie w celu wychwycenia różnicy tekstur warstw skalnych. Analiza tekstur polega na znalezieniu i wydobyciu z obrazu tekstury charakterystycznej dla różnych obiektów, w omawianym przypadku obiektami są warstwy węgla i skały. W badaniach wykorzystano metodę przestrzennej szarej macierzy współwystępowania opartą na statystyce. Każda szara powierzchnia obrazu może być uważana za powierzchnię w przestrzeni trójwymiarowej. Kolejnym etapem jest obliczanie wartości

cech tekstury w oparciu o metodę macierzy współwystępowania szarej przestrzeni. Można wyróżnić wektory cech tekstury, takie jak energia, kontrast, korelacja i entropia. Energia oddaje głównie rozkład szarości obrazu i chropowatość tekstury. Jeśli energia jest wysoka tekstura jest szorstka. Dla skał posiadających gładszą teksturę energia jest niższa. Rysunek 10 przedstawia zdjęcie wykonane w ścianie wydobywczej, w górnej części znajduje się mułowiec w kolorze szarym, zaobserwować można ślady po nożach urabiających (A), które odznaczają się jaśniejszą barwą, powodem tego jest obecność minerałów ilastych. W dolnej części obrazu znajduje się węgiel w kolorze czarnym, zaobserwować można także refleksy świetlne związane z obecnością różnych litotypów węgla (B). Można wyróżnić cztery litotypy węgla: wityryn-węgiel błyszczący, klaryn-węgiel półbłyszczący, duryn-węgiel matowy, fuzyn-węgiel włóknisty [45]. Czerwona przerywana linia zaznaczono miejsce połączenia warstw skalnych węgla i mułowca (C).



Rysunek 11. Różnica tekstury węgla i mułowca (zdjęcie własne).

Rozpoznanie warstw za pomocą sieci neuronowej wytrenowanej za pomocą funkcji tekstury, może odbywać się na podstawie różnicy tekstur i związanych z nimi

odrębnych cech. Trudnością dla tej metody jest utrzymanie obiektywu w czystości co przy urabianiu skał nie jest łatwym zadaniem ze względu na obecność pyłu oraz wody ze zraszaczy zainstalowanych na kombajnie [46, 47, 48, 49].

W metodzie, gdzie jako czujnik zastosowano kamerę termowizyjną wykorzystywana jest różnica w twardości skały urabianej przez noże. Jeśli skała płonna zalegająca w stropie lub w spągu jest urabiana temperatura noży skrawających rośnie w stosunku do temperatury podczas skrawania węgla. Podstawową zaletą tej metody w porównaniu z metodą wykorzystującą obraz jest to, że promieniowanie podczerwone może przenikać przez pył i rozpryski wody bez zbytniego tłumienia. Z tego względu czułość tego systemu jest znacznie wyższa niż w metodzie opartej na kamerze rejestrującej tylko obraz, która wymaga stałego czyszczenia, by mogła pracować w odpowiedni sposób [46, 50, 51].

5.2 Metoda wykorzystująca georadar

Metoda wykorzystuje georadar jako urządzenie do wykrycia granicy warstw. Obecnie najpowszechniej używane są georadary impulsowe. Aparatura pomiarowa składa się z jednostki centralnej oraz dwóch anten nadawczej i odbiorczej. Radar emituje impuls elektromagnetyczny o stosunkowo wysokiej mocy szczytowej i krótkim czasie trwania. Zasięg głębokościowy zwiększa się wraz z wielkością energii generowanego impulsu. W georadarach wykorzystywane są anteny o częstotliwościach od 10 MHz do 2 GHz. Anteny o częstotliwości 400 MHz umożliwiają rejestrację użytecznej informacji do głębokości ok. 8m. Antenami o wyższych częstotliwościach ok. 1 GHz można rejestrować tylko do ok. 1m, jednakże kosztem mniejszej głębokości uzyskuje się wyższą rozdzielczość rzędu centymetrów. Fale rozchodzące się w ośrodku geologicznym ulegają odbiciu, załamaniu i tłumieniu. Podstawą tej metody są różne wartości przewodności elektrycznej i stałej dielektrycznej skał [46, 52]. Przewodność elektryczna to zdolność materiału do przewodzenia prądu elektrycznego. W praktyce przenikalność dielektryczna definiowana jest najczęściej jako parametr ϵ_r wyrażony wielkością bezwymiarową.

$$\epsilon_r = \frac{\epsilon}{\epsilon_0}$$

(39)

gdzie: ϵ -przenikalność elektryczna, ϵ_0 -przenikalność elektryczną próżni.

Przewodność elektryczna skał zależy przede wszystkim od gęstości, zawartości wody, ilości rozpuszczonej soli oraz temperatury. Stała dielektryczna określa zdolność skał do magazynowania ładunku elektrycznego po przyłożeniu do niego pola elektrycznego. Warunkiem skutecznej rejestracji użytecznej informacji jest kontrast względem stałej dielektrycznej pomiędzy badanymi warstwami skał. Im większy kontrast, tym większa amplituda fali odbitej. Dla powietrza stała dielektryczna wynosi ok. 1, dla warstw skalnych waha się od kilku do kilkunastu. Dla pokładów węgla o niewielkim kącie upadu granica warstw jest idealną powierzchnią, od której fale radarowe mogą być odbijane z powrotem. Dokonując pomiaru czasu potrzebnego do odbicia fali radarowej z anteny nadawczej do odbiorczej, można określić grubość badanej warstwy skalnej [53]. Należy zauważyć, że wszelkie zaburzenia w zaleganiu pokładu takie jak odszczepy, żyły klastyczne wypełnione piaskowcem, mogą zaburzyć wynik pomiaru. Wysokie zawodnienie górotworu wpływa także na prawidłowy odczyt pomiarów. Wysoka względna przenikalność dielektryczną wody ($\epsilon_r=81$, w temp. 22°C), wiąże się z jej anormalnymi właściwościami. Z tego względu metoda ta będzie odnosić największą skuteczność w górotworach niezawodnionych. Odległość georadaru od mierzonych warstw powinna być zmniejszona do minimum a jej wartość nie powinna przekraczać 10 cm, ze względu na ograniczenie powstania szczeliny powietrznej. Czujnik georadaru może być zainstalowany na obudowie kombajnu ścianowego jak i na ramieniu głowicy urabiającej [54, 55, 56]. W Tab.3 przedstawiono wartości przenikalności elektrycznej i oporu elektrycznego dla niektórych skał.

Tabela 3 Właściwości elektryczne niektórych skał [53, 55].

Grupa skał	Skała	Rezystywność [Ωm]	Przenikalność dielektryczna względna
Magmowe	granit	10^2-10^7	5-9
	sjenit	10^2-10^5	7-14
	dioryt	10^2-10^8	8-9
	gabro	10^2-10^5	18
	bazalt	10^2-10^6	12
Metamorficzne	kwarcyt	$10-10^5$	7
	gnejs	10^2-10^7	8-15
	marmur	10^2-10^5	8
Osadowe	wapień	10^2-10^3	8-15

	piaskowiec	$10-10^8$	9-11
	piasek	$10-10^{10}$	4-6
	glina	$10-10^6$	7-12
	łupek	$10-10^2$	6-8
	węgiel kamienny	10^2-10^3	3-15
	węgiel brunatny	$10-10^3$	4-5

Wartości przenikalności względnej dla suchej skały porowatej takich jak piasek, węgiel brunatny są znacznie mniejsze niż skał bez porów (bazalt, gabra). W przypadku węgla kamiennego duża rozbieżność pomiędzy minimalną wartością równą 3 a maksymalną 15, zależy od stopnia zwięzłości węgla, zawartości wilgoci oraz stopnia uwęglenia, które mają wysoki wpływ na przenikalność elektryczną.

5.3 Metoda wykorzystująca występowanie naturalnego promieniowania gamma

Promieniotwórczość jest to zdolność jąder niektórych pierwiastków do samorzutnej przemiany w inne, przez stopniowy rozpad i redukcję jąder atomowych. Promieniotwórczość najczęściej związana jest z emisją cząstek alfa, beta i promieniowaniem gamma. Promienie α , β i γ różnią się między sobą stopniem przenikliwości [57]:

- promienie alfa zatrzymywane są przez płytkę aluminiową o grubości 0,04mm lub 8-centymetrowy pierścień powietrza,
- promienie beta przechodzą przez płytkę aluminiową o grubości 5cm,
- promienie gamma posiadają największą przenikliwość, przenikając przez warstwę żelaza o grubości 30 cm potrafią jonizować powietrze.

Pierwiastki promieniotwórcze z ich izotopami układają się w pięć rodzin: uranowo radowa, aktywna, torowa, neptunowa, potasową [57].

Pod względem radioaktywności można wyróżnić trzy typy skał, które cechuje [57]:

- niska radioaktywność-piaski, piaskowce, wapienie, dolomity, sole, anhydryty,
- średnia radioaktywność-iły, gliny, łupki,
- wysoka radioaktywność-łupki ilaste, bentonity.

Złoże węgla kamiennego występuje w rejonie trzech zagłębi węglowych: Dolnośląskiego, Górnośląskiego i Lubelskiego [15]. W roku 2000 zakończono eksploatację węgla w Dolnośląskim Zagłębiu Węglowym.

W pokładach węgla pochodzącego z Górnośląskiego Zagłębia Węglowego występują przede wszystkim naturalne radionuklidy dwóch szeregów: uranowego z izotopem macierzystym ^{238}U i torowego z izotopem macierzystym ^{232}Th [58]. W skład obydwu szeregów wchodzi między innymi izotopy radu ^{226}Ra z rodziny uranowej i ^{228}Ra z rodziny torowej. Średnia aktywność właściwa w węglach GZW wynosi odpowiednio dla pierwszego izotopu 18 Bq/kg, a dla drugiego 11 Bq/kg. Na całym obszarze GZW rozkład stężeń ^{226}Ra i ^{228}Ra nie jest równomierny w niektórych częściach zagłębia odnotowuje się stężenia izotopów radu znacznie przewyższające wartości średnie [59]. Na podstawie przeprowadzonych badań skał otaczających złoża węgla [58, 46] stwierdzono, że zawierają one pewne ilości naturalnych izotopów promieniotwórczych. Stężenie izotopów promieniotwórczych obserwowane w skałach przywęglowych są kilkakrotnie wyższe od wartości odnotowanych w węglu. W Tab. 4 przedstawiono zakres zmienności aktywności właściwej naturalnych izotopów promieniotwórczych dla węgla warstw Łękowych, Siodłowych, Brzeźnych GZW, Obszaru Rybnicko-Jastrzębskiego oraz dla skał przywęglowych (mułowców, łupków ilastych).


Tabela 4 Zakres zmienności aktywności właściwej naturalnych izotopów promieniotwórczych w węglach i skałach [58].

	^{226}Ra	^{228}Ra	^{40}K
	Bq/kg		
Węgiel	7÷48	5÷19	24÷93
Mułowiec, łupek ilasty	51÷120	59÷117	393÷1070


Przedstawione w tabeli 4 wartości promieniowania naturalnych izotopów promieniotwórczych dla skał otaczających pokład węgla takich jak mułowiec i łupek są kilkakrotnie wyższe niż dla pokładu węgla. Największą rozbieżność zaobserwować można dla izotopu potasu, gdzie najwyższa wartość dla mułowca i łupku ilastego wynosząca 393 jest prawie 16-krotnie wyższa od najniższej wartości dla węgla wynoszącej 24. Wysokie różnice wartości promieniowania pomiędzy wartościami dla

węgla i skał dają podstawę do zastosowania metody opartej na pomiarze radioaktywności w skałach.

Koncepcje rozpoznawania granicy węgla i skały bazujące na analizie promieniowania gamma [57] przedstawiono w kilku publikacjach [46, 60, 49, 61]. Zaproponowano rozpoznanie granicy węgla i skały za pomocą detektora zainstalowanego na ramieniu kombajnu ścianowego mierzącego wartość radioaktywności w stropie pokładu Rys.12.



Rysunek. 12 Przykładowe miejsce zainstalowania detektora promieniowania gamma na ramieniu kombajnu ścianowego (opracowanie własne).



Rysunek 13. Miejsce zainstalowania detektora promieniowania gamma na osłonie zawałowej sekcji obudowy zmechanizowanej (opracowanie własne).

Drugim sposobem (Rys.13) jest wykorzystanie stosunkowo nowego systemu eksploatacji grubych pokładów, gdzie pozostawiona łąta pokładu spada na przenośnik zgrzeblowy zainstalowany za sekcjami obudowy zmechanizowanej. Na sekcji obudowy zainstalowany jest detektor mierzący radioaktywność znajdującej się skały od strony zawału [62].

5.4 Metoda wykorzystująca wibracje

Obecnie każdy proces na skalę przemysłową pozyskiwania surowców mineralnych w mniejszym lub większym stopniu odbywa się za pomocą maszyn. Praca ich generuje wibracje, które przy wykorzystaniu odpowiednich przyrządów są mierzalne. Wibracje to drgania o małej amplitudzie i niskiej częstotliwości do kilkudziesięciu Hz. Pomiar wibracji wykorzystywany jest bardzo często w celach diagnostycznych, m.in. dla oszacowania stanu technicznego pracującej maszyny lub stabilności struktur cyklicznie poddawanych naprężeniom takich jak budynki, mosty. Diagnostyka ta pozwala na określenie stanu technicznego obiektu oraz wczesne wykrycie awarii bez konieczności demontażu mechanizmów, a nawet bezkontaktowo [63]. Najpopularniejszym czujnikiem do pomiaru wibracji jest akcelerometr. Wyróżnia się pięć typy akcelerometrów, których nazwy zaczerpnięte są od zastosowanej w nich metody pomiarowej: piezoelektryczne, pojemnościowe, piezorezystancyjne, Akcelerometry napięciowe IEPE (Internal Electronic Piezoelectric), laserowe [64, 65].

Akcelerometry piezoelektryczne są najczęściej stosowane w przemyśle do pomiarów wibracji. Wykorzystują zjawisko piezoelektryczne w kryształkach. Przy pojawieniu się obciążenia mechanicznego kryształ ulega deformacji a na jego ściankach powstaje ładunek elektryczny. W sytuacji odwrotnej doprowadzając do ścianek kryształu pole elektryczne powoduje się zmianę jego wymiarów. Struktura kryształu ma wpływ na generowanie efektu piezoelektrycznego, który może powstawać na skutek jego ściskania, rozciągania jak i ścinania. Zjawisko piezoelektryczne występuje w dielektrykach o dużej pojemności elektrycznej. Zachowanie elementu piezoelektrycznego można porównać do „sprężyny” w akcelerometrze pojemnościowym. Nie zmienia on jednak swojej rezystancji, lecz generuje napięcie elektryczne. Kiedy akcelerometr zostanie poddany wibracji element piezoelektryczny oddziałuje z siłą równą iloczynowi przyspieszenia elementu sejsmicznego i masy, generując ładunek proporcjonalny do przyłożonej siły. Masa sejsmiczna jest stała, więc

ładunek powstały jest proporcjonalny do jej przyspieszenia. Przyspieszenie masy sejsmicznej jest co do amplitudy i fazy równe przyspieszeniu podstawy akcelerometru a przez to równe przyspieszeniu powierzchni, na której jest ona zamocowana. Układy tego typu charakteryzują się dużą czułością. Stosowane są tam, gdzie wymagana jest wysoka czułość np. do pomiarów sejsmicznych, testów niszczących prowadzonych w ekstremalnie trudnych warunkach [64, 66, 67, 68].

Przetworniki pojemnościowe często wytwarzane jako układy w technologii MEMS (ang. Mikro Electro Mechanical System) wykorzystują zmieniającą się pojemność w zależności od położenia ruchomych płytek. Akcelerometr MEMS zbudowany jest z ruchomej masy z okładkami kondensatorów mających odpowiedniki na nieruchomej ramie. Drgania powodują wychylenie ruchomej masy zmieniając odległości pomiędzy okładkami kondensatora zmieniając jego pojemność. Są to najmniejsze i najtańsze sensory dostępne na rynku, wykorzystywane przede wszystkim w urządzeniach mobilnych oraz elektronice użytkowej. Wadą ich jest mała dokładność pomiaru dla sygnałów o wyższych częstotliwościach i amplitudzie, dlatego nie znajdują zastosowania w przemyśle. Ze względu na małe rozmiary wykorzystywane są głównie w urządzeniach mobilnych oraz w elektronice użytkowej [64, 69, 70, 71, 68].

Akcelerometry piezoooporowe działają na zasadzie tensometru. Wykorzystuje się w nich układ tensometryczny do pomiaru wielkości przemieszczenia masy względem obudowy. Mierzy się w nich wartość oporu elektrycznego, który zmienia się w zależności od obciążenia mechanicznego. Konstrukcja zbudowana jest z masy umocowanej na sprężystych belkach na których umieszczono piezorezystory. W wyniku przyspieszenia belki są zginane przez ruch masy względem obudowy, zmiana położenia wykrywana jest przez układ mostkowy. Ten typ akcelerometru charakteryzuje się szerokim zakresem pomiaru, który może rejestrować drgania o wysokiej częstotliwości. Dzięki zdolności do pomiaru sygnałów wolnozmiennych znajdują zastosowanie w prostych systemach nawigacji inercyjnej. Ich wadą jest wrażliwość na zmiany temperatury otoczenia (konieczność kompensacji temperaturowej) oraz dość mała czułość. Głównym obszarem zastosowań jest pomiar silnych drgań impulsowych [64, 65, 49].

Akcelerometry napięciowe IEPE jedne z najczęściej stosowanych do pomiaru wibracji. Pod względem budowy nie różnią się od akcelerometrów piezoelektrycznych, jednak w odróżnieniu od nich posiadają wzmacniacze ładunku i wyjścia o niskiej

impedancji. Do poprawnej pracy potrzebują stałego zasilania z zakresu $2\div 20$ mA. Ze względu na obecne w swej strukturze obwody elektroniczne są mało odporne na warunki środowiskowe. Zakres temperatury pracy wynosi od -40 do $+125^{\circ}\text{C}$ [64, 49, 65].


Laserowe czujniki przemieszczenia wykorzystują zasadę triangulacji sygnału optycznego. Metoda triangulacyjna polega na oświetleniu przedmiotu skupioną wiązką laserową i obserwacji przemieszczenia się obrazu plamki świetlnej. Obserwacja obrazu odbywa się przez układ optyczny, zastosowana linijka elementów światłoczułych decyduje o rozdzielczości metody. Badana powierzchnia może być w zasadzie dowolna, ponieważ plamka świetlna nie powstanie tylko na powierzchni idealnego lustra (emisyjność zero) oraz idealnej czerni (emisyjność jeden) [68]. Wibrometry laserowe zapewniają bezdotykowy pomiar, eliminując zakłócenia spowodowane masą czujnika i temperaturą pomiaru. Pomiar może być dokonywany z wysoką dokładnością z dużej odległości. Czujniki laserowe posiadają dobrą dokładność, pozwalając na analizę drgań od częstotliwości bliskich zera, umożliwiając diagnostykę maszyn bez konieczności ich demontażu [64, 49].

Podczas pracy kombajnu ścianowego w trakcie urabiania generowane są drgania, wielkość drgań jest w dużym stopniu zależna od warstwy skał która jest urabiana. Im twardsza skała tym noże zainstalowane na głowicy kombajnu poddawane są wyższym przeciążeniom generującym wibracje. Szeroko stosowane czujniki drgań mogą być wykorzystane nie tylko do diagnostyki maszyn, ale także jako narzędzie do pozyskiwania danych służących do rozpoznania granicy węgla i skały. Dotychczasowo w artykułach naukowych przedstawiono dwie koncepcje wykorzystania akcelerometrów do wykrywania granicy warstw węgla i skały.

Pierwsza metoda polega na zamontowaniu akcelerometru na ramieniu głowicy urabiającej kombajnu. Podczas eksploatacji pokładu noże zainstalowane na głowicy urabiającej napotykać na opór skał. Każdy rodzaj warstw skalny posiada swoją wytrzymałość na ściskanie. Dla skały płonnej którą jest mułowiec, łupek, lub piaskowiec wytrzymałość na ściskanie zawiera się w granicach $13\div 35$ MPa, a dla węgla $5\div 12$ MPa. Podczas urabiania skał maszyna wprawiana jest w wibracje w zależności od napotkanego przez noże oporu zależnego od wytrzymałości na ściskanie. Wytrzymałość skał jest co najmniej dwa razy mniejsza od węgla. Z tego względu możliwa jest

identyfikacja charakterystyki drgań. Odpowiednio skonstruowany układ pomiarowy pozwala na taką identyfikację [46, 72].

Drugi sposób wykorzystuje akcelerometry zainstalowane na sekcji obudowy zmechanizowanej. W nowoczesnej metodzie LTCC (ang. Longwall Top Coal Caving) za sekcją obudowy zmechanizowanej znajduje się dodatkowy przenośnik zgrzeblowy. Schemat metody przedstawiona na Rys. 14.



Rysunek 14. Miejsce zainstalowania akcelerometru na ramieniu urabiającym kombajnu ścianowego oraz na osłonie zawalowej sekcji obudowy zmechanizowanej (opracowanie własne).

Jest to innowacyjne rozwiązanie przy występowaniu pokładów grubych. Dotychczasowa eksploatacja pokładu odbywała się etapami wybierając jego kolejne warstwy. W metodzie tej urabianie calizny odbywa się w sposób tradycyjny z wykorzystaniem kombajnu ścianowego. Kombajn wycina dolną ławę pokładu pozostawiając ławę pokładu w stropie. Pozostawiona ława pokładu zsuwa się podczas przesuwania sekcji obudowy zmechanizowanej wraz z postępem ściany, gdzie spada na osłonę odzawalową wprawiając ją w wibracje [62]. Różnica w wibracjach powodowanych przez spadający węgiel lub skałę jest podstawą do rozróżnienia czy na przenośniku znajduje się węgiel czy skała.

5.5 Metoda akustyczna

Metoda wykorzystująca fale akustyczne jest metodą podobną do metody wibracji. Zamiast pomiaru wibracji przez akcelrometr wykorzystuje się rejestrację dźwięku. Warstwy skalne posiadają różną wartość wytrzymałości na ściskanie. Podczas urabiania skała o wyższej wytrzymałości na ściskanie generuje wyższą amplitudę mierzonego sygnału. Możliwe jest zatem odróżnienie warstw skalnych o wyższej i niższej wytrzymałości. Aby było to możliwe należy skompletować próbki sygnałów dla danych

warstw skalnych których rozróżnienie nas interesuje. Takie próbki służą jako próbki treningowe dla sieci neuronowej. Sieć neuronowa ma za zadanie porównanie próbek treningowych z próbkami mierzonymi podczas urabiania tak by sterować procesem eksploatacji w zamierzonej warstwie [73, 74, 75, 76, 30].

5.6 Metoda wykorzystująca LIBS

Laserozo wzbudzana spektroskopia emisyjna (ang. LIBS-Laser-Induced Breakdown Spectroscopy) jest uniwersalną metodą analityczną umożliwiającą analizę składu chemicznego próbek ciał stałych, cieczy i gazów. W metodzie tej wykorzystuje się wiązkę lasera impulsowego dużej mocy ($0,1 \text{ GW/cm}^2$). Energia promieniowania laserowego, skupiona na próbce ciała stałego lub cieczy prowadzi do ablacji, w gazach do przebicia elektrycznego. Niewielka ilość badanego materiału odparowuje tworząc świecąca plazmę. W wysokiej temperaturze sięgającej $100\ 000^\circ\text{C}$ plazma emituje intensywne promieniowanie elektromagnetyczne ciągłe, liniowe charakterystyczne dla pierwiastków znajdujących się w próbce. Analiza promieniowania umożliwia identyfikację atomów i jonów pierwiastków badanej próbki [77, 78].

Systemy ILBS to mało skomplikowane, proste mechanicznie oraz pozbawione elementów ruchomych urządzenia. Składają się z trzech elementów: lasera dużej mocy, detektora optycznego, jednostki rejestrującej i przetwarzającej dane.

Proces identyfikacji węgla w ścianie wydobywczej musi mieć wysoką wydajność w czasie rzeczywistym, dlatego proces próbkowania musi odbywać się *in situ*. Analizator ILBS zainstalowany jest prostopadle do czoła ściany, na automatycznie sterowanej ruchomej platformie zabudowanej wzdłuż ściany. Próbkowanie odbywa się w osi pionowej i poziomej. Impulsy lasera posiadają długość fali 1024 i maksymalną energię ograniczoną do 5,5 MJ/impuls ze względu na zapewnienie bezpieczeństwa w kopalni. Analiza dyskryminacyjna modeli cząsteczkowych najmniejszych kwadratów stosowana jest do analizy widm LIBS pozwalając skonstruować uproszczony model spektralny. Model ten wykorzystywany jest do rozpoznania skał przez sieć neuronową [79].

6 Wybrane metody klasyfikacji

Klasyfikacja (ang. classification) polega na zbudowaniu modelu przypisującego nowy, wcześniej nie znany obiekt, do jednej ze zbioru predefiniowanych klas. Otrzymane parametry charakterystyczne dla próbek porównywane są ze sobą, na tej podstawie podejmowana jest decyzja o klasyfikacji danej klasy zgodnie z przyjętą regułą decyzyjną.

Systemy klasyfikacji można podzielić na:

- proste-w których parametry sygnału dźwiękowego są tego samego rodzaju dla wszystkich klas rozpoznawanych sygnałów,
- złożone-w których parametry wejściowe są różnego rodzaju, np. parametry czasowe, częstotliwościowe,
 - jednopoziomowe - w celu klasyfikacji wykorzystywane są, informacje zawarte w pierwotnych parametrach pomiarowych (bez przetwarzania),
 - wielopoziomowe- parametry pierwotne są, pogrupowane na podklasy służące do rozpoznawania pierwotnego, a następnie otrzymane wyniki służą do dalszego poziomu rozpoznawania.

Klasyfikację można podzielić na uczenie nadzorowane (ang. supervised learning), gdzie opis klas ustalany z góry, na podstawie zbioru uczącego budowany jest model. Nienadzorowane (ang. unsupervised learning), przypisanie przynależności do klas nie jest ustalone, brak jest zbioru uczącego [80]. Jednym z najbardziej rozwiniętych w literaturze podejść do klasyfikacji jest podejście statystyczne [40]. W ujęciu statystycznym cechy składowe wektora \mathbf{x} traktowane są jako niezależne zmienne losowe, o pewnym znanym rozkładzie prawdopodobieństwa. Klasyfikacja zostaje sprowadzona do estymacji funkcji gęstości prawdopodobieństwa, określonej w wielowymiarowej przestrzeni wejściowej $\{\mathbf{x} \in \mathbb{R}^n\}$, przez podział tej przestrzeni na obszary odpowiadające pewnym klasom badanej wielkości. Najlepszy wynik klasyfikacji odpowiada znalezieniu najlepszego podziału przestrzeni. Statystyczne algorytmy rozpoznawania można podzielić na parametryczne i nieparametryczne. Jednym z najbardziej znanych klasyfikatorów parametrycznych jest algorytm Bayesa. Najbardziej popularnymi metodami nieparametrycznych metod klasyfikacji są:

Maszyny wektorów nośnych (SVM), Drzewa decyzyjne, algorytm k najbliższych sąsiadów (k-NN), oraz sztuczne sieci neuronowe (ANN) [44, 81].

Klasyfikacja dźwięku w niniejszej pracy została wykonana w programie WEKA. Program WEKA jest to zbiór bezpłatnego oprogramowania stworzonego w języku Java do uczenia maszynowego i analizy danych, licencjonowanego na podstawie Powszechnej Licencji Publicznej GNU. Program zapewnia łatwy dla użytkownika dostęp do analizy danych, dzięki swojemu graficznemu interfejsowi oraz zbioru narzędzi wizualizacyjnych i algorytmów.

6.1 k najbliższych sąsiadów

Algorytm k-najbliższych sąsiadów (ang. k-Nearest Neighbor, k-NN) należy do algorytmów znanych również pod nazwą uczenia leniwego (ang. Instance-based learning), algorytmy takie nie tworzą wewnętrznej reprezentacji danych uczących. Cały zbiór uczący jest zapamiętywany tak, że klasyfikacja nowych niesklasyfikowanych rekordów może zostać dokonana przez porównywanie z najbardziej podobnymi rekordami ze zbioru uczącego [82]. Podczas klasyfikacji wybierane jest k przykładów ze zbioru uczącego najbliższych w stosunku do rozważanego przykładu, następnie nadawana jest klasa wynikająca z głosowania wśród k przykładów. Do głosowania wykorzystywana jest odpowiednia ilość wystąpień k przykładów z różnych klas, dodatkowo można ważyć odpowiednie przynależności do klas odległościami od rozpatrywanego przypadku. W trakcie klasyfikacji od zapamiętanych przykładów trenujących obliczane są odpowiednie odległości. Wyróżnić można wiele stosowanych miar takich jak Czebyszewa, Manhattan, Minkowskiego i inne. Najczęściej stosowaną miarą jest Euklidesowa. Wartość k dobierana jest eksperymentalnie. Wysoka wartość parametru sprawia, że w przyznawaniu etykiety klasy bierze udział więcej sąsiadów. Wpływa to na zmniejszenie szumu odpowiedzi, lecz zwiększa jej rozmycie [83, 84].

Najbardziej popularne stosowane metryki odległości:

- Odległość Euklidesowa (L_2) jest to najczęściej stosowana miara odległości, ograniczona jest do wektorów o wartościach rzeczywistych. Mierzy linię prostą między punktem zapytania a drugim mierzonym punktem. Wyrażona jest wzorem:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$
(40)

gdzie: n -liczba wymiarów, $x_i - y_i$ -współrzędne x i y w wymiarze i .

- Czebyszewa (L_∞) -miara odległości między dwoma punktami.

$$L_\infty = \max_i |x_i - y_i|$$
(41)

- Odległość Manhattan jest to miara odległości mierząca wartość bezwzględną między dwoma punktami. Nazywana jest również odległością między blokami miasta, ponieważ często wizualizowana jest za pomocą siatki, ilustrującej sposób poruszania się z jednego adresu do drugiego ulicami miasta.

$$d(x, y) = \sum_{i=1}^n |x_i - y_i|$$
(42)

- Minkowskiego (L_m) jest uogólnioną miarą odległości między punktami przestrzeni euklidesowej.

$$L_m(x, y) = \left(\sum_{i=1}^n |x_i - y_i|^m \right)^{\frac{1}{m}}$$
(43)

W eksperymencie do klasyfikacji wykorzystano program WEKA opracowany na Uniwersytecie Waikato w Nowej Zelandii. Program jest ogólnodostępnym oprogramowaniem opartym na licencji GNU (ang. General Public Licence) [85].

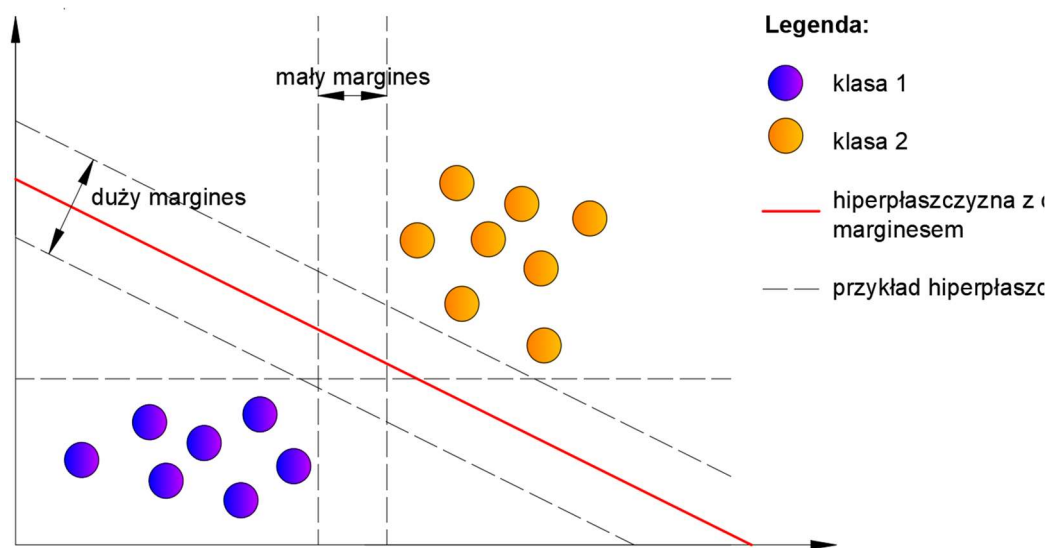
Algorytm k -NN w programie WEKA oznaczony jest jako metoda klasyfikacji IBk. Jak już wspomniano najbardziej popularną miarą odległości jest miara Euklidesowa. Do przeprowadzenia klasyfikacji wybrano dostępne w programie inne miary odległości takie jak Czebyszewa, Minkowskiego oraz Manhattan. Wartość parametru k ustalono eksperymentalnie co zostanie przedstawione w późniejszym rozdziale. W eksperymencie użyto 10-krotnej walidacji krzyżowej. Wielkość walidacji uzależniony jest od wielkości zbioru danych, mniejsze wartości stosowane są dla

mniejszych zbiorów danych. W analizowanym przypadku zastosowano walidację o wartości 10, taka wartość za bardzo nie uszczupla zbioru uczącego. Zbyt mała wielkość zbioru uczącego mogłaby powodować budowę słabej jakości modelu klasyfikacji.

6.2 Maszyny wektorów nośnych

Sieci SVM (ang. Support Vector Machines-SVM) należą do grupy sieci jednokierunkowych, które można zastosować zarówno dla danych liniowych, jak i nieliniowych. Istotą sieci jest konstrukcja hiperpłaszczyzny, separującej dane należące do przeciwnych klas, z możliwie największym marginesem zaufania [86].

Na Rys.15 przedstawiono przykład metody SVM oddzielającej dwie klasy na dwuwymiarowej przestrzeni. Kolorem czerwonym zaznaczono hiperpłaszczyznę o maksymalnej szerokości marginesu separacji oddzielającą dwie klasy. Pokazano także przykład hiperpłaszczyzny z małym marginesem separacji.



Rysunek 15. Przykład metody SVM w dwuwymiarowej przestrzeni [opracowanie własne].

Zakładając zbiór p par uczących (x_i, d_i) dla $i=1, 2, \dots, p$, gdzie x_i -wektor danych wejściowych, $d_i \in \{-1; 1\}$ - reprezentuje dyskryminowane klasy, $d_i=+1$ oznacza klasę dyskryminowaną, $d_i=-1$ oznacza pozostałe klasy. Zakładając liniową separowalność obu klas, hiperpłaszczyzna separująca obie klasy wyrażona jest wzorem [87]:

$$y(x) = w^T x + b = 0 \quad (44)$$

gdzie: w -wektor wag, x -wektor danych wejściowych, b -polaryzacja.

Równania decyzyjne definiujemy:

jeżeli $w^T x + b \geq 0$ wtedy $d_i = +1$

jeżeli $w^T x + b \leq 0$ wtedy $d_i = -1$

Zapisując powyższe równania w postaci nierówności:

$$d_i(w^T x + b) \geq 1 \quad (45)$$

Otrzymuje się wektory nośne (ang. support vectors), decydujących o położeniu hiperpłaszczyzny i szerokości marginesu separacji.

W przypadku klasyfikacji wzorców liniowo nieseparowanych, należy przeprowadzić dodatkowo transformacje danych wejściowych w przestrzeń wyższego wymiaru.

Najczęściej używanymi nieliniowymi funkcjami jądra są:

a. Funkcje wielomianowe

$$K(x_i, x) = (x^T x_i + \gamma)^p \quad (46)$$

b. Funkcje gaussowskie

$$K(x_i, x) = \exp(-\gamma \|x - x_i\|^2) \quad (47)$$

c. Funkcje sigmoidalne

$$K(x_i, x) = \tanh(\beta x^T x_i + \gamma) \quad (48)$$

gdzie: β, γ to stałe współczynniki liczbowe, p -stopień wielomianu.

W programie WEKA metoda SVM występuje pod nazwą funkcji SMO. Funkcja pozwala na normalizację i standaryzację wprowadzonych danych wejściowych podczas wstępnego przetwarzania, pozwalając określić funkcje jądra takie jak: liniową, wielomianową, gaussowską (RBF) [85].

Czas uczenia tej metody może być długi, jednak metoda jest bardzo dokładna dzięki możliwości modelowania złożonych, nieliniowych granic decyzyjnych. Jest znacznie mniej podatna na przeuczenie niż inne metody. Rozpoznawanie wielu klas z wykorzystaniem tej metody wymaga wielokrotnej klasyfikacji. Do najbardziej znanych należy „jeden przeciw wszystkim” i „jeden przeciw jednemu” [25].

6.3 Las losowy (ang. Random Forest)

Las losowy jest pojęciem zaproponowanym przez Leo Breimana. Losowy las łączy wiele losowych drzew, które podejmują decyzję na określony wynik. W algorytmie losowego lasu każdy głos ma taką samą wagę. Każdy klasyfikator wchodzący w skład lasu losowego uczony jest na specjalnie wylosowanej dla niego próbce. Próbka powstaje poprzez wylosowanie n -razy ze zwracaniem próbki D' ze wszystkich N próbek uczących. W ten sposób ta sama obserwacja może zostać wylosowana kilkukrotnie i skopiowana kilka razy do nowego zbioru. Losowanie powtarzane jest tak długo, aż liczba wszystkich obserwacji w nowym zbiorze będzie równa liczbie obserwacji w zbiorze starym. Technika ta nazywana jest Bootstrap aggregating w skrócie *bagging*.

Algorytm lasów losowych posiada wiele zalet, jedną z nich jest odporność na problemy związane z danymi wejściowymi takie jak: brak danych, zmienne objaśniające bez znaczenia, wartości odstające. Potrafi wyznaczyć ważność atrybutów wejściowych, jest odporny na przeuczenie oraz posiada możliwość interakcji pomiędzy zmiennymi [88]. Wadą tej metody jest niestabilność, małe zmiany na wejściu powodują duże zmiany w strukturze drzewa.

6.4 Perceptron wielowarstwowy

Perceptron wielowarstwowy (ang. Multilayer Perceptron), jest jedną z sieci neuronowych jednokierunkowych, dobrze sprawdzających się w klasyfikacji [89]. Jest to szeroko stosowana sieć neuronowa do klasyfikacji zbiorów, które nie są liniowo separowalne. Sieć tego typu najczęściej zbudowana jest z jednej warstwy wejściowej, kilku warstw ukrytych oraz jednej warstwy wyjściowej. Działanie pojedynczego neuronu polega na przekształceniu sygnału wejściowego za pomocą funkcji aktywacji oraz wektora wag w sygnał wyjściowy. Przekształcenie wyraża się wzorem:

$$\hat{y} = h \left(w_0 + \sum_{l=1}^L w_l x_{lL} \right) \quad (49)$$

gdzie: w_0 -waga przypisana dodatkowemu sygnałowi wejściowemu, h -funkcja aktywacji, w_l - l -ta waga, x_{lL} - l -ty sygnał wejściowy dla l -tej zmiennej, L -numer zmiennej.

Typowymi funkcjami aktywacji wpływającymi na właściwość uczenia się sieci, są funkcje:

Progowa

$$h(u) = \begin{cases} 1 & \text{gdy } u > 0 \\ 0 & \text{gdy } u \leq 0 \end{cases} \quad (50)$$

gdzie:

$$u = \left(w_0 + \sum_{l=1}^L w_l x_{lL} \right) \quad (51)$$

Bipolarna

$$h(u) = \begin{cases} 1 & \text{gdy } u > 0 \\ -1 & \text{gdy } u \leq 0 \end{cases}$$

gdzie:

$$u = \left(w_0 + \sum_{l=1}^L w_l x_{lL} \right) \quad (52)$$

Identycznościowa

$$h(u) = u \quad (53)$$

Liniowa

$$h(u) = ku \quad (54)$$

gdzie: k -jest stałą, różną od zera.

Sigmoidalna

$$h(u) = \frac{1}{1 + \exp(-u)} \quad (55)$$

Tangens hiperboliczny

$$h(u) = \operatorname{tgh}\left(\frac{u}{2}\right) = \frac{1 - \exp(u)}{1 + \exp(u)} \quad (56)$$

Perceptron wielowarstwowy jest siecią jednokierunkową, w której nie występuje sprzężenie zwrotne, lecz algorytm uczenia perceptronu wykorzystuje wsteczną

propagację błędu. Wsteczna propagacja błędu polega na obliczeniu wartości teoretycznych zgodnie z funkcjami aktywacji dla obserwacji zbioru uczącego krokiem w przód, następnie krokiem wstecz oblicza się wartość błędu dla każdego wiersza ze zbioru uczącego, w kolejnym etapie następuje minimalizacja funkcji błędu [90]. Sieć neuronowa osiąga bardzo dobre wyniki klasyfikacji, jednakże jest ona jedną z metod potrzebujących więcej czasu do uzyskiwania wyniku.

6.5 Miary jakości klasyfikacji

Macierz konfuzji podsumowuje wydajność klasyfikacyjną klasyfikatora w odniesieniu do niektórych danych testowych. Jest to macierz dwuwymiarowa, indeksowana w jednym wymiarze przez prawdziwą klasę obiektu, a w drugim przez klasę, którą przypisuje klasyfikator [91].

Macierz konfuzji dla przypadku dwuklasowego:

	Klasyfikacja pozytywna	Klasyfikacja negatywna
Stan pozytywny	PP	FP
Stan negatywny	FN	PN

PP-prawdziwie pozytywna

FP-fałszywie pozytywna (błąd pierwszego rodzaju)

FN-fałszywie negatywna (błąd drugiego rodzaju)

PN-prawdziwie negatywna

Dokładność (ang. Accuracy, ACC) - stosunek sumy wyników prawdziwie pozytywnych i negatywnych do sumy wyników prawdziwie pozytywnych i negatywnych oraz fałszywie pozytywnych i negatywnych.

$$ACC = \frac{PP + PN}{PP + FN + FP + PN}$$

(57)

Precyzja (ang. Precision) -prawdopodobieństwo otrzymania poprawnej pozytywnej klasyfikacji, pod warunkiem, że otrzymania przypadku pozytywnego.

$$Precyzja = \frac{PP}{PP + FP} \quad (58)$$

Czułość, pełność (ang. True positive rate (TPR), Recall, Sensitivity) - prawdopodobieństwo, że klasyfikacja będzie poprawna, pod warunkiem, że przypadek jest pozytywny

$$Czułość = \frac{PP}{PP + FN} \quad (59)$$

Specyficzność (ang. Specificity) - prawdopodobieństwo, że klasyfikacja będzie poprawna, pod warunkiem, że przypadek jest negatywny

$$Swoistość = \frac{PN}{FP + PN} \quad (60)$$

F-Measure -średnia harmoniczna czułości i precyzji

$$F - Measure = \frac{2 * precyzja * czułość}{precyzja + czułość} \quad (61)$$

G-Measure -średnia geometryczna czułości i precyzji

$$G - Measure = \sqrt{precyzja * czułość} \quad (62)$$

AUC -pole powierzchni pod krzywą ROC

$$AUC = \frac{czułość + swoistość}{2} \quad (63)$$

Współczynnik Kappa (ang. Cohen's Kappa) – miara zgodności z klasyfikatorem losowym. Przyjmuje wartości w przedziale -1 do +1. Wartość 0 oznacza klasyfikator losowy. Wartości dodatnie oznaczają, że klasyfikator jest lepszy od losowego.

$$\kappa = \frac{Accuracy - Accuracy_{Random}}{1 - Accuracy_{Random}} = \frac{n * d - \sum_{i=j}^K C_i * C_j}{n^2 - \sum_{i=j}^K C_i * C_j} \quad (64)$$

gdzie d jest liczbą poprawnych klasyfikacji, a C macierzą pomyłek.

$$C_i = \sum_{j=1}^K C_{ij} \text{ (suma wiersza)}$$

(65)

$$C_j = \sum_{i=1}^K C_{ij} \text{ (suma kolumny)}$$

(66)

Ocena zgodności dla różnych wartości κ :

- (0, 0.2) – nieistotna,
- (0.21, 0.40) – słaba,
- (0.41, 0.60) – średnia,
- (0.61, 0.80) – zasadnicza,
- (0.81, 1.0) – doskonała zgodność.

7 Metody normalizacji danych

Pod pojęciem normalizacji kryje się „ujednolicanie, standaryzacja wartości cech z punktu widzenia określonego kryterium”, głównym celem tego rodzaju transformacji jest doprowadzenie cech o różnych mianach do porównywalności [92, 93]. W zestawie danych empirycznych wykorzystywanych do klasyfikacji występują najczęściej wielkości o różnych jednostkach miar oraz zróżnicowanych zakresach zmienności. W przypadku niektórych algorytmów może to mieć istotny wpływ na wynik klasyfikacji. Z tego powodu na etapie wstępnego przygotowania danych wykonuje się ich normalizację, skalując oryginalne dane do określonego zakresu np. [-1,1] lub [0,1] [44]. Normalizacja jest przydatna, gdy dane mają różne skale, a używany algorytm nie przyjmuje założeń dotyczących rozkładu danych, takich jak k -najbliższych sąsiadów i sztuczne sieci neuronowe [94]. Najczęściej stosowanymi metodami normalizacji jest metoda odchylenia od wartości minimalnej oraz metoda względem standardowego odchylenia średniokwadratowego. Z tego względu, opisane w rozprawie zostaną tylko powyższe dwie metody normalizacji.

Metoda odchylenia od wartości minimalnej wyraża się wzorem:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (67)$$

gdzie: x -wartość zmiennej, x_{min} -wartość minimalna, x_{max} -wartość maksymalna, x_{norm} -wartość zmiennej znormalizowana.

Transformuje dziedzinę zmiennych w przedział (0,1).

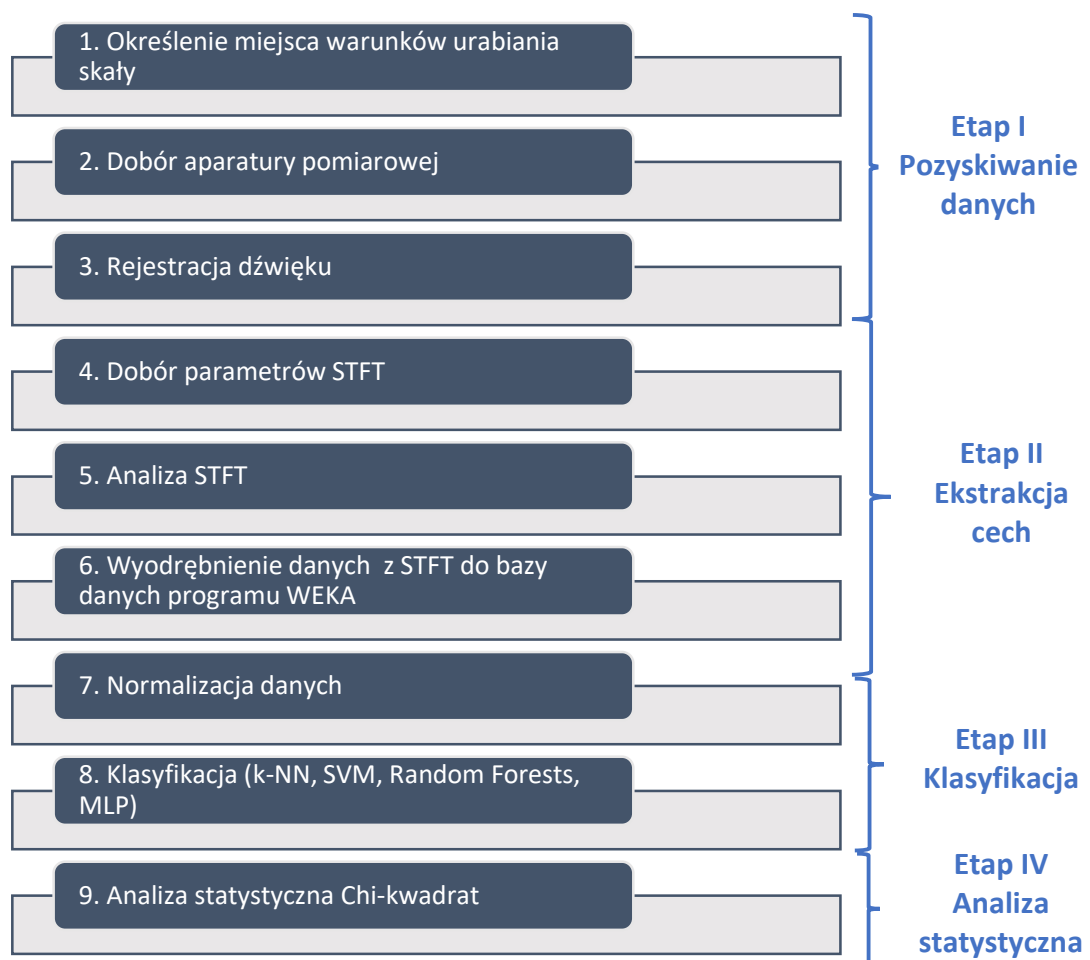
Metoda normalizacji względem standardowego odchylenia średniokwadratowego wyraża się wzorem:

$$x_{norm} = \frac{x - x_{\bar{r}}}{\sigma} \quad (68)$$

gdzie: x -wartość zmiennej, x_{norm} -wartość zmiennej znormalizowana, $x_{\bar{r}}$ -wartość średnia zmiennych, σ -odchylenie standardowe.

8 Opis metody badawczej

Głównym zadaniem realizowanym podczas pracy badawczej była identyfikacja cech sygnału zarejestrowanego dźwięku urabiania węgla i skały, oraz klasyfikacja na podstawie wybranych metod. W rozpatrywanym przypadku jest to algorytm zmierzający do identyfikacji cech sygnału potrzebnych do zidentyfikowania rodzaju urabianej skały. Zaproponowana przez Autora metoda zawiera 9 etapów przedstawionych na rys. 16. Przedstawione kolejno realizowane etapy badań przedstawione i omówione będą w kolejnych podrozdziałach.



Rysunek. 16 Etapy realizacji metody.

Do badań wykorzystano skonstruowane do tego celu stanowisko badawcze zawierające rejestrator dźwięku wraz z mikrofonem kierunkowym, zainstalowane w wyrobisku ścianowym kopalni węgla kamiennego. Do analizy pozyskanych próbek dźwięku na etapie ekstrakcji cech wykorzystano program Matlab-MathWorks. Program

będący interaktywnym środowiskiem do wykonywania obliczeń naukowych posiada w swojej bibliotece szereg funkcji służących do analizy czasowo-częstotliwościowej. Umożliwia także rysowanie dwu i trójwymiarowych wykresów funkcji oraz spektrogramów.

Autor za pomocą utworzonego kodu zaimportował zarejestrowane próbki dźwięku do programu Matlab-MathWorks. Następnie wykorzystał funkcję krótkoczasowego przekształcenia Fouriera STFT zaimplementowaną w programie, funkcja ta została wybrana ze względu na niestacjonarny charakter analizowanego sygnału. Wynikiem analizy STFT są wykresy kaskadowe przedstawiające wartości amplitudy i częstotliwości w czasie, oraz spektrogramy.

Określenie charakterystycznych częstotliwości podczas pracy kombajnu ścianowego urabiającego węgiel lub skałę posłuży do dalszych badań klasyfikacji w programie WEKA.

Uwzględniając powyższe założenia sformułowano następującą tezę pracy: *Na podstawie wybranych metod klasyfikacji: k-najbliższych sąsiadów (k-NN), maszyny wektorów nośnych (SVM), drzew losowych, perceptron wielowarstwowy (MLP), możliwe jest rozróżnienie dźwięku urabiania węgla lub skały.*

Wykorzystanie analizy statystycznej chi-kwadrat, pozwala na wykazanie zasadności hipotezy zerowej, która mówi, że nie istnieje statystycznie istotny związek między pomiędzy dwoma próbkami analizowanego dźwięku.

8.1 Określenie miejsca i warunków urabiania

Etap pierwszy obejmuje określenie warunków pracy kombajnu ścianowego. Pomiaru dokonano w wyrobisku ścianowym w pokładzie 207. Pokład 207 według podziału pokładów stosowanego w górnictwie, należy do serii warstw łaziskich. W rejonie ściany wydobywczej pokład 207 posiada miąższość 3,69÷4,20m. Pokład przeławicony jest trzema przerostami łupku ogniotrwałego o grubości 0,01÷0,03m. W stropie pokładu 207 występuje warstwa szarego mułowca o miąższości od 0,0m do 2,4m lub bezpośrednio nad pokładem zalega piaskowiec różnoziarnisty, którego grubość wynosi od 17,6m do 24,5m. W spągu pokładu 207 występuje warstwa szarego mułowca o grubości od 0,0m do 0,65m lub bezpośrednio pod pokładem piaskowiec różnoziarnisty, średniozwięzły o miąższości do 35m. Upad pokładu wynosi około 6°÷8° w kierunku północno-wschodnim. Na podstawie badań skał w otworach badawczych

penetrometrem określono średnie wytrzymałości na ściskanie (R_c) skał w rejonie ściany nr 5 (Tab.5) [95].

Tabela 5 Wartości wytrzymałości skał na ściskanie w rejonie ściany nr 5.


Warstwa skał	Średnia wytrzymałość na ściskanie R_c [MPa]
Piaskowiec (strop)	22÷34,24
Mułowiec szary (strop)	18,48÷19,2
Węgiel pokład 207	10,3÷18,3
Mułowiec szary (spąg)	nie określono
Piaskowiec (spąg)	11,73÷5,52

Parametry eksploatacyjne ściany nr 5 w pokładzie 207:

Wysokość ściany	- do 4,0 m
Miąższość pokładu 207	- 3,69m ÷ 4,20m
Nachylenie pokładu	- 6,0° ÷ 8,0°
Długość ściany	- 210,0 m
Nachylenie podłużne ściany	- -3,2° ÷ +2,2°
Nachylenie poprzeczne ściany	- +4,2° ÷ +10,0°
Odmiana systemu eksploatacji	- poprzeczny
Kierowanie stropem	- zawał

Kombajn ścianowy wchodzi w skład zespołu urządzeń zwanym kompleksem ścianowym (Rys. 17) stanowiącym system przestrzennie spójny, realizujący poszczególne operacje. System taki składa się z:

1. Maszyny urabiającej (kombajn lub strug),
2. Przenośnika ścianowego zgrzeblowego,
3. Zmechanizowanej obudowy ścianowej,
4. Zgrzeblowego przenośnika podścianowego z kruszarką.



Rysunek 17 Kompleks ścianowy [96].

Ponadto do urządzeń wchodzących w skład kompleksu ścianowego znajdujących się w niedalekiej odległości najczęściej zainstalowanych w wyrobisku przyścianowym wchodzi:

- Hydrauliczny agregat pompowy zasilający obudowę zmechanizowaną,
- Zestaw urządzeń elektrycznych zasilających i sterujących pracą urządzeń ściany,
- Innych agregatów pomocniczych.

Kombajn ścianowy porusza się wzdłuż przenośnika ścianowego na specjalnej konstrukcji. Składa się z podłużnego kadłuba wyposażonego w dwa ruchome ramiona, do których zamocowane są organy skrawające o dużej mocy. Organy skrawające wykonane są na kształt ślimaka z zainstalowanymi nożami skrawającymi z węglików spiekanych. Proces urabiania calizny węglowej przebiega w sposób zależy od zastosowanej technologii. Najczęściej organ wyprzedzający skrawa górną warstwę calizny przedsiębiernie (ruch obrotowy zgodny z ruchem wskazówek zegara). Organ znajdujący się w tyle pracuje nadsiębiernie, urabiając dolną część calizny oraz ładuje pozostały urobek z organu wyprzedzającego niezależnie na przenośnik zgrzeblowy. Przenośnik zgrzeblowy transportuje urobek za pomocą zgrzebeł zainstalowanych na łańcuchach w rynnie przenośnika ścianowego przez kruszarkę na przenośnik

podścianowy skąd trafia dalej na odstawę główną składającą się z ciągu przenośników taśmowych prowadzących na powierzchnię do zakładu przeróbczego.

Warunki ekonomiczne wymuszają na zakładach górniczych planowanie i prowadzenie rozcinki ścianowej wyrobiskami chodnikowymi oraz eksploatacji pokładów wyrobiskami ścianowymi w taki sposób by maksymalnie ograniczyć urabianie skały płonnej. Najczęściej skałę płoną urabia się przy występujących zaburzeniach tektonicznych opisanych w rozdziale 2.

Odpowiednie prowadzenie wyrobiska ścianowego jest ważne ze względu na zminimalizowanie urabiania skały płonnej, której nawet stosunkowo mała ilość wpływa na jakość wydobytej kopaliny, oraz wielkość produkcji odpadów, które muszą być magazynowane na powierzchni lub zatłaczane do zrobów wyrobisk. Zminimalizowanie urabiania kamienia ma również wpływ na stan techniczny maszyn, ich awaryjność oraz dłuższą żywotność. Noże kombajnowe, przekładnie, łańcuch oraz rynnny przenośnika zgrzeblowego zużywają się szybciej podczas urabiania i transportu skał. Nie bez znaczenia pozostaje ilość pyłu wytwarzanego przez noże kombajnowe podczas urabiania kamienia, pomimo zastosowania dysz zraszających na organie kombajnu. Zraszanie nie tylko chłodzi noże kombajnowe, ale przede wszystkim zmniejsza zapylenie. Aby chronić pracowników przed chorobami, takimi jak pylica płuc stosowane są indywidualne ochrony dróg oddechowych, jakimi są maski przeciwpylowe klasy P3. Niestety przy dużym zapyleniu nie zawsze jest to wystarczające.

8.2 Dobór aparatury pomiarowej

Przedstawione wyżej warunki środowiskowe procesu urabiania węgla narzucają szereg wymagań dotyczących pracującej w nich aparatury. Dobór odpowiedniej aparatury jest kluczowym czynnikiem powodzenia przeprowadzenia eksperymentu, ponieważ to mikrofon jest pierwszym elementem toru fonicznego. Z definicji mikrofon jest to przetwornik elektroakustyczny zamieniający energię fali dźwiękowej na energię elektryczną. Konwersja może być przeprowadzona w różny sposób, w zależności od zastosowanego typu przetwornika. Poniżej przedstawiono podział mikrofonów ze względu na sposób przetwarzania drgań membrany, wraz z krótkim opisem zasady działania:

- Stykowe (węglowe)- mikrofon typu podłużnego, Zasada działania mikrofonu polega na zmianie rezystancji tego proszku pod wpływem nacisku membrany drgającej na skutek oddziaływania fal dźwiękowych. Proszek zamknięty jest w komorze z jednej strony ograniczonej metalową płytką stanowiącą membranę, a z drugiej metalową elektrodą. Zaletą tych mikrofonów jest prosta budowa i wysoka skuteczność, wadą wąskie pasmo częstotliwości, węższe nawet od pasma składającego się na ludzką mowę, wynoszące zazwyczaj od 200Hz do 4kHz. Ich inną wadą są duże zniekształcenia, szумы oraz nierównomierna przemiana poszczególnych częstotliwości [97, 98],
- Piezoelektryczne- mikrofony piezoelektryczne pod względem elektrycznym są kondensatorami, przetwarzają sygnał akustyczny w sygnał napięciowy pod wpływem odkształcenia mechanicznego. Wierni odtwarzają wysokie tony, stosowane jako czujnik ultradźwięków, wrażliwe na zmiany temperatury i wilgoć, stosowane jako przetworniki w instrumentach akustycznych [97, 98].
- Dynamiczne:
 - Cewkowe- zbudowany z nieruchomego magnesu, pod wpływem drgań wywołanych przez fale akustyczne, porusza się cewka połączona z membraną. Potrafi przenosić pasmo 30-10kHz, zaleta jest niska cena, wysoka odporność, dobra kierunkowość. Wadami są niska skuteczność oraz mało efektywne przenoszenie wysokich częstotliwości [97, 98, 99].
 - Wstęgowe- zamiast cewki zastosowano, wstążkę karbowaną wykonaną z folii metalowej, osadzonej między nabiegunnikami magnesu. Cechuje się wiernym odtwarzaniem w zakresie pasma 30-15kHz, nie wymaga dodatkowego zasilania. Podatny na uszkodzenia, wysoka cena [97, 98, 99].
- Pojemnościowe (elektrostatyczne)-konstrukcja składa się z dwóch elektrod, z których jedna jest nieruchoma, druga pełni rolę membrany i wystawiona jest na działanie fal akustycznych, elektrody pełnią rolę okładek kondensatora, zmiana odległości pomiędzy elektrodami powoduje powstanie składowej zmiennej w napięciu stałym kondensatora. Mikrofon

wymaga napięcia stałego, najczęściej 48V. Posiada bardzo szerokie pasmo przenoszenia, bardzo dobra charakterystyka kierunkowa, mała wrażliwość na wstrząsy, wysoka cena, możliwość łatwego przesterowania ze względu na czułość [97, 98].

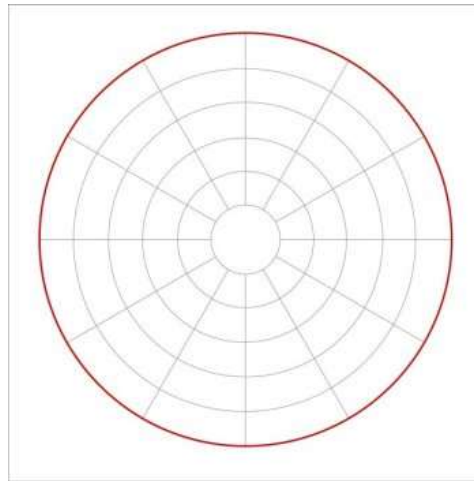
- Pojemnościowe elektretowe- membrana wykonana jest z elektretu -dielektryka o trwałej polaryzacji elektrycznej.
- Laserowe- sygnał dźwiękowy reprodukowany na elemencie światłoczułym dzięki wiązce lasera odbijającej się od drgającej powierzchni, małe wymiary, niewrażliwość na zakłócenia elektromagnetyczne, bezstratna transmisja, mniejszy stosunek sygnału do szumu niż w typowych mikrofonach [100, 98].

Wyróżnić można cztery typy mikrofonów ze względu na oddziaływanie dźwięku na membranę [101]:

- Ciśnieniowe- jedna strona membrany jest osłonięta szczelną komorą, tylko jedna strona mikrofonu jest wrażliwa na oddziaływanie fal dźwiękowych, czule są tylko na zmiany ciśnienia akustycznego bez względu na kierunek, z którego napływa fala akustyczna [101],
- Gradientowe- proces odbierania dźwięku następuje poprzez działanie różnic ciśnienia po dwóch stronach membrany. Mikrofon jest dwukierunkowy a charakterystyka kierunkowości ma kształt ósemki-[101];
- Ciśnieniowo-gradientowe- zmiany ciśnienia akustycznego przedostają się do drugiej strony membrany przez odpowiednie kanały oraz otwory, mikrofony wykazują właściwości kierunkowe, najbardziej czule na fale padające prostopadle na membranę od przodu mikrofonu [101],
- Ciśnieniowo-gradientowe-interferencyjne- posiadają długi kanał z otworami bocznymi, fale napływające wzdłuż osi głównej są uprzywilejowane [101].


Ważnym aspektem w rejestracji dźwięku z określonego miejsca badań mają charakterystyki kierunkowości mikrofonu, odnoszące się do obszaru, z którego mikrofon zbiera dźwięki. Dobór odpowiedniej charakterystyki do określonego zastosowania w pewnym stopniu eliminuje rejestrację niepożądanych dźwięków lub utraty żądanych informacji niezbędnych do analizy. Wyróżnić można cztery główne charakterystyki kierunkowe:

- Dookólna- charakterystyka w kształcie kuli, mikrofon zbiera dźwięki ze wszystkich stron (rys.18) [100, 102],




Rysunek 18. Dookólna charakterystyka mikrofonu [100].

- Kardiodalna- charakterystyka w kształcie serca, mikrofon jest najczulszy dla dźwięków dobiegających od przodu (Rys.19) [102],




Rysunek 19. Kardiodalna charakterystyka mikrofonu [100].

- Hyperkardiodalna- podobna do kardiodalnej, lecz o większej kierunkowości (Rys.20) [102],



Rysunek 20. Hyperkardioidalna charakterystyka mikrofonu [100].

- Ósemkowa- dźwięki rejestrowane są z przodu i z tyłu mikrofonu, a tłumione z boków (Rys.21) [102].



Rysunek 21. Charakterystyka ósemkowa mikrofonu [100].

Należy także, zwrócić uwagę na dobór mikrofonu o odpowiednich parametrach. Poniżej przedstawiono jedne z ważniejszych parametrów mikrofonu mających wpływ na rejestrację dźwięku, które wzięto pod uwagę wybierając mikrofon do eksperymentu:

- Zakres dynamiki wyrażony w [dB], jest różnica między największą i najmniejszą wartością ciśnienia akustycznego przenoszonego przez mikrofon [98],
- Czułość- zależność między ciśnieniem akustycznym wywieranym na membranę mikrofonu a napięciem wyjściowym [98],

- SNR (ang. signal-to-noise ratio) -stosunek sygnału do szumu, różnica między napięciem na wyjściu mikrofonu przy ciśnieniu akustycznym równym 1 Pa a napięciem szumów mikrofonu [98],
- Pasmo przenoszenia- zakres częstotliwości akustycznych skutecznie przetwarzanych przez mikrofon [97],
- Typ zastosowanego przetwornika,
- Charakterystyka kierunkowości.

Do przeprowadzenia eksperymentu wykorzystano pojedynczy mikrofon Synco D- 1 (Rys.23). W doborze kierowano się charakterystyką kierunkową hiperkardioidalną pozwalającą na rejestrację dźwięku z interesującego nas obszaru, pasmem przenoszenia, parametrami SNR. Nie bez znaczenia był także materiał, z którego był wykonany mikrofon. Ze względu na trudne środowiskowe otoczenia, taki jak pył, woda oraz możliwość uszkodzenia mikrofonu przez okruchy skalne, wybrano mikrofon o wytrzymałej budowie wykonanej z mosiądzu. Połączone złącze kablowe umożliwiło uzyskanie jak najwyższej jakości rejestrowanego dźwięku. Dodatkowo, żeby zabezpieczyć mikrofon przed oddziaływaniem pyłu zastosowano osłonę w formie gąbki akustycznej, która mogła częściowo odizolować przetwornik od czynników szkodliwych.



Rysunek 22 mikrofon kierunkowy Synco D-1 [103].

Wykorzystany do nagrań mikrofon charakteryzuje się następującymi parametrami:

- Rodzaj przetwornika: Tylny, elektretowy pojemnościowy,
- Charakterystyka kierunkowości: Hiperkardioidalna,

- Pasmo przenoszenia: 40Hz do 20KHz,
- Zakres dynamiczny: 106dB/ 91dB 11KHz przy Max. SPL,
- Sygnał/szum: 78dB (1KHz przy 1Pa),
- Czułość: -34dB/32dB±2dB (1dB=1V/Pa przy 1KHz),
- Max. wejście SPL: 450Ω±20% (przy 1KHz),
- Impedancja wyjściowa: 500Ω/600Ω 48V/1.5V.

Oprócz mikrofonu jako pierwszego elementu systemu rejestracji dźwięku, kolejnym był dobór odpowiedniego rejestratora audio. W wyborze kierowano się głównie kryteriami możliwie wysokiej jakości dźwięku. Ograniczone możliwości finansowe pozwoliły na zakup rejestratora ZOOM H5.



Rysunek 23 Rejestrator dźwięku ZOOM H5.


Urządzenie pozwala na rejestrację dźwięku z jakością (44,1kHz/24bit), przydatną funkcją urządzenia jest możliwość korekcji głośności nagrywanego dźwięku poprzez zainstalowane wyskalowane potencjometry, moc sygnału wyświetlana jest na monitorze w formie potencjometrów. Korekcja jest ważnym elementem podczas etapu rejestracji, ponieważ rejestrator umożliwia automatycznie wzmacnianie sygnałów o niskim poziomie oraz obniżać poziom zbyt mocnych sygnałów przeciwdziałając przesterowaniu. Dodatkową użyteczną funkcją w procesie rejestracji, gdzie eksperymentu nie można powtórzyć wielokrotnie jest funkcja nagrywania zapasowego w osobnym pliku o poziomie niższym o 12 dB od standardowego. Taką kopię zapasową można wykorzystać, np. jeśli ustawiono zbyt wysoki poziom nagrywania, w wyniku czego sygnał został przesterowany. Ponadto urządzenie oprócz zainstalowanych dwóch

mikrofonów pojemnościowych ustawionych pod kątem 90 stopni, posiada dwa wejścia na mikrofony zewnętrzne, które mogą być wykorzystane do rejestracji np. dwóch sygnałów w jednym czasie.

Dodatkowo do rejestracji dźwięku z uwagi na potrzebę zachowania pewnej odległości od organu urabiającego, podyktowanej przepisami BHP, wykorzystano statyw mikrofonowy o wysokości 1,8m.

8.3 Rejestracja dźwięku

Rejestracja dźwięku ze względu na możliwość niekontrolowanego obrywu czoła ściany przy organie urabiającym oraz na możliwość uszkodzenia samego mikrofonu przez skałę jak i wodę z instalacji zraszania kombajnu przebiegała w pewnej odległości. Mikrofon zainstalowany na statywie o długości 1,8m znajdował się w odległości ok. 2 m od organu urabiającego (Rys.24). Ze względów bezpieczeństwa podczas rejestracji dźwięku możliwe było zarejestrowanie wybranych fragmentów wyrobiska ścianowego. Podyktowane było to warunkami technicznymi, bezpieczeństwa oraz warunkami geologicznymi. Wysokość ściany wydobywczej wynosi do 4m, co stwarza zagrożenie obsypania się pokładu węgla na przenośnik zgrzeblowy oraz zainstalowane obstawki przenośnika chroniące obsługę przed opadającymi bryłami węgla. Należy zauważyć, że przebywanie w bliskiej odległości od organu urabiającego jest zabronione przepisami BHP.



Rysunek 24 Schemat lokalizacji mikrofonu w wyrobisku ścianowym.

W ścianie, w której dokonywano rejestracji dźwięku nie występowały zaburzenia geologiczne, w których mogłaby występować duża ilość piaskowca, dlatego zdecydowano o rejestracji próbek dźwiękowych urabiania mułowca w spągu wyrobiska. Rejestracja urabiania skały w stropie wyrobiska nie była możliwa ze względu na słabą wytrzymałość skał stropowych i związaną z tym możliwość obwałowania skał stropowych. Podczas pracy kombajnu zarejestrowano dwie próbki, pierwsza urabianie węgla

o długości 119s oraz druga urabianie węgla z mułowcem w spągu o długości 65s. Należy zwrócić uwagę na niekorzystne warunki panujące podczas dokonywania pomiaru. Wysokie zapylenie, obecność wody z systemu zraszania zainstalowanego na kombajnie, możliwość niekontrolowanego opadu skał, warunki te przekraczają możliwości dysponowanej aparatury pomiarowej w zakresie długotrwałej eksploatacji i przyczyniają się do szybkiego zużycia sprzętu. W przyszłości opracowanie systemu rozpoznającego dźwięk wymusza zastosowanie aparatury o odpowiedniej pyło i wodoszczelności. Według autora zakres ochrony powinien wynosić co najmniej IP68 (ang. IP-International Protection Rating). Pierwsza cyfra w podanym skrócie oznacza poziom ochrony przed kontaktem z ciałami stałymi. Wyrażona jest w skali [104]:

- X – brak danych, by określić stopień ochrony,
- 0 – brak ochrony przed ciałami stałymi i dotknięciem,
- 1 – ochrona przed dotknięciem części niebezpiecznych wierzchem dłoni oraz przed wnikaniem ciał stałych o średnicy 50 mm i większej,
- 2 – ochrona przed dotknięciem części niebezpiecznych palcem oraz przed wnikaniem ciał stałych o średnicy 12,5 mm i większej,
- 3 – ochrona przed dotknięciem części niebezpiecznych narzędziem oraz przed wnikaniem ciał stałych o średnicy 2,5 mm i większej,
- 4 – ochrona przed dotknięciem części niebezpiecznych drutem oraz przed wnikaniem ciał stałych o średnicy 1 mm i większej,
- 5 – ochronę użytkowników przed jakimkolwiek dotknięciem niebezpiecznych części oraz przed wnikaniem pyłu,
- 6 – najwyższa ochrona przed jakimkolwiek dotknięciem części niebezpiecznych i wnikaniem pyłu.

Druga cyfra charakterystyczna informuje o ochronie przed wnikaniem wody i wyrażona jest w skali [104]:

- X – brak danych, by określić stopień ochrony,
- 0 – brak ochrony przed wodą,
- 1 – ochrona przed padającymi kroplami wody,
- 2 – ochrona przed padającymi kroplami wody przy wychyleniu budowy pod dowolnym kątem do 15° od pionu w każdą stronę,
- 3 – ochrona przed natryskiwaniem wodą pod dowolnym kątem do 60° od pionu w każdą stronę,


- 4 – ochrona przed bryzgami wody z wszystkich kierunków,
- 5 – ochrona przed strumieniem wody do 12,5 l/min, lanym na obudowę z dowolnego kierunku,
- 6 – ochrona przed strumieniem wody do 100 l/min, lanym na obudowę z dowolnego kierunku,
- 7– ochrona przed skutkami krótkotrwałego zanurzenia w wodzie na czas 30 min i o głębokości 15 cm powyżej wierzchu obudowy i 1 m poniżej jej spodu (wartości dla obudowy niższej niż 85 cm),
- 8– ochrona przed skutkami ciągłego zanurzenia w wodzie w warunkach określonych przez producenta, lecz trudniejszych niż w punkcie 7,
- 9– odporność na długotrwałe zanurzenie i ochrona przed zalaniem silną strugą wody pod wysokim ciśnieniem (80-100 bar) i temperaturze do 80°C.

Dobór aparatury z tak wysoką odpornością na warunki atmosferyczne pozwoli na długotrwałą eksploatację systemu. Kopalnia, w której przeprowadzono pomiary jest kopalnią niemetanową. Z tego powodu nie wymagane było spełnienie warunków budowy przeciwwybuchowej, jednakże w polskim górnictwie zdecydowana większość kopalń jest kopalniami metanowymi, które wymagają urządzeń z odpowiednimi certyfikatami zezwalającymi na stosowanie w wyrobiskach górniczych. Certyfikaty wystawiają jednostki upoważnione do przeprowadzania badań i oceny wyrobów określone w rozporządzeniu Rady Ministrów (Dz.U.poz.1853 z dnia 20.12.2007 r.).

8.4 Dobór parametrów STFT

Zgodnie z zaproponowaną metodą zarejestrowany dźwięk urabiania węgla i skały zostaje w pierwszej kolejności poddany analizie STFT w celu określenia charakterystycznych przedziałów częstotliwościowych dla próbek. STFT dzieli sygnał wejściowy w dziedzinie czasu na kilka oddzielnych lub nakładających się ramek poprzez pomnożenie sygnału przez funkcję okna, a następnie stosuje transformatę Fouriera (FFT) dla każdej ramki, wyniki z każdego z odcinków łączone są w całość. Podzielenie sygnału na odcinki czasowe pozwala uznać sygnał za stacjonarny w danym odcinku czasowym. Transformaty Fouriera wykonywane są podczas przesuwania okna, zastosowana technika może mierzyć zmiany zawartości częstotliwości w czasie. Transformacja STFT charakteryzuje się ustaloną rozdzielczością w dziedzinie czasu i częstotliwości. W pierwszym etapie analizy, jednym z najważniejszych problemów

jest określenie długości stacjonarnych podrealizacji sygnału, odbywa się to poprzez odpowiedni dobór rozmiaru okna czasowego o długości będącej zwykle potęgą liczby 2. Długość okna ma wpływ na wielkość rozdzielczości czasowej i częstotliwościowej. Okno krótkie w dziedzinie czasu powoduje wydłużenie okna w dziedzinie częstotliwości, okno długie sprawia, że wynik jest odwrotny. Sytuację przedstawia Rys. 25. Nie można jednocześnie zapewnić dobrej rozdzielczości w domenie czasu i częstotliwości [22, 19].




Rysunek 25 Rozdzielczość czasowa i częstotliwościowa w zależności od doboru okna [22]

Prawidłowo dobrane okno powinno spełniać wymagania:

- okno powinno być na tyle wąskie by przedział sygnału mógł być uznany za stacjonarny,
- powinno zapewniać odpowiednią rozdzielczość dla analizowanego sygnału w dziedzinie czasu i dziedzinie częstotliwości.


Analiza sygnału metodą STFT wymaga kompromisu pomiędzy doborem rozdzielczości czasowej a częstotliwościowej, jest to główna wada tej metody. W celu rozróżnienia granicy między węglem i skałą najbardziej pożądanym jest określenie w jakim przedziale częstotliwościowym można stwierdzić, że kombajn urabia węgiel lub skałę. W celu zobrazowania problemu doboru wielkości okna poddano analizie jedną z próbek dźwiękowych. Spektrogram wykreślony został dla okna o wielkości 1024 oraz 4096, przy przesunięciu okna 25% i zastosowaniu okna Hamminga. Na Rys.26 przedstawiono wykres kaskadowy, na którym widać sytuację zastosowania zbyt

wąskiego okna czasowego. Można zauważyć, że wykres wzdłuż osi X wyrażonej jako częstotliwość (Hz) jest rozszerzony, zgodnie z Rys.25, gdzie wąskie okno w domenie czasowej powoduje rozciągnięcie okna w domenie częstotliwościowej. Nie zostaje zapewniona optymalna rozdzielczość w domenie częstotliwościowej, wartości amplitudy zostają uśrednione a tym samym cały wykres zostaje wygładzony, tracone są informacje o wielkości amplitud dla poszczególnych częstotliwości. W osi reprezentującej czas podział wykresu jest bardziej szczegółowy, ponieważ ramka okienkowania jest węższa (Rys.25) zapewniając wyższą rozdzielczość czasową.



Rysunek 26 Obraz próbki dźwięku po zastosowaniu okna wąskiego (1024) (opracowanie własne).

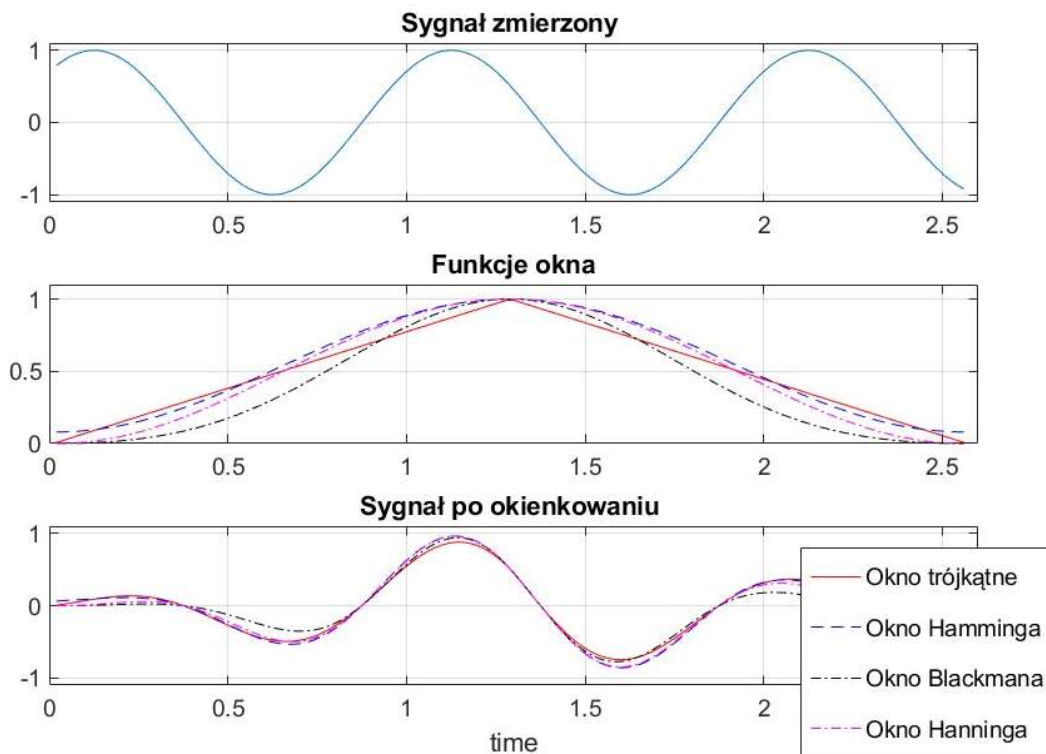
W przypadku zastosowania okna szerokiego w domenie czasowej (Rys.27) o wielkości (4096), zgodnie z Rys.25, okno częstotliwościowe jest węższe, zapewniając wyższą szczegółowość wykresu w osi częstotliwości. Wartości amplitud są wyższe, nie traci się ważnych informacji o ich wielkości. W osi wyrażającej czas wykres jest bardziej rozszerzony. W procesie rozpoznawania urabiania węgla i skały interesującą w badaniach informacją są charakterystyczne przedziały częstotliwościowe dla poszczególnych warstw skalnych. Ponieważ na tej podstawie przy zastosowaniu metod klasyfikacji można rozróżnić interesującą nas warstwę.



Rysunek 27. Obraz próbki dźwięku po zastosowaniu okna szerokiego (4096) (opracowanie własne).

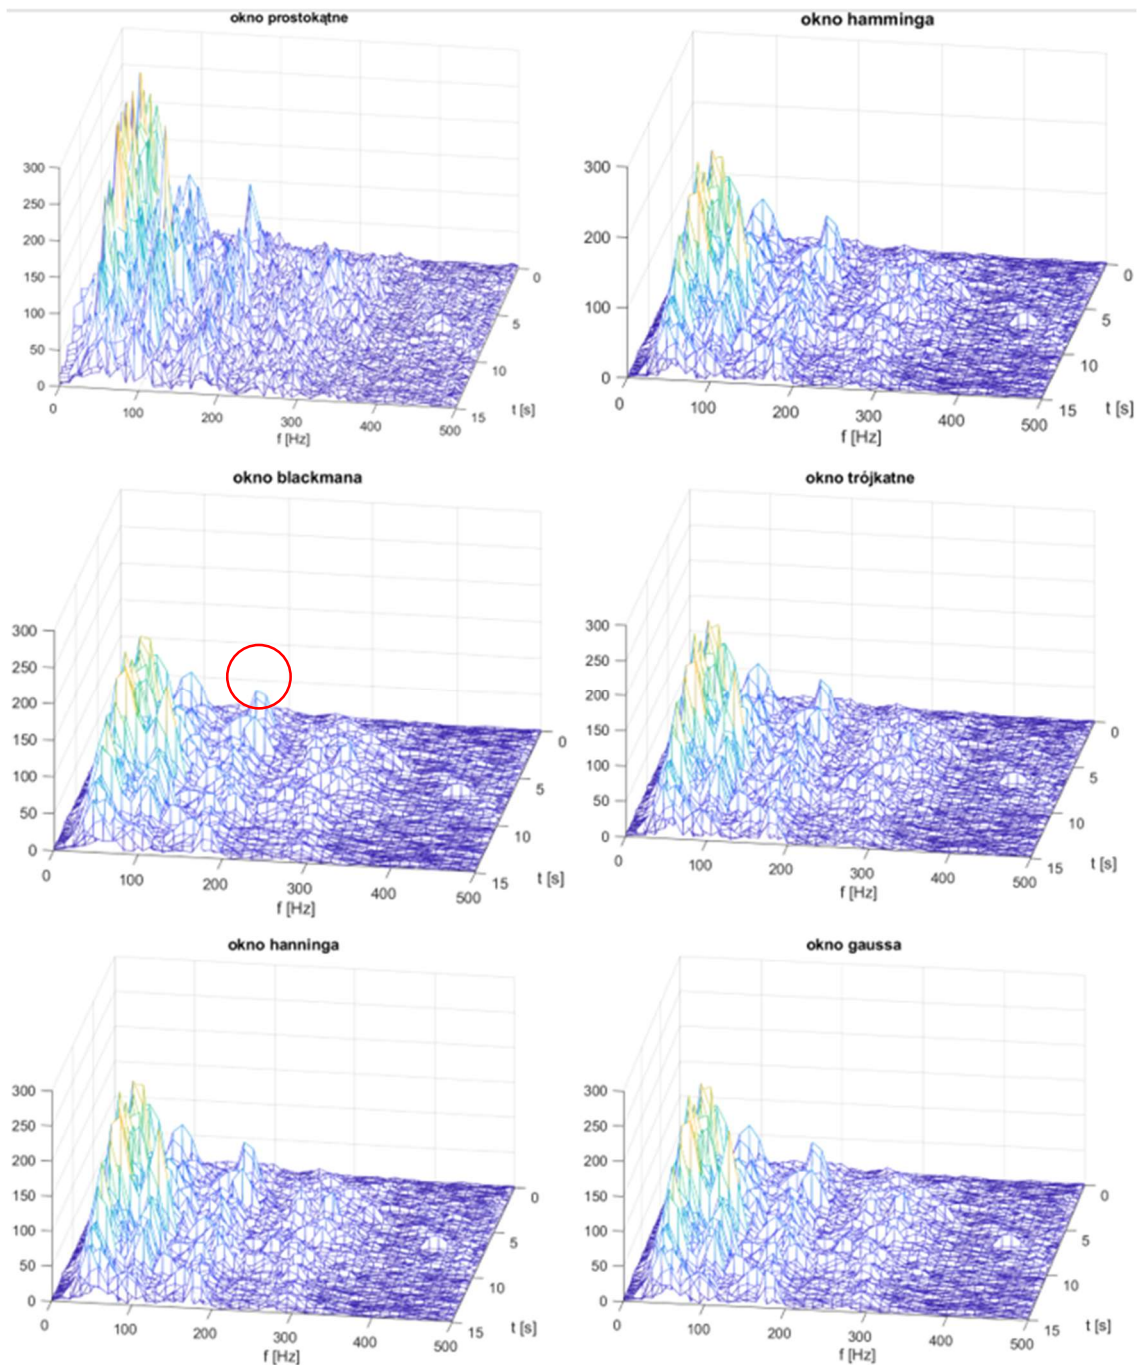
Funkcja okna wprowadzana jest w celu zminimalizowania przecieku energii w widmie częstotliwościowym. Długość funkcji okna jest niezerowa w dziedzinie czasu i powinna być parzysta. Istnieje wiele funkcji okna, najbardziej typowymi i często implementowanymi w programach komputerowych są okna: prostokątne, Hamminga, Hanninga, Blackmana, trójkątne. Najprostszym z okien jest okno prostokątne, które nie wpływa aktywnie na kształt zarejestrowanego sygnału, posiada najwyższy listek główny i dużą liczbę listków bocznych. Pozostałe okna swoim kształtem są podobne do siebie, ale różnią się szczegółami, powodującymi istotne różnice w ich transformatach Fouriera. Każda z funkcji okna wpływa aktywnie na kształt zarejestrowanego sygnału, zmieniając jego wartości. Najbardziej uniwersalnym oknem jest okno Hamminga, zapewniające akceptowalne tłumienie listków bocznych (ponad 40dB) przy stosunkowo niewielkim rozszerzeniu pasma. Stąd okno to jest najczęściej używane w praktyce [22]. Przykład wpływu okienkowania na sygnał przedstawia Rys. 28. Wszystkie rodzaje okien funkcyjnych ze względu na swój kształt tłumią sygnał do zera na początku i końcu czasu pomiarowego, kształt sygnału został zmieniony (wypłaszczony) w całym zakresie

pomiarowym. Dla każdego okna kształt sygnału jest nieznacznie zmieniony [22, 25, 29].



Rysunek 28 Wpływ okienkowania na kształt sygnału [25]

Na rys. 22 przedstawiono wykresy kaskadowe analizy STFT dźwięku przy użyciu różnych funkcji okna. Wykorzystano następujące funkcje okna: prostokątne, Hamminga, Blackmana, trójkątne, Hanninga i Gaussa. Wszystkie okna oprócz prostokątnego dały wynik podobny z niewielką różnicą wielkości amplitudy. Okno prostokątne z wąskim listkiem głównym ma lepszą rozdzielczość częstotliwościową jednak słabe tłumienie listków bocznych zwiększa przecieki częstotliwościowe tła. W pozostałych oknach, listek główny jest szerszy, z prawie 1,5 krotnym poszerzeniem pasma częstotliwościowego transformacji co pogarsza rozdzielczość uzyskanego widma sygnału przy częstotliwościach bliskich sobie. Jednakże mocne tłumienie listków bocznych nie pozwala na przeciek tła.



Rysunek 29 Przykład zastosowania różnych funkcji okna

W przypadku analizy z zastosowaniem okna prostokątne, wykres posiada ostrzejsze słupki amplitud dla poszczególnych częstotliwości realizowanych w czasie. W przypadku zastosowania innych okien nie zaobserwowano większego wpływu na uzyskane wyniki analizy STFT. W zastosowanym oknie Blackmana niewielkie różnice widać w zakresie częstotliwości ok. 190 gdzie wykres jest bardziej wygładzony w stosunku do innych, obszar zaznaczony jest na wykresie kolorem czerwony. Dla

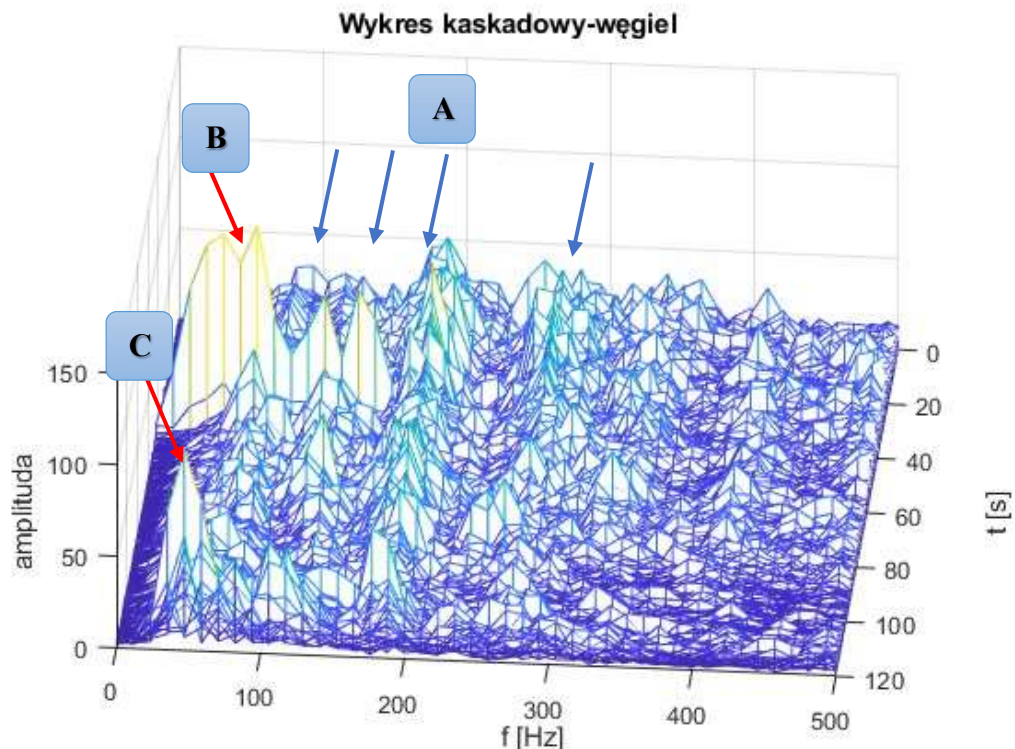
zastosowanych innych okien wykresy są bardziej wygładzone, wartości amplitud są niższe w porównaniu do okna prostokątnego. W każdym z uzyskanych wykresów można zaobserwować charakterystyczne większe od tła wartości amplitud w danych zakresach częstotliwości. Dlatego można wysunąć wniosek, że zastosowanie okna prostokątnego daje najbardziej ostry wykres w zakresie częstotliwość-amplituda, jednakże trudno dostrzec charakterystyczne zakresy częstotliwości w porównaniu z pozostałymi funkcjami okna. Z opisu okien w literaturze wynika, że okno Hamminga jest najbardziej uniwersalnym oknem [22] dlatego wybrano je do dalszej części analizy STFT.

8.5 Analiza próbek-STFT

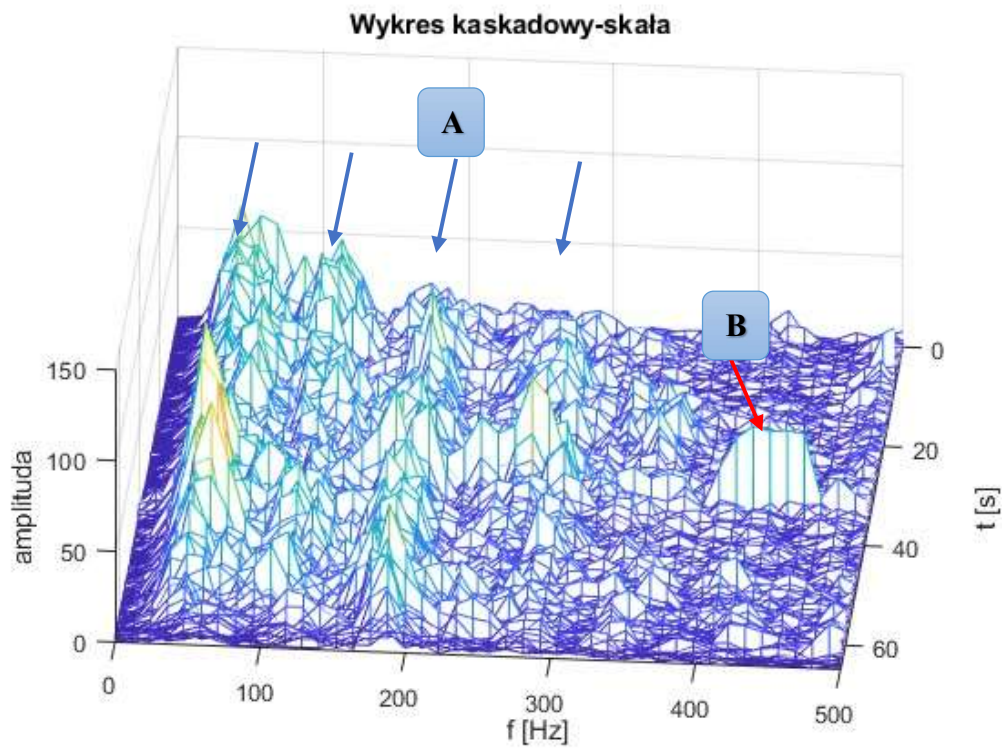
Analizę STFT przeprowadzono w programie Matlab-MathWorks. Próbkę zarejestrowano z częstotliwością próbkowania 44,1kHz. Wyniki analizy przedstawiono w formie wykresów kaskadowych, spektrogramów.

Do analizy nagrań węgla i skały dobrano następujące parametry:

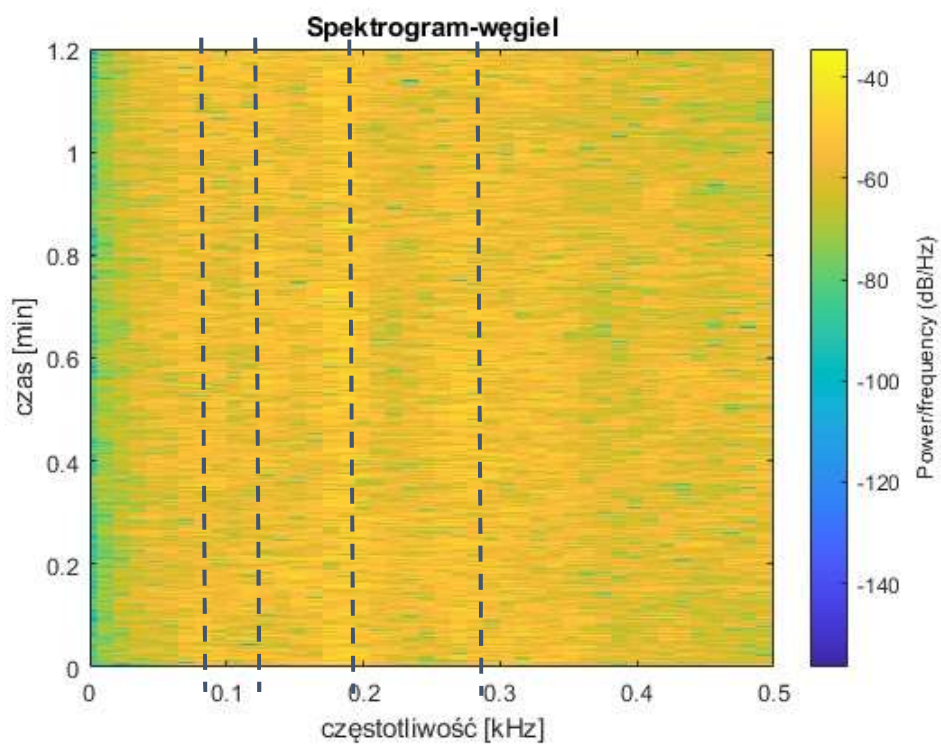
- wielkość okna 4096,
- funkcja okna Hamminga,
- wielkość przesunięcia okna 25%.



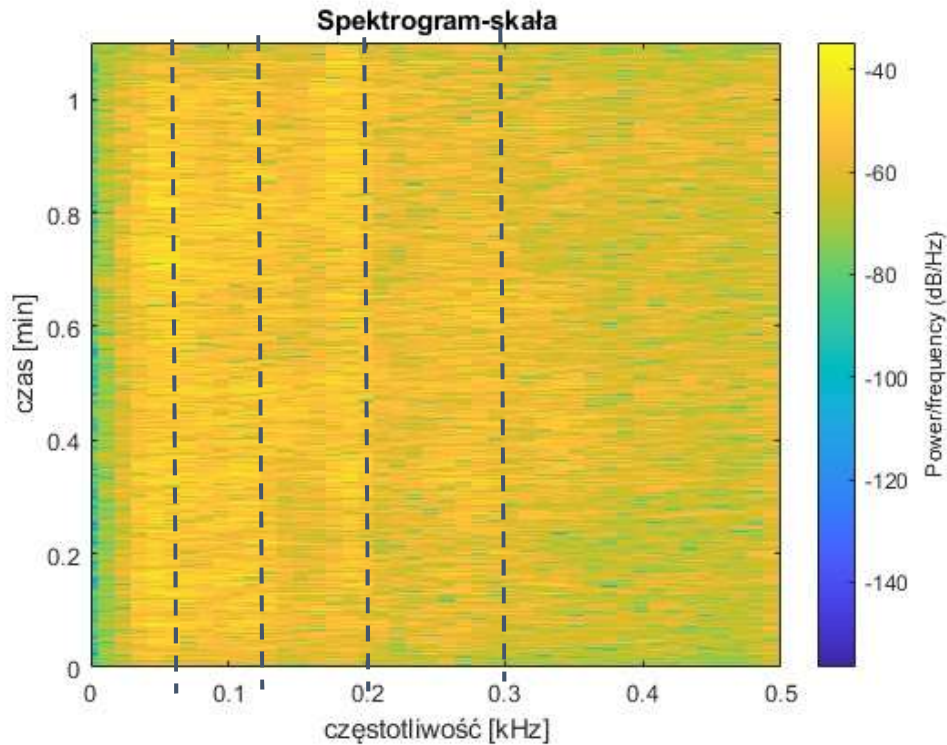
Rysunek 30 Wykres kaskadowy-węgiel.



Rysunek 31 Wykres kaskadowy-skala.



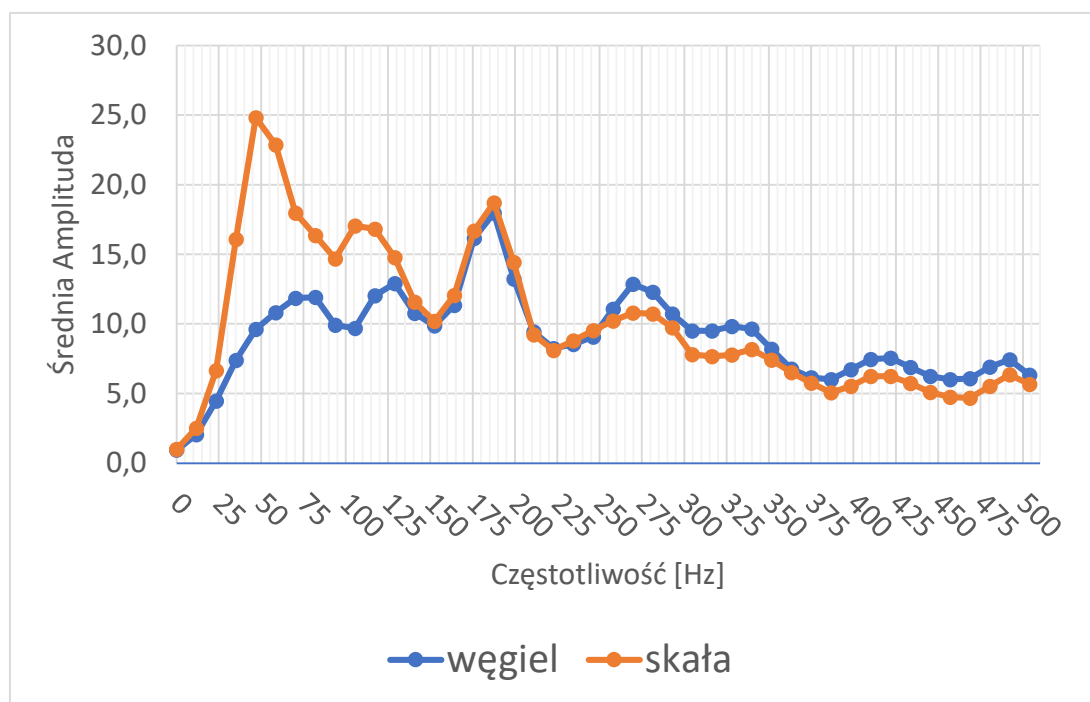
Rysunek 32 Spektrogram-węgiel.



Rysunek 33 Spektrogram-skała.

Wykreślone wykresy kaskadowe przedstawiają reprezentację czasowo-częstotliwościową dźwięku urabiania węgla i skały przez kombajn (rys 30, rys.31). Oś X przedstawia częstotliwość f [Hz], oś Y amplitudę sygnału, oś Z czas nagrania [s]. Zakres danych na wykresach kaskadowych jak i spektrogramach ograniczono do 500Hz, miało to na celu uwypuklenie charakterystycznych zmian amplitudy. Powyżej zakresu 500Hz wartości amplitudy, wraz ze wzrostem częstotliwości, dążą do zera. Na wykresie próbki węgla (Rys.30) zaobserwować można powtarzające się przedziały częstotliwości o wyższej amplitudzie zaznaczone strzałkami (A). W 44s (B) nagrania oraz 119s (C) w części wykresu próbki węgla występuje podwyższona amplituda sygnału w stosunku do pozostałych wartości. W sekundzie 44 amplituda jest podwyższona w zakresie częstotliwości 0-165Hz i wynosi maksymalnie 119Hz. W 119s nagrania w zakresie częstotliwości 20-140Hz maksymalna amplituda wynosi 108. Podobnie wykresie próbki skały (Rys. 31), zaobserwować można charakterystyczne przedziały o podwyższonej amplitudzie (A) oraz anomalię gdzie w 38s (B) w zakresie częstotliwości 140-500Hz wartość amplitudy jest wyższa od pozostałych i dochodzi maksymalnie do wartości 80,5. Powyższe anomalie mogły powstać poprzez uderzenie, lub ruch stojaka mikrofonu i zapisane przez rejestrator audio. Spektrogramy na Rys.32,

Rys.33 przedstawiają próbki dźwięku po analizie STFT na płaszczyźnie czas-częstotliwość. Oś Y określa czas [min] na oś X częstotliwość [kHz], legenda po prawej stronie spektrogramu pokazuje, że barwa koloru zmienia z zielonego się do jasnożółtego wraz z wielkością gęstości widmowej mocy. Liniami przerywanymi o kolorze czarnym zaznaczono przebieg charakterystycznych częstotliwości. Poniżej przedstawiono wykres średnich amplitud dla poszczególnych częstotliwości w czasie trwania nagrań (Rys.34).



Rysunek 34 Wykres średnich amplitud w czasie całego nagrania próbek dźwięku

Najbardziej różniącym się przedziałem częstotliwościowym dla próbek węgla i skały jest przedział 0-150Hz. W częstotliwości ok 188Hz wykres dla węgla i skały osiąga prawie taką samą wartość amplitudy. W dalszej części wykresu 150-500Hz wartości amplitudy różnią się o wartość 0,2-1,9. Amplituda dla skały osiąga najwyższą średnią wartość w okolicach 47Hz. Z wykresu można wnioskować, że charakterystycznym zakresem amplitud dla skały jest zakres w okolicy 35-70Hz, ponieważ w tym zakresie odnotowano najwyższe wartości. Dla węgla charakterystyczny zakres amplitudy 170-200Hz, ponieważ w tym zakresie występują najwyższe wartości amplitudy. W zakresie 150-220Hz wykres dla obydwóch nagrań różni się nieznacznie wartością amplitudy, związane jest to z tym, że podczas

nagrywania próbki dla urabiania mułowca organ kombajnu skrawał także część czoła ściany, gdzie znajdował się pokład węgla.

8.6 Przygotowanie bazy danych do programu WEKA

Wartości amplitudy dla poszczególnych częstotliwości wyeksportowano z programu Matlab-MathWorks do programu MS Excel. W arkuszu MS Excel opracowano tabelę zawierającą dane wejściowe niezbędne do dalszej analizy w programie WEKA. Kolumny jako atrybuty przedstawiają częstotliwości. Końcowa kolumna oznacza klasę, dla węgla klasa wynosi 1 dla skały 0. Określenie klasy przypisuje dane wejściowe do danego zbioru wykorzystywanego w klasyfikacji. W wierszach nazwane są kolejno identyfikatory próbek węgiel lub skała wraz z numerem porządkowym próbki. Fragment bazy danych opracowanych w tabeli przedstawiono poniżej (Tab.6).

Tabela 6 Dane wejściowe do programu WEKA.

Nazwa \ f [Hz]	0	12	23	35	47	59	...	Klasa
W1	1	1	3	1	3	3	...	1
W2	0	2	3	6	4	8	...	1
W3	1	2	3	4	5	1	...	1
W4	1	2	2	1	2	4	...	1
W5	0	0	0	1	2	5	...	1
W6	0	2	3	2	3	7	...	1
W7	1	1	3	4	4	8	...	1
W8	1	1	3	5	3	7	...	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮		⋮

Opracowaną bazę danych w programie MS Excel zapisano w postaci pliku csv. (Załącznik 1). Plik ten następnie przekonwertowano do pliku typu ARFF (ang. Attribute-Relation File Format) opisującą tzw. listę instancji współużytkujących zestaw atrybutów i stosowaną na potrzeby przetwarzania technikami uczenia maszynowego w programie WEKA. Program WEKA obsługuje także plików z rozszerzeniem .csv, jednakże baza danych odczytana z pliku .arff umożliwia szybsze przetwarzanie danych oraz ułatwia zarządzanie dostępnymi etykietami danych. Struktura danych wejściowych w formacie *.arff wyglądają następująco:

@RELATION WS-nazwa pliku wsadowego
@attribute attribute_name attribute_type - nazwa i typ atrybutu
@attribute attribute_name2 attribute_type

@attribute attribute_nameN attribute_type
@attribute attribute_class {class_name1, class_name2,...class_nameN}-nazwa klasy
@data
 Value1, Value2,..., ValueN, clas_name- wartość i nazwa klasy
 Value1, Value2,..., ValueN, clas_name

Fragment bazy danych [WS] opracowanej w powyższym formacie przedstawiono na Rys. 35.

```

@RELATION WS

@ATTRIBUTE name {S1,S10,S100,S1000,S1001,S1002,S1003,...}
.
.
.
@ATTRIBUTE 0 REAL
@ATTRIBUTE 12 REAL
@ATTRIBUTE 23 REAL
.
.
.

@ATTRIBUTE class {0,1}

@DATA
W1,1,1,3,1,3,3,...
W2,0,2,3,6,4,8,...
.
.
.
  
```

Rysunek 35. Fragment struktury danych wykorzystanych do analizy w programie WEKA

Plik z kompletną bazą danych zamieszczono w pliku WS–norm.arff Załącznik 2.

W pracy zastosowano normalizację danych względem wartości minimalnej. W programie WEKA w procesie przygotowania danych wybrano z listy filtrów nienadzorowanych filtr normalizujący zbiór danych. Każdy możliwy do wyboru filtr można dostosować do żądanych do badań ustawień. Uzyskane wartości amplitud dla poszczególnych częstotliwości z transformaty STFT są większe od zera, z tego względu

by zwiększyć dokładność klasyfikacji zastosowano do badań filtr normalizacyjny o zakresie [0,1].

8.7 Klasyfikacja k-NN

Do klasyfikacji posłużyły dane uzyskane po zastosowaniu transformaty STFT w programie Matlab-MathWorks. Z nagrań węgla o długości 119s oraz skały o długości 65s. Uzyskano 1867 atrybutów dla węgla i 1029 atrybutów dla skały, co sumarycznie wyniosło 2896 atrybutów. Liczbę atrybutów dla poszczególnych próbek przedstawiono w tabeli 7.


Tabela 7 Liczba wykorzystanych atrybutów do analizy k-NN.

Próbki	liczba
Węgiel	1867
Skała	1029
Suma	2896

Wartość współczynnika k dobrano eksperymentalnie. Dobór współczynnika ze względu na eksperyment odbywający się na klasyfikacji opartej na dwóch klasach przeprowadzono ze skokiem nieparzystym [1;3;5;7;...]. Parzysta liczba k może dokonywać błędnej klasyfikacji wśród dwóch klas. Liczba k ponadto musi być na tyle duża, by redukować wrażliwość algorytmu na trudne przykłady i odpowiednio mała by nie wybierać sąsiadów mocno osadzonych w innej klasie. Kiedy k jest większe tym algorytm potrzebuje więcej czasu do klasyfikacji. Większa wartość k pozwala uwzględniać trudne lokalne rozkłady (szum, nakładanie się-overlapping). Odpowiedni dobór parametru ma wpływ na klasyfikację, która może być niska w przypadku np. gdy wśród 10 sąsiadów, dwóch będzie z wartością „tak” i ośmiu z wartością „nie”. Dobierając wartość $k=3$ w przypadku, gdzie dla analizowanej obserwacji trzema najbliższymi sąsiadami będą te dwa z wartością na „tak” (która w danym zbiorze jest mniej liczna) i jeden na „nie”, klasyfikator zaliczy przypadek jako „tak”, co fałszuje wynik klasyfikacji. [105, 106, 107].

Poniżej (Rys.36) przedstawiono wyniki dla poszczególnych wartości k dobieranych eksperymentalnie. Największą dokładność klasyfikacji uzyskano dla wartości $k=21$, która wyniosła 80,32%. Powyższą wartość wybrano do dalszej analizy, do której wykorzystano 10-krotną walidację krzyżową. Walidacja krzyżowa to technika

oceny modeli predykcyjnych. Zbiór danych dzielony jest najczęściej na 10 podzbiorów (ang. fold). Model jest trenowany i oceniany k razy za każdym razem przy użyciu innego zestawu walidacji, gdzie jedna część ze zbioru jest brana do testowania a pozostała do treningu [108].



Rysunek 36 Dobór eksperymentalny wartości k klasyfikacji k-NN

Klasyfikacje przeprowadzono przy założeniu $k=21$, oraz 10-krotnej walidacji krzyżowej dla poszczególnych wybranych odległości przedstawionych w Tab.8.

Tabela 8 Wyniki klasyfikacji k-NN dla $k=21$.

Odległość	CCI	Precyzja	Współczynnik Kappa
Czebyszewa	64,47	-	0
Euklidesowa	80,32	0,54	0,81
Manhattan	79,52	0,80	0,51
Minkowskiego	83,32	0,81	0,54

Z klasyfikacji wynika, że odległość Minkowskiego jest optymalną odległością, która poprawnie sklasyfikowała model z wynikiem CCI (ang. Correctly Classified Instances) 83,32%, precyzją na poziomie 0,81 i współczynnikiem Kappa 0,54 kształtującym się na poziomie średnim w porównaniu do klasyfikatora losowego. Niewiele gorszym wynikiem klasyfikacji cechują się odległość Euklidesowa z wynikiem 80,32% i Manhattan z wynikiem 79,52%. Najniższym wynikiem

klasyfikacji okazała się odległość Czebyszewa, której wynik CCI wyniósł 64,47% jest to wynik na poziomie poprawnie sklasyfikowanych instancji klasyfikatora ZeroR (ang. zero rules), który nie zakłada żadnych założeń klasyfikacyjnych i pokazuje jak wygląda stopień klasyfikacji, jeśli nie narzucone zostaną modelowi żadne reguły. Spowodowane może być to tym, że odległość Czebyszewa oblicza maksymalną różnicę między dwoma obiektami i z tego powodu klasyfikator oparty na tej odległości nie jest w stanie poprawie rozpoznać atrybutów.

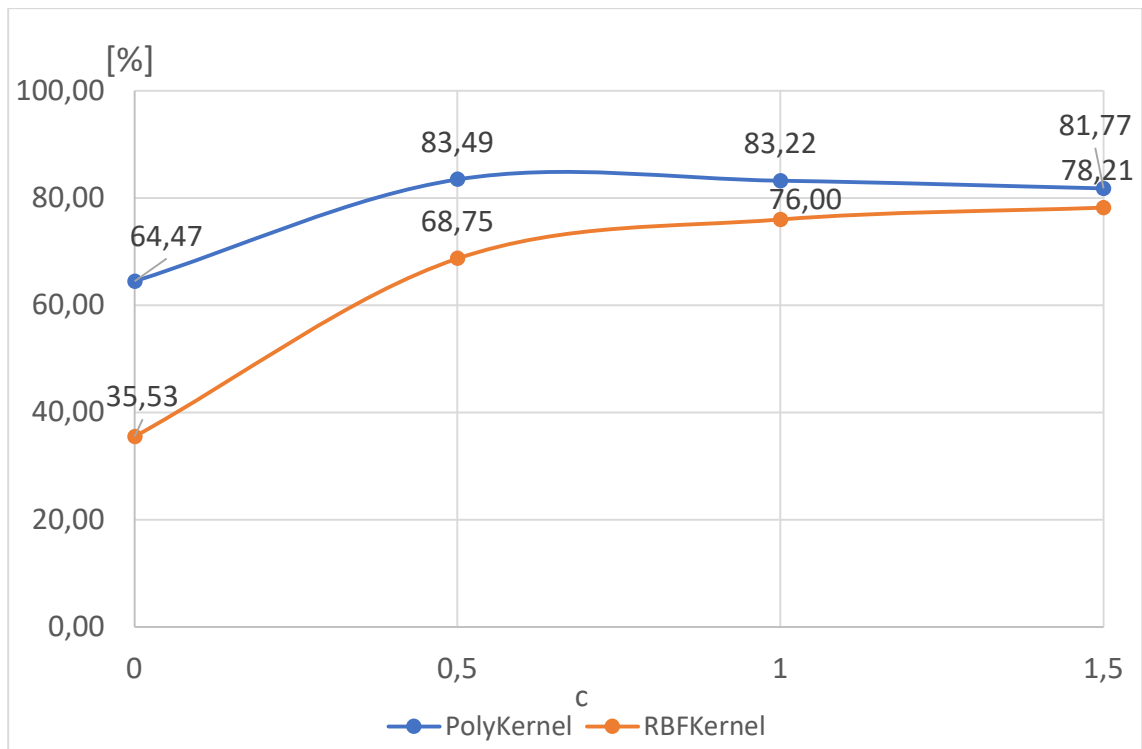
8.8 Klasyfikator SVM

Maszyny wektorów nośnych (SVM) zostały opracowane dla problemów z klasyfikacją binarną, istnieją także rozszerzenia tej techniki wykorzystywane w klasyfikacji wieloklasowej i regresji. Algorytm opracowany został dla numerycznych zmiennych wejściowych. Dane wejściowe są normalizowane przed klasyfikacją. SVM działa poprzez znalezienie linii, która najlepiej rozdziela dwie grupy danych. Jednakże niewiele zestawów danych da się podzielić za pomocą linii. W przypadku, kiedy trzeba wytyczyć linię z krzywymi lub regionami wielokątnymi stosuje się funkcję jądra. Funkcje jądra rzutują dane na przestrzeń o wyższych wymiarach w celu narysowania linii zwanej hiperpłaszczyzną. W programie WEKA zaimplementowane są wybrane funkcje jądra. Do eksperymentu wybrano popularne funkcje wielomianową jądra Kernel (PolyKernel) oraz Radial Basis Function Kernel (RBFKernel), które są w stanie „uczyć się” zamkniętych wielokątów i złożonych kształtów w celu oddzielenia klas. Oprócz doboru funkcji jądra w eksperymencie przeprowadzonym w programie WEKA przeanalizowano wpływ tzw. parametru złożoności (C) na skuteczność klasyfikacji. Parametr ten kontroluje, jak elastyczny może być proces rysowania linii rozdzielającej klasy. Wartość 0 nie dopuszcza żadnych naruszeń marginesu, podczas gdy wartość domyślna to 1 [109, 110]. W eksperymencie do każdej z dwóch wybranych funkcji jądra dobrano parametr C o wartościach? kolejno 0, 0.5, 1.0. Do każdej klasyfikacji wykorzystano 10-krotną walidację krzyżową. W Tab.9 przedstawiono wyniki klasyfikacji dla poszczególnych funkcji jądra oraz parametru C.

Tabela 9 Wyniki klasyfikacji dla poszczególnych funkcji jądra oraz parametru C.

C=0			
	CCI [%]	Precyzja	Współczynnik Kappa
PolyKernel	64,47	-	0
RBFKernel	35,53	-	0
C=0,5			
	CCI [%]	Precyzja	Współczynnik Kappa
PolyKernel	83,49	0,83	0,63
RBFKernel	68,75	0,76	0,16
C=1,0			
	CCI [%]	Precyzja	Współczynnik Kappa
PolyKernel	83,22	0,83	0,62
RBFKernel	76,00	0,79	0,40
C=1,5			
	CCI [%]	Precyzja	Współczynnik Kappa
PolyKernel	81,77	0,82	0,58
RBFKernel	78,21	0,80	0,47

Kolorem zielonym zaznaczono wynik najlepszego wyniku klasyfikacji wynoszącego 83,49% dla współczynnika C=0,50 i funkcji jądra Polykernel.



Rysunek 37 Poprawnie sklasyfikowane przypadki klasyfikacji SVM

Na rys.37 przedstawiono poprawnie sklasyfikowane przypadki klasyfikacji SVM. Jądro wielomianowe Kernel odznacza się lepszą skutecznością klasyfikacji od jądra RBF Kernel, Najlepszym wynikiem dla tego jądra jest 83,49% przy zadanym współczynniku $c=0,5$. Precyzja w tym przypadku jest wysoka i wynosi 0,83 a współczynnik Kappa wynosi 0,63 i określa współczynnik zgodności jako zasadniczy. Dla współczynnika $c=0$, czyli niedającego marginesu, wyniki klasyfikacji są najgorsze i klasyfikują przypadki tylko do jednej z klas, albo do klasy węgla w przypadku jądra wielomianowego albo do klasy skały w przypadku jądra RBF.

8.9 Klasyfikacja Random Forest

W metodzie klasyfikacji Random Forest budowane drzewa decyzyjne są stosunkowo proste (każdy węzeł reprezentuje decyzję, a każda gałąź reprezentuje możliwy rezultat tej decyzji), rezultat modelu wyznaczany jest poprzez głosowanie i uśrednianie [111]. Algorytm w programie WEKA dostosowywany jest do optymalnych parametrów za pomocą:

- Włączona metoda Bootstrap-zestaw danych dzielony na typ in-bag i out-bag,

- Liczba drzew decyzyjnych do budowy modelu,
- Liczbę cech (atrybutów), używanych przy wyborze losowym,
- Głębokość drzew- wartość maksymalna.

Parametry dobrane do eksperymentu (liczba drzew oraz cech) wraz z wynikami przedstawiono w Tab.4. Głębokość drzew ustawiono na maksymalną wartość proponowaną przez program. Dobór liczby drzew oraz cech ograniczono do 52 drzew oraz 16 cech, ponieważ nie zaobserwowano wzrostu poprawności wraz ze wzrostem dobieranych parametrów. Najlepszą poprawność uzyskano dla 4 cech i 44 drzew, która wyniosła 82,80%. Wraz ze wzrostem liczby drzew uzyskiwano lepszą poprawność klasyfikacji, wzrost liczby cech nie powodował wzrostu poprawności w analizowanym przypadku.

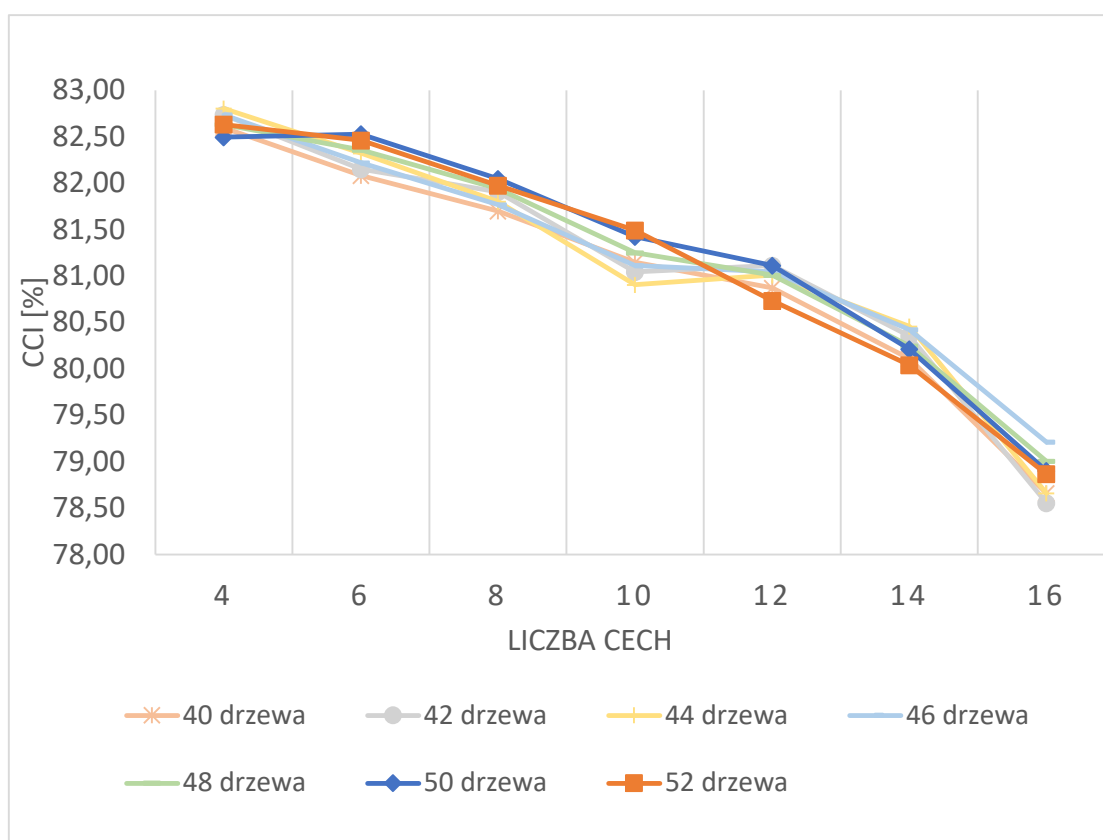
Tabela 10 Wyniki poprawności metody Random Forest w zależności od liczby drzew i liczby cech.

Drzewa\Cechy	4	6	8	10	12	14	16
4 drzewa	78,97	79,18	79,07	79,14	78,76	77,69	78,69
6 drzewa	79,97	79,73	81,04	79,45	79,07	78,38	76,86
8 drzewa	80,49	80,87	81,28	80,42	81,04	79,39	78,18
10 drzewa	80,63	80,87	81,11	80,46	80,11	79,42	78,07
12 drzewa	81,35	81,08	81,08	80,54	80,39	79,45	77,24
14 drzewa	81,04	81,32	80,90	81,08	80,32	79,39	78,04
16 drzewa	81,42	81,53	81,08	80,87	80,77	79,18	78,00
18 drzewa	81,73	81,32	81,25	80,94	80,70	80,11	78,38
20 drzewa	81,97	81,25	81,08	80,87	81,01	80,28	79,14
22 drzewa	81,91	81,49	81,42	81,15	80,97	80,59	79,45
24 drzewa	82,15	81,63	81,15	81,46	81,04	80,42	79,45
26 drzewa	82,22	81,53	81,42	81,56	81,18	80,46	79,25
28 drzewa	82,29	81,84	81,73	81,39	81,32	80,52	79,39
30 drzewa	82,42	81,98	81,77	81,46	81,39	80,80	79,56
32 drzewa	82,31	82,04	81,91	81,25	81,42	80,80	79,73
34 drzewa	82,63	82,18	81,56	81,46	81,04	80,56	79,39
36 drzewa	82,67	82,15	81,77	81,28	80,97	80,21	79,32
38 drzewa	82,73	82,29	81,84	81,28	81,15	80,49	78,90
40 drzewa	82,60	82,08	81,70	81,15	80,87	80,11	78,66
42 drzewa	82,73	82,15	81,91	81,04	81,11	80,35	78,56
44 drzewa	82,80	82,32	81,80	80,90	81,01	80,46	78,66
46 drzewa	82,73	82,22	81,77	81,11	81,04	80,42	79,21
48 drzewa	82,63	82,36	81,94	81,25	81,01	80,25	79,01
50 drzewa	82,49	82,53	82,04	81,42	81,11	80,21	78,90
52 drzewa	82,63	82,46	81,98	81,49	80,73	80,04	78,87

Tabela 11 Wyniki klasyfikacji Random Forest

	CCI [%]	Precyzja	Współczynnik Kappa
Random Forest	82,80	0,83	0,60

Procent poprawnie skasyfikowanych przypadków dla metody drzew losowych (Tab.11) wyniósł 82,80%, wartość precyzji jest wysoka i wynosi 0,83, współczynnik Kappa wyniósł 0,60, wartość ta oznacza, że klasyfikacja nie jest losowa.



Rysunek 38 Poprawność klasyfikacji w zależności od liczby drzew oraz liczby cech

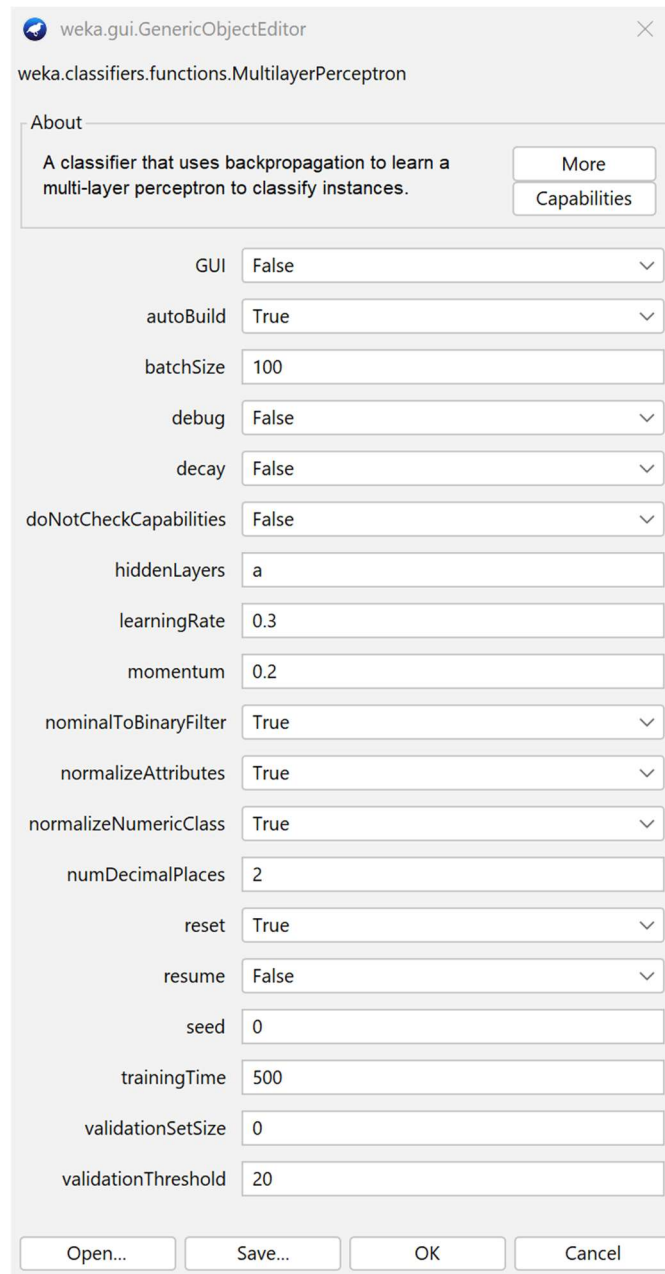
Na Rys. 30 przedstawiono wykres dla najwyższych wartości klasyfikacji. Najlepsze wyniki osiągnięto przy wartości cech 4 i liczby drzew powyżej 40. Wraz ze wzrostem liczby cech wykorzystywanych do klasyfikacji wartość pewności spadała do wartości ok. 78%.

8.10 Klasyfikacja MLP

Klasyfikacja MLP (ang. Multilayer Perceptron) jest jedną z najpopularniejszych typów sztucznych sieci neuronowych [89]. Budowa tego typu sieci składa się zwykle z kilku warstw o sigmoidalnych funkcjach aktywacji [90]. Pierwsza to warstwa wejściowa, występują w niej neurony, które nie wykonują obliczeń i wprowadzane są do niej dane treningowe. Warstwy ukryte najczęściej składają się z jednej lub kilku warstw pomiędzy warstwą wejściową a wyjściową, działanie tych warstw ukrytych nie może być bezpośrednio obserwowane. Warstwa wyjściowa stanowi wyjście całej sieci, odpowiada za reprezentację wyniku klasyfikacji. W programie WEKA przeprowadzono kilka eksperymentów wykorzystujących klasyfikację MLP. Można je podzielić na dwie części z brakiem normalizacji i z normalizacją atrybutów i klas. W każdej z części budowano kilka modeli zmieniając liczbę warstw ukrytych oraz liczbę neuronów, sprawdzając jaki model uzyska najlepszy wynik klasyfikacji. Interfejs programu WEKA posiada możliwość dostosowania ustawień sieci w menu edycji (Rys.39). Do najistotniejszych funkcji programu należą:

- *GUI*-wyświetla graficzny interfejs użytkownika. Umożliwia on wstrzymywanie i modyfikowanie sieci neuronowej podczas treningu. Pozwala na dodanie lub usuwanie węzłów, oraz nowych połączeń między węzłami,
- *hideLayers*- określa liczbę ukrytych warstw sieci neuronowej i liczbę neuronów w każdej warstwie. Wartość „a” w komórce oznacza funkcję automatycznego doboru przez program optymalnej liczby warstw, wartość „0” -brak ukrytych warstw, wartość dodatnich liczb całkowitych oddzielonych przecinkami określa liczbę warstw oraz liczbę neuronów w warstwie np. „15,10,5”,
- *learningRate*- stopień, w jakim wagi są aktualizowane,
- *momentum*- współczynnik rozpędu, to wartość stosowana do wag podczas aktualizacji,
- *nominalToBinaryFilter*- reprezentuje filtr, który będzie wstępnie przetwarzał instancje,
- *normalizeNumericClass*- normalizacja klasy, jeśli jest ona numeryczna, normalizacja może poprawić wydajność sieci,
- *normalizeAttributes*- normalizacja atrybutów,

- *validationSetSize*- procentowy rozmiar zestawu walidacyjnego. Nauka sieci będzie kontynuowana, dopóki błąd w zestawie walidacyjnym nie będzie się powiększał lub jeśli czas treningu został osiągnięty,
- *trainingTime*- liczba epok do przeszkolenia, jeśli zestaw walidacyjny nie jest równy „0”, może zakończyć proces uczenia sieci.



Rysunek 39 Okno dostosowywania parametrów sieci MLP w programie WEKA

W eksperymencie dostosowano następujące parametry klasyfikacji MLP:

- *hideLayers*- w przeprowadzonym eksperymencie sprawdzono wpływ liczby warstw ukrytych oraz liczby neuronów w danej warstwie, na dokładność klasyfikacji,
- *normalizeNumericClass*- przeprowadzono osobne eksperymenty z zastosowaniem normalizacji klas i bez jej zastosowania,
- *normalizeAttributes*- zastosowano lub nie zastosowano normalizacji atrybutów,
- *cross-validation*- 10-krotna walidacja krzyżowa,
- *learningRate*- 0,3-wartość dobrana automatycznie przez program,
- *momentum*- 0,2-wartość dobrana automatycznie przez program.

Klasyfikacje MLP przeprowadzono dla kilku wartości warstw z różną wartością neuronów w każdej warstwie. Przykładowo dla wartości z tabeli 150,100,50-klasyfikacja odbywała się dla trzech warstw ukrytych, z których pierwsza warstwa posiadała 150 neuronów, druga 100, trzecia 50. Klasyfikacja odbywała się z normalizacją atrybutów i klas oraz bez normalizacji. Wyniki klasyfikacji przedstawiono w Tab.12.

Tabela 12 Wyniki klasyfikacji MLP z normalizacją.


	normalizacją		
Warstwy	1	10	50
CCI [%]	64,47	58,67	58,67
ICI [%]	35,53	41,33	41,33
Precyzja	-	0,54	0,54
Wsp. Kappa	0,00	0,00	0,00
Czas budowy modelu [s]	103	875	68114

W przypadku przeprowadzenia normalizacji największa dokładność poprawnie sklasyfikowanych przypadków wyniosła 64,47%, współczynnik kappa wyniósł 0, która to wartość pozwala stwierdzić, że wynik klasyfikacji jest zgodny z klasyfikatorem losowym. Czas potrzebny do zbudowania modelu wyniósł 103s. Dalsze badania ze zwiększaniem liczby neuronów w warstwie na 5 i 50 nie powodowały wzrostu dokładności, z tego powodu nie przeprowadzono dalszych analiz z wykorzystaniem normalizacji.

Tabela 13 Wyniki klasyfikacji MLP bez normalizacji.

bez normalizacji							
Warstwy	1	10	50	10,5	15,10,5	150,100,50	250,150,50
CCI [%]	70,17	65,33	74,79	66,51	70,17	79,24	79,32
ICI [%]	29,83	34,67	25,21	33,49	29,83	20,75	20,68
Precyzja	0,72	0,63	0,74	0,67	0,72	0,79	0,80
Wsp. Kappa	0,23	0,16	0,40	0,10	0,23	0,55	0,56
Czas budowy modelu [s]	1086	906	5047	559	1959	12104	19747

Dalsze badania przeprowadzono bez normalizacji, najwyższy wynik dokładności poprawnie sklasyfikowanych przypadków wyniósł 79,32% (w tabeli oznaczony na zielono) dla trzech warstw ukrytych, z których pierwsza warstwa posiadała 250 neuronów, druga 150, trzecia 50. Współczynnik kappa wyniósł 0,56, wartość ta zawiera się w przedziale średniej zgodności 0,41-0,60. Czas potrzebny do zbudowania modelu sieci neuronowej wyniósł 19 747s. Wyniki dla poszczególnych doświadczeń przedstawiono na wykresie Rys.40.



Rysunek 40. Wyniki poprawnej klasyfikacji MPL.

Podczas przeprowadzania doświadczenia zwrócono szczególną uwagę na czas potrzebny do zbudowania modelu sieci. Jest to ważny element przy budowie systemu rozpoznającego dźwięk urabianej skały oraz sterującego automatycznie pracą kombajnu ścianowego. W tym przypadku najbardziej pożądana a wręcz niezbędna jest szybkość

rozpoznania, a co za tym idzie szybkość reakcji systemu na zmianę położenia głowicy tnącej. W takich warunkach obliczenia tą metodą przy użyciu mocy obliczeniowej obecnie dostępnego sprzętu są zbyt długotrwałe do wykorzystania w automatyzacji procesu urabiania. Ponieważ najmniej złożona sieć składająca się z jednej warstwy i jednego neuronu potrzebuje dla metody z normalizacją 103s do zbudowania modelu a analogiczny model bez normalizacji aż 906s. W przypadku wykorzystania innych metod klasyfikacji zbudowanie modelu wraz z 10-krotną walidacją pozwala na uzyskanie wyniku w kilka sekund.

9 Analiza statystyczna Chi-kwadrat

Jednym z najczęściej stosowanych nieparametrycznych testów niezależności jest test Chi-kwadrat Pearsona (χ^2 Pearsona). Test niezależności χ^2 Pearsona stosuje się w celu zbadania związku między dwoma zmiennymi nominalnymi. Test ten, tak jak inne testy nieparametryczne nie jest uzależniony od rozkładu badanej zbiorowości i może być stosowany zarówno, gdy dane posiadają rozkład normalny, jak i we wszystkich innych przypadkach. Bazuje on na porównaniu wartości obserwowanych (otrzymanych po badaniu) a wartościami teoretycznymi obliczonymi przy założeniu, że pomiędzy zmiennymi nie ma żadnego związku. Statystyka χ^2 Pearsona związana jest z pewnymi ograniczeniami założeń stosowalności testu takimi jak: minimalna liczebność próby i niezależność grup. Zdania statystyków co do liczebności próby są podzielone. W literaturze [112] można spotkać się ze stwierdzeniem, że im próba większa, tym mniejszy jest błąd w uogólnianiu wyników na populację. Za taką próbę uznaje się, próbę składająca się z co najmniej 30 jednostek analizy, w innych publikacjach [113, 112] taka próba powinna być większa od 50 choć ci sami autorzy przyznają, że trudno powiedzieć, kiedy liczebność jest duża i traktują wskazaną liczbę jako orientacyjną [112, 113]. Liczba jednostek analizy, znajdująca się w tabeli krzyżowej, nie powinna być mniejsza od 5, jednakże inni badacze [114] uważają, że dla tablic dwudzielnych większych niż 2x2 test χ^2 Pearsona można wykorzystać, jeśli liczebności oczekiwane nie są mniejsze od 1 oraz kiedy wartości mniejszych od 5 nie jest więcej niż 20%. Cochran [114] natomiast uważa, że wystarczy tylko jedna wartość większa od 5 by można zastosować statystykę χ^2 [114]. Niezależność grupy polega na tym, że jeden element nie może znaleźć się w więcej niż jednej podgrupie. Problem ten pojawia się tam, gdzie zadawane pytanie daje możliwość wielokrotnej odpowiedzi,

wtedy jeden respondent może znaleźć się w wielu grupach – wtedy nie spełnia się warunku niezależności [115, 116]. Rozkład χ^2 Pearsona jest rozkładem ciągłym, test χ^2 Pearsona jest testem, gdzie występują z frekwencją, dlatego dla tablic dwuwartościowych 2x2, jeśli którakolwiek z liczebności oczekiwanych jest mniejsza od 5 należy zastosować poprawkę ciągłości Yatesa [117].

Do obliczeń statystyki χ^2 przyjęto średnie amplitud otrzymanych dla nagrań węgla i skały dla poszczególnych częstotliwości. Procedurę obliczeniową statystyki χ^2 przedstawiono poniżej.

Stosując test χ^2 postawiono dwie hipotezy: zerową i alternatywną:

H_0 -nie istnieje istotny statystycznie związek pomiędzy badanymi zmiennymi. Test nie jest statystycznie istotny.

H_1 -istnieje statystycznie istotny związek pomiędzy zmiennymi. Test jest statystycznie istotny.

Liczebności obserwowane są to średnie amplitud dla poszczególnych próbkowanych częstotliwości pochodzących z wcześniej zastosowanej STFT.

Liczebności oczekiwane (teoretyczne) obliczone są przy założeniu, że zmienne są niezależne. Do obliczeń liczebności teoretycznych (E_{ij}) wykorzystuje się wzór:

$$E_{ij} = \frac{f(i.) * f(j.)}{n} \quad (70)$$

gdzie: n -liczebność próby, $f(i)$ - suma liczebności brzegowej dla wiersza i , $f(j)$ - suma liczebności brzegowej dla kolumny j .

Wyliczenie wartości statystyki χ^2 przeprowadzono na podstawie wzoru:

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^k \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \quad (71)$$

gdzie: O_{ij} -liczebności obserwowane, E_{ij} -liczebności oczekiwane (teoretyczne), r - wiersze, k -kolumny, i -numer danego wiersza, j -numer danej kolumny.

Wyniki obliczeń przedstawiono w Tab.14. Wartość obliczonego testu chi-kwadrat należy porównać z tablicami rozkładu chi-kwadrat. W tym celu należy obliczyć liczbę stopni swobody oraz wskazać akceptowalny dla badań poziom ufności. Liczbę stopni swobody oznacza się skrótem ν i oblicza według wzoru:

$$v = (\text{liczba wartości pierwszej zmiennej} - 1) * (\text{liczba wartości drugiej zmiennej} - 1) \quad (72)$$

W analizowanym przypadku liczba wartości pierwszej zmiennej wynosi 2, ponieważ analizujemy dwie próbki węgla i skały, liczba wartości drugiej zmiennej wynosi 44, jest to ilość próbek częstotliwości biorących udział w analizie, podstawiając wartości do wzoru uzyskano liczbę stopni swobody równą:

$$v = (2-1)*(44-1)=43 \quad (73)$$

Do analizy przyjęto najczęściej stosowany poziom ufności $\alpha=0,05$.

Tabela 14 Wyniki obliczeń statystyki χ^2

		Węgiel	Skała		E oczekiwana		χ^2			
Nr	Hz	Z22-1	Z24-1	suma	Z22-1	Z24-1	Z22-1	Z24-1	suma χ^2	Stopień swobody
1	0	1	1	2	1	1	0,0	0,0	0,0	43,0
2	12	2	3	5	2	2	0,0	0,0	0,0	χ^2 -obliczone
3	23	4	7	11	5	6	0,1	0,1	0,2	20,7
4	35	7	16	23	11	12	1,2	1,1	2,3	Statystyka z tabeli
5	47	10	25	34	16	18	2,7	2,5	5,2	59,3
6	59	11	23	34	16	18	1,6	1,5	3,1	
7	70	12	18	30	14	16	0,4	0,3	0,7	
8	82	12	16	28	13	15	0,2	0,1	0,3	
9	94	10	15	25	12	13	0,3	0,2	0,5	
10	105	10	17	27	13	14	0,7	0,6	1,3	
11	117	12	17	29	14	15	0,2	0,2	0,4	
12	129	13	15	28	13	15	0,0	0,0	0,0	
13	141	11	12	22	11	12	0,0	0,0	0,0	
14	152	10	10	20	9	11	0,0	0,0	0,0	
15	164	11	12	23	11	12	0,0	0,0	0,0	
16	176	16	17	33	16	17	0,0	0,0	0,0	
17	188	18	19	37	17	19	0,0	0,0	0,0	
18	199	13	14	28	13	15	0,0	0,0	0,0	
19	211	9	9	19	9	10	0,0	0,0	0,1	
20	223	8	8	16	8	9	0,0	0,0	0,1	
21	234	9	9	17	8	9	0,0	0,0	0,0	
22	246	9	10	19	9	10	0,0	0,0	0,0	
23	258	11	10	21	10	11	0,1	0,1	0,2	
24	270	13	11	24	11	12	0,3	0,2	0,5	
25	281	12	11	23	11	12	0,2	0,2	0,3	
26	293	11	10	20	10	11	0,1	0,1	0,2	

27	305	9	8	17	8	9	0,2	0,2	0,4
28	316	10	8	17	8	9	0,2	0,2	0,5
29	328	10	8	18	8	9	0,3	0,2	0,5
30	340	10	8	18	8	9	0,2	0,2	0,3
31	352	8	7	16	7	8	0,1	0,1	0,2
32	363	7	7	13	6	7	0,0	0,0	0,1
33	375	6	6	12	6	6	0,0	0,0	0,1
34	387	6	5	11	5	6	0,1	0,1	0,2
35	398	7	6	12	6	6	0,1	0,1	0,3
36	410	7	6	14	6	7	0,1	0,1	0,3
37	422	8	6	14	7	7	0,2	0,1	0,3
38	434	7	6	13	6	7	0,1	0,1	0,3
39	445	6	5	11	5	6	0,1	0,1	0,3
40	457	6	5	11	5	6	0,2	0,2	0,3
41	469	6	5	11	5	6	0,2	0,2	0,4
42	480	7	6	12	6	7	0,2	0,2	0,3
43	492	7	6	14	7	7	0,1	0,1	0,2
44	504	6	6	12	6	6	0,1	0,1	0,1

Dysponując trzema wartościami: wynikiem testu χ^2 równym 20,7, stopniem swobody równym 43 oraz założonym poziomem ufności $\alpha=0,05$ odczytuje się wartość z tabeli wartości krytycznych χ^2 . Odczytując właściwą liczbę z tabeli wartości krytycznych na przecięciu się poziomu ufności (0,05) oraz liczby stopni swobody (43), wartość wynosi 59,3. Jeśli wartość testu χ^2 jest większa od wartości podanej w tabeli odrzuca się hipotezę zerową. W analizowanym przypadku wartość χ^2 wynosi 20,7, a wartość odczytana z tabeli 59,3, zatem odrzuca się hipotezę alternatywną. Wyniki testu χ^2 potwierdzają zasadność hipotezy zerowej, która mówi, że *nie istnieje statystycznie istotny związek między zmiennymi*. Potwierdza to wyniki wcześniej przeprowadzonych klasyfikacji, które z wysoką dokładnością rozróżniały badane próbki dźwięku.

10 Wnioski i przyszłe prace

Wdrażanie nowych technologii oraz postępująca cyfryzacja w przedsiębiorstwach produkcyjnych umożliwia coraz większą automatyzację produkcji. W przedsiębiorstwach produkcyjnych, takich jak kopalnie węgla kamiennego i nie tylko coraz częściej stosowane jest centralne oprogramowanie do zarządzania i sterowania procesów. Dzięki takim systemom możliwe jest kontrolowanie procesów produkcji oraz parametrów poszczególnych maszyn i urządzeń na bieżąco. W przypadku kopalń dostęp do takich informacji ma dyspozytor kopalni oraz poszczególne oddziały, takie jak dział elektromaszynowy czy telekomunikacji. Z systemu poza informacjami takimi jak stan wentylacji, stan działania pomp głównego odwadniania, praca poszczególnych przenośników taśmowych, uzyskuje się informacje ze ścian i przodków eksploatacyjnych. Informacjami dostarczonymi ze ściany są m.in. stan pracy i pozycja kombajnu, pozycja organów urabiających, obciążenie silników, praca przenośnika ścianowego, czy przesuw sekcji obudowy zmechanizowanej te dane mogą posłużyć do opracowania automatycznego systemu urabiania. Analiza STFT zebranych próbek dźwiękowych wykazała, że odpowiedzi górotworu na wymuszenie organem skrawającym kombajnu w przypadku węgla i skały różnią się znacząco tak w zakresie częstotliwości, jak i amplitudy. Dzięki dalszej analizie mogą one zostać wykorzystane jak podstawy do uczenia sieci neuronowych. Łatwość montażu oraz relatywnie niski koszt aparatury pomiarowej rejestrującej i analizującej dźwięk w porównaniu do innych metod, daje duże perspektywy praktycznego jej wykorzystania. Opracowanie automatycznego systemu urabiania w oparciu o proponowaną metodę może być jednym z rozwiązań, które mogą zrewolucjonizować funkcjonowanie zakładów górniczych w przyszłości. Automatyzacja procesu eksploatacji pozwoli obniżyć liczbę osób zatrudnionych w ścianie wydobywczej, obniżając koszty załogi, poprawi bezpieczeństwo ograniczając do minimum udział załogi w najbardziej niebezpiecznych strefach wydobywania co przełoży się na wzrost opłacalności produkcji.

Opracowane stanowisko pomiarowe składające się z mikrofonu kierunkowego oraz rejestratora audio pozwoliły w sposób bezpieczny na rejestrację dźwięku urabiania w trudnych warunkach środowiskowych. Przeprowadzone badania wykazały, istotne różnice pomiędzy sygnałami uzyskanymi z urabiania węgla i skały. Wykorzystanie

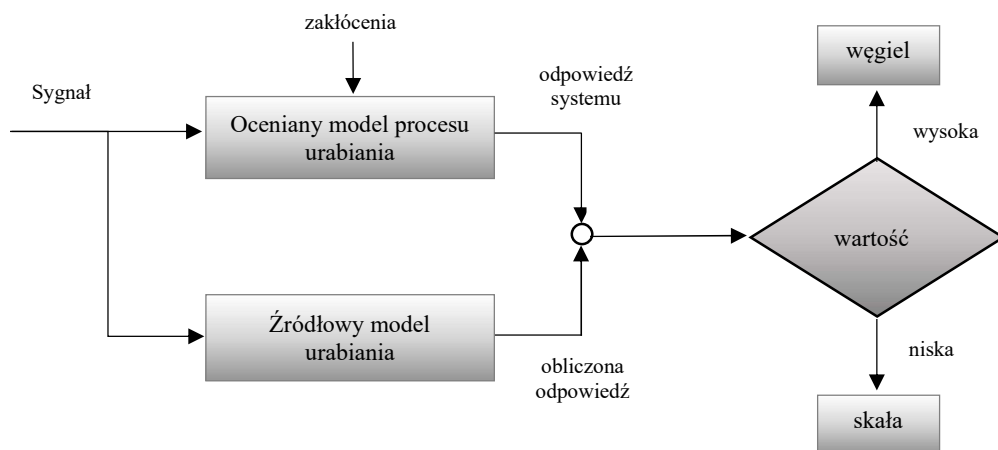
wybranych metod klasyfikacji umożliwiło sprawdzenie z jaką dokładnością system rozpoznawania dźwięku urabiania może klasyfikować dźwięk poszczególnej warstwy skalnej.

Analiza STFT próbek dźwięku węgla i skały wykazała, że podczas urabiania skał można zauważyć charakterystyczne zakresy częstotliwości, gdzie amplituda jest wyraźnie wyższa. Dla węgla jest to zakres 170-200Hz a dla skały 35-70Hz.

Najlepsze uzyskane wyniki klasyfikacji próbek węgla i skały dla poszczególnych metod wynoszą: k-NN=80,32%, SVM=83,19%, Random Forest=82,80%, MLP=79,32%, co pozwala stwierdzić, że z wysokim prawdopodobieństwem można rozróżnić dwa rodzaje skał podczas urabiania kombajnem ścianowym.

Wyniki testu χ^2 potwierdzają zasadność hipotezy zerowej, która mówi, że nie istnieje statystycznie istotny związek między zmiennymi. Potwierdza to wyniki wcześniej przeprowadzonych klasyfikacji, które z wysoką dokładnością rozróżniały badane próbki dźwięku.

W dalszych badaniach przewiduje się opracowanie modelu procesu urabiania, działającego według schematu przedstawionego na Rys.41, w którym sygnał dźwiękowy uzyskany w sąsiedztwie pracującej głowicy urabiającej będzie niośł informację o oporze urabianej skały, natomiast na wyjściu będzie sygnał niosący informację o reakcji silnika kombajnu na obciążenie.



Rysunek. 41 Model rozpoznawania węgla i skały.

Opracowany, koncepcyjny model systemu urabiania pokładu węgla po wytrenowaniu za pomocą narzędzi uczenia maszynowego będzie umożliwiał analizę porównawczą sygnałów uzyskanych z działającego układu z sygnałem wyjściowym, uzyskując reszty, które będą dalej poddawane klasyfikacji. Rejestracja znacznej różnicy między wydajnością zmierzoną a obliczoną potwierdzi lub zaprzeczy stwierdzeniu, że kombajn urabia skałę.

Dalsze prace mogą także koncentrować się na opracowaniu metod hybrydowych, w których wykorzystywane będą dwie lub więcej rodzajów czujników np. metoda wizyjna i dźwiękowa lub dźwiękowo-wibracyjna. Celem zastosowania takich metod hybrydowych jest dalsza poprawa dokładności rozpoznawania urabiania węgla lub skały.

11 Bibliografia

- [1] S. Grabowska i K. Sieka, „Inteligentne fabryki przemysłu 4.0,” *Management and Quality- Zarządzanie i Jakość*, tom 1, nr 1, pp. 52-60, 2019.
- [2] P. Strzałkowski, *Górnictwo ogólne*, Gliwice: Wydawnictwo Politechniki Śląskiej, 2015.
- [3] A. Kasprusz, S. Mikula i M. Wojtas, „Sterowanie elektrohydrauliczne DOH-matic do automatyzacji pracy obudowy zmechanizowanej,” *Wiadomości górnicze*, tom 64, nr 5, pp. 275-282, 2013.
- [4] M. Janik, J. Kuska, P. Świeczak, M. Wojtas i K. Fitowski, „Próby ruchowe sterowania elektrohydraulicznego DOH-matic w ścianie 305 w pokładzie 206 w Kopalni Węgla Kamiennego „Ziemowit,” *Napędy i Sterowanie*, tom 14, nr 9, pp. 118-122, 2012.
- [5] A. Kozieł, D. Jasiulek, K. Stankiewicz i S. Bartoszek, „Inteligentne systemy mechatroniczne w maszynach górniczych,” *Napędy i Sterowanie*, nr 2, pp. 112-116, 2012.
- [6] [Online]. Available: <https://dziennikzachodni.pl/sztuczna-inteligencja-w-kopalni-pniowek-gornicy-niepotrzebni/ar/c3-586769>. [Data uzyskania dostępu: 15 sierpień 2022].
- [7] T. Siemieniec, „Nowoczesny, wydajny i bezpieczny zautomatyzowany kompleks ścianowy w KWK "Pniówek" - doświadczenia eksploatacyjne,” *Maszyny Górnicze*, tom 30, nr 3, pp. 59-61, 2012.
- [8] FAMUR PRO, [Online]. Available: <https://famur.com/krok-w-przyszlosc-automatyczny-kompleks-scianowy-famuru>. [Data uzyskania dostępu: 15 08 2022].
- [9] „DOCPLAYER,” [Online]. Available: <https://docplayer.pl/8170274-Zautomatyzowany-kompleks-scianowy->

odbiorca-jastrzebska-spolka-weglowa-s-a-kwk-pniowek-informacje-techniczne.html. [Data uzyskania dostępu: 10 08 2022].

- [10] W. Szczepanek, *Zarys Górnictwa*, Warszawa: Wydawnictwo Szkolnictwa Zawodowego, 1952.
- [11] W. Budryk i W. Lesiecki, *Zarys górnictwa*, Katowice: Wydawnictwo Górniczno-Hutnicze, 1959.
- [12] W. Gabzdyl, *Geologia węgla*, Gliwice: Wydawnictwo Politechniki Śląskiej, 1988.
- [13] C. Zając, „Materiały dydaktyczne dla górników,” [Online]. Available: <https://www.czek.eu>. [Data uzyskania dostępu: 05 05 2022].
- [14] K. Chmura, *Geologia stosowana*, Gliwice: Wydawnictwo Politechniki Śląskiej, 1975.
- [15] W. Gabzdyl, *Geologia złóż*, Gliwice: Wydawnictwo Politechniki Śląskiej, 1995.
- [16] J. Bromowicz i J. Magiera, „Geneza żył klastycznych w skałach karbonu rejonu Rybnika,” *Annales Societatis Geologorum Poloniae*, tom 60, pp. 125-148, 1990.
- [17] Z. Czesław, „Czek.eu,” [Online]. Available: czek.eu. [Data uzyskania dostępu: 15 10 2023].
- [18] C. Cempel, *Podstawy wibroakustycznej diagnostyki maszyn*, Warszawa: Wydawnictwo Naukowo-Techniczne, 1982.
- [19] A. Timofiejczuk, w *Metody analizy sygnałów niestacjonarnych*, Gliwice, Wydawnictwo Politechniki Śląskiej, 2004.
- [20] W. Cholewa i W. Moczulski, *Diagnostyka techniczna maszyn : pomiary i analiza sygnałów*, Gliwice: Wydawnictwo Politechniki Śląskiej, 1993.
- [21] J. S. Bendat i A. G. Piersol, *Metody analizy i pomiaru sygnałów losowych*, Warszawa: Państwowe Wydawnictwo Naukowe, 1976.
- [22] S. Ossowski, w *Cyfrowe przetwarzanie sygnałów z zastosowaniem MATLABA*, Warszawa, Oficyna Wydawnicza Politechniki Warszawskiej, 2016.

- [23] M. Tarasiuk i Z. Gosiewski, „Przetwarzanie mowy w celu sterowania urządzeniami mechatronicznymi,” *Mechanik*, tom 88, nr 7, pp. 572-575, 2015.
- [24] S. W. Smith, *Digital signal processing: Practical Guide for Engineers and Scientists* by Steven W. Smith, California: California Technical Publishing San Diego, 1999.
- [25] S. Ossowski, A. Cichocki i K. Siwek, w *MATLAB w zastosowaniu do obliczeń obwodowych i przetwarzania sygnałów*, Warszawa, Oficyna wydawnicza Politechniki Warszawskiej, 2006.
- [26] R. Lyons, *Wprowadzenie do cyfrowego przetwarzania sygnałów*, Warszawa: Wydawnictwa Komunikacji i Łączności WKŁ, 1999.
- [27] A. Oppenheim i R. Schaffer, *Cyfrowe przetwarzanie sygnałów*, Warszawa: Wydawnictwa Komunikacji i Łączności WKŁ, 1986.
- [28] M. Pasko i J. Walczak, *Teoria sygnałów*, Gliwice: Wydawnictwo Politechniki Śląskiej, 2007.
- [29] T. P. Zieliński, w *Cyfrowe przetwarzanie sygnałów. Od teorii do zastosowań.*, Warszawa, Wydawnictwa komunikacji i łączności sp. z o.o, 2014.
- [30] X. Jing, W. Zhongbin, T. Chao, S. Lei i L. Xinhua, „Cutting Pattern Identification for Coal Mining Shearer through a Swarm Intelligence-Based Variable Translation Wavelet Neural Network,” *Sensors*, January 2018.
- [31] W. Rakowski, *Przekształcenia falkowe. Aspekty obliczeniowe w praktyce inżynierskiej.*, Białystok: Oficyna Wydawnicza Politechniki Białostockiej, 2018.
- [32] D. Stranneby, *Cyfrowe przetwarzanie sygnałów*, Warszawa: Wydawnictwo BTC, 2004.
- [33] A. Timofiejczuk, *Metoda badania maszyn wirnikowych w warunkach rozruchu, rozbiegu i wybiegu*, Gliwice: Politechnika Śląska, 1999.

- [34] „MathWorks,” [Online]. Available: <https://www.mathworks.com/help/wavelet/ref/cwt.html>. [Data uzyskania dostępu: 05 01 2024].
- [35] A. Zawada-Tomkiewicz, „Zastosowanie Empirical Mode Decomposition do analizy zmian chropowatości w czasie skrawania,” *Pomiary Automatyka Kontrola*, tom 56, nr 4, pp. 326-329, 2010.
- [36] S. S. Shen i N. E. Huang, „Introduction to the Hilbert-Huang Transform and Its Related Mathematical Problems,” w *Hilbert-Huang Transform and Its Applications*, World Scientific, 2005, pp. 1-26.
- [37] W. Gawędzki, M. Socha i P. Sławik, „Dekompozycja sygnałów EEG w dziedzinie czasu przy zastosowaniu transformacji Hilberta-Huanga HHT,” *Przegląd elektrotechniczny*, tom 5, nr 91, pp. 33-36, 2015.
- [38] M. Jasiński i S. Radkowski, „Low-energy failures detection using of local mean decomposition method,” *Zeszyty Naukowe Instytutu Pojazdów / Politechnika Warszawska*, tom 95, nr 4, pp. 59-70, 2013.
- [39] J. Xu, Z. Wang, W. Zhang i Y. He, „Coal-rock Interface Recognition Based on MFCC and Neural Network,” *International Journal of Signal Processing, Image Processing and Pattern Recognition*, August 2013.
- [40] T. Wieczorek, *Neuronowe modelowanie procesów technologicznych*, Gliwice: Wydawnictwo Politechniki Śląskiej, 2008.
- [41] I. Guyon, S. Gunn, M. Nikravesh i L. Zadeh, „An Introduction to Feature Extraction,” w *Feature Extraction*, Berlin, Springer, 2006, pp. 1-28.
- [42] K. Kaczmarek i A. Nowak, „Sieci neuronowe,” w *Sieci analiza i optymalizacja*, Gliwice, Wydawnictwo Politechniki Śląskiej, 2007, pp. 112-136.
- [43] J. Gutenbaum, „Sieci neuronowe,” Instytut Badań Systemowych. Polska Akademia Nauk, Warszawa, 2001.

- [44] W. Duch, J. Korbicz, L. Rutkowski i R. Tadeusiewicz, *Sieci neuronowe*, Warszawa: Akademicka Oficyna Wydawnicza EXIT, 2000.
- [45] W. Gabzdyl, *Petrografia węgla*, Gliwice: Wydawnictwo Politechniki Śląskiej, 1987.
- [46] K. Basu, *Feasibility of an integrated thin seam coal mining and waste disposal system*, Blacksburg, Virginia, USA, 1997.
- [47] M. Hui-ling i M. Li, „Characteristic Analysis and Recognition of Coal-Rock Interface Based on Visual Technology,” *International Journal of Signal Processing, Image Processing and Pattern Recognition*, pp. 61-68, 2016.
- [48] A. Mazid i R. Sahoo, „Application of opto-tactile sensor in shearer machine design to recognise rock surfaces in underground coal mining,” w *IEEE International Conference on Industrial Technology*, 2009.
- [49] P. Kiljan i K. Kalinowski, „Przegląd metod rozpoznawania granic węgla i skał w celu automatyzacji pracy kombajnu ścianowego,” w *nowacyjne techniki i technologie dla górnictwa bezpieczeństwo - efektywność - niezawodność : KOMTECH 2020. Praca zbiorowa*, Instytut Techniki Górniczej KOMAG, 2020, pp. 83-92.
- [50] J. C. Ralston, „Automated longwall shearer horizon control using thermal infrared-based seam tracking,” w *IEEE International Conference on Automation Science and Engineering (CASE)*, Seoul, 2012.
- [51] S. Lei, W. Zhongbin, L. Yiwen i T. Chao, „Online Identification Of Shearer Cutting State Using Infrared Thermal Images of Cutting Unit,” *Applied Sciences*, 2018.
- [52] J. Ralston i A. Strange, „An Industrial Application of Ground Penetrating Radar for Coal mining Horizon Sensing,” w *ISAP*, Hobart, 2015.
- [53] S. Gierlotka, „Własności elektryczne i magnetyczne skał,” *Energetyka*, pp. 325-328, 2019.

- [54] S. Miao, X. Liu, Z. Liu i L. Zhang, „Ground Penetrating Radar Based Experimental Simulation and Signal Interpretation on Coal-Rock Interface Detection,” 2018.
- [55] R. Drożdżak i K. Twardowski, „Przenikalność dielektryczna ośrodków porowatych-czynniki wpływające na jej zmienność,” *Wiertnictwo, Nafta, Gaz*, tom 27, pp. 111-120, 2010.
- [56] A. Strange, J. C. Ralston i V. Chandran, „Near-Surface Interface Detection for Coal Mining Applications Using Bispectral Features and GPR,” *Subsurface Sensing Technologies and Applications*, tom 6, pp. 125-149, kwiecień 2005.
- [57] S. Plewa, „Zastosowanie badań promieniotwórczości skał w otworach wiertniczych,” *Przegląd Geologiczny*, tom 1, nr 8, pp. 22-25, 1953.
- [58] T. Okulski, „Zawartość uranu i toru w węglach polskich i amerykańskich,” *Polityka energetyczna*, tom 11, nr 1, pp. 323-334, 2008.
- [59] L. Róg, „Promieniotwórczość naturalna węgla kamiennych i frakcji gęstościowych węgla o zróżnicowanej budowie petrograficznej i chemicznej,” *Prace Naukowe GIG. Górnictwo i Środowisko.*, tom 3, pp. 81-101, marzec 2005.
- [60] Z. Ningbo i L. Changyou, „Radiation characteristic of natural gamma-ray from coal and gangue for recognition in top coal caving,” *Scientific Reports*, 2018.
- [61] P. Kiljan i K. Kalinowski, „Selected methods for material identification on the border of geological layers for the automation of industrial processes of obtaining raw materials,” w *IOP Conference Series Materials Science and Engineering*, 2021.
- [62] T. Dung Le, R. Mitra, J. Oh i B. Hebblewhite, „A review of cavability evaluation in longwall top coal caving,” *International Journal of Mining Science and Technology*, tom 27, nr 6, pp. 907-9015, 2017.

- [63] D. Buchcik, „Czujniki przyspieszenia,” w *Labolatorium zintegrowanych czujników pomiarowych*, Gliwice, Wydawnictwo Politechniki Śląskiej, 1997, pp. 19-31.
- [64] D. Tomaszewski, „ElektronikaB2B,” [Online]. Available: <https://elektronikab2b.pl/technika/50568-przeglad-roznych-rodzajow-czujnikow-do-pomiaru-wibracji>. [Data uzyskania dostępu: 10 03 2021].
- [65] P. Mendelowski, K. Sz wajka, J. Zielińska-Sz wajka i W. Żelasko, *Predykcja w układach mechanicznych i automatycznych 2020 - pomiary i badania*, Rzeszów: Oficyna Wydawnicza Politechniki Rzeszowskiej, 2020.
- [66] „Zakład Obwodów I Sygnałów Elektrycznych,” [Online]. Available: https://zoise.wel.wat.edu.pl/dydaktyka/Czujniki%20i%20przetworniki/CW5_Przetworniki_piezoelektryczne_teorja_2015.pdf, . [Data uzyskania dostępu: 01 09 2020].
- [67] R. Gryboś, *Drgania maszyn*, Gliwice: Wydawnictwo Politechniki Śląskiej, 2009.
- [68] J. Zakrzewski i M. Kampik, *Sensory i przetworniki pomiarowe*, Gliwice: Wydawnictwo Politechniki Śląskiej, 2013.
- [69] J. Balcerzak, *Rozpoznawanie wzorców ruchowych przy użyciu żyroskopu i akcelerometru*, Warszawa: Politechnika Warszawska, 2015.
- [70] M. Andrejašic. [Online]. Available: <http://docplayer.net/20641887-University-of-ljubljana-faculty-for-mathematics-and-physics-department-of-physics-seminar-mems-accelerometers-author-matej-andrejasic.html>. [Data uzyskania dostępu: 10 03 2021].
- [71] K. Jamielniak. [Online]. Available: <https://docplayer.pl/8798050-Sensoryka-3-czujniki-drgan.html> . [Data uzyskania dostępu: 10 03 2021].
- [72] Z. Guoxin, W. Zengcai i Z. Lei, „Recognition of rock–coal interface in top coal caving through tail beam vibrations by using stacked sparse autoencoders,” *Jurnal of vibroengineering*, tom 18, nr 7, 2016.

- [73] X. Jing, W. Zhongbin, T. Chao, L. Daohua, W. Baigong, S. Zhen i t. Yanbing, „Cutting Pattern Identification for Coal Mining Shearer through Sound Signals Based on a Convolutional Neural Network,” *Symmetry*, December 2018.
- [74] L. Yong, C. Gang, C. Xihui i L. Chang, „Coal–rock interface recognition based on permutation entropy of LMD and supervised Kohonen neural network,” *Current Science*, pp. 96-103, January 2019.
- [75] X. Chen, Y. Zenan i C. Gang, „Research on coal-rock recognition based on sound signal analysis,” *EDP Sciences*, tom 232, 2018.
- [76] Z. Guoxin, W. Zengcai, Z. Lei i W. Jinshan, „Coal-Rock Recognition in Top Coal Caving Using Bimodal Deep Learning and Hilbert-Huang Transform,” *Shock and Vibration*, 2017.
- [77] A. Miziolek, V. Palleschi i I. Schechter, *Laser-Induced Breakdown Spectroscopy*, Cambridge: Cambridge University Pres, 2006.
- [78] „Metalogis,” 08 11 2019. [Online]. Available: <https://metalogis.com/baza-wiedzy/spektrometria-libs-podstawy-teoretyczne/>. [Data uzyskania dostępu: 07 05 2024].
- [79] L. Cong, L. Yimin i Z. Qizhi, „Laser-Induced Breakdown Spectroscopy-Based Coal-Rock Recognition: An In Situ Sampling and Recognition Method,” *IEEE Access*, 5 Grudzień 2021.
- [80] M. Mirończuk, „Przegląd i klasyfikacja zastosowań, metod oraz technik eksploracji danych,” *Studia i Materiały Informatyki Stosowanej*, tom 2, nr 2, pp. 35-46, 2010.
- [81] R. Tajdusiewicz, *Sygnały mowy*, Warszawa: Wydawnictwa Komunikacji i Łączności, 1988.
- [82] D. T. Larose, *Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych*, Warszawa: Wydawnictwo Naukowe PWN, 2006.
- [83] A. Jóźwik, S. Serpico i F. Rozli, „A parallel network of modified 1-NN and k-NN classifiers – Application to remote-sensing image classification,” *Pattern Recognition Letters*, pp. 57-62, 01 maj 1998.

- [84] A. Rosner, M. Michalak i B. Kostek, „A Study on Influence of Normalization Methods on Music Genre Classification Results Employing knn Algorithm,” *Studia informatica*, pp. 411-423, 01 01 2013.
- [85] I. H. Witten, E. Frank i M. A. Hall, *Data Mining Practical Machine Learning Tools and Tachniques*, San Francisco: Morgan Kaufmann Publishers Inc., 2011.
- [86] N. Jankowski, *Ontogeniczne sieci neuronowe. O sieciach zmieniających swoją strukturę.*, Warszawa: Uniwersytet Mikołaja Kopernika, 2003.
- [87] A. Ławrynowicz i V. Tresp, „Introducing Machine Learning,” *Perspectives on Ontology Learning*, 2014.
- [88] F. Livingstone, „Implementation of Breiman’s random forest machine learning algorithm,” *ECE591Q Machine Learning Journal Paper*, pp. 1-13, 2005.
- [89] M. Pełka, „Sieci neuronowe dla danych symbolicznych : perceptron wielowarstwowy,” *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu. Taksonomia*, tom 16, nr 47, pp. 223-230, 2009.
- [90] E. Gatnar, *Podejście wielomodelowe w zagadnieniach dyskryminacji i regresji*, Warszawa: Wydawnictwo Naukowe PWN, 2008.
- [91] K. M. Ting, *Confusion Matrix*, Boston: Springer, 2011.
- [92] T. Borys, „Metody normowania cech w statystycznych badaniach porównawczych,” *Przegląd statystyczny* 3, pp. 371-382, 1978.
- [93] T. Borys, *Elementy teorii jakości.*, Warszawa: Wydawnictwo Naukowe PWN, 1980.
- [94] J. Brownlee, „Machine learning Mastery,” 11 12 2019. [Online]. Available: <https://machinelearningmastery.com/normalize-standardize-machine-learning-data-weka/>. [Data uzyskania dostępu: 20 08 2023].
- [95] Południowy Koncern Węglowy S.A., *Dokumentacja mierniczo-geologiczna*.

- [96] J. Konarski, „Efektywny czas pracy kompleksu ścianowego i przyczyny jego zmniejszania,” *Inżynieria Mineralna*, tom 2, nr 2, 13 styczeń 2022.
- [97] [Online]. Available: https://zstio-elektronika.pl/pliki_t_elektronik/UE-03.pdf. [Data uzyskania dostępu: 20 04 2024].
- [98] A. Sitek i B. Kostek. [Online]. Available: <https://sound.eti.pg.gda.pl/student/ts/mikrofony.pdf>. [Data uzyskania dostępu: 20 04 2024].
- [99] L. Marek, „Cyfrowe.pl,” [Online]. Available: <https://blog.cyfrowe.pl/mikrofonowy-slowniczek-co-o-sprzecie-mowiaw-jego-parametry/>. [Data uzyskania dostępu: 20 04 2024].
- [100] „Muzyczny Portal Społecznościowy-only4music.com,” [Online]. Available: <https://only4music.com/czytelnia/18-musictech/704-mikrofony-czyli-jak-nagrac-swoj-glos>. [Data uzyskania dostępu: 20 04 2024].
- [101] B. Mróz. [Online]. Available: <https://multimed.org/student/tn/mikrofony.pdf>. [Data uzyskania dostępu: 18 04 2024].
- [102] „Spirit by soundcraft,” [Online]. Available: <https://essaudio.pl/pdf/soundcraft/guide.pdf>. [Data uzyskania dostępu: 19 03 2024].
- [103] [Online]. Available: <https://www.cyfrowe.pl>. [Data uzyskania dostępu: 10 maj 2022].
- [104] „JUMO,” [Online]. Available: <https://www.jumo.pl/web/about-us/blog-pl/ip68-protection>. [Data uzyskania dostępu: 20 04 2024].
- [105] J. Stefanowski, „Klasyfikator k-NN,” 2020. [Online]. Available: <http://www.cs.put.poznan.pl/jstefanowski/ml/kNN-2020.pdf>. [Data uzyskania dostępu: 15 07 2023].

- [106] D. Majerek, „Eksploracja danych,” 11 03 2020. [Online]. Available: <https://dax44.github.io/datamining/>. [Data uzyskania dostępu: 15 07 2023].
- [107] A. Nowak-Brzezińska, „Przygotowanie danych w środowisku R,” 2011.
- [108] P. Shanthababu, „K-Fold Cross Validation Technique and its Essentials,” 14 02 2022. [Online]. Available: <https://www.analyticsvidhya.com/blog/2022/02/k-fold-cross-validation-technique-and-its-essentials/>. [Data uzyskania dostępu: 2023 07 15].
- [109] J. Brownlee, „Machine Learning Mastery,” 25 czerwiec 2016. [Online]. Available: <https://machinelearningmastery.com/use-classification-machine-learning-algorithms-weka/>. [Data uzyskania dostępu: 2023 07 17].
- [110] „Scikit-learn,” [Online]. Available: <https://scikit-learn.org/stable/modules/svm.html>. [Data uzyskania dostępu: 2023 07 31].
- [111] W. Lewoniewski, K. Węcel i W. Abramowicz, „Analiza porównawcza modeli jakości informacji w narodowych wersjach Wikipedii,” w *Matematyka i informatyka na usługach ekonomii*, Poznań, Wydawnictwo UEP, 2017, pp. 54-68.
- [112] D. Mider i A. Marcinkowska, *Analiza danych ilościowych dla politologów. Praktyczne wprowadzenie z wykorzystaniem programu GNU PSPP.*, Warszawa, 2013.
- [113] G. U. Yule, *An Introduction to the Theory of Statistics*, Stany Zjednoczone: Creative Media Partners, LLC, 2018.
- [114] P. Sulewski, „Moc testów niezależności w tablicy dwudzielczej większej niż 2x2,” *Przegląd Statystyczny*, tom LXIII, nr 2, pp. 191-209, 2016.
- [115] S. Magdalena, „WYKORZYSTANIE TESTU CHI-KWADRAT W BADANIACH PREFERENCJI ŻYWIENIOWYCH KONSUMENTÓW,” *Nauki Inżynierskie i Technologie*, tom 32, nr 1, pp. 24-38, 2019.

- [116] P. Kwasiborski i M. Sobol, „Test niezależności chi-kwadrat i jego zastosowanie w interpretacji wyników badań klinicznych,” *Kardiochirurgia i Torakochirurgia*, nr 4, pp. 550-554, 2011.
- [117] „Naukowiec.org,” 2024. [Online]. Available: https://www.naukowiec.org/wiedza/statystyka/poprawka-na-ciagloscyatesa_517.html. [Data uzyskania dostępu: 15 03 2024].
- [118] J. Kawa, „Metodologia, metodyka, metoda jako podstawa wywodu naukowego,” *Studia prawnoustrojowe*, nr 21, pp. 169-188, 2013.
- [119] H. Schuman, *Metoda i znaczenie w badaniach sondażowych*, Warszawa: Oficyna Naukowa, 2013.
- [120] J. Fraden, *Handbook of Modern Sensors*, London: Springer-Verlag New York, 2010.

Załącznik 1

Zawiera plik z Opracowaną bazą danych w programie MS Excel zapisaną w postaci pliku csv.

Załącznik 2

Plik z kompletną bazą danych zamieszczono w pliku WS–norm.arff wykorzystana w programie WEKA.

Streszczenie rozprawy doktorskiej w języku polskim:

Tytuł rozprawy doktorskiej w języku polskim:

Metoda określania systemu identyfikacji węgiel-skała.

W ramach badań przedstawiono wykorzystanie czujnika dźwięku w celu rozpoznania dźwięku urabiania węgla lub skały przez kombajn ścianowy w ścianie wydobywczej kopalni węgla kamiennego. Do pozyskania próbek niezbędnych do analizy posłużyło zbudowane stanowisko pomiarowe złożone z aparatury rejestrującej dźwięk w wyrobisku ścianowym podczas pracy kombajnu. Zarejestrowane próbki dźwięku zostały poddane analizie opartej na krótkoczasowym przekształceniu Fouriera. Wynikiem tej analizy było określenie charakterystycznych częstotliwości urabiania węgla i skały, które zostały wykorzystane w metodach klasyfikacji. W pracy wykorzystano wybrane metody klasyfikacji, takie jak: k-najbliższych sąsiadów (k-NN) Drzewa losowe, Maszyny wektorów nośnych (SVM), Perceptron wielowarstwowy (MLP). Wyniki eksperymentu zawierały się w przedziale ok.79-83% skuteczności klasyfikacji. W kolejnym etapie badań sprawdzono, wykorzystując test chi-kwadrat, zasadność hipotezy, że nie istnieje statystycznie istotny związek pomiędzy zmiennymi dla dźwięku urabiania węgla i skały, potwierdzając wyniki analizy klasyfikacji.

Streszczenie rozprawy doktorskiej w języku angielskim:

Tytuł rozprawy doktorskiej w języku angielskim:

Method for determining the coal-rock identification system.

The research presents the use of a sound sensor to recognize the sounds of coal or rock extraction by a longwall shearer in the mining wall of a hard coal mine. In order to collect samples necessary for analyses, a measurement station was built consisting of devices recording sound in longwall workings during the operation of the shearer. The recorded sound samples were analyzed based on the short-time Fourier transform. The result of this analysis was the determination of characteristic frequencies of coal and rock mining, which were used in classification methods. The work uses selected classification methods such as: k-nearest neighbors (k-NN), random forest, support vector machines (SVM), multi-layer perceptron (MLP). The experimental results were in the range of approximately 79-83% classification efficiency. In the next stage of the research, the validity of the hypothesis that there is no statistically significant relationship between the variables for the sound of coal and rock mining was verified using the chi-square test, confirming the results of the classification analysis.