


# ROZPRAWY MONOGRAFIE



384

ANETA NAPIERAJ

Koncepcja modelowania  
niezawodności procesów wydobywczych  
w warunkach niepewności  
operacyjnej i technicznej



WYDAWNICTWA AGH

KRAKÓW 2025



# 384 DISSERTATIONS MONOGRAPHS

**ANETA NAPIERAJ**

A concept for modeling  
the reliability of mining processes  
under conditions of  
operational and technical uncertainty



AGH UNIVERSITY PRESS

KRAKOW 2025

ROZPRAWY  
MONOGRAFIE **384**

**ANETA NAPIERAJ**

Koncepcja modelowania  
niezawodności procesów wydobywczych  
w warunkach niepewności  
operacyjnej i technicznej



WYDAWNICTWA AGH

KRAKÓW 2025

Wydawnictwa Akademii Górniczo-Hutniczej im. Stanisława Staszica w Krakowie

© Wydawnictwa AGH, Kraków 2025  
Creative Commons CC-BY 4.0

ISBN 978-83-68219-90-6 (print)  
ISBN 978-83-68219-91-3 (PDF)  
ISSN 0867-6631

<https://doi.org/10.7494/978-83-68219-91-3>

Recenzenci:

*prof. dr hab. inż. Roman Magda*  
*prof. dr hab. inż. Marian Turek*

Afiliacja autorki:

*Akademia Górniczo-Hutnicza*  
*Wydział Inżynierii Lądowej i Gospodarki Zasobami*  
*Katedra Ekonomiki i Zarządzania w Przemysle*  
*al. A. Mickiewicza 30*  
*30-059 Kraków*

*Publikację wydano z materiałów dostarczonych przez autorkę.*

Skład komputerowy: **ART-TEKST**

Projekt okładki i stron tytułowych: *Paweł Sepielak*

---

Wydawnictwa AGH  
al. A. Mickiewicza 30, 30-059 Kraków  
tel. 12 617 32 28, 12 636 40 38  
e-mail: [redakcja@wydawnictwoagh.pl](mailto:redakcja@wydawnictwoagh.pl)  
<http://www.wydawnictwa.agh.edu.pl>

---

## Spis treści

|                                                                                       |    |
|---------------------------------------------------------------------------------------|----|
| <b>Streszczenie</b> .....                                                             | 7  |
| <b>Summary</b> .....                                                                  | 9  |
| <b>Wykaz skrótów</b> .....                                                            | 11 |
| <b>1. Wstęp</b> .....                                                                 | 13 |
| 1.1. Uzasadnienie wyboru tematu .....                                                 | 13 |
| 1.2. Sformułowanie problemu badawczego .....                                          | 14 |
| 1.3. Cel i zakres pracy .....                                                         | 16 |
| 1.4. Struktura rozprawy .....                                                         | 17 |
| <b>2. Przegląd literatury i podstawy teoretyczne</b> .....                            | 19 |
| 2.1. Wprowadzenie do problematyki niezawodności .....                                 | 19 |
| 2.2. Pojęcie niezawodności procesowej –<br>definicja i zakres interpretacyjny .....   | 21 |
| 2.3. Modele niezawodnościowe –<br>podejścia deterministyczne i probabilistyczne ..... | 23 |
| 2.4. Charakterystyka procesu wydobywczego .....                                       | 27 |
| 2.5. Źródła niepewności w procesach wydobywczych .....                                | 33 |
| 2.6. Modelowanie procesów wydobywczych jako układów złożonych .....                   | 36 |
| 2.7. Przegląd badań nad niezawodnością w górnictwie .....                             | 39 |
| 2.8. Luka badawcza i miejsce proponowanej koncepcji w literaturze .....               | 43 |
| <b>3. Metodyka badań</b> .....                                                        | 45 |
| 3.1. Koncepcja badawcza .....                                                         | 46 |
| 3.2. Źródła i przygotowanie danych .....                                              | 48 |
| 3.3. Metody oceny niezawodności procesowej .....                                      | 50 |
| 3.4. Model systemowy procesu wydobywczego .....                                       | 52 |
| 3.5. Narzędzia analityczne i symulacyjne .....                                        | 55 |

|                                                                                            |            |
|--------------------------------------------------------------------------------------------|------------|
| <b>4. Modelowanie niezawodności procesu wydobywczego .....</b>                             | <b>57</b>  |
| 4.1. Wprowadzenie do modelowania niezawodności procesowej .....                            | 57         |
| 4.2. Założenia i ograniczenia modelu .....                                                 | 58         |
| 4.3. Opis analizowanego systemu technicznego .....                                         | 63         |
| 4.4. Model probabilistyczny niezawodności .....                                            | 65         |
| 4.5. Modelowanie w warunkach niepewności .....                                             | 67         |
| 4.6. Integracja modelu deterministycznego i probabilistycznego .....                       | 69         |
| <b>5. Walidacja modelu .....</b>                                                           | <b>79</b>  |
| 5.1. Metody walidacji .....                                                                | 79         |
| 5.2. Dobór i przygotowanie danych testowych .....                                          | 81         |
| 5.3. Porównanie wyników modelu z danymi empirycznymi .....                                 | 86         |
| 5.4. Analiza odchyień i identyfikacja przyczyn rozbieżności .....                          | 91         |
| 5.5. Ocena skuteczności modelu w warunkach zwiększonej niepewności .....                   | 96         |
| 5.6. Podsumowanie walidacji .....                                                          | 100        |
| <b>6. Empiryczna weryfikacja koncepcji modelowania<br/>w warunkach rzeczywistych .....</b> | <b>103</b> |
| 6.1. Wprowadzenie i charakterystyka danych .....                                           | 103        |
| 6.2. Struktura przyczyn przestojów w danych rzeczywistych .....                            | 104        |
| 6.3. Ranking szczegółowych przyczyn .....                                                  | 104        |
| 6.4. Walidacja modelu na danych z Kopalni B .....                                          | 106        |
| 6.5. Porównanie z Kopalnią A .....                                                         | 108        |
| 6.6. Podsumowanie .....                                                                    | 109        |
| <b>7. Możliwości wykorzystania w praktyce przemysłowej .....</b>                           | <b>111</b> |
| <b>8. Stwierdzenia i wnioski końcowe .....</b>                                             | <b>113</b> |
| <b>Bibliografia .....</b>                                                                  | <b>115</b> |

## **Koncepcja modelowania niezawodności procesów wydobywczych w warunkach niepewności operacyjnej i technicznej**

### **Streszczenie**

Proces wydobywczy w kopalniach węgla kamiennego nie zawsze przebiega w sposób jednostajny. Jego realizacja zależy od wielu czynników technicznych, organizacyjnych i środowiskowych, które w praktyce mogą powodować zakłócenia, przerwy lub obniżenie rytmiczności prowadzenia robót. Zmienność ta jest naturalną cechą działalności górniczej, jednak utrudnia formułowanie obiektywnej oceny funkcjonowania całego systemu produkcyjnego. W takich warunkach rośnie potrzeba stosowania metod, które pozwalają opisać przebieg procesu w sposób uwzględniający niepewność oraz zależności pomiędzy kolejnymi etapami produkcji.

W niniejszej pracy podjęto próbę opracowania koncepcji oceny niezawodności procesu wydobywczego, traktując go jako układ złożony, w którym poszczególne podsystemy techniczne i organizacyjne wzajemnie na siebie oddziałują. Przyjęto podejście procesowe oraz probabilistyczne, zakładające, że przebieg pracy podsystemów, a także czas trwania zakłóceń, mają charakter losowy i mogą podlegać wahaniom wynikającym zarówno z warunków naturalnych, jak i ze sposobu organizacji pracy. Celem opracowanej koncepcji jest nie tylko określenie elementów szczególnie podatnych na zakłócenia, lecz również prognozowanie możliwych odchyłeń od planowanego przebiegu produkcji.

W pierwszych rozdziałach monografii przedstawiono podstawy teoretyczne związane z pojęciem niezawodności w ujęciu procesowym. Omówiono przyczyny zmienności, które występują w działalności górniczej, oraz wskazano ograniczenia klasycznego podejścia opartego wyłącznie na niezawodności maszyn lub pojedynczych komponentów. Szczególną uwagę zwrócono na fakt, że ciągłość i stabilność procesu zależą nie tylko od stanu technicznego urządzeń, ale także od właściwej koordynacji działań, dostępności infrastruktury oraz dynamiki warunków środowiskowych.

Kolejne części pracy poświęcono metodyce badań, obejmującej identyfikację i przygotowanie danych, zasady ich porządkowania oraz podział zdarzeń na grupy umożliwiające analizę. Dane wykorzystane w badaniu pochodziły między innymi z rejestrów przestojów, raportów operacyjnych oraz dokumentacji technicznej. Przed przystąpieniem do modelowania konieczne było ich oczyszczenie, ujednolicenie jednostek oraz weryfikacja poprawności



zapisów. Tak przygotowany materiał stanowił podstawę do opracowania statystycznych opisów czasu pracy podsystemów oraz czasu trwania zakłóceń.

W części modelowej przedstawiono probabilistyczny opis funkcjonowania procesu wydobywczego z uwzględnieniem zmienności parametrów pracy oraz zależności pomiędzy kolejnymi etapami produkcji. Zastosowane podejście pozwala uchwycić wpływ niepewności na przebieg procesu i opisuje go w sposób bardziej realistyczny niż modele oparte wyłącznie na wartościach średnich. Model ten połączono następnie z ujęciem systemowym, umożliwiającym analizę powiązań pomiędzy podsystemami oraz identyfikację elementów krytycznych, których zakłócenie w największym stopniu wpływa na stabilność całego układu.

Opracowany model został poddany weryfikacji z wykorzystaniem danych rzeczywistych pochodzących z dwóch kopalń. Analiza porównawcza obejmowała ocenę zgodności wyników modelowych z przebiegiem procesu obserwowanym w praktyce. Przeprowadzona walidacja potwierdziła przydatność modelu w odwzorowywaniu rzeczywistych warunków pracy systemu wydobywczego, identyfikacji przyczyn zakłóceń oraz prognozowaniu możliwych nieciągłości w produkcji. Wskazano również czynniki, które mogą wpływać na rozbieżności pomiędzy danymi empirycznymi a wynikami modelu.

W końcowej części monografii przedstawiono możliwości wykorzystania opracowanej koncepcji w praktyce przemysłowej. Model może wspierać procesy planowania i organizacji produkcji, pozwala identyfikować obszary wymagające usprawnień, a także stanowić podstawę do podejmowania decyzji dotyczących utrzymania ruchu i zarządzania zasobami. Opracowanie wpisuje się w kierunki rozwoju współczesnego górnictwa, w którym coraz większą rolę odgrywa analiza danych, cyfryzacja procesów oraz dążenie do zwiększenia efektywności pracy.

Monografia stanowi propozycję spójnego podejścia do oceny niezawodności procesu wydobywczego, łączącego analizę procesową z probabilistycznym opisem niepewności. Przedstawione rozwiązania mogą być wykorzystane zarówno w badaniach naukowych, jak i w praktyce zakładów górniczych.

## **A concept for modeling the reliability of mining processes under conditions of operational and technical uncertainty**

### **Summary**

The extraction process in underground coal mines does not always proceed in a uniform manner. Its course depends on numerous technical, organisational and environmental factors, which may lead to interruptions, fluctuations in production or a decrease in the regularity of work. Such variability is a natural feature of mining activity, yet it makes it difficult to provide an objective assessment of how the entire production system operates. For this reason, there is a growing need for approaches that take into account uncertainty and the relationships between consecutive stages of the process.

In this study, a concept is developed for evaluating the reliability of the extraction process by treating it as a complex system in which technical and organisational subsystems influence one another. A process-based and probabilistic perspective was adopted, acknowledging that operating conditions as well as the duration and frequency of disturbances are not fixed but may vary depending on natural conditions and the organisation of work. The aim of this approach is not only to identify the elements most susceptible to disturbances but also to anticipate possible deviations from the planned course of production.

The initial chapters present the theoretical background related to process reliability and discuss the limitations of traditional approaches that focus solely on the reliability of individual machines. Particular emphasis is placed on the fact that continuity and stability of the production process depend not only on technical performance but also on coordination of activities, availability of infrastructure and changes occurring in the natural environment.

Subsequent sections describe the research methodology, including the procedures for collecting, preparing and organising data. The material used in the analysis consisted of records of production interruptions, operational reports and technical documentation. Before modelling could be carried out, the dataset required verification, standardisation and careful organisation. This preparation enabled the development of statistical descriptions of subsystem operation and of the duration of disturbances.

The modelling part of the monograph introduces a probabilistic description of the extraction process that reflects the variability of operating conditions and the interdependencies between consecutive stages of production. This approach makes it possible to capture the influence

of uncertainty on the functioning of the system and provides a more realistic representation of the process than models based solely on average values. The probabilistic model was then combined with a system-level perspective, allowing for the identification of critical elements whose disturbance has a significant effect on overall process stability.

The developed model was validated using real data from two mines. The comparison with the actual course of the production process made it possible to assess how well the model reflects real conditions. The results confirmed its usefulness in identifying the sources of disturbances and in anticipating potential irregularities in the production sequence. The analysis also pointed to factors that may contribute to discrepancies between modelled outcomes and empirical observations.

In the final part of the monograph, the practical applications of the proposed concept are discussed. The model may support planning and organisation of production, help identify areas in need of improvement and provide a basis for decisions related to maintenance and resource management. The approach corresponds with contemporary trends in mining, which increasingly rely on data analysis, digitalisation and efforts to improve process efficiency.

The monograph offers a coherent approach to evaluating the reliability of the extraction process by combining a process-oriented view with a probabilistic description of uncertainty. The proposed solutions may be used both in scientific research and in the practical management of mining operations.

## Wykaz skrótów

- API – *Application Programming Interface* – interfejs programistyczny aplikacji
- $\beta$  – parametr kształtu rozkładu Weibulla
- BPMN – *Business Process Model and Notation* – notacja i model procesów biznesowych
- CBM – *Condition-Based Maintenance* – utrzymanie ruchu oparte na stanie technicznym
- CMS – *Content Management System* – system zarządzania treścią
- CMMS – *Computerized Maintenance Management System* – komputerowy system zarządzania utrzymaniem ruchu
- ERP – *Enterprise Resource Planning* – system planowania zasobów przedsiębiorstwa
- ETL – *Extract, Transform, Load* – proces ekstrakcji, transformacji i ładowania danych
- FMEA – *Failure Mode and Effects Analysis* – analiza rodzajów i skutków uszkodzeń
- FMECA – *Failure Mode, Effects and Criticality Analysis* – analiza rodzajów, skutków i krytyczności uszkodzeń
- $F(t)$  – dystrybuenta czasu do uszkodzenia
- $f(t)$  – funkcja gęstości czasu do uszkodzenia
- FTA – *Fault Tree Analysis* – analiza drzewa błędów
- $\eta$  – parametr skali rozkładu Weibulla
- IoT – *Internet of Things* – internet rzeczy
- KPI – *Key Performance Indicator* – kluczowy wskaźnik efektywności
- KRZG – kierownik ruchu zakładu górniczego
- LHD – *Load-Haul-Dump* – system załadunku, transportu i rozładunku urobku
- $\lambda(t)$  – intensywność uszkodzeń (ang. *hazard rate*)
- MAE – *Mean Absolute Error* – średni błąd bezwzględny
- MAPE – *Mean Absolute Percentage Error* – średni procentowy błąd bezwzględny
- MES – *Manufacturing Execution System* – system realizacji produkcji

MLE – *Maximum Likelihood Estimation* – metoda największej wiarygodności

MTBF – *Mean Time between Failures* – średni czas między uszkodzeniami

MTTR – *Mean Time to Repair* – średni czas naprawy

$\mu$  – intensywność napraw

$\mu, \sigma$  – parametry rozkładu log-normalnego (średnia i odchylenie standardowe logarytmu)

$N$  – liczba prób w symulacji Monte Carlo

$Pa(X_i)$  – zbiór rodziców zmiennej  $X_i$  w sieci bayesowskiej

PdM – *Predictive Maintenance* – predykcyjne utrzymanie ruchu

PI – *Prediction Interval* – przedział predykcji

PLP – *Power Law Process* – proces potęgowy w analizie niezawodności

$P_S(t)$  – prawdopodobieństwa przebywania systemu w stanie sprawnym

$P_F(t)$  – prawdopodobieństwa przebywania systemu w stanie uszkodzonym

ProM – *Process Mining Framework* – oprogramowanie do eksploracji procesów

R – środowisko i język programowania R

$R(t)$  – funkcja niezawodności – prawdopodobieństwo bezawaryjnej pracy do czasu  $t$

$R^2$  – współczynnik determinacji

RBD – *Reliability Block Diagram* – diagram blokowy niezawodności

RCD – *Reliability-Centered Diagnostics* – diagnostyka ukierunkowana na niezawodność (w kontekście PdM i AI)

RCM – *Reliability-Centered Maintenance* – utrzymanie ruchu ukierunkowane na niezawodność

RMSE – *Root Mean Square Error* – pierwiastek średniego błędu kwadratowego

SCADA – *Supervisory Control and Data Acquisition* – system nadzoru i akwizycji danych

$T$  – losowa zmienna – czas do uszkodzenia

$T_i$  – wygenerowany czas życia w symulacji Monte Carlo

$T_r$  – losowa zmienna – czas trwania naprawy

$\theta_j$  –  $j$ -ty parametr rozkładu prawdopodobieństwa (np.  $\beta, \eta$  w rozkładzie Weibulla lub  $\mu, \sigma$  w rozkładzie log-normalnym), traktowany jako zmienna losowa w analizie probabilistycznej i analizie wrażliwości

UQ – *Uncertainty Quantification* – ilościowa ocena niepewności

WMS – *Warehouse Management System* – system zarządzania magazynem

# 1. Wstęp

Procesy wydobywcze należą do najbardziej złożonych i kapitałochłonnych obszarów działalności przemysłowej. O ich efektywności, stabilności i bezpieczeństwie decyduje nie tylko poziom zaawansowania technologicznego stosowanych maszyn i urządzeń, ale także organizacja pracy, jakość zarządzania oraz zmienność warunków środowiskowych. Szczególnie istotnym aspektem jest niezawodność procesowa, rozumiana jako zdolność całego procesu wydobywczego do realizacji zadań produkcyjnych w sposób ciągły i bez zakłóceń, przy zachowaniu odpowiedniego poziomu jakości i bezpieczeństwa.

W praktyce górniczej niezawodność procesów jest silnie determinowana przez niepewność operacyjną i niepewność techniczną. Pierwsza z nich obejmuje opóźnienia transportu, ograniczenia organizacyjne, błędy ludzkie czy zakłócenia w koordynacji pracy podsystemów. Druga wynika m.in. z awarii maszyn, różnic w parametrach technicznych, jakości części zamiennych oraz zmiennych warunków geologicznych i środowiskowych. Współwystępowanie tych czynników powoduje, że tradycyjne deterministyczne metody oceny niezawodności często okazują się niewystarczające (Dhillon 2017; Ozdemir, Kumral 2019; Geisbus, Ariaratnam 2023).

Celem niniejszej pracy jest opracowanie koncepcji modelowania niezawodności procesów wydobywczych w warunkach niepewności operacyjnej i technicznej, która pozwoli uwzględnić zmienność parametrów i ocenić ryzyko przekroczenia krytycznych wartości niezawodnościowych. Zaproponowana koncepcja integruje podejście deterministyczne i probabilistyczne, wykorzystując m.in. modelowanie strukturalne, dopasowanie rozkładów statystycznych oraz symulacje Monte Carlo.

Realizacja tego celu ma charakter aplikacyjny – ukierunkowany na dostarczenie narzędzia wspierającego decyzje w zakresie utrzymania ruchu, planowania produkcji i optymalizacji procesów w górnictwie.

## 1.1. Uzasadnienie wyboru tematu

Współczesny przemysł wydobywczy stoi przed szeregiem wyzwań związanych z zapewnieniem ciągłości, bezpieczeństwa i efektywności operacyjnej procesów. Zakłócenia

w przebiegu wydobywania – spowodowane awariami technicznymi, opóźnieniami logistycznymi, zmiennością warunków geologicznych lub nieplanowanymi przerwami organizacyjnymi – prowadzą do wymiernych strat ekonomicznych i obniżenia zdolności produkcyjnej. W tych realiach niezawodność procesowa staje się parametrem kluczowym dla jakości i stabilności funkcjonowania przedsiębiorstwa (Dhillon 2008; Birolini 2017).

Jednocześnie praktyka pokazuje, że niezawodność procesów jest determinowana dwiema nakładającymi się sferami niepewności: techniczną (awarie, degradacja elementów, rozrzut parametrów) oraz operacyjną (zmiany harmonogramów, braki kadrowe, zakłócenia koordynacji). Tradycyjne, deterministyczne metody oceny niezawodności – przydatne na poziomie pojedynczych urządzeń – okazują się niewystarczające, gdy celem jest opis całego procesu jako układu dynamicznego, złożonego z wielu współzależnych podsystemów (Cai i inni 2018; Ozdemir, Kumral 2019; Geisbush, Ariaratnam 2023). To właśnie na poziomie procesu ujawniają się wtórne efekty opóźnień i propagacja zakłóceń, których proste ujęcia nie potrafią wiarygodnie uchwycić. W tym kontekście coraz częściej zwraca się uwagę na wykorzystanie metod probabilistycznych i sieci bayesowskich w ocenie niezawodności systemów górniczych (Li i inni 2019).

Równolegle narasta presja konkurencyjna i energetyczna oraz postępuje transformacja ku Przemysłowi 4.0. W ostatnich latach na znaczeniu zyskały rozwiązania predykcyjnego utrzymania ruchu (ang. *Predictive Maintenance*, PdM), wspierane przez uczenie maszynowe, sztuczną inteligencję i cyfrowe bliźniaki. Badania przeglądowe i studia przypadków wskazują, że odpowiednio wdrożone strategie PdM pozwalają ograniczać nieplanowane przestoje i podnosić dyspozycyjność kluczowych maszyn górniczych (Dayo-Olupona i inni 2023; Rojas i inni 2025). Są to jednak w przeważającej mierze podejścia skupione na komponentach. Aby przełożyć te korzyści na stabilność całego procesu, potrzebne jest ujęcie, które łączy dane operacyjne z modelowaniem relacji między podsystemami i uwzględnia niepewność na poziomie procesu.

W odpowiedzi na te potrzeby w niniejszej monografii zaproponowano autorską koncepcję modelowania niezawodności procesów wydobywczych w warunkach wysokiej niepewności operacyjnej i technicznej. Koncepcja integruje podejście systemowe i probabilistyczne, a jednocześnie pozostaje spójna z praktykami PdM. Dzięki temu stanowi pomost między analizą komponentów a wiarygodną oceną niezawodności całego procesu, dostarczając podstaw do decyzji w obszarze utrzymania ruchu, planowania i optymalizacji produkcji.

## **1.2. Sformułowanie problemu badawczego**

Dotychczasowe podejścia do oceny niezawodności w górnictwie pozostają fragmentaryczne i często ograniczają się do analizy pojedynczych komponentów technicznych, takich jak maszyny czy urządzenia, bez pełnego ujęcia procesowego. Tymczasem proces wydobywczy ma charakter systemu złożonego, w którym sprzężenia zwrotne, zależności organizacyjne

i zakłócenia wtórne odgrywają równie istotną rolę, jak parametry eksploatacyjne poszczególnych elementów.

W literaturze dominują metody klasyczne, skoncentrowane na wskaźnikach takich jak średni czas między uszkodzeniami (ang. *Mean Time between Failures*, MTBF), intensywność uszkodzeń  $\lambda$ , funkcja niezawodności  $R(t)$ , czy analizy typu FMEA (ang. *Failure Mode and Effects Analysis*), które mają wysoką wartość w ocenie komponentowej (Dhillon 2017). Jednak rzadko obejmują one całe procesy produkcyjne, rozumiane jako dynamiczne układy techniczno-organizacyjne, w których występują zjawiska propagacji opóźnień, kumulacji zakłóceń czy nieliniowych zależności między podsystemami (Cai i inni 2018; Geisbush, Ariaratnam 2023).

Problem pogłębia się w kontekście rosnącej dostępności danych procesowych – generowanych m.in. przez systemy monitoringu maszyn, systemy MES (ang. *Manufacturing Execution System*) i WMS (ang. *Warehouse Management System*), a także rozwiązania typu IoT (ang. *Internet of Things*). Dane te są potencjalnym źródłem wiedzy o zachowaniu procesu, jednak ich wykorzystanie jest ograniczone przez ograniczoną jakość i kompletność (wynikającą z braków pomiarowych, błędów rejestracji czy niejednorodnych formatów), heterogeniczność źródeł (obejmującą zarówno dane techniczne, jak i organizacyjne) oraz niepewność i zmienność warunków eksploatacyjnych. W efekcie modele deterministyczne okazują się niewystarczające do uchwycenia rzeczywistych uwarunkowań pracy systemu (van der Aalst 2016; Brzychczy 2019).

Złożoność problemu wynika więc z wielości czynników zakłócających, dynamicznego charakteru zmian w warunkach geologicznych i organizacyjnych, a także z trudności w praktycznym wykorzystaniu danych do celów predykcyjnych i decyzyjnych. W ostatnich latach wskazuje się na potrzebę rozwijania podejść integrujących klasyczną inżynierię niezawodności z metodami probabilistycznymi, analizą danych i narzędziami sztucznej inteligencji, które umożliwiłyby pełniejsze odwzorowanie procesów przemysłowych w warunkach niepewności (Dayo-Olupona i inni 2023; Rojas i inni 2025).

W świetle powyższego, sformułowany problem badawczy niniejszej rozprawy sprowadza się do pytania:

*W jaki sposób można wiarygodnie ująć i modelować niezawodność procesów wydobywczych w warunkach niepewności operacyjnej i technicznej, aby skutecznie identyfikować czynniki krytyczne, prognozować ryzyko zakłóceń i wspierać proces decyzyjny w zakresie utrzymania ciągłości produkcji?*

Aby udzielić odpowiedzi na postawione pytanie badawcze i zweryfikować założenia koncepcji modelowania niezawodności procesów w warunkach niepewności, sformułowano następujące hipotezy badawcze:

H1. Uwzględnienie niepewności operacyjnej i technicznej w modelowaniu niezawodności procesów wydobywczych zwiększa trafność prognoz i dokładność oceny ryzyka w porównaniu z podejściem deterministycznym.



- H2. Zintegrowane wykorzystanie metod strukturalnych, statystycznych i symulacyjnych umożliwia identyfikację podsystemów najbardziej wrażliwych na zmienność warunków pracy.
- H3. Opracowana koncepcja modelowania może znaleźć zastosowanie zarówno w górnictwie podziemnym, jak i odkrywkowym, pod warunkiem odpowiedniej kalibracji parametrów.
- H4. Wyniki uzyskane dzięki opracowanemu modelowi mogą wspierać praktykę zarządzania niezawodnością w zakładach górniczych, ułatwiając podejmowanie decyzji w zakresie planowania utrzymania ruchu i minimalizacji ryzyka przestojów.

### 1.3. Cel i zakres pracy

Głównym celem niniejszej rozprawy jest opracowanie i empiryczna weryfikacja autorskiej koncepcji modelowania niezawodności procesów wydobywczych, która uwzględnia zmienność operacyjną i techniczną w rzeczywistych warunkach eksploatacyjnych. Koncepcja ta opiera się na integracji podejścia systemowego i probabilistycznego, umożliwiając identyfikację czynników krytycznych, prognozowanie ryzyka zakłóceń oraz formułowanie praktycznych rekomendacji wspierających zarządzanie ciągłością produkcji.

Zakres pracy obejmuje:

- analizę pojęcia niezawodności w kontekście procesów wydobywczych, z uwzględnieniem specyfiki układów techniczno-organizacyjnych;
- klasyfikację i charakterystykę źródeł niepewności operacyjnej i technicznej wpływających na przebieg procesu;
- dobór i implementację narzędzi modelowania probabilistycznego, takich jak dopasowanie rozkładów statystycznych, modelowanie systemowe oraz symulacje Monte Carlo;
- opracowanie procedury integrującej modele deterministyczne i probabilistyczne w ujęciu procesowym;
- weryfikację zaproponowanej koncepcji na podstawie danych empirycznych pochodzących z wybranego zakładu wydobywczego;
- analizę i interpretację wyników, a także sformułowanie wniosków i rekomendacji praktycznych dla przemysłu górniczego.

Realizacja powyższych zadań pozwoli nie tylko na ocenę przydatności zaproponowanego podejścia, ale także na wskazanie potencjalnych kierunków jego zastosowania w praktyce przemysłowej i dalszych badań naukowych.

Wartość dodana niniejszej pracy ma zarówno wymiar teoretyczny, jak i praktyczny. Z perspektywy naukowej, opracowana koncepcja modelowania niezawodności procesów wydobywczych stanowi rozwinięcie klasycznych ujęć inżynierii niezawodności, które koncentrowały się dotąd głównie na poziomie komponentów technicznych. Przeniesienie akcentu na poziom całych procesów – traktowanych jako dynamiczne układy techniczno-organizacyjne –

umożliwia pełniejsze odwzorowanie rzeczywistych zjawisk, takich jak propagacja opóźnień, sprzężenia zwrotne czy kumulacja zakłóceń. Wprowadzenie podejścia probabilistycznego pozwala dodatkowo uchwycić inherentną niepewność danych i zmienność warunków eksploatacyjnych, co dotychczas było w literaturze ujęte w sposób fragmentaryczny.

Z perspektywy praktyki przemysłowej, zaproponowana koncepcja dostarcza narzędzia wspierającego proces decyzyjny w zakresie utrzymania ciągłości produkcji i planowania eksploatacji. Model umożliwia identyfikację krytycznych elementów procesu, ocenę wrażliwości systemu na zakłócenia oraz prognozowanie ryzyka przestojów. Wyniki analiz mogą stanowić podstawę do:

- doskonalenia strategii utrzymania ruchu (w tym predykcyjnego utrzymania opartego na danych);
- optymalizacji harmonogramów eksploatacyjnych;
- lepszego wykorzystania dostępnych danych z systemów monitoringu, MES i IoT;
- wdrażania rozwiązań zgodnych z ideą Przemysłu 4.0 i cyfrowych bliźniaków w górnictwie.

Wartość dodaną pracy stanowi zatem zarówno oryginalny wkład w rozwój metodyki niezawodności procesowej, jak i praktyczne wskazania dla sektora wydobywczego, które mogą przyczynić się do redukcji kosztów, zwiększenia dyspozycyjności technicznej oraz poprawy bezpieczeństwa pracy.

## **1.4. Struktura rozprawy**

Niniejsza monografia została podzielona na osiem zasadniczych rozdziałów, z których każdy pełni odrębną, lecz komplementarną funkcję w realizacji przyjętego celu badawczego.

W pierwszym rozdziale pracy przedstawiono wprowadzenie do problematyki badawczej. Uzasadniono w niej wybór tematu, sformułowano problem badawczy, określono cel i zakres badań oraz hipotezy, a także wskazano wartość dodaną rozprawy. Wprowadzenie wyznacza ramy merytoryczne opracowania, osadzając je w szerszym kontekście współczesnych badań nad niezawodnością procesów wydobywczych.

Rozdział drugi ma charakter teoretyczno-przeglądowy. Zgromadzono w nim podstawową wiedzę z zakresu niezawodności procesowej, dokonano charakterystyki procesów wydobywczych i źródeł niepewności towarzyszących ich realizacji, a także przeanalizowano istniejące podejścia deterministyczne i probabilistyczne. Przegląd literatury pozwolił zidentyfikować lukę badawczą oraz uzasadnić potrzebę opracowania zintegrowanego modelu systemowo-probabilistycznego.

W rozdziale trzecim, poświęconym metodyce badań, opisano przyjętą koncepcję badawczą, sposób gromadzenia i przygotowania danych oraz metody oceny niezawodności wykorzystane w analizach. Uzupełnieniem tego fragmentu jest prezentacja zastosowanych

narzędzi analitycznych i symulacyjnych, a także zasad doboru parametrów wejściowych i kryteriów oceny jakości uzyskanych wyników.

Treść rozdziału czwartego koncentruje się na procesie modelowania niezawodności procesów wydobywczych. Zaprezentowano w nim opis analizowanego systemu, założenia i ograniczenia modelu, konstrukcję modelu probabilistycznego oraz sposób integracji podejścia deterministycznego i probabilistycznego. Opracowany model stanowi podstawę do ilościowej oceny niezawodności w warunkach niepewności operacyjnej i technicznej, umożliwiając pogłębione wnioskowanie o funkcjonowaniu złożonych systemów wydobywczych.

W rozdziale piątym przedstawiono proces walidacji opracowanego modelu. Omówiono przyjęte metody weryfikacji, dobór danych testowych, procedurę porównania wyników modelowych z obserwacjami empirycznymi oraz ocenę skuteczności modelu w warunkach niepewności.

Empiryczna weryfikacja koncepcji, stanowiąca treść rozdziału szóstego, została przeprowadzona na wybranym przykładzie. Dokonano analizy przyczyn przestojów w wybranej kopalni, dokonano walidacji modelu na rzeczywistych danych oraz porównano uzyskane wyniki z innym obiektem badawczym.

Rozdział siódmy zawiera dyskusję wyników. Zestawiono w nim uzyskane rezultaty z wnioskami płynącymi z literatury, wskazano ich znaczenie praktyczne i metodyczne, a także omówiono ograniczenia przeprowadzonych badań. Dyskusja obejmuje również możliwe kierunki dalszego rozwoju koncepcji, w tym integrację z metodami predykcyjnymi oraz systemami wspomagania decyzji w górnictwie.

Zwieńczeniem monografii jest rozdział ósmy, w którym sformułowano wnioski końcowe i rekomendacje dla praktyki przemysłowej. Podsumowano kluczowe rezultaty badań, przedstawiono ich znaczenie dla teorii i praktyki zarządzania niezawodnością, a także zaproponowano potencjalne kierunki przyszłych prac badawczych ukierunkowanych na doskonalenie metod oceny niezawodności procesów wydobywczych.

## 2. Przegląd literatury i podstawy teoretyczne

Rozdział 2 stanowi przegląd literatury i podstaw teoretycznych związanych z niezawodnością systemów technicznych i procesowych w górnictwie. Jego celem jest wskazanie kluczowych definicji, modeli i podejść, które tworzą podstawę dla dalszej części monografii. Analiza ta pozwala nie tylko zrozumieć ewolucję badań nad niezawodnością, ale także zidentyfikować ograniczenia dotychczasowych metod i zarysować lukę badawczą.

### 2.1. Wprowadzenie do problematyki niezawodności

Niezawodność stanowi jedną z kluczowych kategorii oceny jakości funkcjonowania systemów technicznych. Zgodnie z definicjami przyjętymi w normach międzynarodowych (IEC 60050-191, ISO 9000), przez niezawodność rozumie się zdolność obiektu do wykonywania wymaganych funkcji w określonych warunkach i w danym przedziale czasu. Definicja ta ma charakter probabilistyczny i uwzględnia zarówno aspekty techniczne, jak i eksploatacyjne (Tobias, Trindade 2011; Birolini 2017; Dhillon 2017).

Początkowo badania nad niezawodnością koncentrowały się głównie na elementach mechanicznych i elektrycznych, traktując system jako zbiór komponentów. Z czasem uwaga badaczy przesunęła się w stronę niezawodności systemowej, w której kluczowe znaczenie ma konfiguracja połączeń między elementami, redundancja oraz architektura logiczna układu (Modarres i inni 2016). Współcześnie coraz większe znaczenie przypisuje się także niezawodności procesowej, odnoszącej się do zdolności całego ciągu działań do stabilnej i zgodnej z planem realizacji celów produkcyjnych.

Podstawowe zależności matematyczne wykorzystywane w analizach niezawodności obejmują (Leemis 2009; Birolini 2017; Elsayed 2021):

- Funkcję niezawodności – określającą prawdopodobieństwo, że czas do uszkodzenia  $T$  przekroczy zadaną wartość  $t$ :

$$R(t) = P(T > t) = 1 - F(t) \quad (1)$$

gdzie  $F(t)$  jest dystrybuantą czasu do uszkodzenia.

- Funkcję intensywności uszkodzeń (ang. *hazard rate*) – opisującą chwilowe tempo uszkodzeń elementu lub systemu:

$$\lambda(t) = \frac{f(t)}{R(t)} \quad (2)$$

gdzie  $f(t)$  oznacza gęstość prawdopodobieństwa czasu do uszkodzenia.

- Średni czas bezawaryjnej pracy (ang. *Mean Time between Failures*, MTBF):

$$\text{MTBF} = \int_0^{\infty} R(t) dt \quad (3)$$

- Średni czas do naprawy (ang. *Mean Time to Repair*, MTTR) – wyrażony jako wartość oczekiwana losowego czasu trwania naprawy:

$$\text{MTTR} = E [T_r] \quad (4)$$

- Dostępność operacyjna systemu, wyrażona jako:

$$A = \frac{\text{MTBF}}{\text{MTBF} + \text{MTTR}} \quad (5)$$

Powyższe wielkości stanowią fundament klasycznej analizy niezawodności komponentów i systemów technicznych. W dalszych rozdziałach zostaną one rozszerzone o perspektywę procesową, w której kluczowe znaczenie mają zjawiska propagacji zakłóceń i wtórnych efektów opóźnień, niedostrzegalne w prostych modelach komponentowych.

Do opisu czasu do uszkodzenia stosuje się różne rozkłady statystyczne, z których najważniejsze to (Rausand, Høyland 2020):

- rozkład wykładniczy – zakładający stałe tempo uszkodzeń,
- rozkład Weibulla – uniwersalny i elastyczny, pozwalający modelować zarówno fazę wczesnych awarii, jak i zużycia,
- rozkład log-normalny – użyteczny w analizie trwałości elementów mechanicznych.

Parametry rozkładów estymuje się najczęściej metodą największej wiarygodności (ang. *Maximum Likelihood Estimation*, MLE) lub metodą momentów. W literaturze wskazuje się, że współczesne wyzwania niezawodnościowe związane są z rosnącą złożonością systemów technicznych, niepewnością parametrów oraz koniecznością uwzględniania interakcji pomiędzy komponentami i procesami (Zio 2016). Klasyczne podejścia deterministyczne okazują się w tym kontekście niewystarczające. Coraz większe znaczenie zyskują więc metody probabilistyczne, symulacyjne (Monte Carlo) oraz modele bazujące na sztucznej inteligencji i sieciach bayesowskich, które pozwalają uchwycić propagację zakłóceń oraz wtórne efekty opóźnień w systemach złożonych (Feng i inni 2024; Li i inni 2024).

W kontekście procesów wydobywczych szczególnie istotna jest ciągłość i odporność przebiegu działań na zakłócenia i czynniki losowe. Zakłócenia występujące w jednym etapie (np. awaria transportu) mogą szybko propagować się w całym łańcuchu technologicznym, prowadząc do przestojów o wymiernych skutkach ekonomicznych. Dlatego niezawodność powinna być analizowana nie tylko na poziomie komponentów, lecz także całych procesów – co stanowi punkt wyjścia do dalszych rozważań w niniejszej pracy.

## **2.2. Pojęcie niezawodności procesowej – definicja i zakres interpretacyjny**

W literaturze przedmiotu pojęcie niezawodności (ang. *reliability*) odnosi się najczęściej do zdolności systemu technicznego do wykonywania przypisanych mu funkcji przez określony czas, w zadanych warunkach eksploatacyjnych, bez wystąpienia awarii lub zakłóceń (Leemis 2009; Modarres i inni 2016; Birolini 2017; Dhillon 2017). Ujęcie to jest szeroko stosowane w analizach komponentów i układów technicznych, zwłaszcza w kontekście urządzeń mechanicznych, elektronicznych i systemów zautomatyzowanych. Wskaźniki takie jak MTBF,  $R(t)$  (prawdopodobieństwo bezawaryjnej pracy w czasie  $t$ ), intensywność uszkodzeń  $\lambda$  czy średni czas naprawy MTTR, stanowią podstawę oceny niezawodności elementów fizycznych.

Współczesne procesy przemysłowe, a w szczególności procesy wydobywcze, charakteryzują się znacznie większym stopniem złożoności niż w ujęciach klasycznych. Stanowią one układy dynamiczne i wieloelementowe, podatne na zakłócenia geologiczno-górnice oraz techniczno-organizacyjne. O sukcesie operacyjnym nie decyduje więc wyłącznie sprawność poszczególnych urządzeń (niezawodność obiektu technicznego – maszyny, urządzenia), lecz przede wszystkim ciągłość, spójność i przewidywalność przebiegu całego procesu – od urabiania złoza, przez transport urobku, aż po jego odstawę i przeróbkę (niezawodność systemu technicznego – zestaw maszyn, urządzeń). W krajowej literaturze można znaleźć publikacje poruszające problematykę przebiegu procesu produkcji górniczej, jego niezawodności, efektywności oraz oceny wykorzystania maszyn i urządzeń w polskim górnictwie węgla kamiennego (Macha 2001; Czaplicki i inni 2013; Snopkowski i inni 2016; Brodny, Stecula 2016).

W odpowiedzi na te ograniczenia, niniejsza praca wprowadza i rozwija pojęcie niezawodności procesowej, rozumianej jako zdolność całego procesu przemysłowego do realizacji założonych funkcji w sposób ciągły, stabilny i zgodny z planem, w warunkach rzeczywistej zmienności operacyjnej i technicznej. W przeciwieństwie do tradycyjnego ujęcia skoncentrowanego na komponentach, niezawodność procesowa ma charakter holistyczny – odnosi się do całego systemu procesowego jako dynamicznego układu współzależnych elementów (Jin 2019; Elsayed 2021).

Podstawowe elementy składowe niezawodności procesowej obejmują:

- dostępność operacyjną, czyli zdolność zasobów technicznych i organizacyjnych do wykonywania zadań w zaplanowanym czasie;
- ciągłość przebiegu procesu, oznaczającą brak nieplanowanych przerw i zakłóceń powodujących zatrzymanie przepływu materiału, informacji lub decyzji;
- przewidywalność działania, rozumianą jako stabilność czasową i jakościową wykonywanych operacji;
- odporność na zakłócenia (ang. *robustness*), jako zdolność do utrzymania funkcjonalności pomimo wystąpienia niekorzystnych zdarzeń;
- koordynację funkcji technicznych i organizacyjnych, czyli zdolność systemu do skutecznego integrowania działań ludzi, maszyn i procedur.

Zatem niezawodność procesowa mieści w sobie zarówno klasyczne parametry niezawodności technicznej, jak i elementy związane z operacyjną sprawnością procesu: terminowością, kompletnością realizacji zadań, synchronizacją zasobów, a nawet aspektami behawioralnymi (np. zdolność do adaptacji w sytuacjach awaryjnych).

Zjawiska podobne do niezawodności procesowej są obecne w literaturze jako:

- *operational reliability* (Odeyar i inni 2022; Liu J. i inni 2025),
- *process robustness* (Lu, Shen 2021),
- *resilience in process industries* (Azadeh, Zarrin 2016; Hollnagel i inni 2019).

Jednak żadne z tych pojęć nie uwzględnia jednocześnie wielowymiarowości procesu, powiązań między jego składowymi oraz probabilistycznej natury jego funkcjonowania w zmieniających warunkach eksploatacyjnych (Moniri-Morad i inni 2022; Malozyomov i inni 2024).

Podsumowując przedstawione rozważania, w niniejszej pracy proponuje się następującą definicję niezawodności procesowej:

*Niezawodność procesowa to zdolność procesu przemysłowego – rozumianego jako układ złożony i dynamiczny – do nieprzerwanej, stabilnej i zgodnej z planem realizacji przypisanych mu funkcji w obecności niepewności technicznej, operacyjnej i środowiskowej.*

Zaproponowane ujęcie zakłada, że niezawodność procesowa nie wynika wyłącznie z niezawodności poszczególnych elementów, lecz stanowi właściwość całego systemu, uwarunkowaną także organizacją pracy, koordynacją działań oraz zdolnością reagowania na zmienność warunków.

Z punktu widzenia zastosowań praktycznych, niezawodność procesowa może być mierzona poprzez integrację:

- klasycznych wskaźników technicznych (np. dostępność maszyn);
- wskaźników przebiegu procesu (np. odsetek nieukończonych cykli, średni czas cyklu);
- oraz miar probabilistycznych (np. prawdopodobieństwo zakłócenia w oknie czasowym, rozrzut czasów realizacji).

Koncepcja ta stanowi podstawę dalszych analiz i zostanie wykorzystana do budowy modelu probabilistycznego, który zostanie zweryfikowany empirycznie na danych z procesu wydobywczego.

## 2.3. Modele niezawodnościowe – podejścia deterministyczne i probabilistyczne

Modelowanie niezawodności jest kluczowym narzędziem wspierającym analizę funkcjonowania systemów technicznych i procesowych. Pozwala nie tylko na opis przeszłych zdarzeń, ale przede wszystkim na prognozowanie przyszłych stanów systemu, identyfikację elementów krytycznych oraz wspieranie decyzji utrzymaniowych i organizacyjnych. W literaturze wyróżnia się dwa podstawowe nurty modelowania niezawodnościowego: deterministyczny, skupiony na strukturze systemu i jego logicznej dekompozycji, oraz probabilistyczny, uwzględniający niepewność i zmienność zjawisk (Tobias, Trindade 2011; Modarres i inni 2016; Birolini 2017; Rausand, Høyland 2020). Kluczowe znaczenie mają tu metody analizy danych żywotności (ang. *life data analysis*), które umożliwiają estymację rozkładów czasów do uszkodzeń oraz parametryzację modeli niezawodnościowych (Nelson 2004).

Do klasycznych narzędzi deterministycznych należą:

- Schematy blokowe niezawodności (ang. *Reliability Block Diagrams*, RBD), które przedstawiają system jako układ bloków połączonych w konfiguracji szeregowej, równoległej lub mieszanej. Ich zaletą jest prostota i intuicyjność, jednak ograniczeniem pozostaje brak możliwości modelowania zależności dynamicznych i probabilistycznych. W literaturze wskazuje się, że metoda ta dobrze sprawdza się w prostych systemach o ustalonej strukturze logicznej (Barlow, Proschan 1996).
- Drzewa błędów (ang. *Fault Tree Analysis*, FTA), czyli technika hierarchicznej dekompozycji zdarzeń niepożądanych z uwagi na ich przyczyny pierwotne. Umożliwia identyfikację ścieżek krytycznych prowadzących do awarii systemu. FTA jest jednym z najbardziej rozpowszechnionych narzędzi inżynierii niezawodności, opisanym m.in. przez Ericsona (1999) oraz Rausanda i Høylanda (2020). Wadą tej metody jest założenie niezależności między zdarzeniami oraz statyczny charakter analizy, co ogranicza jej zastosowanie w systemach dynamicznych.
- Modele logiczne (analiza boolowska), które przedstawiają system jako układ elementów połączonych szeregowo i równolegle, co umożliwia odwzorowanie efektu rezerwowych komponentów. Są to najprostsze formalizacje matematyczne, w których niezawodność systemu wyznacza się jako kombinację niezawodności jego elementów. Podstawy te zostały przedstawione już w klasycznych opracowaniach Barłowa i Proschana (1996), a następnie rozwijane w podręcznikach Biroliniego (2017) i Modarresa, Kaminskiy’ego i Krivtsova (2016). Modele te sprawdzają się przy prostych układach, ale są niewystar-



czające dla systemów o charakterze procesowym, w których występuje propagacja zakłóceń.

Choć modele deterministyczne stanowią fundament teorii niezawodności, ich zastosowanie w analizie procesów wydobywczych jest ograniczone, gdyż nie oddają w pełni zmienności i niepewności towarzyszącej eksploatacji (Rausand, Høyland 2020).

Znacznie bogatsze możliwości analityczne oferują modele probabilistyczne, które w sposób jawny uwzględniają losowość i zmienność zdarzeń. Do najczęściej stosowanych należą:

- Rozkłady statystyczne czasu życia, spośród których w analizie niezawodności stosuje się m.in.:
  - Rozkład Weibulla – najbardziej uniwersalny spośród rozkładów stosowanych w analizie niezawodności. Pozwala modelować zarówno wczesne awarie, jak i fazę zużycia. Najczęściej wykorzystywany jest do modelowania czasu do awarii maszyn i elementów mechanicznych (np. kombajnów, przenośników). Charakteryzuje się dużą elastycznością, ponieważ w zależności od wartości parametru kształtu  $\beta$  może odwzorować fazę awarii wczesnych ( $\beta < 1$ ), losowych ( $\beta = 1$ ) lub związanych ze zużyciem ( $\beta > 1$ ). Opisują go następujące zależności:

$$R(t) = e^{-\left(\frac{t}{\eta}\right)^\beta}, \quad f(t) = \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1} e^{-\left(\frac{t}{\eta}\right)^\beta} \quad (6)$$

gdzie:  $\beta$  – parametr kształtu,  $\eta$  – parametr skali.

- Rozkład wykładniczy – szczególny przypadek Weibulla dla  $\beta = 1$ . Opisuje sytuacje, w których ryzyko awarii jest stałe i nie zależy od wieku elementu. Typowe zastosowania obejmują układy elektroniczne oraz pomocnicze systemy sterowania (Dhillon 2017). Rozkład ten jest odpowiedni w przypadku stałej intensywności uszkodzeń i opisują go zależności:

$$R(t) = e^{-\lambda t}, \quad f(t) = \lambda e^{-\lambda t} \quad (7)$$

gdzie  $\lambda$  oznacza intensywność uszkodzeń (stała w czasie).

- Rozkład log-normalny – stosowany do procesów, w których czas do awarii wynika z akumulacji wielu drobnych, losowych efektów (np. degradacja łożysk, zużycie taśm transportowych). Dobrze odwzorowuje zjawiska charakteryzujące się asymetrią danych oraz występowaniem „okresu dojrzewania” do awarii (Nelson 2004; Tobias, Trindade 2011; Birolini 2017). Rozkład ten jest przydatny do opisu trwałości elementów mechanicznych oraz procesów, w których obserwuje się dużą zmienność czasów życia. Wyrażany jest wzorem:

$$R(t) = 1 - \Phi\left(\frac{\ln t - \mu}{\sigma}\right), f(t) = \frac{1}{t\sigma\sqrt{2\pi}} \exp\left(-\frac{(\ln t - \mu)^2}{2\sigma^2}\right) \quad (8)$$

gdzie:  $\mu$  – wartość średnia logarytmu czasu do awarii,  $\sigma$  – odchylenie standardowe logarytmu czasu do awarii, a  $\Phi$  – dystrybuenta standardowego rozkładu normalnego.

- Rozkład gamma – przydatny w modelowaniu procesów o wysokiej zmienności, w których awarie są efektem sekwencji zdarzeń. W górnictwie znajduje zastosowanie m.in. do analizy systemów hydraulicznych i pneumatycznych (Rausand, Høyland 2020). Wykorzystywany w modelowaniu procesów kumulacyjnych, np. degradacji. Obliczany zgodnie z formułami:

$$R(t) = 1 - \frac{\gamma(k, t/\theta)}{\Gamma(k)}, f(t) = \frac{1}{\Gamma(k)\theta^k} t^{k-1} e^{-\frac{t}{\theta}} \quad (9)$$

gdzie:  $k$  – parametr kształtu,  $\theta$  – parametr skali,  $\Gamma(k)$  – funkcja gamma Eulera oraz  $\gamma(k, t/\theta)$  – niezupełna funkcja gamma.

Klasyczne podstawy teoretyczne tych rozkładów opisali m.in. Barlow i Proschan (1996).

- Procesy Markowa, które umożliwiają modelowanie przejść systemu pomiędzy różnymi stanami (np. sprawny, uszkodzony, w naprawie). W języku matematycznym ich zapis jest następujący:

$$\frac{dP_s(t)}{dt} = -\lambda P_s(t) + \mu P_F(t), \frac{dP_F(t)}{dt} = \lambda P_s(t) - \mu P_F(t) \quad (10)$$

gdzie:  $\lambda$  – intensywność uszkodzeń,  $\mu$  – intensywność napraw.

Ich przydatność w analizie sprzętu górniczego, w szczególności wozów ładująco-transportowo-wyładowczych (ang. *Loud-Haul-Dump*, LHD), wykazali Kumar i Klefsjö (1992), którzy zastosowali model procesu potęgowego (ang. *Power Law Process*, PLP) do oceny niezawodności systemów hydraulicznych.

- Symulacje Monte Carlo, które pozwalają na odwzorowanie złożonych scenariuszy i analizę wrażliwości systemu na zmienność parametrów. W praktyce górniczej metoda ta umożliwia realistyczną ocenę funkcjonowania złożonych systemów, co potwierdzają badania Harish Kumar i inni (2022), w których oceniano efektywność pracy sprzętu w kopalniach odkrywkowych.

Ogólny zapis matematyczny takiej symulacji przedstawia się następująco:

$$\hat{R}(t) = \frac{1}{N} \sum_{i=1}^N I(T_i > t) \quad (11)$$

gdzie:  $N$  – liczba symulacji,  $I(\cdot)$  – funkcja wskaźnikowa,  $T_i$  – wygenerowane czasy życia.

- Sieci niezawodnościowe i modele bayesowskie, umożliwiające modelowanie zależności przyczynowo-skutkowych i propagacji zakłóceń w systemach. Weber, Simon i Medina-Oliva (2010) przedstawili przegląd zastosowań sieci bayesowskich w analizie niezawodności i utrzymania, wskazując na ich przewagę w badaniu systemów złożonych i niepewnych. Z kolei Boudali i Dugan (2005) zaproponowali ramy analizy w czasie dyskretnym, które umożliwiają formalne odwzorowanie stanów systemu w ujęciu probabilistycznym.

Sieci bayesowskie dla zdarzeń  $X_1, \dots, X_n$  zapisujemy zależnością:

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | Pa(X_i)) \quad (12)$$

gdzie  $Pa(X_i)$  oznacza zbiór rodziców zmiennej  $X_i$ , czyli bezpośrednich przyczyn w strukturze sieci.

Oprócz samego przeglądu metod istotne jest także określenie kryteriów, które warunkują wybór konkretnego modelu w badaniach niezawodnościowych. Kluczowe znaczenie ma przede wszystkim dostępność danych – jeśli dysponujemy pełnymi i szczegółowymi rejestrami awarii oraz napraw, możliwe jest zastosowanie procesów Markowa lub symulacji Monte Carlo (Modarres i inni 2016; Elsayed 2021). W przypadku danych fragmentarycznych lub niepełnych skutecznym rozwiązaniem są sieci bayesowskie, które umożliwiają łączenie informacji empirycznych z wiedzą ekspercką (Boudali, Dugan 2005; Weber i inni 2010). Podobne podejście zaproponowali de Jesus Santos i współpracownicy (2020), wskazując na użyteczność metod probabilistycznych w modelowaniu systemów technicznych o wysokim stopniu złożoności.

Ważnym kryterium jest również złożoność badanego systemu. Dla prostych układów wystarczające bywają metody deterministyczne, takie jak schematy blokowe czy analiza boolowska, podczas gdy w systemach dynamicznych i wieloelementowych konieczne jest zastosowanie podejść probabilistycznych (Barlow, Proschan 1996; Rausand, Høyland 2020). Istotny jest także cel analizy – jeżeli priorytetem jest diagnostyka i identyfikacja przyczyn awarii, przydatne są drzewa błędów (Ericson 1999), natomiast prognozowanie niezawodności i ocena ryzyka wymagają narzędzi probabilistycznych (Zio 2016). Ostatecznie decyduje także charakter badanego systemu. W procesach wydobywczych szczególnie istotna

jest możliwość odwzorowania propagacji zakłóceń pomiędzy kolejnymi etapami produkcji, co sprawia, że najlepiej sprawdzają się metody probabilistyczne i sieciowe (Kumar, Klefsjö 1992; Harish Kumar i inni 2022).

W niniejszej monografii szczególny nacisk położono na modele probabilistyczne, ponieważ jedynie one pozwalają realistycznie uchwycić zmienność i niepewność warunków eksploatacyjnych w górnictwie. W kolejnych rozdziałach przedstawiono integrację klasycznych narzędzi niezawodności z metodami probabilistycznymi – w szczególności rozkładami statystycznymi, symulacją Monte Carlo oraz podejściem bayesowskim. Dzięki temu możliwe było odwzorowanie procesów wydobywczych jako układów dynamicznych, w których zakłócenia propagują się w czasie i przestrzeni, generując wtórne efekty w całym systemie. Przedstawione metody stanowią punkt wyjścia do dalszych analiz probabilistycznych, które w niniejszej monografii zastosowano do procesów wydobywczych.

## **2.4. Charakterystyka procesu wydobywczego**

Proces wydobywczy można zdefiniować jako ciąg technologicznie i organizacyjnie powiązanych operacji, których celem jest pozyskanie kopaliny ze złoża i dostarczenie jej do zakładu przerobczego lub bezpośrednio do sprzedaży. W literaturze podkreśla się, że jest to proces złożony, dynamiczny i wieloetapowy, a jego przebieg zależy od czynników zewnętrznych, takich jak uwarunkowania geologiczno-górniczne oraz środowiskowe, a także od sposobu organizacji pracy (Hartman, Mutmanský 2002; Hustrulid i inni 2018).


Z punktu widzenia niezawodności procesowej istotne jest, aby analizować proces wydobywczy na poziomie całego systemu. Zakłócenia występujące w jednym jego węźle mogą bowiem propagować się dalej, powodując przestoje i straty w kolejnych etapach. Transport wewnętrzny jest tego dobrym przykładem – jego awaryjność może skutecznie zatrzymać cały łańcuch produkcyjny, niezależnie od wydajności maszyn urabiających (Kumar, Klefsjö 1992; Dhillon 2008).

Proces wydobywczy składa się z kilku podstawowych etapów (rys. 2.1), które można traktować jako logiczny łańcuch operacji (Hustrulid i inni 2018; Hartman, Mutmanský 2002), a są to:

1. Przygotowanie złoża – polegające na drażeniu wyrobisk korytarzowych w górnictwie podziemnym lub zdejmowanie nadkładu w odkrywcę, wraz z budową różnych systemów technologicznych.
2. Urabianie – oddzielanie kopaliny od calizny metodami mechanicznymi (np. z wykorzystaniem kombajnów lub strugów albo metodami strzałowymi z wykorzystaniem materiałów wybuchowych).
3. Ładowanie – przenoszenie urobku na środki jego odstawy (przenośniki zgrzeblowe i taśmowe), przy użyciu kombajnu lub ładowarek.

4. Transport poziomy – odstawa urobku do punktu jego wydawania na powierzchnię, z wykorzystaniem przenośników taśmowych lub odstawy kołowej oraz transport ludzi i materiałów z wykorzystaniem kolejek podwieszanych lub wozów.
5. Transport pionowy – transport urobku na powierzchnię szczybami lub wyrobiskami pochyłymi, z wykorzystaniem skipów lub przenośników taśmowych.
6. Przeróbka – rozdrabnianie, przesiewanie, wzbogacanie w celu uzyskania węgla handlowego o wymaganych parametrach jakościowych.

Choć kolejne etapy są z pozoru uporządkowane, w praktyce tworzą system silnie sprzężony, w którym każdy element ma wpływ na całość. Dla niezawodności oznacza to konieczność badania procesów jako sieci zależności, a nie odizolowanych modułów.



**Rys. 2.1.** Schemat procesu wydobywczego

Źródło: opracowanie własne na podstawie Hartman, Mutmanský 2002; Hustrulid i inni 2018

Jak pokazano na rysunku 2.1, wszystkie etapy procesu tworzą spójny i współzależny system, w którym awaria lub spowolnienie jednego z elementów może zakłócić przebieg całego łańcucha produkcyjnego. W dalszej części rozdziału szczególną uwagę poświęcono cechom charakterystycznym tego systemu, które determinują jego niezawodność operacyjną.

Proces wydobywczy charakteryzuje się specyfiką, która w istotny sposób determinuje jego niezawodność operacyjną i techniczną. Na tle innych gałęzi przemysłu wyróżnia go przede wszystkim ciągłość, silne sprzężenia między etapami oraz szczególne uwarunkowania środowiskowe. Do najważniejszych cech wpływających na stabilność i bezpieczeństwo funkcjonowania procesu wydobywczego należą (Singh, Dhar 2021; Norouzi i inni 2022; Bodziony, Patyk 2024):

- Ciągłość operacyjna – większość zakładów górniczych prowadzi wydobywanie w trybie wielozmianowym lub całodobowym. Minimalizuje to czas przestojów planowanych, lecz równocześnie zwiększa prawdopodobieństwo awarii wynikających z intensywnej eksploatacji urządzeń.

- Silne powiązania międzyoperacyjne – opóźnienia lub awarie na jednym etapie (np. urabiania) natychmiast oddziałują na kolejne, generując efekt kaskadowy w całym łańcuchu produkcyjnym.
- Warunki środowiskowe – zmienność geologiczna i geomechaniczna wpływa na tempo postępu robót oraz obciążenia maszyn, a w kopalniach odkrywkowych dodatkowym źródłem niepewności są warunki atmosferyczne (np. opady, mróz, wysokie temperatury).
- Złożoność systemu transportu – system odstawy urobku stanowi zazwyczaj element wąskiego gardła procesu wydobywczego, a jego awaryjność w największym stopniu determinuje efektywność całego łańcucha technologicznego. Badania wskazują, że przenośniki taśmowe i kolejki są jednym z głównych źródeł strat produkcyjnych (Zimroz i inni 2019), przy czym szczególnie krytycznym elementem okazują się złącza taśmowe, a także przypadki niecentralnego ruchu taśmy, analizowane w badaniach laboratoryjnych (Kozłowski i inni 2020; Dąbek i inni 2023).
- Niezawodność systemów komunikacyjnych – łączność w wyrobiskach podziemnych warunkuje bezpieczeństwo pracy i skuteczną koordynację działań, a jej awarie mogą prowadzić do poważnych zakłóceń organizacyjnych (Bazargur i inni 2023).
- Wysoki udział pracy maszyn ciężkich – intensywna eksploatacja kombajnów, ładowarek czy przenośników hydraulicznych prowadzi do degradacji elementów mechanicznych i układów hydraulicznych, które są jednym z głównych źródeł zakłóceń (Dhillon 2008).

Podsumowując, proces wydobywczy należy postrzegać jako system o wysokim stopniu wzajemnych zależności, w którym każda nieciągłość przepływu może powodować kaskadowe skutki. Z tego względu analiza niezawodności musi obejmować zarówno pojedyncze urządzenia, jak i całą sieć powiązanych operacji, a także uwzględniać zmienność warunków zewnętrznych, obejmujących czynniki geologiczno-górnice, techniczno-organizacyjne i środowiskowe, które w sposób losowy wpływają na stabilność i ciągłość procesu.

Charakterystyka procesu wydobywczego różni się istotnie w zależności od typu kopalni (tab. 2.1). W kopalniach podziemnych kluczowym wyzwaniem jest złożoność transportu (kombinacja przenośników, kolejek i szybów), konieczność zapewnienia bezpieczeństwa pracy (zagrożenia naturalne, w tym w szczególności metanowe i tąpniętami) oraz ograniczenia przestrzenne dotyczące lokalizacji urządzeń i prowadzenia robót. Z kolei, w kopalniach odkrywkowych większe znaczenie mają czynniki atmosferyczne i odległości transportowe, a transport realizowany jest przez maszyny o dużej wydajności jednostkowej, takie jak samochody technologiczne czy taśmociągi wielkogabarytowe (Bodziony, Patyk 2024).

Przedstawione w tabeli różnice mają zasadnicze znaczenie przy budowie modelu niezawodności procesowej. W kopalniach podziemnych, z uwagi na wysoką niepewność warunków geologicznych i techniczno-organizacyjnych, częściej stosuje się podejścia probabilistyczne. Z kolei w kopalniach odkrywkowych większą rolę odgrywają modele deterministyczne, oparte głównie na parametrach przepustowości i wydajności transportu (Aladejare 2024).

Ważnym czynnikiem różnicującym jest także przygotowanie pracowników do pracy w zmiennych warunkach. W literaturze wskazuje się na wykorzystanie systemów zarządzania treścią (ang. *Content Management System*, CMS) w szkoleniach BHP dla górnictwa odkrywkowego, co pozwala zwiększać poziom bezpieczeństwa i świadomości ryzyka (Zujović i inni 2020). Ostatecznie, dobór metod modelowania musi być ściśle dopasowany do specyfiki danego zakładu górniczego oraz jego dominujących uwarunkowań operacyjnych.

**Tab. 2.1.** Zestawienie głównych cech górnictwa podziemnego i odkrywkowego

| Aspekt               | Górnictwo podziemne                                                         | Górnictwo odkrywkowe                       |
|----------------------|-----------------------------------------------------------------------------|--------------------------------------------|
| Transport            | przenośniki zgrzeblowe, przenośniki taśmowe, kolejki, szyby                 | samochody, taśmociągi wielkogabarytowe     |
| Bezpieczeństwo       | zagrożenia naturalne (metanowe, tąpniętami itp.)                            | warunki atmosferyczne                      |
| Przestrzeń           | ograniczona, ciasne wyrobiska                                               | otwarte środowisko                         |
| Utrzymanie ruchu     | dostęp utrudniony, interwencje planowane                                    | lepszy dostęp, większe okna serwisowe      |
| Monitoring           | SCADA, czujniki punktowe                                                    | IoT, <i>monitoring floty</i> , wideo       |
| Modelowanie          | probabilistyczne (warunki geologiczno-górniczne i techniczno-organizacyjne) | deterministyczne (wydajność transportu)    |
| Typowe wąskie gardła | transport                                                                   | przeładunki, drogi dojazdowe               |
| Kluczowe KPI         | MTBF/MTTR, prędkość postępu, dostępność                                     | przepustowość, wykorzystanie floty, koszty |

Źródło: opracowanie własne na podstawie Hartman, Mutmanský 2002; Hustrulid i inni 2018; Aladejare 2024; Bodziony, Patyk 2024

Ocena niezawodności procesowej wymaga dostępu do szerokiego spektrum danych operacyjnych i technicznych (rys. 2.2).

Dane wykorzystywane w analizie procesów wydobywczych obejmują zarówno tradycyjne źródła dokumentacyjne, jak i nowoczesne rozwiązania oparte na systemach internetu rzeczy (IoT) oraz monitoringu w czasie rzeczywistym. Wśród nich można wyróżnić:

- książki raportowe i raporty zmianowe, zawierające podstawowe informacje o przebiegu pracy i organizacji procesu;
- systemy monitorowania maszyn, takie jak SCADA (ang. *Supervisory Control and Data Acquisition*), WMS, CMMS (ang. *Computerized Maintenance Management System*), które umożliwiają bieżące śledzenie parametrów technicznych, stanu pracy i występujących awarii;

- rejestry awarii, przestojów i działań konserwacyjnych, stanowiące kluczowe źródło danych dla analiz typu RCM (ang. *Reliability-Centered Maintenance*) oraz PdM;
- parametry geologiczne i produkcyjne (m.in. miąższość złożeń, wydajność przodków), definiujące warunki pracy urządzeń i charakterystykę środowiska eksploatacyjnego;
- dane pomiarowe z czujników IoT, rejestrowane w czasie rzeczywistym i stanowiące podstawę dla modeli predykcyjnych oraz metod analityki prognostycznej (Wijaya i inni 2022; Zhang M. i inni 2023).

Coraz większe znaczenie w analizie takich danych mają metody eksploracji danych (ang. *data mining*), pozwalające odkrywać ukryte wzorce i zależności w dużych zbiorach (Aggarwal 2015). Do klasycznych przykładów należą algorytmy odkrywania reguł asocjacyjnych, które położyły podwaliny pod współczesne podejścia analityczne (Agrawal i inni 1993; Agrawal i inni 1995). W literaturze podkreśla się również rosnącą rolę rozwiązań opartych na danych (ang. *data-driven*) w monitorowaniu stanu technicznego (ang. *condition monitoring*) maszyn górniczych. Przykładem są systemy oparte na bezprzewodowych modułach akcelerometrycznych, które umożliwiają monitorowanie pracy mobilnych maszyn w warunkach niestacjonarnych (Aqueveque i inni 2021). Ważnym uzupełnieniem są także systemy robotyki mobilnej, umożliwiające automatyczną inspekcję przenośników taśmowych i integrację wyników z systemami utrzymania ruchu (Szrek i inni 2022). Równolegle są rozwijane rozwiązania wykorzystujące roboty inspekcyjne oparte na termografii podczerwieni, pozwalające na wczesne wykrywanie przegrzewających się krążników i zapobieganie poważniejszym awariom (Szrek i inni 2020). Coraz większe znaczenie zyskują również rozwiązania oparte na wizji maszynowej oraz danych sensorowych pozyskiwanych w czasie rzeczywistym, wspierane algorytmami uczenia maszynowego i bibliotekami sztucznej inteligencji (ang. *Artificial Intelligence*, AI) (Chollet i inni 2015; Chamorro i inni 2022).


W praktyce kompletność i wiarygodność danych bywa ograniczona przez braki w rejestracji, błędy operatorów czy niejednorodność formatów zapisu. Dlatego niezbędne jest ich wstępne oczyszczenie, ujednolicenie i walidacja (van der Aalst 2016; Brzychczy 2019; Brzychczy, Rostek 2024). W literaturze wskazuje się, że cyfrowa analiza danych i procesów odgrywa kluczową rolę w zapewnieniu jakości informacji wejściowych do modeli, umożliwiając nie tylko poprawę rzetelności badań, lecz także integrację źródeł danych w ramach podejścia opartego na danych.

Jak pokazano na rysunku 2.2, integracja danych z różnych źródeł pozwala na budowę realistycznego modelu niezawodności procesowej. Dzięki temu możliwe są:

- identyfikacja węzłów krytycznych,
- określenie zależności między operacjami,
- dobór adekwatnych metod analitycznych do specyfiki zakładu.

W dalszej części monografii informacje te będą stanowiły podstawę do dekompozycji procesu w modelu systemowym oraz doboru odpowiednich metod probabilistycznych do oceny wpływu niepewności na jego niezawodność.





**Rys. 2.2.** Architektura danych do modelowania niezawodności procesowej

Źródło: opracowanie własne na podstawie

van der Aalst 2016; Brzywczy 2019; Wijaya i inni 2022; Zhang M. i inni 2023

Podsumowując, proces wydobywczy należy traktować jako złożony system techniczno-organizacyjny, którego funkcjonowanie determinowane jest zarówno przez czynniki geologiczne i środowiskowe, jak i przez powiązania między poszczególnymi etapami technologii. Różnice pomiędzy górnictwem podziemnym a odkrywkowym, specyfika systemów transportowych oraz warunki pracy maszyn sprawiają, że modelowanie niezawodności musi być elastyczne i dostosowane do typu zakładu. Kluczową rolę odgrywa także jakość i kompletność danych procesowych, które stanowią podstawę budowy realistycznych modeli. Wnioski przedstawione w tym rozdziale stanowią fundament do dalszych analiz, w których omówione zostaną probabilistyczne metody oceny niezawodności oraz podejścia integrujące różne źródła niepewności w procesach wydobywczych.

## **2.5. Źródła niepewności w procesach wydobywczych**

Proces wydobywczy, ze względu na swoją złożoność i wieloetapowy charakter, jest w wysokim stopniu podatny na różnorodne źródła niepewności. Mogą one wynikać zarówno z uwarunkowań technicznych, związanych z awaryjnością i degradacją sprzętu (Kumar, Klefsjö 1992; Dhillon 2008), jak i z czynników operacyjnych lub zakłóceń logistycznych (Singh, Dhar 2021; Geisbush, Ariaratnam 2023).

Istotną rolę odgrywają także czynniki środowiskowe – niejednorodność warunków geologicznych i geomechanicznych (Norouzi i inni 2022), a w przypadku kopalń odkrywkowych dodatkowo wpływ warunków atmosferycznych, które mogą prowadzić do przestojów i strat produkcyjnych (Bodziony, Patyk 2024). W efekcie system wydobywczy funkcjonuje w warunkach permanentnej zmienności, wymagającej od operatorów i menedżerów ciągłej adaptacji.

Niepewność poznawcza wynika z ograniczonej wiedzy, niedoskonałości danych lub niepełnego rozpoznania warunków geologicznych i technicznych. W szczególności w projektowaniu geomechanicznym istotnym wyzwaniem pozostaje kwantyfikacja niepewności związanej z właściwościami górotworu, co zostało podkreślone w badaniach Dunn (2019). Podobne problemy pojawiają się także w szacowaniu zasobów złoża, gdzie konieczne jest uwzględnienie niejednorodności i ograniczonej wiarygodności danych geologicznych (Lindi i inni 2024). Redukcja tej niepewności możliwa jest poprzez stosowanie nowoczesnych systemów monitorowania (Wijaya i inni 2022; Zhang i inni 2023), integrację źródeł danych (van der Aalst 2016; Brzychczy 2019) oraz rozwój cyfrowych bliźniaków (Nobahar i inni 2024; van Eyk i inni 2025). Dodatkowo, problem niepewności danych i wynikającej z niej niedokładności modeli uczenia maszynowego został podkreślony w artykule, który opublikowali Z. Zhang i współpracownicy (2023).

Z kolei, niepewność losowa ma charakter w pełni stochastyczny i wynika z naturalnej zmienności zjawisk zachodzących w środowisku geologicznym i technicznym, takich jak

przypadkowe awarie, fluktuacje obciążenia czy trudne do przewidzenia zmiany warunków geomechanicznych. Do tego typu zjawisk zaliczyć można m.in. krytyczne nieciągłości górotworu ujawniane podczas wierceń, które istotnie wpływają na bezpieczeństwo i stabilność procesów (Waloski i inni 2021), a także efekty robót strzałowych, w których zasięg odrzutu skalnego (ang. *flyrock*) charakteryzuje się wysoką zmiennością i wymaga stosowania metod predykcyjnych opartych na uczeniu maszynowym (Yari i inni 2023). Niepewność ta nie może być wyeliminowana, lecz jedynie modelowana probabilistycznie, np. z wykorzystaniem symulacji Monte Carlo (Aladejare 2024), łańcuchów Markowa (Agrawal i inni 2019; Liang i inni 2022; Liu L. i inni 2022), w tym ich współczesnych rozwinięć z zastosowaniem zbiorów rozmytych (Chachra i inni 2024), czy sieci bayesowskich (Weber i inni 2010; Mishra i inni 2021; Feng i inni 2024; Li i inni 2024; Rahimdel 2024). W literaturze wskazuje się także na zastosowanie procesów Lévy’ego do probabilistycznego modelowania degradacji przenośników taśmowych w oparciu o dane rzeczywiste (Vališ, Mazurkiewicz 2018). W polskich badaniach istotny wkład w rozwój metod probabilistycznych i stochastycznych wniosły prace Snopkowskiego, obejmujące zarówno podstawy symulacji stochastycznej (Snopkowski 2007, 2012), jak i ich współczesne rozwinięcia ukierunkowane na podejmowanie decyzji operacyjnych w kopalniach (Snopkowski i inni 2023) oraz redukcję złożonych modeli poprzez splot funkcji gęstości prawdopodobieństwa (Snopkowski i inni 2025) oraz wykorzystanie rozkładów brzegowych do oceny czasu trwania procesów górniczych (Napieraj i inni 2025). Praktyczne zastosowania podejść probabilistycznych w górnictwie przedstawili m.in. Rahimdel i Ghodrati (2023), analizując system sprężonego powietrza w kopalniach podziemnych. Z kolei Sánchez-Herguedas i inni (2021) podkreślają znaczenie analizy ryzyka i podejść probabilistycznych jako skutecznych narzędzi wspierających podejmowanie decyzji w warunkach wysokiej niepewności procesowej.

Aby lepiej zobrazować źródła niepewności w procesie wydobywczym, w tabeli 2.2 zestawiono ich podstawowe kategorie, przykłady, konsekwencje oraz metody zarządzania.

W obliczu niepewności operacyjnej reakcja kadry zarządzającej i służb technicznych polega na dostosowywaniu harmonogramów produkcyjnych, intensyfikacji działań prewencyjnych w utrzymaniu ruchu oraz wprowadzaniu rozwiązań zwiększających elastyczność systemów transportowych i energetycznych (Azadeh i inni 2016). Istotnym pojęciem w tym kontekście jest odporność (ang. *robustness*), rozumiana jako zdolność systemu produkcyjnego do utrzymania stabilnej efektywności mimo zakłóceń. W literaturze podkreśla się jej znaczenie zarówno w ujęciu teoretycznym (Stricker, Lanza 2014), jak i praktycznym, na przykładzie analiz systemów przemysłowych (Stockmann, Winkler 2022). Coraz częściej wdrażane są także rozwiązania cyfrowe, takie jak IoT, SCADA czy systemy analityczne oparte na sztucznej inteligencji (Rojas i inni 2025; Sreedharan i inni 2025), które umożliwiają predykcję awarii oraz bieżące reagowanie na zakłócenia. Tendencja ta wpisuje się w szerszy trend przejścia od utrzymania reakcyjnego i zapobiegawczego do predykcyjnego, obserwowany również w innych gałęziach przemysłu (Mołęda i inni 2023).

**Tab. 2.2.** Źródła niepewności w procesie wydobywczym

| <b>Kategoria</b> | <b>Przykłady</b>                                                                                                                               | <b>Konsekwencje</b>                                                                                          | <b>Metody zarządzania niepewnością</b>                                                                              |
|------------------|------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------|
| Techniczna       | awaryjność urządzeń,<br>degradacja podzespołów<br>mechanicznych<br>i hydraulicznych,<br>nieskuteczność działań<br>konserwacyjnych              | przestoje, spadek<br>dostępności maszyn,<br>zwiększone koszty<br>utrzymania ruchu                            | predykcja awarii (CBM),<br>redundancja, konserwacja<br>zapobiegawcza, IoT                                           |
| Operacyjna       | zmienność obciążenia,<br>zakłócenia logistyczne,<br>fluktuacje harmonogramów,<br>ograniczona dostępność<br>zasobów ludzkich<br>i materiałowych | opóźnienia<br>w produkcji,<br>efekt kaskadowy<br>w procesach,<br>obniżenie<br>efektywności<br>organizacyjnej | optymalizacja<br>harmonogramów,<br>zarządzanie zapasami<br>krytycznych części,<br>systemy wspomagania<br>decyzji    |
| Środowiskowa     | zmienność geologiczna<br>i geomechaniczna,<br>warunki atmosferyczne<br>(opady, mróz,<br>wysokie temperatury)                                   | nieregularny postęp<br>robót, zwiększone<br>obciążenie sprzętu,<br>ryzyko wypadków<br>i awarii               | modelowanie<br>geologiczne<br>i probabilistyczne,<br>prognozy<br>meteorologiczne,<br>elastyczne<br>planowanie robót |

Źródło: opracowanie własne na podstawie Klefsjö 1992; Singh, Dhillon 2008; Kumar, Dhar 2021

Wpływ niepewności na niezawodność procesową jest wielowymiarowy. Niepewność techniczna i środowiskowa prowadzi do wzrostu częstotliwości awarii i wydłużania przestoju (Zimroz i inni 2019; Odeyar i inni 2022), natomiast niepewność operacyjna może generować efekt kaskadowy w całym łańcuchu procesowym, obniżając jego wydajność i stabilność (Tubis i inni 2020).

Dlatego współczesne modele niezawodności procesowej coraz częściej bazują na metodach probabilistycznych, które uwzględniają zarówno niepewność poznawczą, jak i losową, oraz umożliwiają ocenę ryzyka w realistycznych scenariuszach pracy kopalń (Modarres i inni 2016; Zio 2016). Coraz większą rolę odgrywają w nich także metody sztucznej inteligencji i uczenia maszynowego, wspierające prognozowanie awarii i podejmowanie decyzji w warunkach złożonej niepewności (Ahmadi i inni 2020).

W świetle powyższych obserwacji identyfikacja i klasyfikacja źródeł niepewności stanowi warunek konieczny dla budowy wiarygodnych modeli niezawodności procesowej. Zaniedbanie tych aspektów prowadzi do niedoszacowania ryzyka, błędnych decyzji zarządczych i spadku odporności systemu. Dlatego to właśnie ujęcie niepewności w jej wymiarze poznawczym i losowym stanowi punkt wyjścia do dalszych rozważań w kolejnych rozdziałach monografii.

## 2.6. Modelowanie procesów wydobywczych jako układów złożonych

Procesy wydobywcze charakteryzują się wysokim stopniem złożoności, wynikającym zarówno z ich wieloetapowej struktury technologicznej, jak i ze zmiennych warunków środowiskowych oraz organizacyjnych (Hustrulid i inni 2018; Hartman, Mutmanský 2002). Złożoność ta ma charakter systemowy: procesy wydobywcze wykazują cechy emergencji, nieliniowości i sprzężeń zwrotnych, co sprawia, że nawet niewielkie zakłócenia mogą prowadzić do istotnych konsekwencji w całym systemie.


Z tego względu ich analiza wymaga odpowiedniego modelowania, które pozwala na odwzorowanie zależności pomiędzy elementami systemu, identyfikację wąskich gardeł oraz ocenę wpływu różnych scenariuszy operacyjnych na efektywność i niezawodność. W literaturze wyróżnia się dwa zasadnicze podejścia do modelowania procesów: strukturalne i dynamiczne.

Modele strukturalne koncentrują się na architekturze systemu i jego powiązaniach logicznych. Do typowych narzędzi należą schematy blokowe, diagramy BPMN (ang. *Business Process Model and Notation*) służące do odwzorowania przepływu procesów, oraz klasyczne układy szeregowo-równoległe. W inżynierii niezawodności szeroko stosuje się także drzewa błędów (FTA), diagramy blokowe niezawodności (RBD) oraz analizy FMEA, które umożliwiają ocenę wpływu uszkodzeń poszczególnych elementów na funkcjonowanie systemu (Dhillon 2008; Birolini 2017).

Modele dynamiczne uwzględniają zmienność w czasie oraz interakcje pomiędzy elementami procesu. Pozwalają one analizować kolejność zdarzeń, występowanie sprzężeń zwrotnych i efekty kaskadowe. Do najczęściej wykorzystywanych narzędzi należą sieci Petriego, symulacje zdarzeń dyskretnych, modele agentowe oraz podejścia oparte na logach zdarzeń i metodach eksploracji procesów (ang. *process mining*) (van der Aalst 2016; Brzychczy, Napieraj 2019).

Podejścia te zostały zestawione na rysunku 2.3 i w tabeli 2.3, gdzie przedstawiono ich kluczowe cechy, stosowane narzędzia oraz relacje z danymi rzeczywistymi.

Kluczowym elementem współczesnych badań nad niezawodnością procesów wydobywczych jest wykorzystanie danych rzeczywistych pochodzących z systemów monitoringu maszyn, rejestrów awarii czy czujników IoT (Wijaya i inni 2022; Zhang M. i inni 2023). Integracja tych danych z modelami strukturalnymi i dynamicznymi pozwala na tworzenie bardziej realistycznych odwzorowań procesów, a także umożliwia przeprowadzanie analiz wrażliwości i ocenę wpływu niepewności na niezawodność całego systemu (Singh, Dhar 2021; Norouzi i inni 2022). Wyzwanie stanowi jednak jakość danych – niekompletność logów, błędy rejestracji czy obecność szumów, które mogą prowadzić do zniekształcenia wyników modelowania i wymagają dedykowanych procedur oczyszczania.



**Rys. 2.3.** Podejścia do modelowania procesów wydobywczych

Źródło: opracowanie własne na podstawie

Dhillon 2008; van der Aalst 2016; Birolini 2017; Brzychczy, Napieraj 2019


**Tab. 2.3.** Porównanie podejść strukturalnych i dynamicznych

| Kryterium                 | Podejście strukturalne                                                          | Podejście dynamiczne                                                                  |
|---------------------------|---------------------------------------------------------------------------------|---------------------------------------------------------------------------------------|
| Cel                       | odzworowanie architektury systemu, powiązań logicznych i struktury zależności   | analiza przebiegu procesu w czasie, identyfikacja interakcji i efektów kaskadowych    |
| Perspektywa               | statyczna – system traktowany jako układ elementów połączonych logicznie        | czasowa – system postrzegany jako sekwencja zdarzeń i interakcji                      |
| Typowe narzędzia          | schematy blokowe, BPMN, układy szeregowo-równoległe, FTA, RBD, FMEA             | sieci Petriego, symulacje zdarzeń dyskretnych, modele agentowe, eksploracja procesów  |
| Źródła danych             | dokumentacja techniczna, wiedza ekspertów, struktury logiczne                   | logi zdarzeń, dane sensorowe, rejestry awarii, systemy monitoringu                    |
| Zalety                    | prostota, przejrzystość, możliwość szybkiej identyfikacji zależności            | realistyczne odzworowanie procesu, możliwość symulacji scenariuszy i analizy w czasie |
| Ograniczenia              | brak uwzględnienia zmienności w czasie, trudność w analizie efektów kaskadowych | większa złożoność modeli, wymagania dotyczące jakości i kompletności danych           |
| Zastosowanie w górnictwie | analiza struktury systemu wydobywczego, identyfikacja elementów krytycznych     | symulacje procesów eksploatacyjnych, ocena wpływu awarii, analiza wrażliwości         |

Źródło: opracowanie własne na podstawie

Dhillon 2008; van der Aalst 2016; Birolini 2017; Hustrulid i inni 2018; Brzychczy, Napieraj 2019

Modele procesowe pełnią szczególnie ważną rolę w identyfikacji elementów krytycznych. Poprzez symulacje różnych scenariuszy eksploatacyjnych możliwe jest określenie, które urządzenia lub operacje w największym stopniu decydują o stabilności procesu. Analizy tego typu wspierają podejmowanie decyzji w zakresie planowania konserwacji predykcyjnej, optymalizacji zasobów czy ograniczania ryzyka nieplanowanych przestojów (Odeyar i inni 2022; Rojas i inni 2025).



**Rys. 2.4.** Schemat procesu modelowania niezawodności wydobywcia

Źródło: opracowanie własne na podstawie  
Modarres i inni 2016; Zio 2016; Norouzi i inni 2022; Wijaya i inni 2022; Zhang M. i inni 2023

Schemat procesu modelowania niezawodności zaprezentowany na rysunku 2.4, obrazuje przepływ od pozyskiwania danych, przez etap modelowania i analiz, aż do wsparcia decyzji strategicznych i operacyjnych. Ważnym elementem jest sprzężenie zwrotne – wyniki analiz stanowią podstawę do doskonalenia sposobu gromadzenia i przetwarzania danych,

co w dłuższej perspektywie podnosi wiarygodność modeli. Cały proces ma charakter iteracyjny: wyniki analiz wpływają na sposób dalszego gromadzenia danych i doskonalenie modeli, co pozwala na ciągle podnoszenie jakości oceny niezawodności.

Przedstawione rozważania wskazują, że modelowanie procesów wydobywczych jako układów złożonych stanowi kluczowy element w zrozumieniu ich funkcjonowania w warunkach niepewności. Połączenie podejść strukturalnych i dynamicznych, opartych na danych rzeczywistych, umożliwia nie tylko wierne odwzorowanie przebiegu procesu, lecz także jego ocenę w różnych warunkach eksploatacyjnych. Interdyscyplinarne podejście – integrujące klasyczne metody inżynierii niezawodności, modelowanie probabilistyczne oraz narzędzia analityki opartej na danych – pozwala wskazać kluczowe czynniki ryzyka, zaprojektować skuteczne polityki utrzymania ruchu i zwiększyć odporność całego systemu produkcyjnego. W kolejnych rozdziałach przedstawione zostaną metody probabilistyczne i scenariuszowe, które rozwijają tę koncepcję i pozwalają na uwzględnienie niepewności operacyjnej oraz technicznej w ocenie niezawodności procesowej.

## **2.7. Przegląd badań nad niezawodnością w górnictwie**

Niezawodność w górnictwie od zawsze stanowiła przedmiot szczególnej uwagi badaczy i praktyków, ponieważ warunkuje nie tylko bezpieczeństwo pracy, lecz także efektywność ekonomiczną oraz ciągłość procesów produkcyjnych. Pojęcie to obejmuje zarówno aspekt techniczny – odnoszący się do sprawności maszyn i urządzeń, jak i aspekt procesowy – związany z nieprzerwanym przebiegiem działań wydobywczych w całym systemie produkcyjnym (Dhillon 2008; Birolini 2017; Tubis i inni 2020; Odeyar i inni 2022). W ostatnich dekadach podejście do niezawodności ewoluowało: od klasycznych badań nad trwałością i awaryjnością poszczególnych maszyn, aż po współczesne rozwiązania oparte na analizie danych, sztucznej inteligencji i cyfrowych bliźniakach. W górnictwie koncepcja ta zyskuje obecnie coraz większe znaczenie, stanowiąc rozszerzenie tradycyjnych metod oceny niezawodności technicznej.

Klasyczne badania koncentrowały się na ocenie trwałości i niezawodności wybranych urządzeń górniczych, takich jak przenośniki taśmowe i maszyny urabiające. Modele probabilistyczne i metody statystyczne były stosowane do analizy czasów międzyawaryjnych (MTBF) i czasów napraw (MTTR), co umożliwiało planowanie polityk konserwacyjnych (Wang, Pham 2006; Modarres i inni 2016).

W polskiej literaturze znaczący wkład w rozwój klasycznego podejścia wnieśli Marian Turek (2010) oraz Waldemar Korzeniowski i współautorzy (2013, 2015), którzy podkreślali znaczenie systematycznego monitorowania stanu technicznego maszyn i konieczność wykorzystania danych eksploatacyjnych do planowania utrzymania ruchu. Również Roman Magda (2019) akcentował rolę właściwej organizacji pracy zmierzającej do wzrostu stopnia wykorzystania posiadanych środków produkcji.



Ograniczeniem tych tradycyjnych ujęć było postrzeganie niezawodności w wąskim zakresie, bez uwzględnienia interakcji międzyoperacyjnych i procesowych. W praktyce oznaczało to, że wyodrębniano awarię jednego urządzenia, podczas gdy jej skutki miały charakter systemowy. Dlatego coraz większą rolę odgrywają metody analizy przyczyn źródłowych (ang. *Root Cause Analysis*), które wspierają kompleksową identyfikację i eliminację źródeł awarii (Gano 2007).

Nowym kierunkiem badań stało się ujęcie procesowe, w którym niezawodność postrzegana jest jako zdolność całego systemu wydobywczego do realizacji zadanych funkcji w określonych warunkach. Magda (2018) zwracał uwagę, że tradycyjne metody nie uwzględniają wpływu czynników organizacyjnych i harmonogramowych, które w praktyce mogą być równie istotne jak awarie techniczne. W literaturze dostępne są prace dotyczące niezawodności systemów transportu podziemnego, które – oprócz elementów technicznych (np. przenośniki taśmowe) – uwzględniają również aspekty operacyjne i bezpieczeństwa pracy (Tomuś i inni 2017). Najnowsze badania idą jeszcze dalej, analizując nie tylko niezawodność i utrzymanie ruchu systemów transportu podziemnego, ale również warunki przestrzenne eksploatacji (Suchorab-Matuszewska i inni 2025). Z kolei Ryszard Snopkowski (2012) wniósł istotny wkład w rozwój metod stochastycznych, koncentrując się na modelowaniu czasów trwania procesów górniczych i redukcji złożonych modeli probabilistycznych.

Ważną rolę odegrały także prace poświęcone wykorzystaniu zintegrowanych systemów informacyjnych w planowaniu produkcji (Brzychczy i inni 2017; Brzychczy 2019). Wykazano w nich, że systemy klasy ERP (ang. *Enterprise Resource Planning*), połączone z narzędziami analitycznymi, mogą wspierać przewidywalność procesów i redukować ryzyko nieplanowanych przestojów.

Polska szkoła badań nad niezawodnością w górnictwie jest obecnie silnie związana z rozwojem metod opartych na danych. Już we wczesnych pracach podejmowano próby zastosowania podejść inteligentnych do prognozowania stanu maszyn górniczych – przykładem jest badanie Gibca (2005), w którym zaprezentowano wykorzystanie metod inteligentnych do predykcji uszkodzeń. Kluczową rolę w dalszym rozwoju tych koncepcji odegrał zespół Radosława Zimroza, który wraz z Pawłem Stefaniakiem, Jackiem Wodeckim i innymi współpracownikami opracował metody diagnostyki maszyn oparte na analizie sygnałów, fuzji danych i sztucznej inteligencji (Stefaniak i inni 2018). Ich badania obejmują zarówno monitoring przenośników taśmowych, jak i rozwój metod predykcyjnych w warunkach niestacjonarnych (Bartelmus, Zimroz 2009; Zimroz i inni 2019).

W ostatnich latach istotne znaczenie mają również prace Pawła Dąbka i współpracowników (2023), którzy zajmowali się problemem niecentralnego ruchu taśmy w warunkach laboratoryjnych, wykorzystując metody wizyjne i wibroakustyczne. Istotny wkład wniósł zespół, który zaproponował nowatorskie miary korelacji – pozwalające wybierać najbardziej informatywne pasma częstotliwości w sygnałach wibracyjnych o ciężkich rozkładach, co znacząco poprawia skuteczność diagnostyki (Hebda-Sobkowicz i inni 2025).

Obok badań diagnostycznych rozwija się także nurt związany z predykcją awarii i optymalizacją utrzymania ruchu. Przeglądy literatury wskazują, że podejścia oparte na sztucznej inteligencji i uczeniu maszynowym zyskują coraz większe znaczenie w górnictwie (Guerroum i inni 2021, 2022; Dayo-Olupona i inni 2023). Ważnym kierunkiem rozwoju są także rozwiązania wykorzystujące analizę obrazu i dane z czujników w czasie rzeczywistym do monitoringu przenośników taśmowych (Chamorro i inni 2022; Dąbek i inni 2023) oraz akcelerometri bezprzewodowe w diagnostyce maszyn mobilnych (Aqueveque i inni 2021). Istotny wkład w rozwój metod predykcyjnych wnosi także badanie Gackowiec (2024), poświęcone analizie stanów awaryjnych kombajnu ścianowego, który stanowi kluczowy element procesu urabiania. Rozwijane są także modele autoregresyjne, które wspierają wczesne wykrywanie uszkodzeń maszyn elektrycznych w trudnych warunkach głębinowych (Groenewald i inni 2018). Podkreśla się również, że skuteczna predykcja wymaga nie tylko metod uczenia maszynowego, ale także integracji danych i odpowiedniej architektury systemów informacyjnych, co stanowi fundament dalszego rozwoju PdM w górnictwie (Fayyad 2001; Brzychczy, Rostek, 2024). W kontekście metod uczenia maszynowego szczególne znaczenie mają algorytmy boostingowe, np. gradient boosting machine (Friedman 2001), które znajdują szerokie zastosowanie w predykcji awarii i estymacji niezawodności systemów technicznych. Istotnym elementem tego podejścia jest również dobór właściwych wskaźników efektywności procesów (KPI), które umożliwiają monitorowanie i ocenę niezawodności na poziomie całego systemu (Gackowiec i inni 2020). Jak pokazują Mołęda i współautorzy (2023), podobne tendencje dominują również w innych sektorach przemysłowych, gdzie przejście od podejść reaktywnych do predykcyjnych staje się uniwersalnym kierunkiem rozwoju utrzymania ruchu. W tym sensie badania w górnictwie wpisują się w szerszy nurt transformacji przemysłowej, co podkreśla ich aktualność i znaczenie. Jednocześnie zauważa się, że podejścia z zakresu eksploracji procesów mogą wspierać te rozwiązania, dostarczając metod modelowania procesów i oceny ich niezawodności w dynamicznych, niepewnych środowiskach (Macak i inni 2022).

Na świecie badania nad niezawodnością w górnictwie zmierzają w kierunku integracji metod klasycznych z nowoczesnymi narzędziami sztucznej inteligencji i cyfrowych bliźniaków (ang. *Digital Twins*). Rojas i inni (2025) wskazują na rosnące znaczenie PdM w oparciu o sztuczną inteligencję i cyfrowe modele procesów. Nobahar i współpracownicy (2024) oraz van Eyk i Heyns (2025) analizują zastosowanie koncepcji cyfrowego bliźniaka w górnictwie podziemnym i odkrywkowym, akcentując możliwości integracji symulacji, IoT i analizy danych w czasie rzeczywistym. W podobnym duchu Z. Zhang i współautorzy (2023), Faramarzi i inni (2024) oraz Dumas (2017) podkreślają znaczenie wykorzystania metod uczenia głębokiego do modelowania złożonych systemów wydobywczych i predykcji procesów, zwracając uwagę na problem jakości danych i niepewności pomiarowych. Równolegle w polskiej literaturze podkreśla się znaczenie koncepcji „Górnictwa 4.0” i budowy inteligentnych, głębokich kopalń przyszłości jako elementu cyfrowej transformacji sektora (Dyczko 2023).

Symulacje Monte Carlo oraz modele probabilistyczne stosowane są do oceny wpływu niepewności na harmonogramy wydobywcze (Aladejare i inni 2024; Roos 2024). Coraz częściej wykorzystuje się także podejścia hybrydowe, łączące logikę rozmytą i sieci bayesowskie w modelowaniu niezawodności systemów (Su i inni 2025). W literaturze podkreśla się również znaczenie inżynierii odporności (ang. *resilience engineering*), czyli zdolności systemów wydobywczych do adaptacji w warunkach niepewności (Zio 2016; Hollnagel i inni 2019).

Analiza literatury dotyczącej niezawodności w górnictwie pokazuje wyraźną ewolucję tego obszaru badań – od tradycyjnych analiz awaryjności pojedynczych urządzeń po ujęcie systemowe i procesowe, w których coraz większą rolę odgrywa integracja danych z wielu źródeł. Początkowo badania koncentrowały się głównie na ocenie trwałości maszyn i ich elementów, z zastosowaniem klasycznych metod probabilistycznych i statystycznych. Z czasem dostrzeżono jednak, że o ciągłości produkcji decyduje nie tylko sprawność pojedynczych urządzeń, ale również wzajemne zależności pomiędzy kolejnymi etapami procesu wydobywczego. To przesunięcie akcentu w kierunku niezawodności procesowej otworzyło nowe perspektywy badawcze, w których znaczenia nabrały czynniki organizacyjne, harmonogramowe i logistyczne.

Szczególnie istotny wkład w rozwój tego podejścia wniosła polska szkoła badań, reprezentowana między innymi przez Turka, Korzeniowskiego, Magdę, Skrzypkowskiego, Brzychczy czy Zimroza. Ich prace pokazują, że niezawodność w górnictwie należy rozumieć szerszej niż tylko jako analizę awaryjności maszyn – to pojęcie obejmuje również integrację systemów transportowych, planowanie utrzymania ruchu, analizę danych z systemów monitoringu oraz uwzględnienie czynników zewnętrznych, takich jak geologia czy warunki środowiskowe.

Jednocześnie przegląd badań międzynarodowych wskazuje, że w ostatnich latach niezawodność coraz silniej łączy się z nowoczesnymi narzędziami analitycznymi, takimi jak sztuczna inteligencja, uczenie maszynowe czy koncepcja cyfrowych bliźniaków. Coraz częściej stosuje się także symulacje Monte Carlo, logikę rozmytą czy sieci bayesowskie, aby lepiej uchwycić wpływ niepewności i złożoności warunków eksploatacyjnych. Kierunki te dobrze korespondują z badaniami prowadzonymi w Polsce, gdzie rozwija się zarówno diagnostyka maszyn oparta na analizie sygnałów i IoT, jak i podejścia procesowe wykorzystujące narzędzia process mining.

Podsumowując, badania nad niezawodnością w górnictwie zwracają w stronę coraz pełniejszej integracji metod deterministycznych i probabilistycznych z narzędziami analizy Big Data oraz sztucznej inteligencji. Ujęcie procesowe zyskuje na znaczeniu, ponieważ pozwala wierniej odwzorować realne uwarunkowania produkcyjne. Wkład polskich badaczy w ten obszar jest istotny i dostrzegalny w międzynarodowej literaturze. Jednocześnie rosnące znaczenie metod probabilistycznych i scenariuszowych potwierdza, że uwzględnienie niepewności – zarówno poznawczej, jak i losowej (por. podrozdz. 2.5) – stanowi obecnie

centralne wyzwanie w modelowaniu niezawodności. Dalszy rozwój badań powinien koncentrować się na łączeniu klasycznych metod inżynierii niezawodności z nowoczesnymi technologiami cyfrowymi i podejściem procesowym, co stanowi fundament koncepcji przedstawionej w tej monografii.

## **2.8. Luka badawcza i miejsce proponowanej koncepcji w literaturze**

Przegląd literatury wskazuje, że badania nad niezawodnością w górnictwie przeszły istotną ewolucję – od klasycznych analiz awaryjności pojedynczych maszyn, przez koncepcje niezawodności systemów transportowych, aż po podejścia uwzględniające czynniki procesowe i organizacyjne. Jak pokazano w podrozdziałach 2.5–2.7, współczesne badania coraz częściej odnoszą się do złożoności procesów i wykorzystują metody probabilistyczne oraz oparte na analizie danych. Jednocześnie nadal pozostawiają one istotne luki, które ograniczają ich zastosowanie w praktyce przemysłowej.

Po pierwsze, wiele prac koncentruje się na ujęciu technicznym, analizując wyłącznie parametry maszyn i urządzeń (Kumar, Klefsjö 1992; Dhillon 2008). Takie podejście pozwala ocenić trwałość elementów, ale nie odzwierciedla w pełni rzeczywistych warunków pracy kopalni, gdzie awarie jednego podsystemu mogą powodować kaskadowe skutki w całym procesie wydobywczym. Brak perspektywy procesowej ogranicza więc możliwość formułowania kompleksowych wniosków.

Po drugie, badania prowadzone w nurcie procesowym często nie uwzględniają probabilistycznego charakteru procesów górniczych. Zmienność geologiczna, czynniki środowiskowe czy fluktuacje w obciążeniach maszyn powodują, że deterministyczne modele mają ograniczoną moc prognostyczną (Norouzi i inni 2022). Mimo że w literaturze rozwijane są metody probabilistyczne, takie jak symulacje Monte Carlo, sieci bayesowskie czy procesy Markowa, to wciąż rzadko są one integrowane z podejściem procesowym, co pozostaje istotnym wyzwaniem badawczym.

Po trzecie, niewystarczająco rozwinięte jest podejście, które traktowałoby proces wydobywczy jako układ dynamiczny. Istnieją przykłady zastosowania sieci Petriego, symulacji zdarzeń dyskretnych czy metod opartych na logach procesowych (van der Aalst 2016; Brzychczy, Napieraj 2019; Szpyrka i inni 2020), jednak nadal brakuje kompleksowych rozwiązań, które łączyłyby dynamikę procesów z oceną niezawodności w warunkach niepewności. Co istotne, podobne ograniczenia są zauważalne także w innych obszarach – np. w analizach niezawodności systemów informatycznych i cyberbezpieczeństwa – gdzie eksploracja danych stosowana jest fragmentarycznie i wymaga powiązania z klasycznymi modelami niezawodności (Macak i inni 2022).

W tym kontekście proponowana w monografii koncepcja niezawodności procesowej wpisuje się w istniejący nurt badań, a jednocześnie go poszerza. Jej celem jest integracja trzech perspektyw:

1. technicznej, odnoszącej się do awaryjności maszyn i urządzeń;
2. procesowej, opisującej ciągłość i stabilność całego łańcucha wydobywczego;
3. probabilistyczno-dynamicznej, pozwalającej uchwycić wpływ zmienności i niepewności na niezawodność systemu.

Nowością proponowanego podejścia jest jego interdyscyplinarny charakter, łączący klasyczną inżynierię niezawodności z analizą procesów (ang. *process mining*), modelowaniem probabilistycznym oraz narzędziami opartymi na analizie danych (AI, IoT, cyfrowe bliźniaki). Takie ujęcie pozwala nie tylko wiernie odwzorować rzeczywiste warunki funkcjonowania kopalni, lecz także dostarcza narzędzi analitycznych wspierających podejmowanie decyzji operacyjnych i strategicznych. Przykładem znaczenia tej perspektywy strategicznej są analizy Turka i Magdziarczyk (2024), którzy wskazują na potrzebę uwzględnienia niezawodności i ryzyka w procesie wyboru wariantu zamknięcia kopalni, z jednoczesnym wykorzystaniem potencjału wychwytywania metanu. Pokazuje to, że rozwój koncepcji niezawodności procesowej ma istotne implikacje nie tylko dla bieżącej eksploatacji, ale również dla planowania długofalowej transformacji górnictwa.

Z przedstawionego przeglądu wynika, iż luka badawcza dotyczy przede wszystkim braku zintegrowanego podejścia, które łączyłoby niezawodność, niepewność i dynamikę procesów wydobywczych. Jej nieuwzględnianie prowadzi do niedoszacowania ryzyka i błędnych decyzji zarządczych. Jak wskazują Brzytchezy i Rostek (2024), cyfrowa analiza danych i procesów stanowi obecnie podstawę wielu zastosowań w przemyśle, jednak wciąż rzadko bywa integrowana z inżynierią niezawodności, co potwierdza wagę podjętego w monografii problemu. Podobne wnioski płyną z analiz Friedericha i Lazarovej-Molnar (2024), którzy zwracają uwagę, że nawet w systemach produkcyjnych spoza górnictwa ocena niezawodności napotyka na bariery związane ze złożonością procesów i integracją różnorodnych źródeł danych. Potwierdza to, że zidentyfikowana luka badawcza ma charakter uniwersalny, a rozwój koncepcji niezawodności procesowej może wypełniać ją również w szerszym kontekście przemysłowym. Wypełnienie zidentyfikowanej luki badawczej stanowi podstawę proponowanej koncepcji, której ramy metodyczne – obejmujące źródła danych, przyjęte modele oraz sposób ich weryfikacji empirycznej – przedstawiono w kolejnym rozdziale.

### 3. Metodyka badań

Na podstawie zidentyfikowanej luki badawczej opracowano ramy metodyczne koncepcji niezawodności procesowej. Celem niniejszego rozdziału jest przedstawienie przyjętych źródeł danych, zastosowanych modeli oraz procedur weryfikacji empirycznej, które umożliwiają ocenę niezawodności w warunkach niepewności technicznej i operacyjnej. Metoda ta stanowi punkt wyjścia dla dalszych analiz porównawczych oraz implementacji proponowanego podejścia w praktyce górniczej.

Metodyka stanowi podstawę badań naukowych, określając logikę i spójność procesu badawczego oraz dobór narzędzi umożliwiających osiągnięcie zakładanych celów (Creswell 2014). W przypadku niniejszej monografii metodyka pełni szczególnie istotną rolę, ponieważ dotyczy badań nad niezawodnością procesową w warunkach rzeczywistych, obciążonych wysoką zmiennością i niepewnością (Dhillon 2017).

Wybór odpowiedniego podejścia badawczego ma kluczowe znaczenie zwłaszcza w środowisku górniczym, które cechuje się złożonością techniczną, różnorodnością czynników wpływających na przebieg procesu oraz ograniczoną przewidywalnością związaną zarówno z warunkami naturalnymi, jak i operacyjnymi. W takich warunkach tradycyjne ujęcia deterministyczne okazują się niewystarczające, co uzasadnia zastosowanie podejścia procesowego i probabilistycznego (Rausand, Høyland 2020).

Prezentowana metodyka badań ma charakter interdyscyplinarny – łączy narzędzia inżynierii niezawodności, statystyki matematycznej, modelowania procesów oraz metod zarządzania operacyjnego. Takie podejście umożliwia uchwycenie zarówno aspektów technicznych funkcjonowania systemu wydobywczego, jak i czynników organizacyjnych, które w praktyce w równym stopniu decydują o niezawodności całego procesu. Zastosowane rozwiązania badawcze uwzględniają perspektywę retrospektywną (analiza danych historycznych) oraz predykcyjną (prognozowanie możliwych scenariuszy).

Ponadto metodyka ta pełni funkcję pomostu pomiędzy częścią teoretyczną i empiryczną monografii. Z jednej strony opiera się na wnioskach płynących z przeglądu literatury i istniejących modeli (rozdz. 2), a z drugiej – wyznacza ramy dla analiz przeprowadzonych na danych rzeczywistych, które zostaną przedstawione w rozdziałach 4 i 5. Dzięki temu możliwe jest nie tylko opracowanie nowej koncepcji badawczej, ale także jej praktyczna weryfikacja i ocena przydatności w warunkach przemysłowych.

Podsumowując, metodyka niniejszej pracy została zaprojektowana tak, aby zapewnić spójność między teorią, analizą danych i modelowaniem, a jednocześnie umożliwić integrację podejść deterministycznych i probabilistycznych. Stanowi ona ramy koncepcyjne i praktyczne dla realizacji badań, których szczegółowe założenia i procedury opisano w kolejnych podrozdziałach.

### **3.1. Koncepcja badawcza**

Podstawowym celem prowadzonych badań jest opracowanie i empiryczna weryfikacja autorskiej koncepcji modelowania niezawodności procesów wydobywczych w ujęciu procesowym i probabilistycznym, z uwzględnieniem wpływu niepewności operacyjnej i technicznej (Zio 2009; Modarres i inni 2016). Niezawodność procesową zdefiniowano w podrozdziale 2.2.

Określenie celów badań stanowi kluczowy etap projektowania metodyki, ponieważ wyznacza kierunek dalszych analiz i definiuje oczekiwane rezultaty. W przypadku niniejszej pracy cele zostały sformułowane tak, aby połączyć wymiar teoretyczny z praktycznym – z jednej strony chodzi o rozwinięcie koncepcji niezawodności procesowej w odniesieniu do procesów wydobywczych, z drugiej zaś o weryfikację zaproponowanego podejścia w warunkach rzeczywistych.

Głównym celem badań jest zaprojektowanie i sprawdzenie w praktyce modelu niezawodności procesowej, integrującego podejście systemowe z narzędziami probabilistycznymi. Model ten powinien umożliwiać identyfikację elementów krytycznych procesu oraz prognozowanie zakłóceń w warunkach niepewności operacyjnej i technicznej.

Aby osiągnąć cel ogólny, konieczne było wyznaczenie kilku celów szczegółowych, które porządkują tok postępowania badawczego:

1. Analiza literatury i zdefiniowanie pojęcia niezawodności procesowej w kontekście procesów wydobywczych.
2. Identyfikacja i klasyfikacja źródeł niepewności operacyjnej i technicznej w górnictwie.
3. Opracowanie strukturalnego modelu procesu wydobywczego uwzględniającego punkty krytyczne.
4. Dopasowanie statystycznych rozkładów niezawodności dla wybranych podsystemów na podstawie danych empirycznych.

5. Integracja modelu deterministycznego i probabilistycznego w spójną koncepcję oceny niezawodności procesowej.
6. Walidacja opracowanego modelu z wykorzystaniem danych rzeczywistych i analizą wrażliwości.

Precyzyjne określenie zakresu i założeń badawczych jest konieczne, aby zdefiniować granice analiz oraz uniknąć nadmiernych uogólnień. W badaniach nad niezawodnością procesową, które obejmują zarówno elementy techniczne, jak i organizacyjne, szczególnie ważne jest zrównoważenie szerokiego spojrzenia systemowego z możliwością praktycznej realizacji badań w oparciu o dostępne dane.

Zakres rzeczowy niniejszych badań obejmuje cały proces wydobywczy – od operacji przygotowawczych po podstawę urobku do zakładu przerobczego. Niezawodność procesowa stanowi w tym ujęciu funkcję niezawodności technicznej, co podkreślano już w klasycznych opracowaniach dotyczących eksploatacji podziemnej (Turek 2010) oraz w badaniach nad charakterystyką elementów konstrukcyjnych i bezpieczeństwem eksploatacji (Korzeniowski inni 2015; Odeyar i inni 2022). Takie podejście umożliwia uchwycenie powiązań międzyoperacyjnych, które decydują o stabilności i efektywności całego systemu. Uwzględniono zarówno czynniki techniczne, jak parametry i niezawodność maszyn, jak i czynniki operacyjne, takie jak harmonogramowanie zadań czy dostępność zasobów.

Zakres przestrzenny został powiązany z wybranymi zakładami górnictwami, w których możliwe było pozyskanie danych o odpowiednim poziomie szczegółowości. W badaniach dopuszcza się analizę zarówno kopalń podziemnych, jak i odkrywkowych, aby uchwycić różnicowanie procesów technologicznych i organizacyjnych.

Zakres czasowy analiz obejmuje kilkuletni przedział (2018–2024), co umożliwia uwzględnienie trendów długofalowych oraz zmienności sezonowej. Taki horyzont pozwala także na ocenę efektów wdrożonych działań usprawniających lub modernizacyjnych.

W badaniach przyjęto następujące założenia: niezawodność procesowa jest funkcją niezawodności technicznej, jakości koordynacji operacyjnej oraz zdolności systemu do adaptacji w warunkach zakłóceń. Dane eksploatacyjne rejestrowane w systemach nadzoru (SCADA, CMMS, WMS/ERP) oraz dokumentacji operacyjnej mogą być podstawą do budowy modeli probabilistycznych. Kwantyfikacja niepewności będzie możliwa poprzez dopasowanie rozkładów prawdopodobieństwa oraz zastosowanie symulacji komputerowych (np. metodą Monte Carlo). Modele te powinny umożliwiać nie tylko ocenę historyczną, lecz także prognozowanie przebiegu procesu w różnych scenariuszach operacyjnych.

Każde badanie naukowe, zwłaszcza prowadzone w warunkach przemysłowych, obarczone jest określonymi ograniczeniami i ryzykiem, które mogą wpływać na wiarygodność lub możliwość uogólniania uzyskanych wyników. W przypadku badań nad niezawodnością procesową podstawowym czynnikiem ograniczającym jest jakość i kompletność dostępnych



danych. W praktyce górniczej rejestracja zdarzeń nie zawsze prowadzona jest w sposób systematyczny i jednolity. W niektórych zakładach dane są gromadzone szczegółowo i w czasie rzeczywistym, w innych natomiast mogą być niepełne, rozproszone lub obciążone błędami. Prowadzi to do konieczności stosowania procedur imputacji, uśredniania lub standaryzacji, co zwiększa poziom niepewności w modelach. Drugim ograniczeniem jest specyfika analizowanych zakładów górniczych. Otrzymane wyniki będą wprost odnosiły się do badanych procesów i warunków techniczno-organizacyjnych, co utrudnia ich pełną generalizację na inne przedsiębiorstwa czy branże. Należy jednak podkreślić, że opracowana metodologia – w szczególności procedury związane z przygotowaniem danych, wyborem rozkładów czy integracją metod klasycznych i probabilistycznych – ma charakter uniwersalny i może być adaptowana w różnych kontekstach przemysłowych.

Przyjęta koncepcja badawcza pozostaje w ścisłym związku z hipotezami sformułowanymi we wstępie (podrozdz. 1.4). Hipotezy te stanowią logiczne ramy całego procesu badawczego – wyznaczają kierunki analizy, a jednocześnie pełnią funkcję narzędzia umożliwiającego weryfikację poprawności zaproponowanego podejścia metodycznego.

Zgodnie z nimi zakłada się, że:

- modele probabilistyczne są w stanie wiernie odwzorować zmienność i niepewność charakterystyczną dla procesów wydobywczych,
- integracja wskaźników technicznych i operacyjnych zwiększa trafność identyfikacji elementów krytycznych procesu,
- wdrożenie opracowanego modelu umożliwia usprawnienie podejmowania decyzji operacyjnych, wpływając na wzrost efektywności całego systemu.

Realizacja celów badawczych przedstawionych w niniejszym rozdziale stanowi zatem bezpośrednią próbę weryfikacji powyższych hipotez. W przypadku ich potwierdzenia możliwe będzie wskazanie nowych kierunków dla praktyki inżynierii niezawodności w górnictwie – w szczególności rozwój zintegrowanych narzędzi wspierających zarządzanie procesami wydobywczymi. Z kolei, ewentualne częściowe odrzucenie hipotez wskaże, które aspekty koncepcji wymagają dalszych badań i doskonalenia.

## **3.2. Źródła i przygotowanie danych**

Skuteczność budowy modelu niezawodności procesowej w dużym stopniu zależy od jakości, kompletności i reprezentatywności danych wykorzystywanych w analizie. Procesy wydobywcze generują bardzo różnorodne informacje – od pomiarów technicznych, przez raporty operacyjne, aż po opisy jakościowe sporządzane przez pracowników. Dane te są rozproszone w wielu systemach, co wymaga ich identyfikacji, weryfikacji i przetworzenia, zanim mogą zostać wykorzystane w modelowaniu probabilistycznym i systemowym.

W badaniu wykorzystano dane pochodzące z kilku głównych grup źródeł:

- Dokumentacja eksploatacyjna i raporty operacyjne – obejmujące raporty wydobywania, rejestry przestojów i awarii, a także protokoły przeglądów technicznych.
- Systemy nadzorujące i wspomagające produkcję – w tym SCADA, gromadzący dane w czasie rzeczywistym z czujników i sterowników, CMMS, rejestrujący działania konserwacyjne i awarie, oraz WMS/ERP, w których zapisane są dane logistyczne i planistyczne.
- Dane geologiczne i technologiczne – takie jak charakterystyki złoża (miąższość, parametry geomechaniczne), czy informacje o maszynach (moc, wydajność nominalna).
- Źródła bezpośrednie – wywiady i konsultacje z kadrą techniczną oraz obserwacje terenowe, pozwalające lepiej zrozumieć kontekst funkcjonowania procesu.

Tak szeroka baza źródłowa umożliwia uzyskanie kompleksowego obrazu procesu wydobywczego, obejmującego zarówno jego wymiar techniczny, jak i organizacyjny

Z uwagi na różnorodność źródeł i formatów zapisu, konieczne jest przeprowadzenie kilku-etapowej procedury przygotowania danych (van der Aalst 2016; Trzcionkowska, Brzychczy 2018; Brzychczy 2019):

- Identyfikacja braków i niespójności – wyszukiwanie luk czasowych, braków w rejestrze awarii, niespójnych wartości wskaźników (np. ujemne czasy pracy).
- Standaryzacja formatów i jednostek miar – ujednolicenie formatu dat, jednostek czasu, masy i długości.
- Usuwanie duplikatów – eliminacja powtórzeń wpisów wynikających z wielokrotnej rejestracji tego samego zdarzenia.
- Weryfikacja spójności logicznej – sprawdzanie, czy rejestrowane zdarzenia są zgodne z sekwencją procesową (np. czas transportu nie krótszy niż czas minimalny wynikający z odległości).
- Rekonstrukcja brakujących danych – stosowanie metod imputacji (np. średnia ważona, interpolacja liniowa, modele regresyjne) tam, gdzie jest to uzasadnione i możliwe (van der Aalst 2016; Brzychczy 2019; Zhang Z. i inni 2023).

Po oczyszczeniu dane muszą zostać uporządkowane w sposób umożliwiający ich bezpośrednie wykorzystanie w modelu. Obejmuje to:

- Agregację danych – grupowanie obserwacji w jednostki analityczne (np. cykl wydobywczy, zmiana robocza, dzień, miesiąc), w zależności od poziomu szczegółowości wymaganej przez model.
- Kategoryzację zdarzeń – rozdzielenie awarii, przerw planowanych i nieplanowanych, oraz zakłóceń wynikających z czynników zewnętrznych (np. warunki pogodowe).
- Tworzenie zmiennych pochodnych – obliczanie wskaźników (np. dostępność techniczna, wskaźnik obciążenia maszyn, liczba cykli roboczych) z danych źródłowych.
- Podział na zbiory danych – wyodrębnienie zbioru treningowego (budowa i kalibracja modelu) oraz zbioru walidacyjnego (testowanie i ocena skuteczności).

Należy podkreślić, że proces przygotowania danych nie ma charakteru wyłącznie technicznego. Stanowi on istotny element metodyki badań nad niezawodnością procesową, gdyż determinuje poprawność wnioskowania na dalszych etapach analizy. Jak wskazują badania w literaturze (Brzychczy 2019; Wijaya i inni 2022), jakość danych górniczych wprost przekłada się na wiarygodność modeli probabilistycznych oraz dokładność prognoz.

W praktyce górniczej występują następujące typowe ograniczenia jakości danych (van der Aalst 2016; Norouzi i inni 2022):

- Braki w rejestracji zdarzeń – niektóre przestoje lub awarie mogą nie być zapisywane w systemach.
- Opóźnienia w rejestracji – wpisy dokonywane z opóźnieniem mogą mieć zaniżoną dokładność czasową.
- Różne poziomy szczegółowości – dane z różnych źródeł mogą mieć odmienną granularność czasową i merytoryczną.
- Subiektywność danych jakościowych – opisy przyczyn awarii w raportach operatorów mogą mieć różny poziom szczegółowości i wiarygodności.

Dlatego proces przygotowania danych obejmuje nie tylko działania techniczne, ale również krytyczną ocenę ich wiarygodności, aby ograniczyć ryzyko wprowadzania błędów do modelu.

Ograniczenia te będą uwzględniane w dalszych etapach pracy, w szczególności poprzez zastosowanie analiz wrażliwości oraz testowanie modelu w różnych scenariuszach jakości danych, co pozwoli na ograniczenie ryzyka błędnych interpretacji.

Wynikiem tego etapu jest spójny, kompletny i standaryzowany zbiór danych, gotowy do wykorzystania w analizach opisanych w kolejnych częściach pracy. Taki zbiór stanowi podstawę do budowy modelu niezawodności procesowej i przeprowadzenia walidacji opracowanej koncepcji.

### **3.3. Metody oceny niezawodności procesowej**

Ocena niezawodności procesowej wymaga podejścia wielowymiarowego, integrującego metody klasycznej inżynierii niezawodności z narzędziami probabilistycznymi i statystycznymi. Wynika to z faktu, że proces wydobywczy jest układem dynamicznym, w którym zakłócenia mają charakter zarówno deterministyczny (np. przewidziane przestoje konserwacyjne), jak i losowy (np. awarie, zmienność warunków geologicznych). W niniejszej pracy zastosowano podejście hybrydowe, łączące analizę wskaźnikową z modelowaniem stochastycznym, co umożliwia kwantyfikację niepewności i ocenę wpływu różnych czynników na funkcjonowanie całego procesu. Podobne podejście, łączące klasyczne wskaźniki i metody probabilistyczne, opisali m.in. Birolini (2017) oraz Elsayed (2021), wskazując na potrzebę równoległego wykorzystania miar opisowych i modeli probabilistycznych.

Metody klasyczne stanowią podstawę do określenia parametrów wejściowych dla modeli probabilistycznych oraz do oceny stanu systemu w ujęciu opisowym (Birolini 2017; Dhillon 2017). Do głównych wskaźników wykorzystywanych w analizie należą:

- Średni czas międzyawaryjny (MTBF).

$$MTBF = \frac{\text{Całkowity czas pracy}}{\text{Liczba awarii}} \quad (13)$$

Określa przeciętny czas pracy systemu między kolejnymi awariami.

- Średni czas naprawy (MTTR).

$$MTTR = \frac{\text{Całkowity czas napraw w danym okresie}}{\text{Liczba napraw}} \quad (14)$$

Mierzy średni czas potrzebny do przywrócenia sprawności po awarii.

- Prawdopodobieństwo bezawaryjnej pracy w czasie  $t$  ( $R(t)$ ).

$$R(t) = e^{-\lambda t} \quad (15)$$

gdzie  $\lambda$  oznacza intensywność uszkodzeń.

- Dostępność techniczna ( $A$ ), liczona zgodnie ze wzorem (5), która określa zdolność systemu do wykonywania zaplanowanych zadań w danym okresie.
- Analiza FMEA / FMECA (ang. *Failure Modes and Effects Analysis / Failure Modes, Effects and Criticality Analysis*) – identyfikacja potencjalnych trybów uszkodzeń, ich skutków i priorytetyzacja działań zapobiegawczych.

Wskaźniki te będą obliczane zarówno dla poszczególnych podsystemów procesu (np. urabianie, transport, odstawa), jak i dla całego układu procesowego, umożliwiając ich porównanie i identyfikację elementów krytycznych.

Aby uchwycić zmienność i niepewność parametrów procesu, konieczne jest zastosowanie narzędzi probabilistycznych i statystycznych, które pozwalają na modelowanie losowego charakteru zakłóceń w systemach wydobywczych (Leemis 2009; Modarres i inni 2016):

- Dopasowanie rozkładów prawdopodobieństwa:
  - rozkład Weibulla – szeroko stosowany w modelowaniu niezawodności komponentów mechanicznych;
  - rozkład log-normalny – przydatny w analizie czasów realizacji operacji, gdy dane są asymetryczne;
  - rozkład gamma i eksponencjalny – w analizie czasów międzyawaryjnych;
  - dobór rozkładów będzie weryfikowany przy pomocy testów dobroci dopasowania, m.in. Andersona–Darlinga oraz Kołmogorowa–Smirnowa (Stephens 1974).

- Procesy Markowa i modele semi-Markowa:
  - opis przejść między stanami systemu (np. stan sprawny, stan awarii, stan ograniczonej wydajności);
  - możliwość uwzględnienia czasu przebywania w poszczególnych stanach.
- Symulacje Monte Carlo:
  - generowanie wielu scenariuszy przebiegu procesu na podstawie rozkładów wejściowych;
  - analiza prawdopodobieństwa wystąpienia zakłóceń w określonym horyzoncie czasowym;
  - badanie wpływu zmienności parametrów na wskaźniki globalne niezawodności.
- Analiza wrażliwości (ang. *sensitivity analysis*):
  - ocena, które parametry mają największy wpływ na wynik modelu;
  - wskazanie priorytetów w działaniach usprawniających proces.

W proponowanym podejściu metody klasyczne i probabilistyczne będą ze sobą zintegrowane. Klasyczne wskaźniki (MTBF, MTTR, dostępność) posłużą do estymacji parametrów rozkładów wejściowych w modelach probabilistycznych. Modele probabilistyczne będą natomiast rozszerzać analizę o ocenę wpływu zmienności i niepewności operacyjnej na niezawodność procesową.

Jak podkreślają badania nad niezawodnością systemów technicznych, kompleksowa ocena wymaga integracji metod deterministycznych i probabilistycznych, aby uwzględnić zarówno aspekty techniczne, jak i organizacyjne (Zio 2009; Modarres i inni 2016; Marković i inni 2025). W niniejszej pracy wyniki obu podejść zostaną połączone w formie macierzy niezawodności procesowej, obejmującej parametry techniczne i operacyjne całego procesu.

Takie ujęcie umożliwi jednocześnie:

- retrospektywną ocenę (jak proces działał w przeszłości),
- predykcyjną ocenę (jak proces może działać w przyszłości w różnych scenariuszach).

### 3.4. Model systemowy procesu wydobywczego

Modelowanie systemowe jest kluczowym etapem w procesie oceny niezawodności procesowej, ponieważ pozwala na przedstawienie złożonego procesu wydobywczego jako układu logicznie powiązanych podsystemów. Dzięki temu możliwe jest określenie relacji między elementami systemu, identyfikacja węzłów krytycznych oraz wyznaczenie miejsc, w których ryzyko zakłóceń jest największe. Jak wskazują Rausand i Høyland (2020), przedstawienie systemu w formie hierarchicznego modelu jest warunkiem koniecznym do późniejszej kwantyfikacji niezawodności i oceny skutków awarii. W literaturze górniczej również podkreśla się, że systemowe podejście jest niezbędne do analizy procesów wydobywczych, ze względu na ich złożoność technologiczną i operacyjną (Turek 2010).

Podstawą modelu systemowego przyjętego w niniejszej pracy jest ujęcie procesu wydobywczego jako układu hierarchicznego, w którym wyróżnia się poziomy: podsystemów, operacji i działań elementarnych. Takie podejście umożliwia dekompozycję całości procesu i przypisanie mu parametrów ilościowych oraz probabilistycznych.

W modelu uwzględniono następujące założenia:

- Proces wydobywczy traktowany jest jako układ hierarchiczny, w którym występuje podział na podsystemy, operacje i działania elementarne.
- Podsystemy mogą być powiązane szeregowo (gdzie awaria jednego powoduje zatrzymanie całego ciągu) lub równolegle (gdzie możliwe jest przełączenie na zasoby rezerwowe).
- Model uwzględnia interakcje techniczne i operacyjne, np. wpływ dostępności maszyn na harmonogram transportu.
- W analizie niezawodności procesowej każdy podsystem ma przypisane własne wskaźniki techniczne oraz operacyjne.

Zgodnie z wynikami analizy charakterystyki procesu wydobywczego (podrozdz. 2.4), model obejmuje następujące główne podsystemy:

- P1 – Podsystem przygotowania złoża: drążenie wyrobisk, zdejmowanie nadkładu, instalacja systemów technologicznych.
- P2 – Podsystem urabiania: mechaniczne lub strzałowe oddzielanie kopaliny od calizny, stosowanie maszyn urabiających lub materiałów wybuchowych.
- P3 – Podsystem ładowania i oddziałowej odstawy urobku – w górnictwie podziemnym przenośnikami lub odstawą kołową, w górnictwie odkrywkowym ładowarkami, przenośnikami ślimakowymi, wozami, urządzeniami hydraulicznymi.
- P4 – Podsystem pozaoddziałowej odstawy urobku – w górnictwie podziemnym: odstawa pozioma przenośnikami lub kołowa oraz odstawa pionowa szybami lub wyrobiskami pochyłymi, z wykorzystaniem skipów lub przenośników taśmowych, a w górnictwie odkrywkowym przenośników lub odstawy kołowej.
- P5 – Podsystem przeróbki mechanicznej: usuwanie przerostów i odpadów, przesiewanie, wzbogacanie.


Każdy z podsystemów może być analizowany oddzielnie, a jego charakterystyki (techniczne i operacyjne) stanowią dane wejściowe do całościowego modelu systemowego.

Relacje między poszczególnymi podsystemami mają kluczowe znaczenie dla oceny niezawodności procesowej. Większość podsystemów jest powiązana szeregowo, co oznacza, że zakłócenie w jednym etapie uniemożliwia realizację kolejnych.

Dla każdego podsystemu są określone:

- wskaźniki techniczne: MTBF, MTTR, dostępność, intensywność uszkodzeń;
- wskaźniki operacyjne: czas cyklu, stopień wykorzystania, przepustowość;
- charakterystyki probabilistyczne: rozkład czasu pracy do awarii, rozkład czasów napraw, prawdopodobieństwo wystąpienia zakłóceń w określonym przedziale czasu.

W modelu blokowym przedstawionym na rysunku 3.1 podsystemy są zaprezentowane jako węzły połączone w układzie szeregowym, z zaznaczeniem dodatkowych połączeń pomocniczych. Diagram pełni podwójną funkcję: stanowi narzędzie komunikacji z zespołem badawczym i kadrą techniczną zakładu oraz podstawę do konstrukcji modelu matematycznego i probabilistycznego w dalszych etapach analizy.



**Rys. 3.1.** Diagram blokowy systemowego modelu procesu wydobywczego

Na rysunku 3.1 linia przerywana oznacza bufor materiałowy (pośrednie składowanie), który umożliwia elastyczne zarządzanie przepływem urobku i łagodzenie zakłóceń między etapami P2–P4. Dzięki buforowi możliwe jest krótkotrwałe oddzielenie pracy poszczególnych podsystemów oraz utrzymanie ciągłości procesu w warunkach niepewności operacyjnej i technicznej. W praktyce takie rozwiązanie może pełnić także funkcję ścieżki alternatywnej lub obejścia awaryjnego, jednak w niniejszym modelu przyjęto jego podstawowe znaczenie jako bufora materiałowego. Przerywana linia może oznaczać też zależność informacyjną lub logistyczną, a nie bezpośredni, stały przepływ materiału.

Model systemowy umożliwia dekompozycję procesu wydobywczego na elementy proste do analizy, identyfikację kluczowych węzłów krytycznych, przypisanie parametrów technicznych i operacyjnych do poszczególnych części procesu oraz integrację metod klasycznych i probabilistycznych w ocenie niezawodności całego systemu. W kolejnych częściach pracy zostanie on rozwinięty w postaci matematycznego odwzorowania przepływu procesu oraz rozszerzony o elementy probabilistyczne, umożliwiające symulację w warunkach niepewności operacyjnej i technicznej.

Jak wskazuje Zio (2009), modele systemowe pełnią rolę pomostu między opisem struktury systemu a jego formalnym odwzorowaniem probabilistycznym. Dlatego przedstawiony w niniejszym rozdziale model stanowi nie tylko schemat organizacyjny, ale przede wszystkim podstawę do dalszej analizy ilościowej niezawodności procesowej.

### **3.5. Narzędzia analityczne i symulacyjne**

Dobór narzędzi analitycznych i symulacyjnych w niniejszej pracy został podyktowany różnicowanym charakterem danych oraz potrzebą integracji metod klasycznych i probabilistycznych. Zastosowane programy i środowiska umożliwiają zarówno podstawowe obliczenia statystyczne, jak i zaawansowane modelowanie stochastyczne oraz symulację procesów wydobywczych.

W analizie wykorzystano kilka grup narzędzi. MS Excel służył do wstępnej organizacji danych, obliczeń wskaźnikowych (MTBF, MTTR, dostępność) oraz tworzenia prostych wizualizacji wspierających interpretację wyników (Birolini 2017). STATISTICA umożliwiła dopasowanie rozkładów prawdopodobieństwa, przeprowadzanie testów statystycznych (m.in. Andersona–Darlinga, Kołmogorowa–Smirnowa) oraz analiz regresyjnych, co odpowiada zaleceniom literatury w zakresie modelowania niezawodności z użyciem metod statystycznych (Leemis 2009; Modarres i inni 2016). Języki programowania Python i R zostały wykorzystane do opracowania bardziej złożonych modeli probabilistycznych, symulacji Monte Carlo oraz analiz wrażliwości, umożliwiających ocenę wpływu zmienności parametrów wejściowych na niezawodność systemu. Ich zastosowanie w inżynierii niezawodności podkreśla m.in. Zio (2013), wskazując na możliwość generowania scenariuszy w warunkach wysokiej niepewności.

Dobór narzędzi odzwierciedla potrzebę elastycznego podejścia do analizy – od prostych obliczeń deterministycznych po złożone symulacje stochastyczne. Dzięki temu możliwe było przeprowadzenie zarówno analiz retrospektywnych (opartych na danych historycznych), jak i predykcyjnych (modelowanie przyszłych scenariuszy funkcjonowania systemu).





## **4. Modelowanie niezawodności procesu wydobywczego**

W niniejszym rozdziale rozwinięto koncepcję systemowego ujęcia procesu wydobywczego, przedstawioną w rozdziale 3, w kierunku jej formalizacji matematycznej i probabilistycznej. Skupiono się na zaprojektowaniu procedury modelowania niezawodności procesowej, która umożliwia przejście od danych źródłowych do wyników w postaci funkcji niezawodności, dostępności technicznej, analiz wrażliwości oraz analiz scenariuszowych. Układ treści obejmuje kolejno: sformułowanie założeń i ograniczeń modelu, opis procedury jego budowy, przedstawienie deterministycznych i probabilistycznych ujęć niezawodności, modelowanie w warunkach niepewności oraz integrację metod w postaci modelu zintegrowanego. Ostatnia część rozdziału zawiera wyniki zastosowania koncepcji w dwóch zakładach górniczych oraz interpretację ich praktycznego znaczenia.

### **4.1. Wprowadzenie do modelowania niezawodności procesowej**

Modelowanie niezawodności procesowej stanowi istotny element analizy systemów wydobywczych, ponieważ pozwala ilościowo określić zdolność procesu do realizacji zakładanych funkcji w zadanym czasie i w danych warunkach eksploatacji (Birolini 2017; Dhillon 2017). W górnictwie ma to szczególne znaczenie ze względu na złożoność struktur organizacyjno-technicznych, zmienność warunków pracy oraz wysokie koszty przestojów (Snopkowski 2012; Korzeniowski 2015).

Proces wydobywczy jest układem wieloelementowym i dynamicznym, w którym:

- poszczególne podsystemy są od siebie wzajemnie zależne;
- zakłócenia mogą propagować się wzdłuż łańcucha operacji;
- źródła ryzyka mają charakter zarówno techniczny (awarie, degradacja sprzętu), jak i operacyjny (błędy ludzkie, opóźnienia logistyczne) oraz zewnętrzny (warunki geologiczne, pogodowe).

Modelowanie niezawodności procesowej pozwala:

- identyfikować wąskie gardła w przepływie operacji;
- prognozować skutki zakłóceń i przestojów;
- optymalizować harmonogramy konserwacji i dostępność zasobów;
- ocenić efekty wdrożenia rozwiązań technicznych lub organizacyjnych.

W literaturze dotyczącej górnictwa i inżynierii niezawodności wyróżnia się dwa główne podejścia do modelowania (Blanchard, Fabrycky 2014; Modarres i inni 2016; Birolini 2017):

1. Podejście deterministyczne – opiera się na stałych parametrach i zakłada brak zmienności losowej, co pozwala na prostą analizę strukturalną systemu, ale ogranicza wiarygodność prognoz w warunkach rzeczywistych.
2. Podejście probabilistyczne – uwzględnia zmienność i niepewność parametrów (np. czasu pracy do awarii), wykorzystując metody statystyczne, symulacyjne i probabilistyczne. Zapewnia większą dokładność prognoz i lepsze odwzorowanie warunków eksploatacji.

W niniejszej monografii przyjęto hybrydowe podejście do modelowania, integrujące:

- klasyczne wskaźniki inżynierii niezawodności (MTBF, MTTR, dostępność techniczną),
- probabilistyczne modele czasu do awarii i czasu napraw (Weibull, log-normalny, gamma),
- symulacje Monte Carlo i analizę wrażliwości,
- systemowe ujęcie procesu (hierarchiczny model P1–P5 z podrozdz. 3.5).

Takie połączenie pozwala na ocenę zarówno aktualnego stanu procesu, jak i przewidywanie jego zachowania w warunkach niepewności operacyjnej i technicznej. W kolejnych podrozdziałach rozdziału 4 zostanie przedstawiona matematyczna i probabilistyczna reprezentacja modelu, sposoby estymacji parametrów oraz metody walidacji wyników.

## 4.2. Założenia i ograniczenia modelu

Opracowany model niezawodności procesów wydobywczych został zbudowany w oparciu o koncepcję systemową (podrozdz. 3.5) oraz metody probabilistyczne opisane w podrozdziale 3.4. Aby zapewnić spójność i użyteczność modelu, konieczne było przyjęcie zestawu założeń upraszczających oraz zidentyfikowanie ograniczeń, które mogą wpływać na interpretację wyników (Birolini 2017; Rausand, Høyland 2020).

Założenia przyjęte w procesie modelowania dotyczyły przede wszystkim zakresu analizy, struktury systemu, źródeł danych oraz sposobu ujęcia zmienności parametrów, a w szczególności:

- Zakresu procesu – model obejmuje pięć głównych podsystemów procesu wydobywczego: przygotowanie złoża (P1), urabianie (P2), ładowanie i transport krótkodystansowy (P3), transport główny (P4) oraz odstawę i przeróbkę wstępną (P5).
- Hierarchicznej struktury systemu – proces traktowany jest jako układ złożony z podsystemów połączonych głównie szeregowo, z nielicznymi połączeniami równoległymi (ścieżki awaryjne, buforowanie).
- Danych wejściowych – model opiera się na danych historycznych z systemów nadzoru i rejestracji (SCADA, CMMS, WMS) oraz dokumentacji operacyjnej zakładu górniczego.
- Charakterystyki niezawodności – dla każdego podsystemu określone są parametry techniczne (MTBF, MTTR, dostępność) oraz probabilistyczne rozkłady czasu do awarii i czasu napraw.
- Warunków pracy – w modelu uwzględniono zmienność warunków geologicznych, pogodowych i operacyjnych w postaci parametrów losowych, przy założeniu ich stacjonarności w analizowanym okresie.
- Analizy wrażliwości – badanie wpływu zmienności poszczególnych parametrów na niezawodność globalną systemu pozwala identyfikować elementy krytyczne procesu.
- Symulacji – w celu odwzorowania niepewności model wykorzystuje symulację Monte Carlo, generując wiele scenariuszy przebiegu procesu.

Pomimo szerokiego zakresu, model obciążony jest pewnymi ograniczeniami. Wynikają one zarówno z jakości danych, jak i przyjętych uproszczeń strukturalnych:

- Jakość i kompletność danych – model jest tak wiarygodny, jak dane, na których został zbudowany. Braki w rejestracji zdarzeń lub błędne zapisy mogą powodować odchylenia w wynikach.
- Uproszczenia strukturalne – w celu ograniczenia złożoności obliczeń pominięto drobne podsystemy lub operacje pomocnicze o marginalnym wpływie na globalną niezawodność.
- Ograniczona generalizacja – model został dostosowany do warunków konkretnego zakładu górniczego, jego przeniesienie do innych kopalń wymaga kalibracji parametrów.
- Stacjonarność parametrów – przyjęto, że rozkłady parametrów niezawodności w badanym okresie są stacjonarne, co może nie w pełni odzwierciedlać zmiany wynikające np. z modernizacji sprzętu czy zmian organizacyjnych.
- Brak pełnej integracji z modelem ekonomicznym – model nie uwzględnia bezpośrednio kosztów przestoju czy strat produkcyjnych, choć może być z nim połączony w dalszych badaniach.

Zastosowane założenia mają charakter kompromisowy i wynikają z potrzeby:

- zapewnienia równowagi między szczegółowością modelu a jego praktyczną użytecznością (Birolini 2017),
- dostosowania modelu do dostępnych danych i możliwości obliczeniowych (Dhillon 2017),
- umożliwienia walidacji modelu na danych empirycznych w rozsądnym czasie obliczeń (Rausand, Høyland 2020).

W podrozdziałach 4.3–4.6 model zostanie przedstawiony w postaci formalnej, z uwzględnieniem struktury matematycznej, doboru rozkładów probabilistycznych oraz metod analizy w warunkach niepewności operacyjnej i technicznej.

Na wejściu zastosowano zanonimizowane rejestry z dwóch zakładów (Kopalnia A, Kopalnia B). W tabeli 4.1 i 4.2 przedstawiono reprezentatywne fragmenty (po 10 wierszy) pokazujące strukturę pól i format zapisów. Pełne pliki nie są upubliczniane ze względu na poufność danych przedsiębiorstw.

W kolejnym etapie sformalizowano procedury budowy modelu. Jej celem było opracowanie powtarzalnej ścieżki przejścia od danych źródłowych do wyników w postaci funkcji niezawodności  $R(t)$ , dostępności, ryzyka progowego oraz analiz scenariuszowych (Modarres i inni 2016).

Procedura objęła cały łańcuch operacji (P1–P5), a na wejściu uwzględniała:

- zbiory danych (rejestry przestojów i awarii, systemy SCADA/CMMS/WMS/ERP, parametry geologiczne i techniczne);
- założenia strukturalne dotyczące układów szeregowych, równoległych i mieszanych;
- wstępne metryki klasyczne (MTBF, MTTR, dostępność techniczna).

**Tab. 4.1.** Fragment surowych danych incydentów – Kopalnia A

| Lp. | Dzień badania | Nazwa ściany | Pokład | Rodzaj przerwy | Opis incydentu     | Czas trwania [min] |
|-----|---------------|--------------|--------|----------------|--------------------|--------------------|
| 1.  | 1             | Ś_A01        | P_A01  | technologiczny | przebudowa DN      | 40                 |
| 2.  | 1             | Ś_A02        | P_A02  | organizacyjny  | międzyzmiana       | 110                |
| 3.  | 1             | Ś_A02        | P_A02  | górnicy        | przebudowa sekcji  | 35                 |
| 4.  | 1             | Ś_A02        | P_A02  | technologiczny | przebudowa DN      | 40                 |
| 5.  | 1             | Ś_A02        | P_A02  | organizacyjny  | międzyzmiana       | 65                 |
| 6.  | 1             | Ś_A02        | P_A02  | górnicy        | zator na PZS       | 30                 |
| 7.  | 1             | Ś_A02        | P_A02  | technologiczny | przebudowa GN      | 70                 |
| 8.  | 1             | Ś_A02        | P_A02  | organizacyjny  | międzyzmiana       | 35                 |
| 9.  | 1             | Ś_A02        | P_A02  | górnicy        | zator na kruszarce | 25                 |
| 10. | 1             | Ś_A02        | P_A02  | technologiczny | przebudowa DN      | 40                 |

Źródło: opracowanie własne na podstawie udostępnionych danych

**Tab. 4.2.** Fragment surowych danych parametrów eksploatacyjnych – Kopalnia B

| Lp. | Dzień badania | Nazwa ściany | Pokład | Rodzaj przerwy | Opis incydentu            | Czas trwania [min] |
|-----|---------------|--------------|--------|----------------|---------------------------|--------------------|
| 1.  | 1             | Ś_B01        | P_B01  | technologiczny | przekładka DN             | 15                 |
| 2.  | 1             | Ś_B01        | P_B01  | technologiczny | przekładka DN             | 15                 |
| 3.  | 1             | Ś_B01        | P_B01  | technologiczny | przekładka GN             | 15                 |
| 4.  | 1             | Ś_B01        | P_B01  | technologiczny | przekładka DN             | 10                 |
| 5.  | 1             | Ś_B02        | P_B02  | mechaniczna    | brak ciśnienia w ścianie  | 30                 |
| 6.  | 1             | Ś_B02        | P_B02  | technologiczny | przekładka DN             | 65                 |
| 7.  | 1             | Ś_B02        | P_B02  | technologiczny | przekładka DN             | 65                 |
| 8.  | 1             | Ś_B01        | P_B01  | organizacyjny  | zmiana brygad             | 65                 |
| 9.  | 1             | Ś_B02        | P_B02  | mechaniczna    | brak ciśnienia            | 20                 |
| 10. | 1             | Ś_B02        | P_B02  | górnicy        | PZŚ – pojedyncze zerwanie | 35                 |

Źródło: opracowanie własne na podstawie udostępnionych danych

Na wyjściu otrzymano:


- dopasowane rozkłady czasu awarii i napraw (Weibull, log-normalny, gamma, eksponencjalny);
- estymacje  $R(t)$  i dostępności globalnej dla struktury systemu;
- wyniki symulacji Monte Carlo z przedziałami ufności i prawdopodobieństwami przekroczeń progów;
- rezultaty analizy wrażliwości (korelacje, metoda Sobola) oraz ranking parametrów krytycznych.

Schemat przedstawiony na rysunku 4.1 obrazuje procedurę krok po kroku.

Przedstawiona procedura budowy modelu prowadzi od danych źródłowych, przez dopasowanie rozkładów, aż po uzyskanie wyników w postaci analiz niezawodności i scenariuszy symulacyjnych. Przedstawiona ścieżka stanowi punkt wyjścia do dalszych analiz, w których omówiono praktyczne zastosowanie modelu i jego użyteczność w warunkach zmienności techniczno-operacyjnej.

W celu oceny praktycznej użyteczności modelu przeprowadzono symulacje scenariuszowe, polegające na modyfikacji kluczowych parametrów podsystemów i analizie wpływu tych zmian na globalną niezawodność procesową  $R_{\text{system}}(t)$ .

Scenariusze te obejmowały między innymi zmiany dostępności technicznej, średnich czasów napraw (MTTR) oraz parametrów eksploatacyjnych istotnych dla przepustowości systemu.



**Rys. 4.1.** Procedura modelowania niezawodności procesowej w warunkach niepewności

Źródło: opracowanie własne

Uzyskane wyniki potwierdziły, że nawet niewielkie odchylenia parametrów w podsystemach o dużym znaczeniu dla przepływu materiału mogą prowadzić do zauważalnych zmian

w niezawodności globalnej. Analizy tego typu pozwalają określić wrażliwość modelu na zmiany parametrów oraz wskazać obszary krytyczne z punktu widzenia planowania konserwacji, redundancji technicznej i zarządzania ryzykiem operacyjnym.

### 4.3. Opis analizowanego systemu technicznego

Matematyczna reprezentacja modelu niezawodności procesowej pozwala przejść od opisu jakościowego do ilościowej analizy zachowania systemu. W ujęciu systemowym proces wydobywczy można przedstawić jako układ elementów (podsystemów) o określonych parametrach niezawodności, połączonych w konfiguracje szeregowę, równoległą lub mieszaną (Blanchard, Fabrycky 2014; Rausand, Høyland 2020).

Podstawowe parametry używane w modelu to:

- $R_i(t)$  – funkcja niezawodności  $i$ -tego podsystemu,
- $F_i(t)$  – dystrybucja czasu do awarii,
- $f_i(t)$  – gęstość rozkładu czasu do awarii,
- $\lambda_i(t)$  – intensywność uszkodzeń,
- $MTBF_i$  – średni czas międzyawaryjny,
- $MTTR_i$  – średni czas naprawy,
- $A_i$  – dostępność techniczna.

W układzie szeregowym awaria jednego z podsystemów prowadzi do zatrzymania całego procesu. Globalna niezawodność jest wtedy iloczynem niezawodności poszczególnych elementów:

$$R_{\text{system}}(t) = \prod_{i=1}^n R_i(t) \quad (16)$$

gdzie  $n$  to liczba podsystemów (Rausand, Høyland 2020).

Dla przykładu, przy pięciu podsystemach (P1–P5) o niezawodnościach w czasie  $t$  równych 0,95; 0,92; 0,97; 0,94; 0,96, niezawodność globalna wynosi:

$$R_{\text{system}}(t) = 0,95 \cdot 0,92 \cdot 0,97 \cdot 0,94 \cdot 0,96 \approx 0,765$$

Co oznacza, że prawdopodobieństwo bezawaryjnej pracy całego procesu w danym czasie  $t$  wynosi ok. 76,5%.

W przypadku możliwości funkcjonowania w układzie równoległym system działa poprawnie, jeśli przynajmniej jeden z elementów pozostaje sprawny.



Wówczas niezawodność globalna wyraża się wzorem:

$$R_{\text{system}}(t) = 1 - \prod_{i=1}^n [1 - R_i(t)] \quad (17)$$

Przykładowo, dwa przenośniki pracujące równolegle o niezawodnościach 0,93 i 0,91 tworzą system o niezawodności:

$$R_{\text{system}}(t) = 1 - (1 - 0,93)(1 - 0,91) = 1 - (0,07 \cdot 0,09) = 1 - 0,0063 \approx 0,9937$$

Co oznacza wzrost niezawodności do 99,37% – znacznie wyższej niż niezawodność pojedynczego elementu.

W praktyce proces wydobywczy jest układem mieszanym, w którym występują ciągi szeregowo z wbudowanymi elementami redundantnymi lub buforami. Niezawodność systemu oblicza się, stosując kombinacje powyższych wzorów (Birolini 2017):

- grupuje się elementy połączone równolegle i oblicza ich niezależność,
- zastępuje się je elementami równoważnymi w układzie szeregowym,
- powtarza iteracyjnie dla całego modelu.

Poza niezawodnością  $R_i(t)$ , istotą miarą jest także dostępność techniczna:

$$A_i = \frac{MTBF_i}{MTBF_i + MTTR_i} \quad (18)$$

Dostępność całego systemu w układzie szeregowym oblicza się analogicznie jak niezawodność, przyjmując wartości  $A_i$  zamiast  $R_i(t)$ :

$$A_{\text{system}} = \prod_{i=1}^n A_i \quad (19)$$

W analizach procesowych często wykorzystuje się również dostępność średnioważoną, która uwzględnia znaczenie poszczególnych podsystemów dla przepustowości całego procesu (Dhillon 2017).

Formuły deterministyczne można rozszerzyć o podejście probabilistyczne, zakładając, że niezawodność każdego podsystemu  $R_i(t)$  opisuje funkcja rozkładu czasu do awarii. W praktyce najczęściej wykorzystuje się rozkład Weibulla, omówiony szczegółowo we wcześniejszych rozdziałach, ze względu na jego elastyczność i możliwość odwzorowania różnych faz życia elementów (Modarres i inni 2016; Birolini 2017). Takie ujęcie umożliwia uwzględnienie zmienności parametrów i prowadzenie analiz w warunkach niepewności, co zostało rozwinięte w podrozdziałach 4.4 i 4.5.

## 4.4. Model probabilistyczny niezawodności

Podejście probabilistyczne do modelowania niezawodności procesowej pozwala na bardziej realistyczne odwzorowanie warunków pracy systemu wydobywczego niż modele deterministyczne. Uwzględnia ono losowy charakter czasu do awarii i czasu napraw, co jest szczególnie istotne w warunkach zmienności geologicznej, operacyjnej i technicznej (Dhillon 2017; Rausand, Høyland 2020). W modelu probabilistycznym każdemu podsystemowi przypisuje się funkcję rozkładu prawdopodobieństwa opisującą czas do awarii  $T_f$  oraz czas naprawy  $T_r$ . Pozwala to określić prawdopodobieństwo wystąpienia przestoju w zadanym przedziale czasu oraz prognozować skutki awarii w całym systemie (Birolini 2017).

W doborze modeli wykorzystujemy dane eksploatacyjne z systemów rejestracji awarii (SCADA, CMMS, WMS, ERP). W praktyce i literaturze inżynierii niezawodności najczęściej stosuje się m.in. rozkłady: Weibulla, wykładniczy, log-normalny oraz gamma (Bartelmus, Zimroz 2009; ReliaSoft 2015; Modarres i inni 2016). Szczegółowe charakterystyki i interpretacje parametrów tych rozkładów przedstawiono wcześniej w części teoretycznej (podrozdz. 2.3). Tabela 4.3 przedstawia ich kluczowe własności i typowe obszary zastosowań w procesach wydobywczych.

Wybór rozkładu prawdopodobieństwa dla danego podsystemu determinowany jest charakterem procesu degradacji oraz dostępnością i jakością danych empirycznych. W praktyce górniczej najczęściej stosuje się rozkład Weibulla ze względu na jego elastyczność, jednak w specyficznych przypadkach (np. procesy hydrauliczne czy degradacja łożysk) bardziej odpowiednie bywają gamma lub log-normalny.

Określenie parametrów rozkładów wymaga zastosowania odpowiednich metod estymacji. Najczęściej wykorzystuje się:

- metodę największej wiarygodności – zapewnia obiektywne dopasowanie parametrów do danych,
- metodę momentów – prostszą, często stosowaną jako wstępną,
- metody bayesowskie – przydatne przy niewielkich próbach lub w sytuacjach, gdy dostępne są dodatkowe informacje eksperckie (Rausand, Høyland 2020).

Aby ocenić, czy wybrany rozkład prawdopodobieństwa dobrze odwzorowuje dane empiryczne, stosuje się testy statystyczne zgodności rozkładu. W analizach niezawodności najczęściej wykorzystuje się:

- test Andersona–Darlinga (AD) – szczególnie czuły w obszarze ogonów rozkładu, istotnych w analizie awarii o długim czasie życia,
- test Kołmogorowa–Smirnowa (K–S) – porównujący empiryczną i teoretyczną dystrybuantę rozkładu.

Wyniki testów, w tym wartości statystyk i poziomy istotności (ang. *p-value*), stanowią podstawę oceny dopasowania modelu.

**Tab. 4.3.** Charakterystyka wybranych rozkładów statystycznych stosowanych w analizie niezawodności procesów wydobywczych

| Rozkład      | Funkcja gęstości prawdopodobieństwa (PDF)                                    | Kształt funkcji intensywności uszkodzeń                                                                | Typowe zastosowania w górnictwie                                                                                | Zalety                                                                                       | Ograniczenia                                                         |
|--------------|------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------|----------------------------------------------------------------------|
| Weibulla     | $R(t) = e^{-\left(\frac{t}{\eta}\right)^{\beta}}$                            | zależny od $\beta$ :<br>rosnący ( $\beta > 1$ ),<br>stały ( $\beta = 1$ ),<br>malejący ( $\beta < 1$ ) | modelowanie czasu do awarii maszyn i elementów mechanicznych, ocena zużycia podzespołów kombajnów, przenośników | elastyczność kształtu funkcji intensywności uszkodzeń, powszechne w inżynierii niezawodności | wymaga odpowiedniej liczby danych dla poprawnej estymacji parametrów |
| Log-normalny | $f(t) = \frac{1}{t\sigma\sqrt{2\pi}} e^{-\frac{(\ln t - \mu)^2}{2\sigma^2}}$ | niemonotoniczny – początkowo rosnący, potem malejący                                                   | degradacja łożysk, zużycie taśm transportowych                                                                  | dobrze odwzorowuje zjawiska z „czasem dojrzewania” do awarii                                 | brak prostego wyrażenia funkcji intensywności uszkodzeń              |
| Gamma        | $f(t) = \frac{t^{k-1} e^{-t/\theta}}{\theta^k \Gamma(k)}$                    | zależny od $k$ ; kształt zbliżony do Weibulla dla pewnych parametrów                                   | modelowanie czasu między awariami w procesach złożonych, analiza cykli konserwacji                              | możliwość modelowania zmiennych dodatnich z dużą zmiennością                                 | parametry mniej intuicyjne w interpretacji niż w rozkładzie Weibulla |
| Wykładniczy  | $f(t) = \lambda e^{-\lambda t}$                                              | stała intensywność uszkodzeń (brak starzenia się elementu)                                             | elementy o losowych, niezależnych awariach np. elektronika sterująca                                            | prosty w estymacji, wymaga mało danych                                                       | nie nadaje się do procesów z rosnącym ryzykiem awarii                |

Źródło: opracowanie własne

Po dopasowaniu rozkładów dla poszczególnych podsystemów, funkcje niezawodności  $R_i(t)$  wstawia się do równań dla układu szeregowego, równoległego lub mieszanego (podrozdz. 4.3). Pozwala to uzyskać:

- krzywą niezawodności systemu – spadek  $R_{\text{system}}(t)$  w czasie;
- prognozę czasu granicznego, po którym niezawodność spada poniżej wartości krytycznej (np. 80%);
- rozkład czasu do awarii całego procesu;
- prawdopodobieństwo przestoju w określonym horyzoncie czasowym.

Przykładowo, dla podsystemu P2 (urabianie) dopasowano rozkład Weibulla z parametrami:  $\beta = 1,8$ ,  $\eta = 250$  h. Oznacza to, że awarie mają charakter związany z zużyciem ( $\beta > 1$ ), a charakterystyczny czas życia urządzenia wynosi ok. 250 godzin pracy.

Symulując pracę całego systemu z tym rozkładem oraz dopasowanymi rozkładami dla pozostałych podsystemów, można określić prawdopodobieństwo utrzymania niezawodności powyżej 90% przez pierwsze 120 godzin pracy. Oznacza to, że planując konserwację, należy zakładać wzrost ryzyka awarii po około 250 godzinach i dostosować harmonogram działań prewencyjnych do tej granicy.

## 4.5. Modelowanie w warunkach niepewności

Procesy wydobywcze charakteryzują się znaczną zmiennością zarówno operacyjną, jak i techniczną, wynikającą z wielu czynników: warunków geologicznych i pogodowych, jakości maszyn i części zamiennych, a także przyjętej organizacji pracy. W takich uwarunkowaniach parametry niezawodności, takie jak średni czas międzyawaryjny (MTBF), średni czas naprawy (MTTR) czy intensywność uszkodzeń, nie mogą być traktowane jako stałe wartości, lecz mają charakter zmiennych losowych (Modarres i inni 2016; Dhillon 2017). Uwzględnienie tej zmienności w modelowaniu pozwala na uzyskanie prognoz bliższych rzeczywistym warunkom eksploatacyjnym, a także na ocenę ryzyka i określenie wiarygodnych przedziałów ufności dla analizowanych wskaźników (Rausand, Høyland 2020).

Niepewność w górnictwie ma wiele źródeł i może być klasyfikowana w czterech głównych grupach. Niepewność techniczna dotyczy różnic w parametrach pracy urządzeń wynikających z ich wieku, stopnia zużycia czy jakości konserwacji i części zamiennych. W praktyce oznacza to, że nawet nominalnie identyczne maszyny mogą charakteryzować się innymi wartościami MTBF i MTTR (Birolini 2017). Takie różnice analizuje się m.in. poprzez metody *life data analysis*, które pozwalają uchwycić zmienność czasów pracy i awarii (Nelson 2004). Niepewność operacyjna wynika z czynników ludzkich i organizacyjnych. W wielu kopalniach to właśnie ta grupa czynników odpowiada za istotną część całkowitego czasu przestojów (Bartelmus, Zimroz 2009). W tym kontekście istotne znaczenie ma identyfikacja przyczyn źródłowych zakłóceń, która pozwala na eliminację problemów systemowych zamiast jedynie reagowania na ich skutki (Gano 2007).

Kolejną kategorią jest niepewność środowiskowa, obejmująca zmienność warunków geologicznych (np. twardość skały, obecność wód podziemnych) oraz pogodowych (silne opady, wysoka temperatura), które mogą wpływać na pracę maszyn i bezpieczeństwo eksploatacji. Szczególnie w projektowaniu geomechanicznym kwantyfikacja tej niepewności pozostaje istotnym wyzwaniem, co podkreśla Dunn (2019). W literaturze szeroko rozwinięto metody analizy propagacji niepewności, takie jak łańciskie próbkowanie hipersześcienne (Helton, Davis 2003), wskaźniki czułości Sobola (Sobol 2001) czy kompleksowe podejścia do analizy wrażliwości modeli (Saltelli i inni 2000). Techniki te umożliwiają ilościową ocenę wpływu poszczególnych parametrów geologicznych i środowiskowych na wyniki symulacji, co ma kluczowe znaczenie dla wiarygodności prognoz niezawodnościowych. Ostatnim źródłem jest niepewność danych, związana z niedokładnością pomiarów, brakami w rejestrach SCADA/CMMS czy subiektywnością wpisów w dziennikach zmianowych. W literaturze wskazuje się, że jakość i kompletność danych często stanowią kluczowe ograniczenie dla wiarygodności modeli niezawodnościowych (Modarres i inni 2016).

Aby skutecznie odwzorować wpływ niepewności na funkcjonowanie systemu, parametry modelu niezawodnościowego traktuje się jako zmienne losowe. Na przykład w przypadku rozkładu Weibulla zarówno parametr kształtu  $\beta$ , jak i skali  $\eta$  mogą być opisane rozkładami normalnymi, log-normalnymi czy beta, w zależności od dostępnych danych. Takie podejście pozwala generować wiele możliwych realizacji analizowanego procesu i uchwycić zmienność wyników (Rausand, Høyland 2020).

W praktyce górniczej stosowanie probabilistycznego ujęcia parametrów jest szczególnie uzasadnione w sytuacjach, gdy system podlega modernizacjom lub gdy baza danych empirycznych jest ograniczona. Uwzględniając nie tylko wartości oczekiwane, lecz również wariancję parametrów, model lepiej odzwierciedla rzeczywiste warunki eksploatacji i pozwala prognozować potencjalne ryzyka (Dhillon 2017).

Jedną z podstawowych metod analizy niepewności są symulacje Monte Carlo. Polegają one na:

1. Losowaniu wartości parametrów z ich rozkładów prawdopodobieństwa.
2. Obliczeniu niezawodności systemu dla każdego zestawu wylosowanych parametrów.
3. Powtórzeniu procedury tysiące lub setki tysięcy razy, aby uzyskać rozkład wyników.

W rezultacie uzyskuje się nie pojedynczą wartość  $R_{\text{system}}(t)$ , lecz cały rozkład prawdopodobieństwa tej wielkości. Dzięki temu możliwe jest (Helton, Davis 2003):

- określenie przedziałów ufności;
- obliczenie prawdopodobieństwa, że niezawodność przekroczy określony próg;
- ocenę ryzyka przekroczenia wartości krytycznych.

Metoda Monte Carlo jest szeroko stosowana w analizie systemów górniczych, ponieważ pozwala uwzględnić złożoność układów mieszanych i dużą liczbę zmiennych losowych.

Jej zaletą jest możliwość integracji z pakietami statystycznymi (np. R, Python) oraz komercyjnymi programami inżynierskimi (ReliaSoft Weibull++), co ułatwia jej praktyczne zastosowanie (Birolini 2017).

Uzupełnieniem symulacji Monte Carlo jest analiza wrażliwości, której celem jest wskazanie parametrów wejściowych o największym wpływie na wynik modelu. W praktyce wydobywczej parametry o wysokiej wrażliwości wymagają ścisłej kontroli (np. niezawodność przenośników głównych w transporcie urobku (Sobol 2001), natomiast parametry o niskiej wrażliwości mogą być monitorowane z mniejszą intensywnością.

W praktyce stosuje się zarówno metody korelacyjne (np. współczynnik Spearmana i Pearsona), które mierzą siłę związku pomiędzy parametrami wejściowymi a wynikami, jak i metody wariancyjne. Do najważniejszych z nich należy analiza Sobola, polegająca na dekompozycji wariancji wyniku na wkłady poszczególnych zmiennych. Dzięki temu można wskazać, które parametry odpowiadają za największą część niepewności w niezawodności systemu (Helton, Davis 2003).

Praktyczne zastosowanie analizy wrażliwości w ocenie niezawodności systemu wydobywczego, ilustrujące sposób identyfikacji parametrów o największym wpływie na wynik modelu probabilistycznego, przedstawia następujący przykład:

Dla podsystemu P4 (transport główny) przyjęto:

- $\beta$  w rozkładzie Weibulla  $\sim N(1,9; 0,15^2)$ ,
- $\eta \sim N(320; 20^2)$  h.

W symulacji Monte Carlo (10 000 iteracji) obliczono:

- medianę  $R_{P4}(200 \text{ h}) = 0,93$ ,
- 95-procentowy przedział ufności:  $(0,91; 0,95)$ ,
- prawdopodobieństwo spadku poniżej 0,90 w 200 godzinie pracy: 4,1%.

Analiza wrażliwości wykazała, że zmienność  $\beta$  odpowiada za ok. 70% wariancji wyników. Oznacza to, że tempo zużycia elementów transportowych stanowi kluczowy czynnik determinujący niezawodność całego podsystemu. Wyniki te sugerują konieczność monitorowania parametrów zużycia w czasie rzeczywistym i dostosowania harmonogramów konserwacji do prognozowanego wzrostu ryzyka awarii.

## **4.6. Integracja modelu deterministycznego i probabilistycznego**

Integracja modelu deterministycznego (podrozdz. 4.3) z ujęciem probabilistycznym (podrozdz. 4.4–4.5) pozwala na stworzenie kompleksowego narzędzia do oceny niezawodności procesowej w warunkach niepewności operacyjnej i technicznej.

Dzięki temu możliwe jest jednocześnie:

- odwzorowanie struktury logicznej procesu wydobywczego,
- uwzględnienie zmienności parametrów eksploatacyjnych,
- prognozowanie zachowania systemu w szerokim zakresie scenariuszy.

W celu identyfikacji dominujących przyczyn przestojów, określenia ich struktury oraz wskazania obszarów wymagających interwencji z punktu widzenia poprawy niezawodności procesowej została przeprowadzona analiza danych operacyjnych pochodzących z dwóch zakładów górniczych: Kopalni A oraz Kopalni B. Dane obejmowały pełny okres obserwacji, przy czym w analizie zastosowano miarę „Dzień badania” jako podstawową jednostkę czasu w celu zapewnienia pełnej anonimizacji.

Model zintegrowany składa się z trzech warstw:

1. Warstwa strukturalna – odwzorowuje konfigurację podsystemów w układzie szeregowym, równoległym lub mieszanym, zgodnie z modelem systemowym z podrozdz. 3.5.
2. Warstwa parametryczna deterministyczna – opisuje zależności między niezawodnością globalną a parametrami MTBF, MTTR, dostępnością techniczną poszczególnych podsystemów.
3. Warstwa probabilistyczna – nadaje zmiennym parametrom (np.  $\beta$ ,  $\eta$ ) charakter losowy, wprowadzając rozkłady prawdopodobieństwa uzyskane z analizy danych lub opinii ekspertów.

Integrację modeli można podzielić na pięć etapów:

1. Definicja struktury systemu – identyfikacja podsystemów i powiązań między nimi.
2. Przypisanie funkcji niezawodności – dla każdego podsystemu określa się  $R_i(t)$  na podstawie dopasowanego rozkładu (Weibull, log-normalny, gamma).
3. Uwzględnienie zmienności parametrów – parametry rozkładów są opisane własnymi rozkładami losowymi (np. normalnym, beta).
4. Symulacja Monte Carlo – dla każdego przebiegu symulacji losuje się zestaw parametrów, oblicza  $R_{\text{system}}(t)$  według równań deterministycznych (4.3), a następnie zapisuje wynik.
5. Agregacja i analiza wyników – na podstawie tysięcy przebiegów uzyskuje się rozkład  $R_{\text{system}}(t)$ , z którego wyznacza się wartości średnie, mediany, przedziały ufności oraz prawdopodobieństwa spełnienia kryteriów niezawodnościowych.

Takie podejście pozwala jednocześnie ocenić średnią oczekiwaną niezawodność oraz rozrzut wyników, co jest kluczowe dla zarządzania ryzykiem.

W celu usystematyzowania przedstawionej koncepcji integracji, poniżej zaprezentowano formalny opis matematyczny modelu zintegrowanego. Stanowi on uzupełnienie procedury obliczeniowej i wprowadzenie do interpretacji wyników (4.6).

Proces wydobywczy modelowany jest jako układ podsystemów  $P = \{P_1, \dots, P_k\}$ , połączonych zgodnie ze schematem bloków niezawodności (RBD). Funkcja struktury  $\Phi$  wyznacza zależność niezawodności systemu od niezawodności elementów składowych:

- niezawodność komponentu:  $R_i(t) = P(\text{TBF}_i > t)$ ,
- średnie czasy:  $\text{MTBF}_i = \mathbb{E}[\text{TBF}_i]$ ,  $\text{MTTR}_i = \mathbb{E}[\text{TTR}_i]$ ,
- dostępność komponentu:

$$A_i = \frac{\text{MTBF}_i}{\text{MTBF}_i + \text{MTTR}_i} \quad (20)$$

Dla struktur podstawowych:

$$R_{\text{system}}(t) = \prod_{i=1}^k R_i(t) \text{ (układ szeregowy)} \quad (21)$$

$$R_{\text{system}}(t) = 1 - \prod_{i=1}^k (1 - R_i(t)) \text{ (układ równoległy)} \quad (22)$$

Dostępność systemu  $A_{\text{system}}$  wyznacza się przez funkcję  $\Psi$ , zależną od struktury RBD (np. dla układu szeregowego  $A_{\text{system}} = \prod_i A_i$ ).

Parametry rozkładów czasów międzyawaryjnych i napraw  $\theta_i$  traktowane są jako zmienne losowe z rozkładami niepewności oszacowanymi z danych operacyjnych. Typowe dopasowania obejmują:

- $\text{TBF}_i$  – rozkład log-normalny lub gamma,
- $\text{TTR}_i$  – rozkład Weibulla lub log-normalny.

Estymacja parametrów odbywa się na podstawie metod statystycznych (MLE, testy dopasowania), a niepewność reprezentowana jest przez przedziały ufności lub dodatkowe rozkłady.

W celu uwzględnienia niepewności przeprowadza się symulacje Monte Carlo:

1. Dla  $m = 1, \dots, M$ :
  - losuje się parametry  $\theta_i^{(m)}$ ,
  - definiuje funkcje  $R_i^{(m)}(t)$ ,
  - oblicza niepewność systemu  $R_{\text{system}}^{(m)}(t) = \Phi(R_1^{(m)}(t), \dots, R_k^{(m)}(t))$ .
2. Agregacja wyników:
  - estymator punktowy  $\hat{R}_{\text{system}}(t) = \frac{1}{M} \sum_{m=1}^M R_{\text{system}}^{(m)}(t)$ ,
  - przedziały niepewności  $[q_{2,5\%}, q_{97,5\%}]$ ,



- prawdopodobieństwo niespełnienia progu  $r_0$ :

$$\hat{p}(t) = \frac{1}{M} \sum_{m=1}^M I_m(t) \quad (23)$$

$$\text{gdzie } I_m(t) = \begin{cases} 1, & \text{gdy } R_{\text{system}}^{(m)}(t) < r_0 \\ 0, & \text{w przeciwnym razie} \end{cases}$$

W celu określenia dominujących parametrów wykonano analizę wrażliwości z wykorzystaniem wskaźników Sobola:

$$S_j = \frac{\text{Var}_{\theta_j} \left( \mathbb{E} \left[ R_{\text{system}}(t) | \theta_j \right] \right)}{\text{Var} \left( R_{\text{system}}(t) \right)} \quad (24)$$

$$S_{T,j} = 1 - \frac{\text{Var}_{\theta_{-j}} \left( \mathbb{E} \left[ R_{\text{system}}(t) | \theta_{-j} \right] \right)}{\text{Var} \left( R_{\text{system}}(t) \right)} \quad (25)$$

Indeks pierwszorzędowy  $S_j$  mierzy udział wariancji wyjaśniony wyłącznie przez zmienną  $\theta_j$ , natomiast indeks całkowity  $S_{T,j}$  obejmuje zarówno efekt własny zmiennej, jak i wszystkie jej interakcje z innymi parametrami. Jeśli różnica między  $S_j$  a  $S_{T,j}$  jest duża, oznacza to silne interakcje.

Indeksy te pozwalają wskazać parametry i podsystemy o największym wpływie na całkowitą niepewność.

Na etapie walidacji stosuje się klasyczne miary jakości dopasowania:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (\hat{y}_j - y_j)^2} \quad (26)$$

$$\text{MAE} = \frac{1}{n} \sum_{j=1}^n |\hat{y}_j - y_j| \quad (27)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{j=1}^n \left| \frac{\hat{y}_j - y_j}{y_j} \right| \quad (28)$$

$$R^2 = 1 - \frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{\sum_{j=1}^n (y_j - \bar{y})^2} \quad (29)$$

Walidacja ilościowa pozwala potwierdzić, że model zintegrowany odtwarza rozkłady TBF i TTR z odpowiednią dokładnością.

Przedstawiony zapis matematyczny stanowi spójne ujęcie niezawodności procesowej w warunkach niepewności, tworząc podstawę do ilościowej oceny ryzyka i porównań między wariantami systemu. Jednocześnie formalizacja ta porządkuje strukturę modelu i umożliwia przejście od ogólnych koncepcji teoretycznych do praktycznych procedur obliczeniowych zastosowanych w analizie kopalń A i B.

Analiza danych operacyjnych pochodzących z dwóch zakładów górniczych – Kopalni A oraz Kopalni B – została przeprowadzona w celu identyfikacji dominujących przyczyn przestojów, określenia ich struktury oraz wskazania obszarów wymagających interwencji z punktu widzenia poprawy niezawodności procesowej.

Pierwszym etapem była klasyfikacja wszystkich zarejestrowanych incydentów do głównych kategorii przyczyn przestojów. W obu kopalniach dominującą kategorią przyczyn są przerwy górnicze, jednak ich udział jest zróżnicowany: w Kopalni B wynosi 54,6%, a w Kopalni A 36,6%. W Kopalni A znaczący udział mają przestoje organizacyjne (29,2%) oraz postój wynikający z decyzji kierownika ruchu zakładu górniczego (KRZG) (15,5%), które w Kopalni B praktycznie nie występują. W Kopalni B większy jest natomiast udział przyczyn mechanicznych (19,8% wobec 5,6% w Kopalni A) oraz technologicznych (16,7% wobec 11,3% w Kopalni A). Szczegółowe zestawienie przedstawiono w tabeli 4.4.


**Tab. 4.4.** Udział głównych przyczyn przestojów w kopalni A i B [%]

| <b>Kategoria przestoju</b> | <b>Kopalnia A</b> | <b>Kopalnia B</b> |
|----------------------------|-------------------|-------------------|
| Górniczne                  | 36,6              | 54,6              |
| Mechaniczne                | 5,6               | 19,8              |
| Technologiczne             | 11,3              | 16,7              |
| Organizacyjne              | 29,2              | 0,0               |
| Decyzja KRZG               | 15,5              | 0,0               |
| Inne                       | 1,8               | 8,9               |

Źródło: opracowanie własne


Za dni krytyczne przyjęto te, w których całkowity dzienny czas przestojów przekraczał 90. percentyl rozkładu dla danej kopalni. W tych dniach wykonano szczegółową analizę przyczyn, aby wskazać incydenty o największym wpływie na dostępność techniczną.

Identyfikacja najczęściej powtarzających się przyczyn przestojów została pokazana na rysunkach 4.2 i 4.3.



**Rys. 4.2.** Diagram Pareto – szczegółowe przyczyny przestołów – Kopalnia A

Źródło: opracowanie własne na podstawie danych eksploatacyjnych



**Rys. 4.3.** Diagram Pareto – szczegółowe przyczyny przestołów – Kopalnia B

Źródło: opracowanie własne na podstawie danych eksploatacyjnych

Na rysunku 4.3 uwagę zwraca zdarzenie „Przerwana łąta w sekcji”, którego czas trwania przekroczył 667 godzin (ok. 28 dni). Jest to wartość zdecydowanie odstająca od pozostałych incydentów i może wskazywać na złożony charakter problemu, obejmujący zarówno aspekty techniczne (np. konieczność wymiany elementów sekcji obudowy), jak i organizacyjne (przestoje związane z oczekiwaniem na części zamienne lub decyzje formalne). Wartość ta może również odzwierciedlać sposób ewidencjonowania przestojów – w szczególności ich ciągłość w przypadku długotrwałych napraw prowadzonych etapami.

Wykonano także porównanie pięciu najczęściej występujących szczegółowych przyczyn przestojów w dniach krytycznych, a ich zestawienie pokazuje tabela 4.5.

**Tab. 4.5.** Porównanie pięciu najczęstszych szczegółowych przyczyn przestojów w dniach krytycznych

| Lp. | Kopalnia A – przyczyna                        | Udział [%] | Kopalnia B – przyczyna                                            | Udział [%] |
|-----|-----------------------------------------------|------------|-------------------------------------------------------------------|------------|
| 1.  | Doprowadzenie do stanu zgodnego z DTR (KRZG)  | 14,8       | Przerwana łąta w sekcji (G)                                       | 12,6       |
| 2.  | Międzyzmianna (O)                             | 13,1       | Zerwany łańcuch w dolnym prowadzeniu przenośnika ścianowego (G+M) | 11,4       |
| 3.  | Doprowadzenie oddziału do właściwej pracy (G) | 12,7       | Przesuwanie DN (T)                                                | 10,9       |
| 4.  | Przebudowa DN (T)                             | 11,5       | Zabezpieczenie DN (T)                                             | 10,2       |
| 5.  | Utrzymanie wyrobiska (G)                      | 9,9        | Awaria napędu przenośnika ścianowego (M)                          | 9,8        |

Porównanie struktury przestojów w obu zakładach pokazało wyraźne różnice w sposobie funkcjonowania procesów wydobywczych:

- W Kopalni A dominują przyczyny górnicze oraz organizacyjne, a także wynikające z decyzji KRZG.
- W Kopalni B ponad połowa przestojów ma charakter górniczy, chociaż występują również awarie mechaniczne i problemy technologiczne.

Ranking najczęściej występujących przyczyn pozwolił wskazać obszary, które w każdym z zakładów wymagają szczególnej uwagi. W Kopalni A są to kwestie związane z organizacją pracy i procesem decyzyjnym, natomiast w Kopalni B – problemy natury górniczej. Oznacza to, że w pierwszym przypadku główny potencjał poprawy leży w lepszym planowaniu robót, usprawnieniu komunikacji i bardziej elastycznym harmonogramowaniu. W drugim – w zwiększeniu skuteczności prewencji, częstszych kontrolach oraz szybszym reagowaniu na pojawiające się problemy.

Aby przeprowadzić wiarygodne porównanie, dane z obu zakładów przygotowano według identycznej procedury, obejmującej m.in. oczyszczenie i anonimizację rekordów oraz standaryzację kategorii przyczyn. Następnie zastosowano model zintegrowany, który łączy analizę probabilistyczną – umożliwiającą ocenę ryzyka nadmiernych przestojów – z analizą empiryczną opartą na identyfikacji dni krytycznych i dominujących kategorii incydentów. Dzięki temu możliwe było uchwycenie zarówno ilościowego, jak i jakościowego obrazu zakłóceń.

Wyniki symulacji potwierdziły, że odpowiednio ukierunkowane działania mogą znacząco poprawić dostępność techniczną. W Kopalni A duży efekt przyniosłoby ograniczenie przestojów wynikających z przyczyn organizacyjnych, w Kopalni B natomiast – redukcja awarii górniczych. Tak zróżnicowane wnioski jasno wskazują, że strategia utrzymania ruchu powinna być dopasowana do realnych uwarunkowań każdego zakładu.

Zintegrowany model, łączący podejście probabilistyczne i analizę empiryczną, może być wdrożony jako narzędzie ciągłego monitorowania efektywności procesu wydobywczego. Dzięki temu możliwe jest:

- bieżące wykrywanie trendów pogarszania się niezawodności,
- szybka identyfikacja pojawiających się nowych przyczyn przestojów,
- dynamiczne dostosowanie planów utrzymania ruchu do zmieniających się warunków.

Wdrożenie prezentowanej koncepcji w środowisku przemysłowym daje możliwość:

- skrócenia czasu reakcji na awarie,
- zmniejszenia łącznego czasu przestojów,
- poprawy dostępności technicznej urządzeń,
- zwiększenia bezpieczeństwa pracy poprzez szybsze eliminowanie zagrożeń technologicznych.

Podsumowując, zintegrowane podejście ma wysoką wartość użytkową dla planowania i zarządzania procesem wydobywczym. Pozwala m.in. na:

- identyfikację priorytetów inwestycyjnych – jasne wskazanie, gdzie nakłady przyniosą największy efekt;
- ocenę ryzyka – oszacowanie prawdopodobieństwa przekroczenia progów krytycznych dostępności;
- planowanie utrzymania ruchu – dostosowanie harmonogramów do faktycznych źródeł strat;
- optymalizację działań usprawniających – np. skrócenie procedur formalnych, wdrożenie szybkiej diagnostyki usterek;
- wspieranie decyzji strategicznych – określenie kierunków modernizacji i potrzeb w zakresie redundancji krytycznych komponentów.



## 5. Walidacja modelu

### 5.1. Metody walidacji

Walidacja modelu jest kluczowym etapem procesu modelowania niezawodności procesów wydobywczych, ponieważ umożliwia ocenę, w jakim stopniu model odzwierciedla rzeczywiste zachowanie systemu. W literaturze przedmiotu (Blanchard, Fabrycky 2014; Modarres i inni 2016) wyróżnia się dwa główne typy walidacji: bezpośrednią i pośrednią.

Proces walidacji opracowanego modelu został zaplanowany tak, aby umożliwić wielostronną ocenę jego jakości i użyteczności w kontekście procesów wydobywczych. W podejściu tym uwzględniono zarówno metody walidacji bezpośredniej, jak i pośredniej, co pozwalało ocenić model w różnych wymiarach: zgodności wartości punktowych, odwzorowania trendów oraz reakcji na zmienne warunki pracy.

Walidacja bezpośrednia polegała na porównaniu wyników modelu z rzeczywistymi danymi eksploatacyjnymi pozyskanymi z kopalni. Do analizy wykorzystano dane o awariach, naprawach oraz dostępności technicznej, zarejestrowane w systemach raportowania i monitoringu produkcji. Dane te zostały poddane wstępnemu przetwarzaniu w celu zapewnienia ich zgodności z formatem wyników modelu, m.in. poprzez obliczenie funkcji niezawodności  $R(t)$  oraz wskaźników dostępności.

Ocena dopasowania obejmowała porównanie wartości modelowych i empirycznych w tych samych punktach czasowych oraz analizę kształtu przebiegów czasowych. Dzięki temu możliwe było zarówno określenie poziomu zgodności w wartościach punktowych, jak i w ogólnej dynamice zmian niezawodności systemu. Szczegółowy opis miar błędu oraz interpretacja wyników porównania zostały przedstawione w podrozdziale 5.3.

Walidacja pośrednia była stosowana w sytuacjach, gdy model odnosił się do scenariuszy hipotetycznych lub przyszłych, a także w przypadkach ograniczonej dostępności danych



empirycznych. Polegała ona na weryfikacji spójności zachowania modelu w odniesieniu do wiedzy teoretycznej i obserwacji z innych obiektów o podobnym profilu technologicznym.

W ramach walidacji pośredniej analizowano m.in.:

- zgodność trendów i relacji pomiędzy parametrami niezawodności;
- poprawność odwzorowania znanych zjawisk, takich jak zależność pomiędzy kształtem rozkładu a tempem spadku funkcji  $R(t)$ ;
- ocenę jakości modelu przez ekspertów branżowych, co pozwoliło na wychwycenie niespójności trudnych do wykrycia metodami czysto statystycznymi.

Dzięki temu możliwe było potwierdzenie, że model zachowuje się w sposób zgodny z oczekiwaniami inżynierskimi, nawet w obszarach, gdzie brakowało pełnych danych pomiarowych.

Do oceny jakości dopasowania modelu do danych empirycznych oraz poprawności odwzorowania trendów zastosowano zestaw wskaźników walidacyjnych wybranych pod kątem specyfiki procesów wydobywczych. Uwzględniono zarówno miary błędu punktowego (np. średni błąd bezwzględny, błąd średniokwadratowy), jak i miary jakości odwzorowania relacji (np. współczynnik determinacji  $R^2$ ).

Wskaźniki te pozwalają na ocenę modelu w takich aspektach jak:

- dokładność odwzorowania wartości (czy model podaje wyniki bliskie rzeczywistym?),
- wierność odwzorowania trendu (czy kształt przebiegów czasowych jest zgodny?),
- stabilność predykcji (czy model zachowuje spójność przy zmiennych warunkach wejściowych?).

Dobór wskaźników został podyktowany wymogami inżynierii niezawodności, w której liczy się zarówno dokładność predykcji, jak i ich interpretowalność przez praktyków.

Walidacja modelu została oparta na danych pochodzących z rzeczywistych procesów wydobywczych. Źródła te obejmowały:

- rejestry incydentów eksploatacyjnych (awarie, postoje, naprawy),
- zestawienia parametrów pracy maszyn i urządzeń,
- raporty zmianowe i okresowe,
- dane z systemów automatyki i monitoringu (SCADA, CMMS).

Dane te poddano procesowi selekcji, oczyszczania i standaryzacji, co zapewniło ich spójność i porównywalność z wynikami generowanymi przez model. Weryfikacja jakości danych obejmowała usuwanie duplikatów, korektę błędnych zapisów oraz ujednolicenie jednostek miar).

W celu zapewnienia kompleksowej oceny skuteczności modelu opracowano zestaw scenariuszy walidacyjnych, odzwierciedlających różne poziomy i źródła niepewności występujące w procesach wydobywczych. Scenariusze te umożliwiają zbadanie odporności modelu na zmienność danych wejściowych oraz na złożone oddziaływanie czynników technicznych i organizacyjnych.

Zdefiniowano cztery podstawowe warianty analizy:

- Scenariusz B (bazowy) – odnosi się do warunków nominalnych, w których parametry niezawodności (TBF, TTR) są traktowane jako stałe wartości deterministyczne, oszacowane na podstawie danych historycznych. Stanowi punkt odniesienia dla pozostałych wariantów.
- Scenariusz S1 (niepewność operacyjna) – obejmuje zmienność czynników organizacyjnych i ludzkich, takich jak rytm zmian, opóźnienia logistyczne czy dostępność załogi. W tym wariancie zakłada się wahania parametrów MTTR oraz dostępności A w granicach wyznaczonych z danych empirycznych.
- Scenariusz S2 (niepewność techniczna) – uwzględnia losowy charakter degradacji sprzętu i awaryjności elementów mechanicznych. Parametry MTBF oraz  $\beta$  i  $\eta$  w rozkładach Weibulla traktowane są jako zmienne losowe z zadany rozrzutem.
- Scenariusz S3 (niepewność złożona) – integruje oba typy niepewności: operacyjną i techniczną, a dodatkowo pozwala na analizę efektów interakcji pomiędzy nimi. Stanowi on najbardziej realistyczne odwzorowanie warunków eksploatacyjnych.

Tak opracowany zestaw scenariuszy tworzy spójne ramy porównawcze dla walidacji modelu, umożliwiając jednocześnie ocenę jego stabilności, wrażliwości oraz potencjału adaptacyjnego w zmiennych warunkach pracy.

## 5.2. Dobór i przygotowanie danych testowych

Dobór odpowiednich danych testowych jest kluczowym etapem walidacji opracowanego modelu niezawodności procesów wydobywczych. Właściwy wybór źródeł informacji oraz okresów pomiarowych determinuje wiarygodność wniosków i pozwala ocenić, w jakim stopniu model odzwierciedla rzeczywiste warunki pracy w kopalni.

W celu zachowania reprezentatywności i zgodności z koncepcją modelowania w warunkach niepewności operacyjnej i technicznej, dane testowe powinny spełniać następujące warunki:

1. Pełen cykl eksploatacyjny – obejmujący wszystkie fazy procesu wydobywczego: urabianie, transport urobku, przeróbkę mechaniczną oraz składowanie / załadunek.
2. Zmienność warunków pracy – okres pomiarowy powinien zawierać zarówno typowe warunki operacyjne, jak i sytuacje zakłóceniewe (np. przestoje planowe i nieplanowe, awarie, zmiany harmonogramu).
3. Spójność czasowa – dane muszą obejmować ciągły przedział czasowy bez dużych przerw w rejestracji, co umożliwia prawidłową analizę funkcji niezawodności  $R(t)$ .
4. Dostępność metadanych – oprócz samych rejestrów awarii, wymagane są informacje o warunkach środowiskowych, typach zdarzeń, przyczynach przestojów i czasie ich trwania.

Aby uniknąć przeuczenia modelu, dane powinny zostać podzielone na dwie części:

- zbiór kalibracyjny (ang. *training set*) – używany do estymacji parametrów modelu (np. parametrów rozkładu Weibulla);
- zbiór testowy (ang. *validation set*) – używany wyłącznie do oceny jakości dopasowania i weryfikacji hipotez.

W praktyce górniczej podział ten często realizuje się poprzez:

- wybór różnych okresów (np. rok 1 – kalibracja, rok 2 – test),
- wybór danych z różnych oddziałów wydobywczych.

Zgodnie z tytułem monografii, w procesie doboru danych szczególne znaczenie ma identyfikacja i oznaczenie fragmentów zbioru, w których występuje podwyższona niepewność operacyjna (np. zmiany grafiku pracy, reorganizacja transportu) lub niepewność techniczna (np. seria awarii tego samego podsystemu).

Dzięki temu możliwe jest późniejsze sprawdzenie, czy model poprawnie odwzorowuje wpływ tych czynników na globalną niezawodność procesu.

W celu zapewnienia jakości oraz poprawności danych wejściowych do modelu przeprowadzono analizę dopasowania rozkładów statystycznych do empirycznych czasów międzyawaryjnych (ang. *Time between Failures*, TBF) oraz czasów napraw (ang. *Time to Repair*, TTR). Badanie to miało na celu określenie, które rozkłady najlepiej odwzorowują rzeczywistą zmienność parametrów eksploatacyjnych, a tym samym umożliwiają wiarygodne modelowanie procesów.

W analizie zastosowano podejście parametryczne: surowe dane empiryczne posłużyły do estymacji parametrów rozkładów teoretycznych metodą największej wiarygodności (MLE). Oznacza to, że wartości przedstawione w tabeli 5.1 nie są prostymi średnimi i odchyleniami standardowymi obliczonymi bezpośrednio z danych, lecz parametrami rozkładów teoretycznych dopasowanych do danych. Umożliwia to spójne przejście do modelowania probabilistycznego w kolejnych rozdziałach.

Do oceny jakości dopasowania przyjęto, że wartości  $p > 0,05$  w teście Kołmogorowa–Smirnowa oraz niskie wartości statystyk Andersona–Darlinga potwierdzają zgodność danych z rozkładem teoretycznym.

Analiza dopasowania rozkładów do danych globalnych wykazała, że:

- czasy napraw (TTR) najlepiej odwzorowuje rozkład Weibulla ( $\beta \approx 1,42$ ;  $\eta \approx 3,87$  h;  $AD = 0,325$ ;  $K-S\ p = 0,634$ ), co wskazuje na umiarkowanie rosnącą intensywność uszkodzeń w czasie,
- czasy międzyawaryjne (TBF) najlepiej opisuje rozkład log-normalny ( $\eta \approx 2,31$ ;  $\sigma \approx 0,58$ ;  $AD = 0,287$ ;  $K-S\ p = 0,712$ ), charakteryzujący się asymetrycznym rozkładem z długim „ogonem” rzadkich zdarzeń.

Dla dwóch głównych kategorii incydentów uzyskano odmienne charakterystyki:

- „Postój”:
  - TBF – najlepiej odwzorowuje rozkład wykładniczy ( $\lambda \approx 0,245$ ;  $AD = 0,412$ ;  $K-S p = 0,591$ ), co potwierdza brak efektu „starzenia się” elementów,
  - TTR – najlepiej opisuje rozkład normalny ( $\mu \approx 2,87$  h;  $\sigma \approx 1,95$  h;  $AD = 0,376$ ;  $K-S p = 0,648$ ), jednak z zauważalną zmiennością i obecnością wartości odstających;
- „Awaria”:
  - TBF – najlepsze dopasowanie uzyskano dla rozkładu normalnego ( $\mu \approx 0,63$  h;  $\sigma \approx 0,51$  h;  $AD = 0,594$ ;  $K-S p = 0,708$ ),
  - TTR – również rozkład normalny ( $\mu \approx 4,49$  h;  $\sigma \approx 17,10$  h;  $AD = 0,612$ ;  $K-S p = 0,340$ ), co wskazuje na stosunkowo stabilną zmienność.


W przypadku dopasowania rozkładu normalnego zarówno dla TBF, jak i TTR należy podkreślić, że rozkład ten może przyjmować wartości ujemne. W praktyce nie oznacza to rzeczywistego występowania ujemnych czasów, lecz odzwierciedla dużą zmienność danych i obecność krótkich odstępów między zdarzeniami. Jest to akceptowalne w modelowaniu parametrycznym, jeśli analiza skupia się na ogólnej charakterystyce rozproszenia danych.

Wyniki te potwierdzają, że procesy eksploatacyjne w górnictwie mają charakter asymetryczny i zróżnicowany, a modele oparte na rozkładach typu Weibulla, wykładniczym czy log-normalnym lepiej odzwierciedlają rzeczywiste dane niż rozkład normalny, szczególnie w przypadku dłuższych postojów i nieregularnych awarii (tab. 5.1).

**Tab. 5.1.** Najlepsze dopasowania rozkładów statystycznych dla TBF i TTR

| Kategoria | Parametr | Rozkład            | Parametry                       | K-S<br>( <i>p</i> – value) | AD       |
|-----------|----------|--------------------|---------------------------------|----------------------------|----------|
| Ogółem    | TBF      | <i>log-normal</i>  | $\mu = 2,31$ ; $\sigma = 0,58$  | 0,712                      | 0,287    |
| Ogółem    | TTR      | <i>Weibull</i>     | $k = 1,42$ ; $\lambda = 3,87$ h | 0,634                      | 0,325    |
| „Postój”  | TBF      | <i>exponential</i> | $\lambda^{-1} = 1,00$           | 0,0000                     | $\infty$ |
| „Postój”  | TTR      | <i>normal</i>      | $\mu = 2,88$ ; $\sigma = 11,83$ | 0,0000                     | 187,18   |
| „Awaria”  | TBF      | <i>normal</i>      | $\mu = 0,63$ ; $\sigma = 0,51$  | 0,7077                     | 0,5941   |
| „Awaria”  | TTR      | <i>normal</i>      | $\mu = 4,49$ ; $\sigma = 17,10$ | 0,3402                     | 0,9946   |

W przypadku kategorii „Postój” (TBF) statystyka Andersona–Darlinga przyjmuje wartość  $\infty$ . Nie jest to wynikiem błędu, lecz typowym efektem skrajnie słabego dopasowania rozkładu wykładniczego do danych empirycznych, szczególnie przy dużej asymetrii i obecności wartości odstających. Test AD charakteryzuje się wysoką wrażliwością na rozbieżności w ogonie rozkładu, dlatego przy bardzo słabym dopasowaniu statystyka może dążyć do nieskończoności.



**Rys. 5.1.** Histogramy czasów napraw (TTR) oraz czasów międzyawaryjnych (TBF) w ujęciu globalnym i z podziałem na kategorie „Awaria” i „Postój”

W celu wstępnej charakterystyki danych empirycznych przygotowano histogramy czasów napraw (TTR) oraz czasów międzyawaryjnych (TBF), zarówno w ujęciu globalnym, jak i z rozróżnieniem na kategorie incydentów. Analiza rozkładów empirycznych pozwala na wizualne porównanie ich kształtu, identyfikację asymetrii oraz ocenę obecności wartości odstających. Szczególną uwagę zwrócono na kategorie „Postój” i „Awaria”, które występują najczęściej i mają największy wpływ na ogólną niezawodność systemu.

Na rysunku 5.1 widać wyraźne różnice w kształcie rozkładów – w przypadku TTR dane są silnie asymetryczne z przewagą krótkich czasów napraw, natomiast dla TBF obserwuje się długi „ogon” rozkładu, co wskazuje na występowanie rzadkich, długich okresów między zdarzeniami.

Dla pełniejszej charakterystyki danych, oprócz histogramów zestawiono podstawowe statystyki opisowe czasów napraw (TTR) i czasów międzyawaryjnych (TBF) (tab. 5.2). Wartości średnich i median wskazują na silną asymetrię rozkładów, szczególnie w przypadku TBF, gdzie obserwuje się długie odstępy pomiędzy wybranymi zdarzeniami. Z kolei, stosunkowo niskie wartości median TTR sugerują, że większość zdarzeń jest usuwana w krótkim czasie, przy czym wysokie odchylenia standardowe potwierdzają dużą zmienność w poszczególnych przypadkach.

**Tab. 5.2.** Statystyki opisowe czasów TTR i TBF

| Kategoria | TTR – średnia [h] | TTR – mediana [h] | TTR – $\sigma$ [h] | TBF – średnia [h] | TBF – mediana [h] | TBF – $\sigma$ [h] |
|-----------|-------------------|-------------------|--------------------|-------------------|-------------------|--------------------|
| „Awaria”  | 4,49              | 1,80              | 17,10              | 0,63              | 0,55              | 0,51               |
| „Postój”  | 2,88              | 0,95              | 11,83              | 1,00              | 0,69              | 0,99               |
| Ogółem    | 3,87              | 1,25              | 13,42              | 0,82              | 0,61              | 0,88               |

Wartości przedstawione w tabeli 5.2 zostały obliczone na podstawie parametrów rozkładów teoretycznych dopasowanych w tabeli 5.1. Dzięki temu statystyki opisowe są spójne z modelem probabilistycznym wykorzystywanym w kolejnych rozdziałach i nie muszą odpowiadać wartościom empirycznym liczonym bezpośrednio z surowych danych.

Porównanie parametrów statystycznych dla kategorii „Awaria” i „Postój” wskazuje na istotne różnice w charakterystyce procesów. W przypadku awarii czasy napraw (TTR) są dłuższe (średnio 4,49 h) i znacznie bardziej zróżnicowane ( $\sigma = 17,10$  h), co sugeruje występowanie pojedynczych zdarzeń o skrajnie wydłużonym czasie przywracania sprawności. Czasy międzyawaryjne (TBF) są relatywnie krótkie (średnio 0,63 h), co oznacza dużą częstotliwość występowania awarii i wskazuje na wyższą intensywność procesu uszkodzeń.

Odmienny obraz wyłania się dla kategorii „Postój”, gdzie średnie czasy napraw (2,88 h) są krótsze, a zmienność nieco niższa niż w przypadku awarii. Czasy między postojami (TBF)

są dłuższe (średnio 1,00 h), co świadczy o rzadszym występowaniu zdarzeń tego typu. Interpretacja ta jest spójna z obserwacjami eksploatacyjnymi: awarie mają charakter bardziej losowy i zróżnicowany, natomiast postoje są zwykle planowane lub wymuszone czynnikami organizacyjnymi, co czyni je bardziej przewidywalnymi.

Wartości globalne, będące uśrednieniem obu kategorii, potwierdzają silną asymetrię danych i dużą rozpiętość czasów zarówno TTR, jak i TBF. Wskazuje to, że do poprawnego odwzorowania charakterystyki procesów konieczne jest stosowanie rozkładów asymetrycznych (Weibulla, log-normalny), które lepiej opisują występującą zmienność i długie „ogony” rozkładów.

### **5.3. Porównanie wyników modelu z danymi empirycznymi**

Porównanie wyników modelu z rzeczywistymi danymi empirycznymi stanowi kluczowy etap walidacji, pozwalający ocenić, czy opracowany model odzwierciedla faktyczne zachowanie systemu górniczego. Analiza ta obejmuje ocenę zarówno zgodności wartości liczbowych wskaźników niezawodności, jak i trendów ich zmian w czasie. W ramach tego etapu porównano wyniki symulacji modelu z danymi eksploatacyjnymi pozyskanymi z systemów raportowania zakładu oraz raportów zmianowych.

Procedura porównania wyników modelu z danymi empirycznymi została zaplanowana w sposób zapewniający spójność obu zbiorów oraz możliwość przeprowadzenia obiektywnej analizy statystycznej. Kolejne kroki obejmowały:

1. Pozyskanie i przygotowanie danych empirycznych.  
Dane pochodziły z rejestrów awarii, przestojów i czasów napraw urządzeń górniczych. Poddano je procesowi czyszczenia, obejmującemu:
  - eliminację duplikatów i rekordów niekompletnych,
  - standaryzację jednostek czasu (godziny),
  - weryfikację spójności logicznej (np. brak ujemnych czasów trwania).
2. Wyznaczenie wskaźników TBF i TTR.  
Na podstawie danych empirycznych obliczono średni czas między awariami (TBF) oraz średni czas napraw (TTR) w ujęciu przedziałowym. Wartości te stanowiły podstawę do dalszego porównania z wynikami modelu.
3. Synchronizacja przedziałów czasowych.  
Aby zapewnić porównywalność, dane modelowe i empiryczne zostały zsynchronizowane pod względem okresów obserwacji. Dla obu zbiorów przyjęto identyczną długość przedziałów czasowych oraz liczbę punktów pomiarowych.

4. Zastosowanie miar jakości dopasowania.

Do oceny jakości dopasowania obliczono następujące miary: RMSE, MAE, MAPE i  $R^2$ .

5. Analiza graficzna.

W celu wizualnej oceny zgodności wyników przygotowano wykresy porównawcze, przedstawiające przebieg wartości empirycznych i modelowych w czasie dla TBF i TTR.

Do ilościowej oceny jakości dopasowania modelu do danych empirycznych wykorzystano zestaw klasycznych miar błędu, szeroko stosowanych w analizach niezawodnościowych i prognostycznych:

- błąd średniokwadratowy (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{\text{model}}(t_i) - R_{\text{emp}}(t_i))^2} \quad (30)$$

- średni błąd bezwzględny (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |R_{\text{model}}(t_i) - R_{\text{emp}}(t_i)| \quad (31)$$

- procentowy błąd średni bezwzględny (MAPE):

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{R_{\text{model}}(t_i) - R_{\text{emp}}(t_i)}{R_{\text{emp}}(t_i)} \right| \quad (32)$$

- współczynnik determinacji ( $R^2$ ) oceniający, w jakim stopniu zmienność danych empirycznych jest wyjaśniana przez model:

$$R^2 = 1 - \frac{\sum_{i=1}^n (R_{\text{emp}}(t_i) - R_{\text{model}}(t_i))^2}{\sum_{i=1}^n (R_{\text{emp}}(t_i) - \bar{R}_{\text{emp}})^2} \quad (33)$$

gdzie:

$R_{\text{emp}}(t_i)$  – wartość empiryczna funkcji niezawodności w chwili  $t_i$ ,

$R_{\text{model}}(t_i)$  – wartość obliczona z modelu,

$\bar{R}_{\text{emp}}$  – średnia wartość empiryczna funkcji niezawodności,

$n$  – liczba obserwacji.




W tabeli 5.3 zaprezentowano wyniki miar dopasowania dla scenariusza bazowego (B).

**Tab. 5.3.** Miary dopasowania modelu do danych empirycznych – scenariusz bazowy (B)

| Parametr | RMSE [h] | MAE [h] | MAPE [%] | R <sup>2</sup> |
|----------|----------|---------|----------|----------------|
| TBF      | 3,62     | 2,85    | 11,2     | 0,948          |
| TTR      | 0,71     | 0,55    | 9,6      | 0,931          |

Wyniki wskazują na bardzo dobre odwzorowanie parametrów TBF i TTR. Wartości współczynnika determinacji przekraczające 0,93 potwierdzają, że model uchwycił większość zmienności danych empirycznych. Niskie wartości RMSE i MAE świadczą o niewielkich odchyleniach bezwzględnych, natomiast MAPE poniżej 12% wskazuje, że błędy relatywne są akceptowalne z punktu widzenia przeprowadzonej analizy.



**Rys. 5.2.** Porównanie danych modelowych i empirycznych dla TBF i TTR (scenariusz bazowy)

Rysunek 5.2 przedstawia przebieg wartości empirycznych i modelowych w czasie. W początkowej fazie obserwacji widoczna jest niemal idealna zgodność obu serii, co potwierdza właściwą kalibrację modelu. W środkowej części horyzontu czasowego pojawiają się okresowe odchylenia TBF, które mogą wynikać z losowych awarii o charakterze incydentalnym. Warto jednak zauważyć, że nawet w tych fragmentach model poprawnie odwzorowuje ogólny trend, nie zaniżając ani nie zawyżając systematycznie wartości. W końcowej fazie obserwacji zgodność ponownie się poprawia, co dowodzi stabilności modelu.

Analiza dopasowania rozkładów statystycznych do empirycznych wykazała bliskie pokrywanie się przebiegów wartości modelowych z empirycznymi, co potwierdza wysoką zgodność uzyskanych wyników. Niewielkie rozbieżności obserwowane w początkowych i końcowych przedziałach czasowych wynikają z ograniczonej liczby obserwacji w tych okresach oraz wpływu pojedynczych incydentów o skrajnych wartościach. Ogólnie jednak model poprawnie odzwierciedla charakterystykę zmian TBF i TTR w czasie, co stanowi podstawę do dalszej oceny odporności i interpretacji wyników.

Porównanie wyników modelu z danymi empirycznymi, przedstawione w tabeli 5.3 oraz na rysunku 5.2, pozwala na szczegółową analizę obszarów, w których pojawiają się różnice między odwzorowaniem modelowym a rzeczywistym przebiegiem analizowanych procesów. W szczególności widoczne są trzy główne typy rozbieżności:

1. Rozbieżności systematyczne.

Wynikają z niepełnej reprezentacji rzeczywistości w modelu matematycznym. W analizowanym przypadku zauważalne są one przede wszystkim dla czasów TBF, gdzie model ma tendencję do zaniżania wartości w początkowych przedziałach oraz zawyżania w dalszych okresach. Może to być konsekwencją uproszczeń w przyjętych rozkładach statystycznych (np. dopasowanie log-normalne nie w pełni oddaje długi „ogon” rzadkich zdarzeń awaryjnych). Z praktycznego punktu widzenia oznacza to, że model dobrze sprawdza się przy prognozowaniu ogólnych trendów dostępności, ale może wymagać kalibracji w sytuacjach, gdy planowanie zasobów powinno uwzględniać skrajne wartości – np. długie przestoje powodujące poważne zakłócenia w harmonogramie produkcji.

2. Rozbieżności losowe.

Są efektem pojedynczych, trudnych do przewidzenia zdarzeń, które znacząco wpływają na przebieg danych empirycznych, ale nie zostały uchwycone w modelu. Widać to wyraźnie w przypadku TTR – szczególnie w okresach, gdy występowały długotrwałe i nietypowe naprawy, powodujące chwilowe, lokalne odchylenia od trendu modelowego. Na rysunku 5.2 widoczne są one jako punktowe odskoki krzywej empirycznej względem modelu. Z perspektywy praktyki górniczej tego typu rozbieżności są nieuniknione – nie da się w pełni przewidzieć awarii rzadkich, ale o dużym znaczeniu operacyjnym. Dlatego w planowaniu utrzymania ruchu wskazane jest uwzględnianie dodatkowych buforów czasowych na sytuacje nadzwyczajne.

3. Rozbieżności w okresach podwyższonej niepewności.

Najbardziej istotne z punktu widzenia oceny modelu. Zauważalne są w momentach, gdy równocześnie zmieniają się parametry eksploatacyjne (np. obniżenie dostępności maszyn w związku z prowadzonymi pracami konserwacyjnymi). W takich przypadkach model powinien wiernie odwzorowywać spadki niezawodności i wzrost zmienności wskaźników. Wyniki analizy pokazują, że opracowany model poprawnie odwzorowuje ogólny charakter zmian – zarówno dla TBF, jak i TTR – jednak w przypadku krótkotrwałych, gwałtownych zakłóceń reakcja modelu bywa wygładzona. Z praktycznego punktu widzenia takie „wygładzenie” jest korzystne dla analiz strategicznych (np. długookresowego planowania wydobywania), lecz w zarządzaniu operacyjnym wymaga dodatkowych mechanizmów alarmowych, które wychwycą nagłe odchylenia od normy.

Podsumowując, model charakteryzuje się wysokim stopniem zgodności z danymi empirycznymi ( $R^2 > 0,9$  dla obu analizowanych wskaźników), a rozbieżności – mimo że występują – mają charakter lokalny i nie zaburzają ogólnego obrazu procesu. Co więcej, ich interpretacja dostarcza praktycznych wskazówek: systematyczne różnice sugerują konieczność okresowej kalibracji modelu, rozbieżności losowe wskazują na potrzebę elastycznego podejścia do harmonogramowania prac utrzymaniowych, a odchylenia w okresach niepewności podkreślają wagę monitoringu i adaptacji w warunkach zmieniającej się dostępności technicznej.

Ocena odporności modelu stanowi uzupełnienie walidacji i polega na weryfikacji, czy struktura modelu zachowuje stabilność wyników przy zmianach danych wejściowych oraz w warunkach zwiększonej niepewności operacyjnej i technicznej. W praktyce oznacza to sprawdzenie, czy model pozostaje spójny z danymi empirycznymi również w sytuacjach, gdy pojawiają się zakłócenia o charakterze losowym, skokowe zmiany w parametrach procesowych bądź ograniczenia w dostępności danych.

W ramach przeprowadzonej analizy zastosowano procedurę symulacji scenariuszowych, w której parametry wejściowe TBF i TTR modyfikowano w oparciu o przyjęte poziomy niepewności ( $\pm 5\%$ ,  $\pm 10\%$  i  $\pm 20\%$ ). Dla każdego wariantu obliczono podstawowe miary dopasowania (RMSE, MAE,  $R^2$ ), a uzyskane wyniki zestawiono z wartościami referencyjnymi przedstawionymi w podrozdziale 5.3.

Analiza wykazała, że:

- dla modyfikacji na poziomie  $\pm 5\%$  oraz  $\pm 10\%$  uzyskane wartości  $R^2$  pozostają powyżej 0,85, co oznacza utrzymanie wysokiej zdolności modelu do odwzorowania zmienności danych empirycznych;
- przy największym zakłóceniu ( $\pm 20\%$ ) zauważalny jest spadek dokładności, szczególnie w odniesieniu do TBF, gdzie RMSE wzrósł o ok. 15% w stosunku do wartości bazowej, jednak  $R^2$  utrzymał się na poziomie powyżej 0,75;
- model wykazuje większą odporność na zakłócenia w zakresie TTR niż TBF, co sugeruje, że procesy napraw mają bardziej stabilny charakter i są mniej wrażliwe na losowe fluktuacje danych wejściowych.

Wnioski praktyczne z przeprowadzonej analizy wskazują, że opracowany model można uznać za odporny w sensie operacyjnym – nawet przy istotnym wzroście niepewności parametrycznych zachowuje on zdolność do poprawnego odzwierciedlania ogólnych trendów. Rozbieżności lokalne, pojawiające się w ekstremalnych scenariuszach, mają charakter przewidywalny i nie wpływają na ogólną przydatność modelu w ocenie niezawodności procesów górniczych.

W celu zapewnienia przejrzystości oraz możliwości praktycznego wykorzystania uzyskanych rezultatów, wyniki porównania modelu z danymi empirycznymi zostały zaprezentowane w trzech komplementarnych formach:

1. Tabelarycznej – zestawienia wartości miar dopasowania (RMSE, MAE, MAPE,  $R^2$ ) dla wskaźników TBF i TTR. Pozwala to na szybkie wychwycenie różnic ilościowych oraz jednoznaczną ocenę jakości dopasowania w ujęciu liczbowym. Z punktu widzenia praktyki inżynierskiej istotne jest to, że wartości  $R^2$  przekraczają 0,9, co potwierdza wysoką zgodność modelu z obserwacjami empirycznymi.
2. Graficznej – wykresy zestawiające przebieg wartości empirycznych i modelowych w czasie dla TBF i TTR (rys. 5.2). Wizualizacja ta umożliwia nie tylko weryfikację ogólnych trendów, lecz także identyfikację lokalnych rozbieżności systematycznych i losowych. Na przykład w przypadku TTR dobrze widoczne są chwilowe odchylenia związane z nietypowo długimi naprawami, które w praktyce odpowiadają zdarzeniom o dużej nieprzewidywalności.
3. Opisowej – komentarz interpretacyjny wskazujący na charakter rozbieżności i ich praktyczne znaczenie. Ujęcie jakościowe jest szczególnie ważne w kontekście oceny odporności modelu: pokazuje, że mimo występowania lokalnych różnic, model poprawnie odwzorowuje ogólną dynamikę procesu i może być wykorzystywany do prognozowania niezawodności w warunkach niepewności.

Takie wieloaspektowe raportowanie wyników umożliwia zarówno ocenę matematyczną (precyzja dopasowania), jak i praktyczną (użyteczność w zarządzaniu eksploatacją górniczą). Dzięki temu uzyskane rezultaty mogą być wykorzystywane zarówno przez analityków danych do dalszego doskonalenia modeli, jak i przez praktyków – do planowania działań prewencyjnych oraz podejmowania decyzji operacyjnych. Co istotne, prezentacja w trzech formach ułatwia także komunikację wyników między zespołami badawczymi a kadrą techniczną kopalni, co zwiększa szansę na wdrożenie koncepcji w praktyce.

## **5.4. Analiza odchyłeń i identyfikacja przyczyn rozbieżności**

Proces walidacji modelu, opisany w podrozdziałach 5.1–5.3, wykazał, że pomimo wysokiego stopnia dopasowania, pomiędzy wynikami symulacji a danymi empirycznymi występują

pewne odchylenia. Ich identyfikacja i zrozumienie jest kluczowe dla dalszego doskonalenia modelu oraz zwiększenia jego uniwersalności w zastosowaniach przemysłowych. Analiza odchyleń pozwala wskazać, które elementy modelu wymagają doprecyzowania, oraz określić potencjalne źródła niezgodności, zarówno o charakterze systematycznym, jak i losowym.

W procesie walidacji modelu zidentyfikowano odchylenia między wynikami symulacji a danymi empirycznymi, które można podzielić na trzy główne kategorie:

1. Odchylenia systematyczne:
  - Mają charakter powtarzalny i wynikają z ograniczeń strukturalnych modelu lub różnic w założeniach wejściowych.
  - Przykład: stałe przeszacowanie wartości TBF o 5–8% w scenariuszach z większym udziałem krótkotrwałych przestojów.
  - Przyczyna: brak pełnego uwzględnienia cyklicznych prac konserwacyjnych w harmonogramie modelu.
2. Odchylenia incydentalne:
  - Występują sporadycznie i są związane z pojedynczymi zdarzeniami w danych empirycznych, które nie miały odpowiednika w scenariuszach modelowych.
  - Przykład: nagłe skrócenie TBF w wyniku awarii zewnętrznego systemu zasilania.
  - Przyczyna: zdarzenia o charakterze losowym, nieuwjęte w modelu.
3. Odchylenia skrajne (ekstremalne):
  - Mają największą amplitudę i pojawiają się w wyniku wystąpienia nieprzewidywalnych, rzadkich zdarzeń o dużym wpływie.
  - Przykład: jednorazowe wydłużenie TTR o ponad 100% wskutek równoczesnej awarii kilku kluczowych podzespołów.
  - Przyczyna: kumulacja rzadkich zdarzeń o dużej skali wpływu na system.

Podział na powyższe kategorie pozwala nie tylko opisać charakter odchyleń, ale także powiązać je z konkretnymi czynnikami technicznymi i operacyjnymi. W dalszej analizie te kategorie stanowią punkt odniesienia przy identyfikacji przyczyn rozbieżności oraz ocenie ich wpływu na wiarygodność modelu.

Identyfikacja przyczyn odchyleń między wynikami modelu a danymi empirycznymi została przeprowadzona w oparciu o zestaw metod jakościowych i ilościowych, które umożliwiają zarówno lokalizację źródła rozbieżności, jak i ocenę ich wpływu na parametry niezawodnościowe. Wybrano cztery metody:

1. Analizę trendów czasowych:
  - porównanie przebiegów  $R(t)$ , TBF oraz TTR w modelu i w danych empirycznych dla poszczególnych okresów eksploatacyjnych;
  - wykrywanie momentów rozbieżności oraz ich korelacja z zapisami o zdarzeniach eksploatacyjnych w raportach CMMS.

2. Analizę Pareto odchyłeń:
  - uporządkowanie odchyłeń według ich skumulowanego wpływu na całkowitą różnicę między modelem a obserwacjami;
  - pozwoliło to zidentyfikować 20% zdarzeń odpowiedzialnych za około 80% całkowitych odchyłeń w TBF i TTR.
3. Analizę przyczyn źródłowych – wykorzystanie diagramu Ishikawy do powiązania odchyłeń z głównymi grupami czynników:
  - techniczne – awarie elementów konstrukcyjnych, zużycie części, nieplanowane przeestoje remontowe;
  - operacyjne – błędy obsługi, opóźnienia logistyczne, zmiany w harmonogramie pracy;
  - środowiskowe – warunki geologiczne, czynniki atmosferyczne, wpływ infrastruktury zewnętrznej.
4. Analizę wrażliwości modelu:
  - sprawdzenie, jak zmiana wartości wybranych parametrów wejściowych (np. średni czas naprawy MTTR lub tempo awarii  $\lambda$ ) wpływa na poziom odchyłeń;
  - pozwoliło to określić, które parametry są najbardziej krytyczne dla poprawy zgodności modelu z rzeczywistością.

Wyniki powyższych analiz dostarczyły podstaw do interpretacji odchyłeń w kontekście niepewności operacyjnej i technicznej, co omówiono w dalszej części rozdziału.

Analiza odchyłeń wykazała, że różnice między wynikami modelu a danymi empirycznymi nie są rozłożone równomiernie, lecz silnie zależą od scenariusza pracy systemu oraz poziomu niepewności operacyjnej i technicznej.

W związku z tym ocenę przeprowadzono dla czterech scenariuszy pracy systemu:

1. Warunki bazowe (B).  
W warunkach bazowych średnie odchylenie czasu międzyawaryjnego (TBF) względem danych empirycznych wyniosło +4,8% (ok. +3,6 h), a czasu napraw (TTR) +3,1% (ok. +0,7 h). Otrzymane różnice mieszczą się w granicach akceptowalnych w inżynierii niezawodności, tj.  $\pm 5\%$ .
2. Scenariusz S1 – zwiększona niepewność operacyjna.  
W scenariuszu zwiększonej niepewności operacyjnej odchylenie TBF wzrosło do +7,2% (ok. +5,4 h), a TTR do +5,9% (ok. +1,3 h). Wzrost ten wynika głównie z większej liczby krótkich, nieplanowanych przestojów.
3. Scenariusz S2 – zwiększona niepewność techniczna.  
W warunkach zwiększonej niepewności technicznej odchylenie TBF osiągnęło +10,4% (ok. +7,8 h), natomiast TTR +8,6% (ok. +1,9 h). Największy wpływ na te wartości miały powtarzalne awarie podzespołów oraz wydłużony czas ich naprawy.

4. Scenariusz S3 – kumulacja zakłóceń operacyjnych i technicznych.

W scenariuszu łączącym zakłócenia operacyjne i techniczne odchylenie TBF wyniosło +13,1% (ok. +9,9 h), a TTR +12,4% (ok. +2,7 h). Kumulacja zakłóceń powoduje w tym przypadku największe rozbieżności, jednak model wciąż prawidłowo odwzorowuje ogólne trendy zmian niezawodnościowych.

Z przedstawionych wyników można wnioskować, że:

- Wzrost poziomu niepewności przekłada się na proporcjonalny wzrost odchyleń w TBF i TTR, przy czym TBF reaguje silniej na zakłócenia operacyjne, a TTR – na techniczne.
- Największe odchylenia pojawiają się w scenariuszu S3, co potwierdza hipotezę o kumulatywnym charakterze wpływu zakłóceń.

W celu usystematyzowania wyników przeprowadzono zestawienie odchyleń procentowych wartości TBF i TTR względem danych empirycznych dla wszystkich analizowanych scenariuszy. Wartości te przedstawiono w tabeli 5.4.

**Tab. 5.4.** Odchylenia procentowe wartości TBF i TTR względem danych empirycznych


| Scenariusz | TBF – odchylenie [%] | TTR – odchylenie [%] |
|------------|----------------------|----------------------|
| B          | +4,8                 | +3,1                 |
| S1         | +7,2                 | +5,9                 |
| S2         | +10,4                | +8,6                 |
| S3         | +13,1                | +12,4                |

Dla czytelności podano również przybliżone wartości w jednostkach czasu:

- TBF: od +3,6 h (B) do +9,9 h (S3),
- TTR: od +0,7 h (B) do +2,7 h (S3).

Na rysunku 5.3. przedstawiono odchylenia procentowe w formie zestawienia słupkowego, co umożliwia szybkie porównanie skali rozbieżności pomiędzy TBF a TTR w poszczególnych scenariuszach.

Uzyskane wyniki wskazują, że model dobrze radzi sobie z odwzorowaniem zmienności danych nawet w warunkach podwyższonej niepewności. Wysoka zgodność trendów modelowych z obserwacjami empirycznymi potwierdza jego zdolność do uchwycenia rzeczywistych zależności między parametrami niezawodnościowymi. Największą wrażliwość model wykazuje w odniesieniu do wskaźnika TBF, co jest zgodne z charakterystyką procesów górniczych, w których czasy międzyawaryjne podlegają większym fluktuacjom niż czasy napraw (TTR). Zmienność ta wynika zarówno z losowego charakteru awarii, jak i z różnic w warunkach pracy poszczególnych maszyn oraz nieregularności cykli konserwacyjnych.



**Rys. 5.3.** Odchylenia procentowe TBF i TTR względem danych empirycznych

Mimo obserwowanych odchyłeń – szczególnie w wariancie S3 – model zachowuje zdolność do poprawnego odwzorowania trendów i wskazuje kierunki zmian w niezawodności systemu. Jego zachowanie w tych warunkach potwierdza odporność na zakłócenia o umiarkowanej intensywności oraz stabilność w estymacji parametrów probabilistycznych. Dla praktyki oznacza to, że może być z powodzeniem stosowany do wspomagania decyzji operacyjnych i planowania prewencyjnego, przy jednoczesnym zachowaniu świadomości ograniczeń w sytuacjach ekstremalnych.

**Tab. 5.5.** Miary dopasowania modelu przy różnych poziomach zakłóceń


| Poziom zakłóceń [%]    | RMSE – TBF | RMSE – TTR | MAE – TBF | MAE – TTR | R <sup>2</sup> – TBF | R <sup>2</sup> – TTR |
|------------------------|------------|------------|-----------|-----------|----------------------|----------------------|
| ±0<br>(wartość bazowa) | 1,12       | 0,87       | 0,89      | 0,65      | 0,92                 | 0,94                 |
| ±5                     | 1,18       | 0,91       | 0,94      | 0,69      | 0,88                 | 0,91                 |
| ±10                    | 1,24       | 0,96       | 1,01      | 0,74      | 0,83                 | 0,87                 |
| ±20                    | 1,29       | 1,02       | 1,06      | 0,81      | 0,76                 | 0,82                 |

Źródło: opracowanie własne

Aby usystematyzować uzyskane wyniki, przeprowadzono zestawienie wartości podstawowych miar dopasowania (RMSE, MAE, R<sup>2</sup>) dla różnych wariantów zakłóceń. Dane zestawione w tabeli 5.5 pozwalają na ilościową ocenę stabilności modelu w warunkach zmiennego poziomu niepewności parametrycznej. Porównanie tych wskaźników w poszczególnych scenariuszach umożliwia także identyfikację obszarów, w których dalsze doskonalenie modelu może przynieść największą poprawę dokładności prognoz.



Dla lepszego zobrazowania wpływu zakłóceń na wyniki modelu, na rysunku 5.4 przedstawiono porównanie przebiegu wartości empirycznych i modelowych dla TBF i TTR w wybranych wariantach symulacyjnych ( $\pm 10\%$  i  $\pm 20\%$ ).



**Rys. 5.4.** Średnie odchylenie modelu względem danych empirycznych

Na rysunku 5.4 pokazano, że model poprawnie odzwierciedla ogólną dynamikę zarówno dla TBF, jak i TTR, przy czym charakterystyczne jest większe wygładzanie krótkotrwałych zakłóceń w przypadku TBF. W praktyce oznacza to, że model skutecznie redukuje wpływ incydentalnych odchyłeń i zachowuje przydatność prognostyczną nawet w warunkach znacznej niepewności operacyjnej.

Podsumowując, przeprowadzona analiza potwierdza, że model wykazuje odporność na zmiany w parametrach wejściowych i może być stosowany w warunkach podwyższonej niepewności. Co istotne z punktu widzenia praktyki inżynierskiej, model dostarcza wiarygodnych podstaw do podejmowania decyzji operacyjnych i planowania działań prewencyjnych, nawet w sytuacjach charakteryzujących się znaczną zmiennością warunków eksploatacji. Uzyskane wyniki stanowią tym samym podstawę do sformułowania końcowych wniosków, które zostaną zaprezentowane w rozdziale 6.

## 5.5. Ocena skuteczności modelu w warunkach zwiększonej niepewności

Oceny skuteczności modelu dokonano w czterech scenariuszach zdefiniowanych w podrozdziale 5.1 (B, S1, S2, S3). Takie ujęcie pozwala na systematyczne porównanie wyników uzyskanych w warunkach nominalnych z rezultatami generowanymi przy różnym poziomie zmienności parametrów.

Celem tego etapu walidacji było określenie, w jakim stopniu opracowany model zachowuje zdolność przewidywania kluczowych parametrów niezawodnościowych – średniego czasu między awariami (TBF) oraz średniego czasu naprawy (TTR) – w warunkach rosnącej niepewności operacyjnej i technicznej. Ocena ta ma istotne znaczenie praktyczne, ponieważ w rzeczywistych systemach wydobywczych warunki pracy rzadko są w pełni stabilne. Zmienność obciążeń, różnorodne tryby awarii oraz czynniki zewnętrzne mogą prowadzić do znaczących odchyleń od prognoz modelowych, dlatego niezbędna jest analiza odporności modelu na zakłócenia.

W pierwszej kolejności określono zakres oceny, który obejmuje zarówno dopasowanie wartości modelowych do danych empirycznych, jak i analizę odporności modelu na niepewność wejściową. Następnie przedstawiono miary statystyczne i metody porównania, a w kolejnych częściach omówiono wyniki symulacji i interpretację uzyskanych odchyleń.

Tak przyjęta struktura analizy umożliwia płynne przejście od weryfikacji ilościowej (dokładność odwzorowania danych) do oceny jakościowej (zdolność modelu do uchwycenia trendów i dynamiki procesów), co zapewnia pełny obraz skuteczności opracowanego rozwiązania w warunkach zwiększonej niepewności operacyjnej i technicznej.

Proces oceny skuteczności modelu zaplanowano tak, aby dostarczył zarówno wyników ilościowych, jak i jakościowych. Uwzględniono w nim:

- analizę dokładności dopasowania – na podstawie miar RMSE, MAE i współczynnika determinacji  $R^2$ , obliczonych dla TBF i TTR.
- porównanie trendów czasowych – weryfikację, czy model poprawnie odzwierciedla kierunek i dynamikę zmian parametrów niezawodnościowych.
- identyfikację momentów krytycznych – wskazanie okresów największych rozbieżności, związanych z ekstremalnymi warunkami pracy lub rzadkimi zdarzeniami awaryjnymi.
- ocenę odporności na zakłócenia – sprawdzenie, w jakim stopniu model utrzymuje zdolność predykcji wraz ze wzrostem złożoności i nieprzewidywalności scenariuszy.

Dla zaproponowanych scenariuszy obliczono miary skuteczności modelu osobno dla TBF i TTR. Wyniki przedstawiono w tabeli 5.6 i na ich podstawie dokonano oceny jakości dopasowania modelu do danych empirycznych.


**Tab. 5.6.** Miary skuteczności modelu dla TBF i TTR w różnych scenariuszach

| Scenariusz | RMSE – TBF [h] | MAE – TBF [h] | $R^2$ – TBF | RMSE – TTR [h] | MAE – TTR [h] | $R^2$ – TTR |
|------------|----------------|---------------|-------------|----------------|---------------|-------------|
| B          | 3,62           | 2,85          | 0,948       | 0,71           | 0,55          | 0,931       |
| S1         | 5,41           | 4,18          | 0,926       | 1,33           | 1,06          | 0,912       |
| S2         | 7,78           | 6,21          | 0,903       | 1,88           | 1,54          | 0,894       |
| S3         | 9,94           | 7,88          | 0,872       | 2,67           | 2,14          | 0,861       |

Źródło: opracowanie własne

Analiza uzyskanych wartości pozwala sformułować następujące wnioski:

- Bardzo dobre dopasowanie w scenariuszu B – wysokie wartości  $R^2$  (0,948 dla TBF i 0,931 dla TTR) świadczą o tym, że model bardzo dobrze odwzorowuje zachowanie systemu w warunkach standardowych.
- Stopniowe pogarszanie jakości dopasowania – obserwuje się wyraźny trend wzrostu RMSE i MAE oraz spadku  $R^2$  wraz ze wzrostem poziomu zakłóceń, co jest zgodne z oczekiwaniami wynikającymi z teorii niezawodności w warunkach niepewności.
- Większa wrażliwość TBF – wartości RMSE dla TBF w scenariuszu S3 są blisko trzykrotnie wyższe niż w scenariuszu bazowym, co wskazuje, że średni czas między awariami jest szczególnie podatny na wzrost zmienności w warunkach pracy.
- Stabilniejszy TTR – choć w scenariuszu S3 błędy dla TTR również wzrastają, ich tempo wzrostu jest mniejsze niż w przypadku TBF, co sugeruje, że procesy naprawy są mniej wrażliwe na zakłócenia operacyjne.
- Zachowanie kształtu trendów – mimo pogorszenia dopasowania liczbowego, model prawidłowo odtwarza ogólną dynamikę zmian, co jest kluczowe dla jego wykorzystania w prognozowaniu i planowaniu działań prewencyjnych.



**Rys. 5.5.** Funkcje niezawodności  $R(t)$  w warunkach zwiększonej niepewności

W celu ułatwienia interpretacji, na rysunku 5.5 przedstawiono przebiegi funkcji niezawodności  $R(t)$  w wariantach B, S1, S2 i S3 wraz z punktami z danych empirycznych. Widać wyraźnie, że:


- krzywe modelowe we wszystkich scenariuszach zachowują poprawny kształt funkcji niezawodności i odzwierciedlają dynamikę spadków;
- wzrost niepewności prowadzi do przesunięcia krzywych w dół (niższa niezawodność) i zmniejszenia nachylenia początkowych odcinków, co odpowiada skróceniu TBF;
- największe odchylenia od danych empirycznych występują w późniejszych przedziałach czasowych scenariusza S3, gdzie kumulacja czynników zakłócających jest największa.

**Tab. 5.7.** Wskaźniki skuteczności modelu w warunkach zwiększonej niepewności

| Scenariusz | TBF [h] | TTR [h] | RMSE  | MAE   | R <sup>2</sup> |
|------------|---------|---------|-------|-------|----------------|
| B          | 48,32   | 3,27    | 0,042 | 0,031 | 0,912          |
| S1         | 44,85   | 3,34    | 0,047 | 0,034 | 0,901          |
| S2         | 42,76   | 3,51    | 0,052 | 0,036 | 0,893          |
| S3         | 39,48   | 3,63    | 0,058 | 0,041 | 0,881          |

Wyniki przedstawione na rysunku 5.5 i w tabeli 5.7 są spójne – potwierdzają, że model prawidłowo reaguje na wzrost niepewności, a wartości R<sup>2</sup> utrzymują się w granicach akceptowalnych dla zastosowań przemysłowych.

Dodatkowym uzupełnieniem jest wykres słupkowo-liniowy (rys. 5.6), pokazujący wzrost RMSE i MAE oraz spadek R<sup>2</sup> w kolejnych scenariuszach. Ułatwia on porównanie skali zmian.



**Rys. 5.6.** Porównanie wskaźników skuteczności

Nasuwać się następujące wnioski:

- W warunkach bazowych model cechuje się najwyższą zgodnością z danymi empirycznymi ( $RMSE = 0,042$ ;  $MAE = 0,031$ ;  $R^2 = 0,912$ ).
- W scenariuszach o zwiększonej niepewności obserwuje się pogorszenie wskaźników, ale wartości nadal mieszczą się w przedziale akceptowalnym dla praktyki przemysłowej.
- TBF jest bardziej podatny na niepewność niż TTR, co ma znaczenie dla planowania eksploatacji i działań prewencyjnych.

Podsumowując, opracowany model wykazuje wysoką skuteczność predykcyjną i zachowuje stabilność również w warunkach zwiększonej niepewności, co potwierdza jego praktyczną użyteczność w ocenie niezawodności procesów górniczych.

## 5.6. Podsumowanie walidacji

Analiza dopasowania rozkładów czasów między zdarzeniami (TBF) i czasów trwania zdarzeń (TTR) dla kategorii „Postój” i „Awaria” wykazała, że w większości przypadków najlepsze odwzorowanie uzyskano dla rozkładu Weibulla lub log-normalnego. Wynik ten jest zgodny z klasycznymi podejściami do analizy danych żywotności i niezawodności (Nelson 2004). Parametry dopasowanych rozkładów pozostawały spójne z charakterystyką procesów górniczych, a wartości statystyk Andersona–Darlinga i testu Kołmogorowa–Smirnowa mieściły się w akceptowalnych granicach ( $p > 0,05$ ). Dodatkowo błędy RMSE nie przekraczały 0,05, co potwierdza poprawność przyjętego podejścia probabilistycznego.

Przeprowadzona walidacja potwierdziła wysoki stopień zgodności wyników modelu z danymi empirycznymi oraz jego zdolność do wiernego odwzorowania dynamiki procesów eksploatacyjnych:

- Zgodność wyników modelu z danymi empirycznymi.  
Model wykazał wysoki stopień dopasowania w warunkach standardowej eksploatacji, osiągając średnie wartości  $RMSE = 0,041$ ,  $MAE = 0,033$ ,  $MAPE = 4,82\%$  oraz  $R^2 = 0,913$  w większości analizowanych podsystemów. Wartości te mieszczą się w granicach akceptowalnych dla inżynierii niezawodności ( $RMSE < 0,05$ ), co potwierdza wiarygodność zastosowanego podejścia.
- Odwzorowanie dynamiki w warunkach niepewności.  
W scenariuszu zwiększonej niepewności operacyjnej (S1) model prawidłowo przewidywał moment spadku niezawodności, osiągając  $TAI = 0,874$  i redukcję błędu  $\Delta RMSE = 12,6\%$  względem modelu bazowego. W scenariuszu technicznym (S2) uzyskano  $TAI = 0,861$  i  $\Delta RMSE = 10,9\%$ , natomiast w scenariuszu złożonym (S3)  $TAI = 0,853$  i  $\Delta RMSE = 9,8\%$ . Wyniki te dowodzą, że model zachowuje zdolność predykcyjną również przy rosnącej zmienności parametrów i może być stosowany w warunkach zwiększonej niepewności.

- Identyfikacja przyczyn rozbieżności.

Największe odchylenia ( $RMSE > 0,06$ ) występowały w przypadkach, gdy w danych empirycznych pojawiały się jednorazowe, nietypowe zdarzenia – zwłaszcza awarie krytyczne spowodowane czynnikami zewnętrznymi. W takich sytuacjach model wymaga uzupełnienia o dodatkowe scenariusze awaryjne, aby poprawnie odwzorować skokowe zmiany niezawodności.

Do mocnych stron opracowanej koncepcji należy integracja klasycznych parametrów niezawodności z czynnikami niepewności operacyjnej i technicznej. Model umożliwia symulację reakcji systemu na różne poziomy zakłóceń, co zwiększa jego elastyczność zastosowań. Kluczowe jest również wysokie podobieństwo trendów między danymi modelowymi a empirycznymi – w większości analizowanych przypadków wskaźnik TAI przekraczał 0,85. Dzięki temu model nie tylko wiarygodnie odwzorowuje rzeczywiste zachowanie systemu, lecz także stanowi wartościowe narzędzie prognostyczne.

Należy jednak podkreślić, że obecna wersja modelu w ograniczonym stopniu uwzględnia rzadkie i skrajne zdarzenia o dużym wpływie, które mogą zakłócać ciągłość działania procesu. Wymaga on również dalszej optymalizacji parametrów w zależności od specyficznych warunków geologicznych i technologicznych. W przyszłości warto rozszerzyć bazę danych walidacyjnych o przypadki pochodzące z różnych typów kopalń, co pozwoli na pełniejszą ocenę uniwersalności modelu i zwiększy jego praktyczną przydatność.

Podsumowując, walidacja potwierdziła, że opracowana koncepcja modelowania niezawodności procesów wydobywczych jest skuteczna zarówno w prognozowaniu, jak i w analizie zachowania systemów w warunkach niepewności technicznej i operacyjnej. Model osiągnął wysoką jakość dopasowania ( $RMSE < 0,05$ ;  $R^2 > 0,90$ ) oraz wykazał odporność na zakłócenia ( $TAI = 0,85\text{--}0,87$ ), co czyni go wartościowym narzędziem nie tylko z perspektywy badawczej, lecz także praktycznej. Może on wspierać procesy utrzymania ruchu, planowania konserwacji oraz prognozowania dostępności systemów w różnych scenariuszach eksploatacyjnych.

Uzyskane rezultaty stanowią punkt wyjścia do empirycznej weryfikacji modelu w warunkach rzeczywistych, co omówiono w kolejnym rozdziale na przykładzie Kopalni B.



## **6. Empiryczna weryfikacja koncepcji modelowania w warunkach rzeczywistych**

W celu praktycznego sprawdzenia opracowanego modelu przeprowadzono analizę danych pochodzących z Kopalni B. Procedura obejmowała klasyfikację przyczyn przestojów, ocenę ich struktury, wyznaczenie dominujących obszarów, a następnie walidację modelu z wykorzystaniem miar statystycznych oraz porównanie uzyskanych wyników z wcześniejszą analizą przeprowadzoną w Kopalni A. Dzięki takiej konstrukcji możliwe było nie tylko zweryfikowanie poprawności odwzorowania danych empirycznych, lecz także ocena użyteczności koncepcji w odmiennych warunkach operacyjnych.

### **6.1. Wprowadzenie i charakterystyka danych**

W niniejszym rozdziale zaprezentowano wyniki empirycznej weryfikacji modelu niezawodności procesów wydobywczych w warunkach rzeczywistych. Analizie poddano szczegółowe rejestry incydentów zarejestrowane w Kopalni B, obejmujące pełny okres obserwacji. Uwzględniono wszystkie zdarzenia zakłócające ciągłość pracy, a dane zostały oczyszczone, ujednolicone i zanonimizowane zgodnie z procedurą opisaną w rozdziale 4. W sumie przeanalizowano ponad 803 zdarzenia, które stanowiły podstawę do dalszych analiz statystycznych i porównawczych.

Rozdział ten stanowi studium przypadku, w którym krok po kroku przeprowadzono klasyfikację przyczyn przestojów, ich rangowanie, walidację modelu oraz zestawienie wyników z Kopalnią A. Taki układ pozwala zarówno potwierdzić przydatność modelu, jak i wskazać praktyczne implikacje dla zarządzania niezawodnością w różnych warunkach organizacyjnych i technicznych.



## 6.2. Struktura przyczyn przestojów w danych rzeczywistych

Pierwszym etapem była analiza udziału głównych kategorii przyczyn przestojów w Kopalni B. Wyniki zestawiono w tabeli 6.1.

**Tab. 6.1.** Struktura głównych kategorii przyczyn przestojów w Kopalni B

| Kategoria      | Liczba incydentów | Łączny czas [min] | Udział – liczba [%] | Udział – czas [%] |
|----------------|-------------------|-------------------|---------------------|-------------------|
| Górnicy        | 57                | 51 025            | 7,1                 | 54,6              |
| Mechaniczny    | 35                | 18 475            | 4,4                 | 19,8              |
| Technologiczny | 541               | 15 567            | 67,5                | 16,7              |
| Organizacyjny  | 118               | 5 380             | 14,7                | 5,8               |
| Elektryczny    | 49                | 2 935             | 6,1                 | 3,1               |
| Inne/przestoje | 1                 | 40                | 0,1                 | 0,0               |


Zestawienie potwierdza dominację przestojów górniczych, które odpowiadają za ponad połowę całkowitego czasu niedostępności, przy jednocześnie stosunkowo niewielkiej liczbie incydentów. Świadczy to o dużej wadze jednostkowych, ale długotrwałych zdarzeń w tej kategorii. Znaczącą rolę odgrywają również przyczyny mechaniczne i technologiczne, co podkreśla techniczny charakter determinant dostępności w Kopalni B. Podobne obserwacje pojawiają się w literaturze – wskazuje się, że jednym z najczęstszych źródeł awarii systemu transportowego są uszkodzenia złączy taśmowych (Kozłowski i inni 2020).

W porównaniu z Kopalnią A zauważalna jest zasadnicza różnica – w badanym zakładzie praktycznie nie występują przestoje wynikające z decyzji administracyjnych czy przyczyn organizacyjnych, które w Kopalni A stanowiły ponad jedną czwartą wszystkich zdarzeń. Oznacza to, że w Kopalni B niezawodność procesowa kształtowana jest przede wszystkim przez czynniki techniczne i naturalne, a nie organizacyjne. Podobne wnioski formułują Bodziony i Patyk (2024), wskazując, że kluczowe determinanty dostępności procesów wydobywczych mają w wielu przypadkach charakter techniczny, podczas gdy czynniki organizacyjne odgrywają rolę drugorzędną.

## 6.3. Ranking szczegółowych przyczyn

Na kolejnym etapie dokonano analizy szczegółowych przyczyn przestojów w ramach poszczególnych kategorii. Okazało się, że największe znaczenie miały postoje i awarie, które łącznie odpowiadały za prawie 80% całkowitego czasu niedostępności. Znacznie mniejszy udział miały zdarzenia związane z konserwacją planową czy krótkotrwałe wstrzymania robót.

Aby lepiej uchwycić hierarchię problemów, przygotowano zestawienie dziesięciu najczęściej rejestrowanych szczegółowych przyczyn (rys. 6.1). Wyniki wskazują, że dominują wśród nich problemy techniczne i eksploatacyjne, w szczególności awarie przenośników, układów hydraulicznych i systemu zasilania. Zdarzenia te, choć mniej przewidywalne niż incydenty organizacyjne, generowały znaczące i długotrwałe straty w dostępności. Warto zauważyć, że na wykresie ujęto wyłącznie dziesięć dominujących przyczyn, dlatego przedstawiony łączny czas przestoju nie obejmuje wszystkich zarejestrowanych incydentów.



**Rys. 6.1.** Ranking szczegółowych przyczyn przestoju w Kopalni B (Top 10)

Źródło: opracowanie własne

Na podstawie danych przedstawionych na rysunku można zauważyć, że zdarzenie „Sek. 95–105 przerwana łała” miało zdecydowanie największy udział w całkowitym czasie przestoju, osiągając około 28 dni. Tak długotrwała przerwa może wynikać nie tylko z rzeczywistego, złożonego incydentu technologicznego (np. uszkodzenia elementów sekcji obudowy i konieczności ich wymiany), lecz również z nakładania się danych pochodzących z kilku ścian lub etapów robót. W praktyce rejestrowania zdarzeń często dochodzi do sumowania czasów odnoszących się do sąsiednich lokalizacji lub prowadzenia napraw etapami

w ramach jednego wpisu, co prowadzi do pozornego wydłużenia czasu trwania pojedynczego przestoju.

Z punktu widzenia analizy niezawodności jest to przykład pojedynczego zdarzenia odstającego, które może zaburzać rozkład czasów napraw i wpływać na wartości średnie parametrów TTR. Jednocześnie stanowi ono ważny sygnał diagnostyczny, wskazujący na obszary o podwyższonym ryzyku technicznym i organizacyjnym. Pozostałe przyczyny przedstawione na rysunku 6.1 mają znacznie mniejszy, lecz nadal istotny wpływ na globalną dostępność systemu. Zatem mimo dominacji pojedynczego zdarzenia, większość utraconego czasu wynika z grupy powtarzalnych zakłóceń operacyjnych i technologicznych, które mogą być skutecznie ograniczane poprzez działania prewencyjne i optymalizację harmonogramów pracy.

Uzyskane wyniki wyznaczają jednoznaczne priorytety dla działań w obszarze utrzymania ruchu, wskazując, że redukcja awaryjności wąskiej grupy elementów infrastruktury może przynieść wyraźną poprawę efektywności całego systemu.

## 6.4. Walidacja modelu na danych z Kopalni B

Kolejnym etapem badań była walidacja modelu probabilistyczno-statystycznego, polegająca na ocenie stopnia dopasowania wyników prognozowanych do wartości empirycznych.

Pierwszym krokiem była analiza zgodności rozkładów empirycznych i modelowanych czasów przestojów. Testy dopasowania (Kolmogorowa–Smirnowa, Andersona–Darlinga) potwierdziły, że przyjęte rozkłady prawidłowo odwzorowują charakterystykę zmienności danych. Różnice pomiędzy rozkładem empirycznym a teoretycznym nie były istotne statystycznie na poziomie  $\alpha = 0,05$ .

Następnie przeprowadzono porównanie wartości prognozowanych i rzeczywistych w ujęciu dziennym (tab. 6.2).


**Tab. 6.2.** Miary jakości dopasowania modelu – Kopalnia B

| Miara                                  | Wartość |
|----------------------------------------|---------|
| Procent prognoz w granicach $\pm 10\%$ | 78      |
| Średni błąd względny [%]               | 7,4     |
| Maksymalny błąd [%]                    | 18,6    |
| RMSE [min]                             | 42      |
| $R^2$                                  | 0,82    |

Wyniki wskazują, że:

- W 78% przypadków model przewidział łączny czas przestojów w granicach  $\pm 10\%$  względem wartości empirycznej.
- Średni błąd względny prognozy wyniósł 7,4%.
- Współczynnik determinacji  $R^2$  osiągnął poziom 0,82, co potwierdza wysoką zgodność modelu z danymi rzeczywistymi.

Graficzną ocenę dopasowania przedstawiono na rysunku 6.2. Punkty układające się blisko linii  $y = x$  potwierdzają wysoką trafność odwzorowania. Większe odchylenia pojawiały się jedynie w przypadku rzadkich zdarzeń energetycznych i technologicznych, co wskazuje, że model nieco gorzej radzi sobie z incydentami o niskiej częstotliwości występowania.



**Rys. 6.2.** Porównanie rzeczywistych i prognozowanych wartości czasu przestojów – Kopalnia B

Źródło: opracowanie własne

Dodatkowym elementem walidacji była analiza tzw. dni krytycznych, definiowanych jako te, w których całkowity dzienny czas przestojów przekraczał 90. percentyl rozkładu. W Kopalni B dominowały w nich długotrwałe awarie mechaniczne i technologiczne, które –

mimo stosunkowo niskiej częstości występowania – powodowały znaczące zakłócenia w dostępności technicznej. Profil ten został prawidłowo odtworzony przez model probabilistyczny, który wskazał wysokie ryzyko przekroczenia progów krytycznych właśnie w związku z wystąpieniem takich zdarzeń.

Podsumowując, przeprowadzona walidacja potwierdziła:

- wysoką zgodność modelu z danymi rzeczywistymi Kopalni B,
- możliwość stosowania modelu w zakładach o zróżnicowanej strukturze przyczyn przestojów,
- praktyczną przydatność modelu jako narzędzia wspierającego podejmowanie decyzji w zakresie planowania utrzymania ruchu.

## 6.5. Porównanie z Kopalnią A

Walidacja modelu została rozszerzona o analizę porównawczą dwóch zakładów – Kopalni A i Kopalni B. Zastosowanie jednolitej procedury analitycznej umożliwiło bezpośrednie zestawienie wyników i ocenę elastyczności modelu w odmiennych warunkach eksploatacyjnych.

W obu przypadkach model poprawnie odwzorował rozkłady czasów przestojów oraz strukturę dominujących kategorii przyczyn. Różnice widoczne są jednak w zakresie obszarów największej trafności:

- W Kopalni A model szczególnie dobrze uchwycił krótkotrwałe, lecz częste przestoje organizacyjne i administracyjne (w tym związane z decyzjami KRZG).
- W Kopalni B najtrafniej odwzorowane zostały długotrwałe, rzadziej występujące awarie mechaniczne i technologiczne.

Dane liczbowe potwierdzają te obserwacje – model charakteryzował się porównywalnym poziomem błędów w obu kopalniach, przy czym różnice dotyczyły raczej obszarów dominującej zgodności niż jakości dopasowania jako takiej. Szczegółowe wyniki przedstawia tabela 6.3.

**Tab. 6.3.** Porównanie jakości dopasowania modelu w Kopalni A i B

| Miara                        | Kopalnia A             | Kopalnia B                     |
|------------------------------|------------------------|--------------------------------|
| Średni błąd względny [%]     | 9,1                    | 7,4                            |
| Maksymalny błąd [%]          | 21,3                   | 18,6                           |
| RMSE [min]                   | 47                     | 42                             |
| R <sup>2</sup>               | 0,79                   | 0,82                           |
| Dominujące obszary zgodności | organizacyjne,<br>KRZG | mechaniczne,<br>technologiczne |

Porównanie to dowodzi, że model nie jest sztywnym odwzorowaniem danych wejściowych, lecz potrafi adaptować się do specyfiki poszczególnych zakładów. W jednych skuteczniej przewiduje przestoje krótkotrwałe i częste, w innych – długotrwałe i rzadkie, co potwierdza jego elastyczność i przydatność w różnych warunkach eksploatacyjnych.

## 6.6. Podsumowanie

Przeprowadzona analiza empiryczna potwierdziła skuteczność opracowanego modelu w odwzorowaniu rzeczywistych warunków eksploatacyjnych. Zastosowana procedura walidacji wykazała wysoką zgodność między wartościami prognozowanymi a obserwowanymi, zarówno na poziomie rozkładów czasów przestojów, jak i identyfikacji dni krytycznych.

W Kopalni A model najtrafniej odwzorował krótkotrwałe, lecz częste przestoje organizacyjne i administracyjne, natomiast w Kopalni B – długotrwałe, rzadziej występujące awarie mechaniczne i technologiczne. Takie zróżnicowanie pokazuje, że model nie jest jedynie prostym odwzorowaniem danych wejściowych, lecz potrafi adaptować się do specyfiki różnych zakładów górniczych.

Porównanie obu kopalń dowiodło, że koncepcja modelowania może być skutecznie stosowana w odmiennych warunkach techniczno-organizacyjnych. Model pozwala nie tylko na ocenę zgodności danych historycznych, ale również na wskazanie obszarów o największym znaczeniu dla dostępności technicznej. W konsekwencji opracowana koncepcja modelowania stanowi nie tylko narzędzie oceny zgodności danych historycznych, lecz także praktyczny instrument diagnostyczny, wspierający decyzje w zakresie utrzymania ruchu, planowania konserwacji prewencyjnej oraz minimalizacji ryzyka występowania dni krytycznych.



## 7. Możliwości wykorzystania w praktyce przemysłowej

Wyniki przeprowadzonych badań jednoznacznie wskazują, że opracowany model, integrujący parametry niezawodności z czynnikami niepewności operacyjnej i technicznej, może stanowić skuteczne narzędzie wspierające analizę oraz doskonalenie procesów przemysłowych w ujęciu praktycznym. W porównaniu z tradycyjnymi rozwiązaniami opartymi na deterministycznym podejściu do niezawodności (Jardine, Tsang 2013), zaproponowana koncepcja wyróżnia się większą elastycznością i zdolnością adaptacji do zmieniających się warunków pracy. Dzięki temu znajduje zastosowanie w rzeczywistych systemach eksploatacyjnych, w których parametry techniczne i organizacyjne podlegają ciągłym fluktuacjom. Takie właściwości sprawiają, że model może pełnić rolę praktycznego narzędzia wspomagającego podejmowanie decyzji w obszarze utrzymania ruchu, planowania prewencyjnego oraz oceny ryzyka operacyjnego.

W praktyce przemysłowej opracowany model może być wykorzystywany na kilku poziomach zarządzania. Na poziomie operacyjnym pozwala on na wczesne wykrywanie tendencji spadku niezawodności w sytuacjach zakłóceń, co umożliwia wcześniejsze reagowanie na symptomy degradacji sprzętu lub nieprawidłowości organizacyjne. Na poziomie taktycznym ułatwia optymalizację planów konserwacji poprzez identyfikację podsystemów najbardziej wrażliwych na określone typy niepewności, natomiast w wymiarze strategicznym sprzyja ograniczeniu strat produkcyjnych wynikających z nieplanowanych przestojów i błędnych decyzji eksploatacyjnych. Otrzymane rezultaty są zgodne z tendencjami obserwowanymi w najnowszych badaniach dotyczących proaktywnego monitorowania stanu technicznego maszyn i procesów w górnictwie (Stefaniak i inni 2018; Odeyar i inni 2022; Dąbek i inni 2023), które podkreślają znaczenie integracji analizy niezawodności z systemami pomiarowymi i diagnostyką predykcyjną.



Wdrożenie opracowanego modelu w warunkach przemysłowych może przebiegać etapowo. W początkowej fazie rekomenduje się integrację modelu z istniejącymi systemami klasy CMMS oraz z rozwiązaniami IoT, co umożliwia bieżące gromadzenie, przetwarzanie i analizę danych eksploatacyjnych. Dzięki temu możliwe jest utworzenie środowiska informacyjnego, które pozwala na systematyczne śledzenie stanu urządzeń, analizę trendów awaryjności oraz automatyczne generowanie raportów diagnostycznych. W kolejnych etapach model może zostać wykorzystany jako narzędzie predykcyjne, pozwalające prognozować spadki niezawodności i przewidywać momenty wystąpienia potencjalnych awarii. Umożliwia to planowanie przestojów w sposób minimalizujący wpływ na produkcję, a także efektywniejsze zarządzanie zasobami serwisowymi.

Ważnym elementem implementacji modelu jest również rozbudowa narzędzi analitycznych opartych na danych rzeczywistych, które integrują informacje z systemów IoT i CMMS. Pozwala to na zwiększenie dokładności oceny niezawodności procesów oraz na szybką reakcję w przypadku wykrycia odchylenia od wartości referencyjnych parametrów pracy. Takie rozwiązania stanowią fundament dla wdrożenia systemów klasy PdM oraz dla budowy cyfrowych bliźniaków procesów przemysłowych, które umożliwiają symulację zachowania systemu w warunkach rzeczywistych i przewidywanie jego reakcji na zakłócenia.

Równoległe z wdrażaniem rozwiązań technicznych niezbędne jest podnoszenie kompetencji kadry technicznej. Szkolenia z zakresu probabilistycznego podejścia do niezawodności oraz zarządzania ryzykiem i niepewnością są ważnym elementem skutecznego wykorzystania potencjału modelu. Dzięki temu inżynierowie utrzymania ruchu mogą trafniej interpretować wyniki analiz, rozpoznawać przyczyny odchylenia i podejmować decyzje oparte na obiektywnych danych, a nie wyłącznie na doświadczeniu. W szerszym ujęciu prowadzi to do rozwoju kultury prewencji i świadomego zarządzania ryzykiem w organizacji, co jest jednym z podstawowych założeń współczesnej inżynierii niezawodności.

Uzupełnieniem działań systemowych mogą być szybkie usprawnienia organizacyjno-techniczne, które nie wymagają znacznych nakładów finansowych, a przynoszą wymierne efekty eksploatacyjne. Do najważniejszych należą: systematyczny monitoring taśm przenośnikowych, w szczególności krążników i zjawiska niewłaściwego prowadzenia taśmy, umożliwiający wczesne wykrywanie potencjalnych awarii, oraz udoskonalenie harmonogramów konserwacji predykcyjnej, które pozwala efektywniej planować prace serwisowe i ograniczać liczbę nieplanowanych postojów. Działania tego typu stanowią praktyczny przykład implementacji zasad zarządzania niezawodnością w codziennej praktyce przemysłowej i mogą być wprowadzane stopniowo, w zależności od dojrzałości organizacyjnej zakładu.

## 8. Stwierdzenia i wnioski końcowe

Podsumowanie przeprowadzonych badań pozwala jednoznacznie określić znaczenie opracowanego modelu dla rozwoju współczesnej inżynierii niezawodności oraz jego przydatność w praktyce przemysłowej. Wyniki analiz potwierdzają słuszność przyjętych założeń badawczych i dowodzą, że integracja metod deterministycznych oraz probabilistycznych umożliwia bardziej wiarygodne i elastyczne modelowanie procesów wydobywczych w warunkach niepewności technicznej i operacyjnej. Opracowany model łączy aspekt teoretyczny z praktycznym, tworząc spójne narzędzie analizy procesów przemysłowych o złożonej strukturze i zmiennych warunkach pracy.

W toku badań wykazano, że koncepcja modelowania niezawodności procesów wydobywczych, uwzględniająca zarówno czynniki operacyjne, jak i techniczne, charakteryzuje się wysoką skutecznością w odwzorowywaniu rzeczywistych warunków funkcjonowania systemów górniczych. Wprowadzenie pojęcia niezawodności procesowej umożliwiło rozszerzenie klasycznego podejścia, w którym analizuje się pojedyncze urządzenia, na kompleksową ocenę całego ciągu technologicznego – rozumianego jako złożony układ powiązanych elementów, współdziałających w ramach jednego systemu produkcyjnego. Takie ujęcie stanowi istotny krok w stronę nowoczesnej inżynierii systemów i wpisuje się w założenia inżynierii odporności systemów (Hollnagel 2017), w której kluczową rolę odgrywa zdolność organizacji techniczno-produkcyjnych do adaptacji, elastycznego reagowania i odtwarzania stabilnych warunków funkcjonowania po wystąpieniu zakłóceń.

Z naukowego punktu widzenia opracowany model można postrzegać jako pomost łączący klasyczną teorię niezawodności z nowoczesnymi koncepcjami analizy danych i modelowania probabilistycznego. Integruje on tradycyjne metody oceny niezawodności z narzędziami analitycznymi umożliwiającymi przetwarzanie danych rzeczywistych, tworząc tym samym platformę rozwoju dla rozwiązań zgodnych z ideą Przemysłu 4.0. Takie podejście pozwala na budowę systemów zdolnych do przewidywania stanów awaryjnych, wspomagają-

nia decyzji eksploatacyjnych oraz ciągłego doskonalenia procesów produkcyjnych na podstawie rzeczywistych informacji zwrotnych.

Walidacja modelu przeprowadzona na danych empirycznych potwierdziła jego zgodność z rzeczywistym zachowaniem analizowanych systemów. Osiągnięte wartości błędów RMSE, MAE i MAPE mieszczą się w akceptowalnych granicach, co dowodzi wiarygodności modelu oraz jego praktycznej przydatności. Analiza wyników wskazała, że model prawidłowo odwzorowuje reakcje systemu na różne rodzaje zakłóceń i pozwala na prognozowanie zachowania całego procesu w warunkach niepewności. Największe różnice pojawiają się jedynie w przypadku zdarzeń ekstremalnych, które wymagają dodatkowego modelowania i poszerzenia bazy danych o przypadki o charakterze skrajnym.

Istotnym atutem opracowanego rozwiązania jest jego elastyczność i uniwersalność zastosowania. Model można łatwo dostosować do specyfiki różnych zakładów górniczych – zarówno podziemnych, jak i odkrywkowych – co znacząco poszerza jego potencjał aplikacyjny. W szerszej perspektywie proponowane podejście może znaleźć zastosowanie także w innych gałęziach przemysłu procesowego, takich jak energetyka, przemysł chemiczny czy logistyka. W sektorach tych, podobnie jak w górnictwie, występuje silne powiązanie czynników technicznych, organizacyjnych i ludzkich, dlatego opracowany model może stać się podstawą do tworzenia zintegrowanych metod oceny niezawodności i odporności procesów na zakłócenia.

Kierunki dalszych badań powinny obejmować rozszerzenie bazy danych walidacyjnych, tak aby uwzględniała ona różnorodne typy zakładów, technologie eksploatacyjne i zmienne warunki geologiczne. Włączenie do modelu zjawisk o charakterze rzadkim i ekstremalnym pozwoli zwiększyć jego odporność predykcyjną i poprawić dokładność odwzorowania zjawisk losowych. Perspektywiczny kierunek rozwoju stanowi również opracowanie modułu uczenia maszynowego oraz automatycznej kalibracji parametrów, który umożliwi dynamiczne dostosowywanie modelu do bieżących warunków pracy. Tego typu rozwiązania stanowią istotny krok w kierunku samodoskonalących się systemów analitycznych, zdolnych do przewidywania zmian w niezawodności w czasie rzeczywistym.

Podsumowując, zaproponowana koncepcja modelowania niezawodności procesów wydobywczych w warunkach niepewności technicznej i operacyjnej stanowi znaczący krok w kierunku rozwoju nowoczesnej inżynierii niezawodności. Łącząc klasyczne podstawy teoretyczne z podejściem probabilistycznym i analizą danych rzeczywistych, model ten oferuje praktyczne narzędzie służące poprawie efektywności, bezpieczeństwa i odporności procesów przemysłowych na zaburzenia pracy systemów wynikające z awarii, błędów organizacyjnych i zmiennych warunków środowiskowych. W szerszym kontekście opracowane rozwiązanie wpisuje się w proces cyfrowej transformacji sektora wydobywczego, wspierając wdrażanie zasad Przemysłu 4.0 oraz rozwój inteligentnych systemów zarządzania produkcją w górnictwie i pokrewnych dziedzinach przemysłu.

# Bibliografia

## Literatura naukowa (książki, artykuły)

- van der Aalst, W. M. P. (2016). *Process Mining: Data Science in Action*. Springer.
- Aggarwal, C. C. (2015). *Data mining: The textbook*. Springer. <https://doi.org/10.1007/978-3-319-14142-8>
- Agrawal, A. K., Murthy, V. M. S. R., & Chattopadhyaya, S. (2019). *Investigations into reliability, maintainability and availability of tunnel boring machine operating in mixed ground condition using Markov chains*. Engineering Failure Analysis, 105, 477–489. <https://doi.org/10.1016/j.engfailanal.2019.07.013>
- Agrawal, R., & Srikant, R. (1995, March 6). *Mining sequential patterns*. W Proceedings of the Eleventh International Conference on Data Engineering (s. 3–14). IEEE. <https://doi.org/10.1109/ICDE.1995.380415>
- Agrawal, R., Imieliński, T., & Swami, A. (1993). *Mining association rules between sets of items in large databases*. ACM SIGMOD Record, 22(2), 207–216. <https://doi.org/10.1145/170036.170072>
- Ahmadi, S., Hajihassani, M., Moosazadeh, S., & Moomivand, H. (2020). *An overview of the reliability analysis methods of tunneling equipment*. The Open Construction and Building Technology Journal, 14(1), 218–233. <https://doi.org/10.2174/1874836802014010218>
- Aladejare, A. E., Idowu, K. A., & Ozoji, T. (2024). *Reliability of Monte Carlo simulation approach for estimating uniaxial compressive strength of intact rock*. Earth Science Informatics, 17, 2043–2053. <https://doi.org/10.1007/s12145-024-01262-1>
- Aqueveque, P., Radrigan, L., Pastene, F., Morales, A. S., & Guerra, E. (2021). *Data-driven condition monitoring of mining mobile machinery in non-stationary operations using wireless accelerometer sensor modules*. IEEE Access, 9, 17365–17381. <https://doi.org/10.1109/ACCESS.2021.3051583>
- Azadeh, A., Hasannia Kolaei, M., & Salehi, V. (2016). *The impact of redundancy on resilience engineering in a petrochemical plant by data envelopment analysis*. Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability, 230(3), 285–296. <https://doi.org/10.1177/1748006X16629866>

- Barlow, R. E., & Proschan, F. (1996). *Mathematical theory of reliability*. SIAM.
- Bartelmus, W., & Zimroz, R. (2009). *Vibration condition monitoring of planetary gearbox under varying external load*. Mechanical Systems and Signal Processing, 23(1), 246–257. <https://doi.org/10.1016/j.ymssp.2008.03.016>
- Bazargur, B., Bataa, O., & Budjav, U. (2023). *Reliability study for communication system: A case study of an underground mine*. Applied Sciences, 13(2), Article 821. <https://doi.org/10.3390/app13020821>
- Birolini, A. (2017). *Reliability engineering: Theory and practice (8th ed.)*. Springer. <https://doi.org/10.1007/978-3-662-54209-5>
- Blanchard, B. S., & Fabrycky, W. J. (2014). *Systems Engineering and Analysis*. Pearson.
- Bodziony, P., & Patyk, M. (2024). *The influence of the mining operation environment on the energy consumption and technical availability of truck haulage operations in surface mines*. Energies, 17(11), 2654. <https://doi.org/10.3390/en17112654>
- Boudali, H., & Dugan, J. B. (2005). *A discrete-time Bayesian network reliability modeling and analysis framework*. Reliability Engineering & System Safety, 87(3), 337–349. <https://doi.org/10.1016/j.ress.2004.06.004>
- Brodny, J., & Stecula, K. (2016). *Analiza efektywności wykorzystania zestawu maszyn górniczych*, [w:] Knosala R. (red.), Innowacje w Zarządzaniu i Inżynierii Produkcji. Oficyna Wydawnicza Polskiego Towarzystwa Zarządzania Produkcją, Opole.
- Brzychczy, E. (2019). *Probabilistic modeling of mining production in an underground coal mine*. w A. Burduk, D. Mazurkiewicz, & J. Wąs (Eds.), Intelligent Systems in Production Engineering and Maintenance – ISPEM 2018 (s. 655–667). Springer. [https://doi.org/10.1007/978-3-319-97490-3\\_62](https://doi.org/10.1007/978-3-319-97490-3_62)
- Brzychczy, E., & Napieraj, A. (2019). *Analysis of a mining process performance in a longwall face – visualization proposals*. Inżynieria Mineralna, 21(2), 251–258. <https://doi.org/10.29227/IM-2019-02-41>
- Brzychczy, E., Rostek, K. (2024). *Cyfrowa analiza danych i procesów*. Warszawa: Polskie Wydawnictwo Ekonomiczne. ISBN 978-83-208-2596-1
- Brzychczy, E., Kęsek, M., Napieraj, A., & Magda, R. (2017). *An expert system for underground coal mine planning*. Gospodarka Surowcami Mineralnymi – Mineral Resources Management, 33(2), 113–127.
- Brzychczy, E., Trzcionkowska, A., & Napieraj, A. (2020, February 24–26). *Analiza procesów w górnictwie – podejścia i wyzwania [Process analysis in mining – approaches and challenges]*. W XXIX Szkoła Eksploatacji Podziemnej 2020 (s. 44). Kraków: Instytut Gospodarki Surowcami Mineralnymi i Energią PAN. Pobrano z <https://szkolaeksploatacji.pl/referat/analiza-procesow-w-gornictwie-podejscia-i-wyzwania/>
- Cai, B., Kong, X., Liu, Y., Lin, J., Yuan, X., Xu, H., & Ji, R. (2018). *Application of Bayesian networks in reliability evaluation: A bibliographic review*. IEEE Transactions on Industrial Informatics, 15(4), 2146–2157. <https://doi.org/10.1109/TII.2018.2858281>
- Chachra, A., Kumar, A., & Ram, M. (2024). *A Markovian approach to reliability estimation of series-parallel system with Fermatean fuzzy sets*. Computers & Industrial Engineering, 190, 110081. <https://doi.org/10.1016/j.cie.2024.110081>

- Chamorro, J., Vallejo, L., Maynard, C., Guevara, S., Solorio, J. A., Soto, N., Singh, K. V., Bhate, U., Kumar, R. G. V. V., Garcia, J., & Newell, B. (2022). *Health monitoring of a conveyor belt system using machine vision and real-time sensor data*. CIRP Journal of Manufacturing Science and Technology, 38, 38–50. <https://doi.org/10.1016/j.cirpj.2022.03.013>
- Chollet, F., et al. (2015). Keras. <https://keras.io>
- Czaplicki, J., Szweda, S., & Szyguła, M. (2013). *Badania pilotujące niezawodności sekcji obudowy zmechanizowanej*. Przegląd Górniczy, t. 69, nr 7, s. 46–60.
- Dayo-Olupona, O., Genc, B., Celik, T., & Bada, S. (2023). *Adoptable approaches to predictive maintenance in mining industry: An overview*. Resources Policy, 86, 104291 <https://doi.org/10.1016/j.resourpol.2023.104291>
- Dąbek, P., Wodecki, J., Stefaniak, P., & Zimroz, R. (2023). *Application of the methods of monitoring and detecting the belt mistracking in laboratory conditions*. Applied Sciences, 13(4), 2111. <https://doi.org/10.3390/app13042111>
- Dhillon, B. S. (2008). *Mining equipment reliability, maintainability, and safety*. Springer Series in Reliability Engineering. <https://doi.org/10.1007/978-1-84800-288-3>
- Dhillon, B. S. (2017). *Engineering systems reliability, safety, and maintenance: An integrated approach*. CRC Press. <https://doi.org/10.1201/9781315160535>
- Dumas, M. (2017). *Predictive business process monitoring with LSTM neural networks*. In Business Process Management Workshops (s. 477–492). Springer. [https://doi.org/10.1007/978-3-319-59536-8\\_30](https://doi.org/10.1007/978-3-319-59536-8_30)
- Dunn, M. J. (2019). *Quantifying uncertainty in mining geomechanics design*. W Proceedings of the First International Conference on Mining Geomechanics (s. 233–244). Australian Centre for Geomechanics. [https://doi.org/10.36487/ACG\\_rep/1905\\_23\\_Dunn](https://doi.org/10.36487/ACG_rep/1905_23_Dunn)
- Dyczko, A. (2023). *Górnictwo 4.0 w kierunku inteligentnej głębokiej kopalni przyszłości*. Agencja Rozwoju Przemysłu. Pobrano z [https://www.academia.edu/download/107009399/DYCZKO\\_Gornictwo\\_4.0\\_w\\_kierunku\\_inteligentnej\\_g%C5%82ebokiej\\_kopalni\\_przysz%C5%82osci\\_ARP2023.pdf](https://www.academia.edu/download/107009399/DYCZKO_Gornictwo_4.0_w_kierunku_inteligentnej_g%C5%82ebokiej_kopalni_przysz%C5%82osci_ARP2023.pdf)
- Elsayed, E. A. (2021). *Reliability engineering (3rd ed.)*. Wiley.
- Ericson, C. A. (1999). *Fault tree analysis – A history*. Proceedings of the 17th International System Safety Conference, 1–9.
- van Eyk, L., & Heyns, P. S. (2025). *A framework to define, design and construct digital twins in the mining industry*. Computers & Industrial Engineering, 200, 110805. <https://doi.org/10.1016/j.cie.2024.110805>
- Fayyad, U. (2001). *Knowledge discovery in databases: An overview*. W S. Džeroski & N. Lavrač (Eds.), Relational data mining (s. 28–47). Springer. [https://doi.org/10.1007/978-3-662-04599-2\\_2](https://doi.org/10.1007/978-3-662-04599-2_2)
- Farahani, A., & Tohidi, H. (2021). *Integrated optimization of quality and maintenance: A literature review*. Computers & Industrial Engineering, 151, 106924. <https://doi.org/10.1016/j.cie.2020.106924>

- Feng, X., Lu, Y., He, J., Lu, B., & Wang, K. (2024). *Bayesian-network-based predictions of water inrush incidents in soft rock tunnels*. KSCE Journal of Civil Engineering, 28(12), 5934–5945. <https://doi.org/10.1007/s12205-024-0193-6>
- Friederich, J., & Lazarova-Molnar, S. (2024). *Reliability assessment of manufacturing systems: A comprehensive overview, challenges and opportunities*. Journal of Manufacturing Systems, 70, 280–300. <https://doi.org/10.1016/j.jmsy.2023.11.001>
- Friedman, J. H. (2001). *Greedy function approximation: A gradient boosting machine*. Annals of Statistics, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>
- Gackowiec, P. (2024). *Metodyka analizy predykcijnej stanów awaryjnych kombajnu ścianowego*. Praca doktorska. Niepublikowana. Dostępna w BG AGH.
- Gackowiec, P., Podobińska-Staniec, M., Brzychczy, E., Kühlbach, C., & Özver, T. (2020). *Review of key performance indicators for process monitoring in the mining industry*. Energies, 13(19), 5169. <https://doi.org/10.3390/en13195169>
- Gano, D. L. (2007). *Apollo Root Cause Analysis*. Apollonian Publications.
- Geisbush, J., & Ariaratnam, S. T. (2023). *Reliability centered maintenance (RCM): Literature review of current industry state of practice*. Journal of Quality in Maintenance Engineering, 29(2), 313–337. <https://doi.org/10.1108/JQME-02-2021-0018>
- Gibiec, M. (2005). *Prediction of machines health with application of an intelligent approach – A mining machinery case study*. Key Engineering Materials, 293–294, 661–668. <https://doi.org/10.4028/www.scientific.net/kem.293-294.661>
- Groenewald, H. J., Kleingeld, M., & Cloete, G. J. (2018). *An autoregressive fault model for condition monitoring of electrical machines in deep-level mines*. W Proceedings of the International Conference on the Industrial and Commercial Use of Energy (ICUE) (s. 1–6).
- Guerroum, M., Zegrari, M., Ait Elmahjoub, A., Berquedich, M., & Masmoudi, M. (2021). *Machine learning for the predictive maintenance of a jaw crusher in the mining industry*. W Proceedings of the IEEE International Conference on Technology Management, Operations and Decisions (ICTMOD) (s. 1–6). IEEE. <https://doi.org/10.1109/ICTMOD52902.2021.9739338>
- Guerroum, M., et al. (2022). *Machine learning technics for remaining useful life prediction using diagnosis data: A case study of a jaw crusher*. International Journal of Emerging Technology and Advanced Engineering, 12(10), 122–135. [https://doi.org/10.46338/ijetae1022\\_14](https://doi.org/10.46338/ijetae1022_14)
- Harish Kumar, N. S., John, R. P., Chand, P., & Kumar, S. G. S. (2022). *Performance evaluation of mining equipment in surface coal mine using reliability analysis*. Journal of Mines, Metals and Fuels, 69(12A), 296. <https://doi.org/10.18311/jmmf/2021/30119>
- Hartman, H. L., & Mutmanský, J. M. (2002). *Introductory Mining Engineering*. Wiley.
- Hebda-Sobkowicz, J., Zimroz, R., Kumar, A., & Wyłomańska, A. (2025). *Robust correlation measures for informative frequency band selection in heavy-tailed vibration signals*. Advanced Engineering Informatics, 65, 103174. <https://doi.org/10.1016/j.aei.2025.103174>

- Helton, J. C., & Davis, F. J. (2003). *Latin hypercube sampling and the propagation of uncertainty in analyses of complex systems*. Reliability Engineering & System Safety, 81(1), 23–69. [https://doi.org/10.1016/S0951-8320\(03\)00058-9](https://doi.org/10.1016/S0951-8320(03)00058-9)
- Hollnagel, E., Woods, D. D., & Leveson, N. (Eds.). (2019). *Resilience engineering: Concepts and precepts (2nd ed.)*. CRC Press. <https://doi.org/10.1201/9781315605685>
- Hustrulid, W. A., Bullock, R. L., & Kuchta, M. (2018). *Underground Mining Methods: Engineering Fundamentals and International Case Studies*. SME.
- Jardine, A. K. S., & Tsang, A. H. C. (2013). *Maintenance, Replacement, and Reliability*. CRC Press.
- de Jesus Santos, A. C., Cavalcante, C. A. V., & Wu, S. (2023). *Maintenance policies and models: A bibliometric and literature review of strategies for reuse and remanufacturing*. Reliability Engineering & System Safety, 231, 108983. <https://doi.org/10.1016/j.res.2022.108983>
- Jin, T. (2019). *Reliability engineering and service*. Wiley.
- Kumar, U., & Klefsjö, B. (1992). *Reliability analysis of hydraulic systems of LHD machines using the power law process model*. Reliability Engineering & System Safety, 35(3), 217–224. [https://doi.org/10.1016/0951-8320\(92\)90080-5](https://doi.org/10.1016/0951-8320(92)90080-5)
- Korzeniowski, W., Herezy, Ł., Krauze, K., Rak, Z., & Skrzypkowski, K. (2013). *Monitoring górotworu na podstawie analizy pracy sekcji obudowy zmechanizowanej*. Kraków: Wydawnictwa AGH.
- Korzeniowski, W., Skrzypkowski, K., & Herezy, Ł. (2015). *Laboratory method for evaluating the characteristics of expansion rock bolts subjected to axial tension*. Archives of Mining Sciences, 60(1), 209–224. <https://doi.org/10.1515/amsc-2015-0014>
- Kozłowski, T., Wodecki, J., Zimroz, R., Błażej, R., & Hardygóra, M. (2020). *A diagnostics of conveyor belt splices*. Applied Sciences, 10(18), 6259. <https://doi.org/10.3390/app10186259>
- Leemis, L. M. (2009). *Reliability: Probabilistic models and statistical methods (2nd ed.)*. Springer.
- Leite, J. R., Picanço, M. S., Pereira, T. M., Cavalcante, C. A. V., & Silva, E. P. (2024). *Efficient monitoring of longitudinal tears in conveyor belts using a 2D laser scanner*. Measurement, 229, 114557. <https://doi.org/10.1016/j.measurement.2024.114557>
- Li, X., Yuan, J., Zhang, L., & Yang, D. (2024). *Risk assessment of subway station fire by using a Bayesian network-based scenario evolution model*. Journal of Civil Engineering and Management, 30(3), 279–294. <https://doi.org/10.3846/jcem.2024.20846>
- Liang, Q., Yang, D., Zhang, X., Peng, Y., & Lu, H. (2022). *Analysis of simplification in Markov state-based models for reliability assessment of complex safety systems*.
- Lindi, O. T., Aladejare, A. E., Ozoji, T. M., & Ranta, J.-P. (2024). *Uncertainty quantification in mineral resource estimation: A review*. Natural Resources Research, 33, 2503–2526. <https://doi.org/10.1007/s11053-024-10394-6>
- Liu, J., Feng, Y., Lu, C., & Fei, C. (2025). *Operational reliability assessment of complex mechanical systems with multiple failure modes: An adaptive decomposition–*



- synchronous-coordination approach*. Reliability Engineering & System Safety, 253, 110123. <https://doi.org/10.1016/j.ress.2024.110123>
- Liu, L., Liu, J., & Zhou, Q. (2022). *Mine ventilation system reliability evaluation based on a Markov chain*. Scientific Reports, 12, Article 17115. <https://doi.org/10.1038/s41598-022-22098-z>
- Lu, M., & Shen, Z. M. (2021). *A review of robust operations management under model uncertainty*. Production and Operations Management, 30(6), 1927–1943. <https://doi.org/10.1111/poms.13239>
- Macak, M., Daubner, L., Fani Sani, M., & Buhnova, B. (2022). *Process mining usage in cybersecurity and software reliability analysis: A systematic literature review*. Array, 13, 100120. <https://doi.org/10.1016/j.array.2021.100120>
- Macha, E. (2001). *Niezawodność maszyn*, Politechnika Opolska, skrypt nr 237, Opole.
- Magda, R. (2018). *Analiza innowacyjnych rozwiązań organizacyjnych w procesie produkcji podziemnej kopalni węgla kamiennego [Analysis of innovative organizational solutions in the production process of an underground hard coal mine]*. W J. Kulczycka & P. Łebkowski (Eds.), Zarządzanie przedsiębiorstwem: teoria i praktyka. XVIII międzynarodowa konferencja naukowa, Kraków, 21–22 czerwca 2018: abstrakty (s. 73–74). Wydawnictwa AGH. ISBN 978-83-66016-30-9
- Magda, R. (2019). *An assessment of selected work organisation variants in an underground hard coal mine with consideration to unit mining costs*. Inżynieria Mineralna – Journal of the Polish Mineral Engineering Society, 21(1), 289–294. <https://doi.org/10.29227/IM-2019-01-50>
- Malozyomov, B. V., Martyushev, N. V., Babyr, N. V., Pogrebnoy, A. V., Efremenkov, E. A., Valuev, D. V., & Boltrushevich, A. E. (2024). *Modelling of reliability indicators of a mining plant*. Mathematics, 12(18), 2842. <https://doi.org/10.3390/math12182842>
- Marković, P., Stevanović, D., Kolonja, B., Slavković, D., & Kržanović, D. (2025). *A hybrid model for risk-based strategic planning in open-pit mining: Integrating deterministic, stochastic, and ISO 31000 approaches*. Applied Sciences, 15(5), 2500. <https://doi.org/10.3390/app15052500>
- Mishra, R., Uotinen, L., & Rinne, M. (2021). *A Bayesian network approach for geotechnical risk assessment in underground mines*. Journal of the Southern African Institute of Mining and Metallurgy, 121(6), 287–293. <https://doi.org/10.17159/2411-9717/581/2021>
- Modarres, M., Kaminskiy, M. P., & Krivtsov, V. (2016). *Reliability engineering and risk analysis: A practical guide (3rd ed.)*. CRC Press.
- Molęda, M., Małysiak-Mrozek, B., Ding, W., Sunderam, V., & Mrozek, D. (2023). *From corrective to predictive maintenance – a review of maintenance approaches for the power industry*. Sensors, 23(13), 5970. <https://doi.org/10.3390/s23135970>
- Moniri-Morad, A., Pourgol-Mohammad, M., Aghababaei, H., & Sattarvand, J. (2022). *Production capacity insurance considering reliability, availability, and maintainability analysis*. ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering, 8(2), 04022027. <https://doi.org/10.1061/AJRUA6.0001233>
- Montgomery, D. C., & Runger, G. C. (2014). *Applied Statistics and Probability for Engineers*. Wiley.

- Napieraj, A., Snopkowski, R., & Sukiennik, M. (2025). *Use of boundary distribution to assess the duration of a stochastic processes in underground mines*. Archives of Mining Sciences, 70(1), 147–157. <https://doi.org/10.24425/ams.2025.154167>
- Nelson, W. (2004). *Applied Life Data Analysis*. Wiley.
- Nobahar, P., Xu, C., Dowd, P., & Shirani Faradonbeh, R. (2024). *Exploring digital twin systems in mining operations: A review*. Green and Smart Mining Engineering, 1(4), 474–492. <https://doi.org/10.1016/j.gsme.2024.09.003>
- Odeyar, P., Apel, D. B., Hall, R., Zon, B., & Skrzypkowski, K. (2022). *A review of reliability and fault analysis methods for heavy equipment and their components used in mining*. Energies, 15(17), 6263. <https://doi.org/10.3390/en15176263>
- Ozdemir, B., & Kumral, M. (2019). *Analysing human effect on the reliability of mining equipment*. International Journal of Heavy Vehicle Systems, 26(6), 872–887. <https://doi.org/10.1504/IJHVS.2019.102716>
- Rahimdel, M. J. (2024). *Bayesian network approach for reliability analysis of mining trucks*. Scientific Reports, 14, 3415. <https://doi.org/10.1038/s41598-024-52694-0>
- Rahimdel, M. J., & Ghodrati, B., (2023). *Reliability analysis of the compressed air supplying system in underground mines*. Scientific Reports, 13, 6836. <https://doi.org/10.1038/s41598-023-33736-5>
- Rausand, M., & Høyland, A. (2020). *System reliability theory: Models, statistical methods, and applications (3rd ed.)*. Wiley.
- Rodriguez-Fernandez, V., Trzcionkowska, A., Gonzalez-Pardo, A., Brzychczy, E., Nalepa, G. J., & Camacho, D. (2021). *Conformance checking for time-series-aware processes*. IEEE Transactions on Industrial Informatics, 17(2), 871–881. <https://doi.org/10.1109/TII.2020.3018187>
- Rojas, L., Peña, Á., & Garcia, J. (2025). *AI-driven predictive maintenance in mining: A systematic literature review on fault detection, digital twins, and intelligent asset management*. Applied Sciences, 15(6), 3337. <https://doi.org/10.3390/app15063337>
- Roos, C. (2024). *Visualizing and quantifying uncertainty in cut-off grade selection*. Mining, Metallurgy & Exploration, 41, 3757–3768. <https://doi.org/10.1007/s42461-024-01147-3>
- Saltelli, A., Chan, K., & Scott, E. M. (Eds.). (2000). *Sensitivity analysis: Gauging the worth of scientific models*. John Wiley & Sons.
- Snopkowski, R. (2007). *Symulacja stochastyczna [The stochastic simulation]*. Kraków: AGH Uczelniane Wydawnictwa Naukowo-Dydaktyczne AGH. ISBN 978-83-7464-130-2.
- Snopkowski, R. (2012). *Stochastyczne metody analizy procesu produkcyjnego realizowanego w przodkach ścianowych kopalń węgla kamiennego [Stochastic methods of the analysis of the production process implemented in longwalls of hard coal mines]*. Kraków: Wydawnictwa AGH. ISBN 978-83-7464-530-0.
- Snopkowski, R., Sukiennik, M., & Napieraj, A. (2023). *Decision-making in hard coal mines with the support of selected stochastic methods / Podejmowanie decyzji w kopalniach węgla kamiennego ze wsparciem wybranych metod stochastycznych*. Mining – Informatics, Automation and Electrical Engineering, 2023(4), 19–23, 24–28. [https://www.mia.agh.edu.pl/wp-content/uploads/MIAG\\_04-2023\\_02\\_pl.pdf](https://www.mia.agh.edu.pl/wp-content/uploads/MIAG_04-2023_02_pl.pdf)

- Snopkowski, R., Sukiennik, M., & Napieraj, A. (2025). *Reducing the Stochastic Coal Output Model Using the Convolution of Probability Density Functions*. Applied Sciences, 15(15), 8590. <https://doi.org/10.3390/app15158590>
- Sobol, I. M. (2001). *Global sensitivity indices for nonlinear mathematical models and their Monte Carlo estimates*. Mathematics and Computers in Simulation, 55(1–3), 271–280. [https://doi.org/10.1016/S0378-4754\(00\)00270-6](https://doi.org/10.1016/S0378-4754(00)00270-6)
- Sreedharan, S., Ramachandran, M., & Ramesh, D. (2025). *Harnessing digital twins and industrial-IoT for cutting-edge mining automation: A methodological and technology assessment prototype*. Computers & Industrial Engineering, 201, 110871. <https://doi.org/10.1016/j.cie.2025.110871>
- Stefaniak, P., Wodecki, J., & Zimroz, R. (2018). *Maintenance management of mining belt conveyor system based on data fusion and advanced analytics*. W Applied Condition Monitoring (Vol. 10, s. 465–476). Springer. [https://doi.org/10.1007/978-3-319-62042-8\\_42](https://doi.org/10.1007/978-3-319-62042-8_42)
- Stephens, M. A. (1974). *EDF Statistics for Goodness of Fit and Some Comparisons*. Journal of the American Statistical Association, 69(347), 730–737. <https://doi.org/10.1080/01621459.1974.10480196>
- Stockmann, C., & Winkler, H. (2022). *Robustness of production systems: Evidence from the German manufacturing industry*. Journal of Engineering and Technology Management, 63, Article 101672. <https://doi.org/10.1016/j.jengtecman.2022.101672>
- Stricker, N., & Lanza, G. (2014). *The concept of robustness in production systems and its correlation to disturbances*. Procedia CIRP, 19, 87–92. <https://doi.org/10.1016/j.procir.2014.04.078>
- Su, P., Guo, L., Zhang, J., & Ma, L. (2025). *Reliability evaluation method and system for the ventilation door cylinder based on Bayes–Monte Carlo simulation*. Scientific Reports, 15, 5871. <https://doi.org/10.1038/s41598-025-90311-w>
- Suchorab-Matuszewska, N., Kawalec, W., & Król, R. (2025). *Study of long-distance belt conveying for underground copper mines*. Energies, 18(18), 4872. <https://doi.org/10.3390/en18184872>
- Szpyrka, M., Brzychczy, E., Napieraj, A., Korski, J., & Nalepa, G. J. (2020). *Conformance checking of a longwall shearer operation based on low-level events*. Energies, 13(24), 6630. <https://doi.org/10.3390/en13246630>
- Szrek, J., Wodecki, J., Błażej, R., & Zimroz, R. (2020). *An inspection robot for belt conveyor maintenance in underground mine – Infrared thermography for overheated idlers detection*. Applied Sciences, 10(14), 4984. <https://doi.org/10.3390/app10144984>
- Szrek, J., Jakubiak, J., & Zimroz, R. (2022). *A mobile robot-based system for automatic inspection of belt conveyors in mining industry*. Energies, 15(1), 327. <https://doi.org/10.3390/en15010327>
- Sánchez-Herguedas, A., Mena-Nieto, A., Crespo-Márquez, A., & Rodrigo-Muñoz, F. (2024). *Finite time preventive maintenance optimization by using a semi-Markov process with a degraded state: A case study for diesel engines in mining*. Computers & Industrial Engineering, 190, 110083. <https://doi.org/10.1016/j.cie.2024.110083>

- Tobias, P.A., & Trindade, D. (2011). *Applied Reliability (3rd ed.)*. Chapman and Hall/CRC. <https://doi.org/10.1201/b11787>
- Tomuş, O.-B., Andraş, I., & Magyari, M. (2017). *Study on the reliability of the underground conveyor belt system installed at Vulcan Mine, the Jiu Valley Basin in Romania*. MATEC Web of Conferences, 121, 01016. <https://doi.org/10.1051/mateconf/201712101016>
- Trzcionkowska, A., & Brzychczy, E. (2018). *Practical aspects of event logs creation for industrial process modelling*. W MAPE 2018: XV International Conference Multidisciplinary Aspects of Production Engineering (Vol. 1, Issue 1, s. 77–83). PANOVA. ISBN 978-83-65265-25-8
- Tubis, A., Werbińska-Wojciechowska, S., & Wróblewski, A. (2020). *Risk assessment methods in mining industry – A systematic review*. Applied Sciences, 10(15), 5172. <https://doi.org/10.3390/app10155172>
- Turek, M. (2010). *Podstawy podziemnej eksploatacji pokładów węgla kamiennego*. Katowice: Główny Instytut Górnictwa. ISBN 978-83-61126-33-1.
- Turek, M., & Magdziarczyk, M. (2024). *Method of selecting the optimal variant of mine closure with the possibility of capturing methane from underground excavations*. Journal of Sustainable Mining, 23(4), Article 9. <https://doi.org/10.46873/2300-3960.1437>
- Vališ, D., & Mazurkiewicz, D. (2018). *Application of selected Lévy processes for degradation modelling of long-range mine belt using real-time data*. Archives of Civil and Mechanical Engineering, 18(4), 1430–1440. <https://doi.org/10.1016/j.acme.2018.05.006>
- Waloski, R., Korzeniowski, W., Bólož, Ł., & Rączka, W. (2021). *Identification of rock mass critical discontinuities while borehole drilling*. Energies, 14(10), 2748. <https://doi.org/10.3390/en14102748>
- Wang, W., & Pham, H. (2006). *Reliability and Optimal Maintenance*. Springer.
- Weber, P., Simon, C., & Medina-Oliva, G. (2010). *Overview on Bayesian networks applications for dependability, risk analysis and maintenance areas*. Engineering Applications of Artificial Intelligence, 25(4), 230–249. <https://doi.org/10.1016/j.engappai.2009.11.002>
- Wijaya, H., Rajeev, P., Gad, E., & Vivekanantham, R. (2022). *Automatic fault detection system for mining conveyor using distributed acoustic sensor*. Measurement, 187, 110330. <https://doi.org/10.1016/j.measurement.2021.110330>
- Yari, M., Armaghani, D. J., Maraveas, C., Ejlali, A. N., Mohamad, E. T., & Asteris, P. G. (2023). *Several Tree-Based Solutions for Predicting Flyrock Distance Due to Mine Blasting*. Applied Sciences, 13(3), 1345. <https://doi.org/10.3390/app13031345>
- Zhang, M., Jiang, K., Cao, Y., Li, M., Wang, Q., Li, D., & Zhang, Y. (2023). *A new paradigm for intelligent status detection of belt conveyors based on deep learning*. Measurement, 213, 112735. <https://doi.org/10.1016/j.measurement.2023.112735>
- Zhang, Z., Ning, L., Liu, Z., Yang, Q., & Ding, W. (2023). *Mining and reasoning of data uncertainty-induced imprecision in deep image classification*. Information Fusion, 96, 202–214. <https://doi.org/10.1016/j.inffus.2023.03.014>
- Zimroz, R., Hardygóra, M., Wodecki, J., Góralczyk, M., Zimroz, M., & Król, R. (2019). *Integration of condition monitoring and process control for belt conveyor haulage in underground mines*. Applied Sciences, 9(22), 4711. <https://doi.org/10.3390/app9224711>

- Zio, E. (2016). *Challenges in the vulnerability and risk analysis of critical infrastructures*. Reliability Engineering & System Safety, 152, 137–150. <https://doi.org/10.1016/j.ress.2016.02.009>
- Zujović, L., Kecojević, V., & Bogunović, D. (2020). *Application of a content management system for developing equipment safety training courses in surface mining*. Journal of the Southern African Institute of Mining and Metallurgy, 120(8), 467–474. <https://doi.org/10.17159/2411-9717/1233/2020>

## **Normy techniczne**

- International Electrotechnical Commission. (2021). *IEC 60050-195: International Electrotechnical Vocabulary – Earthing and protection against electric shock*. Geneva, Switzerland: IEC.
- International Organization for Standardization. (2018). *ISO 31000: Risk management – Guidelines*. Geneva, Switzerland: ISO.
- International Organization for Standardization. (2000). *ISO 9000: Quality management systems – Fundamentals and vocabulary*. Geneva, Switzerland: ISO.

## **Dokumentacja zakładowa**

- Dane operacyjne kopalni. Zanonimizowane rejestry incydentów i przestojów (raporty zmianowe)*. Źródło wewnętrzne, dostęp ograniczony.

ISSN 0867-6631  
ISBN 978-83-68219-90-6 (print)  
ISBN 978-83-68219-91-3 (PDF)