

**SCIENTIFIC
STUDIES**

**PRACE
NAUKOWE**

Leszek Chomacki

**Zastosowanie inteligencji
obliczeniowej sieci Bayesa do oceny
ryzyka powstania uszkodzeń
budynków na terenach górniczych**

Application of the computational intelligence
of the Bayesian network to the assessment
of the risk of damage to buildings in mining areas



Instytut Techniki Budowlanej

Warszawa 2023

PUBLIKACJE INSTYTUTU TECHNIKI BUDOWLANEJ

obejmują m.in. następujące wydawnictwa:

PRACE NAUKOWE – MONOGRAFIE, ROZPRAWY, STUDIA

INSTRUKCJE, WYTYCZNE, PORADNIKI

WARUNKI TECHNICZNE WYKONANIA I ODBIORU ROBÓT BUDOWLANYCH

PROJEKTOWANIE WEDŁUG EUROKODÓW

RADA PROGRAMOWA WYDAWNICTW ITB

Przewodniczący

Sekretarz

Członkowie

dr hab. inż. Jadwiga Fangrat, prof. instytutu

inż. Marek Gębarzewski

prof. dr hab. inż. Lech Czarnecki

mgr inż. Jan Sieczkowski

dr hab. inż. Jacek Szer, prof. uczelni

dr hab. inż. Wojciech Węgrzyński, prof. instytutu

dr inż. Michał Wójtowicz

**SCIENTIFIC
STUDIES**

Monographs

**PRACE
NAUKOWE**

Monografie

Leszek Chomacki

**Zastosowanie inteligencji
obliczeniowej sieci Bayesa do oceny
ryzyka powstania uszkodzeń
budynków na terenach górniczych**

Application of the computational intelligence
of the Bayesian network to the assessment
of the risk of damage to buildings in mining areas



Instytut Techniki Budowlanej

Warszawa 2023

KOMITET REDAKCYJNY

Redaktor naczelny
Z-cy redaktora naczelnego

Sekretarz
Członkowie

prof. dr hab. inż. LECH CZARNECKI
prof. dr inż. LESŁAW BRUNARSKI
dr hab. inż. JADWIGA FANGRAT, prof. instytutu
dr MICHAŁ GAJOWNIK
dr hab. inż. PAWEŁ LEWIŃSKI, prof. instytutu
mgr inż. JAN SIECZKOWSKI
dr inż. EWA SZEWCZAK
dr inż. SEBASTIAN WALL

Recenzenci:

prof dr hab. inż. ŁUKASZ DROBIEC
prof dr hab. inż. KRZYSZTOF TAJDUŚ

Redakcja
dr MICHAŁ GAJOWNIK

© Copyright by Instytut Techniki Budowlanej
Warszawa 2023

*Czteryście siedemdziesiąta czwarta pozycja
„Prac Naukowych ITB”*

ISBN 978-83-249-8649-1 (PDF)

Wydawca i Autorzy dołożyli wszelkich starań, aby publikowane informacje pochodziły z rzetelnych źródeł. Wydawca nie ponosi odpowiedzialności, ani też nie zaciąga zobowiązań w wyniku wykorzystania przez użytkowników treści niniejszej publikacji. W szczególności nie ponosi odpowiedzialności w stosunku do czytelników i/lub strony trzeciej za jakiegokolwiek poniesione straty, wydatki i szkody bezpośrednie i pośrednie, łącznie z utratą zysku i innych korzyści majątkowych, które mogły powstać lub być związane bezpośrednio lub pośrednio z treściami opublikowanymi, w tym ewentualnymi błędami lub pominięciami zawartymi w publikowanych materiałach.



Instytut Techniki Budowlanej

Dział Wydawnictw Naukowych

02-656 Warszawa, ul. Ksawerów 21, tel.: 22 843 35 19
tel.: 22 56 64 208, e-mail: wydawnictwa@itb.pl www.itb.pl

Spis treści

<i>Streszczenie</i>	5
<i>Summary</i>	6
Od Autora	7
1. Wprowadzenie	9
1.1. Budownictwo na terenach górniczych i oddziaływania górnicze ...	9
1.2. Wpływ eksploatacji górniczej na budynki	15
1.3. Ocena ryzyka powstania uszkodzeń	19
1.4. Najnowsze doświadczenia dotyczące powstawania uszkodzeń w budynkach na skutek eksploatacji górniczej	20
2. Problematyka uszkodzonych budynków poddanych wpływom górnictwem	27
2.1. Metody oceny możliwości powstania uszkodzeń budynków na terenach górniczych	27
2.2. Doświadczenia ze stosowania metod inteligencji obliczeniowej w budownictwie na terenach górniczych	36
2.3. Wnioski z analizy źródeł literaturowych	38
3. Charakterystyka utworzonej bazy danych	41
3.1. Uwagi ogólne	41
3.2. Charakterystyka badanej zabudowy	41
3.3. Uszkodzenia budynków	48
3.4. Oddziaływania górnicze w rejonie badanej zabudowy	50
4. Charakterystyka metod inteligencji obliczeniowej	53
4.1. Podstawy metodyczne dotyczące inteligencji obliczeniowej	53
4.2. Sieć Bayesa (BN – Bayesian Network)	54
5. Model oceny ryzyka powstania uszkodzeń jako sieć Bayesa	63
5.1. Informacje ogólne i przygotowanie danych do analiz	63
5.2. Interpretacja wyników oraz przyjęty sposób ich weryfikacji	65
5.3. Wyniki obliczeń otrzymane dla sieci Bayesa z wykorzystaniem różnych metod uczenia struktury sieci	67
5.4. Analiza wpływu zmiennych wejściowych na prognozowaną kategorię uszkodzeń	89

6. Warianty wykorzystania utworzonego modelu oceny ryzyka powstania uszkodzeń w budownictwie na terenach górniczych	95
6.1. Uwagi ogólne	95
6.2. Symulacja działania modelu do predykcji powstania uszkodzeń danej kategorii	95
6.3. Wykorzystanie sieci w przypadku diagnozy przyczyn zaobserwowanych uszkodzeń	99
6.4. Wykorzystanie sieci w przypadku niepełnych danych	100
7. Podsumowanie, wnioski oraz dalsze kierunki badań	105
Bibliografa	109
Załącznik 1. Zestawienie danych z podziałem na zmienne, ich stany i liczności w zbiorach	123
Załącznik 2. Tablice prawdopodobieństw warunkowych (CPT) dla struktury BN, metody uczenia TAN-CL i funkcji celu AIC	129

ZASTOSOWANIE INTELIGENCJI OBLICZENIOWEJ SIECI BAYESA DO OCENY RYZYKA POWSTANIA USZKODZEŃ BUDYNKÓW NA TERENACH GÓRNICZYCH

Streszczenie

Podziemna eksploatacja górnicza powoduje wstrząsy górniczne, a także deformacje powierzchni terenu, które w praktyce inżynierskiej opisuje się jako nieckę obniżeń. Jednym z istotnych wskaźników tej deformacji są odkształcenia poziome, które niejednokrotnie przyczyniają się do powstania uszkodzeń budynków murowanych na powierzchni. Dotychczas nie opracowano skutecznego i uniwersalnego narzędzia umożliwiającego ocenę ryzyka powstania uszkodzeń takich budynków.

Metody wykorzystujące inteligencję obliczeniową pozwalają na symulację skomplikowanych zjawisk w wielu dziedzinach nauki. Spośród dostępnych metod wybrano te, które dają sposobność na uzyskanie wyników ze wskazaniem prawdopodobieństwa wystąpienia zdarzenia. Takie prawdopodobieństwo można interpretować jako ocenę ryzyka zdarzenia, którym w niniejszej monografii jest powstawanie uszkodzeń budynków.

Opisano kryteria wyboru grupy 207 budynków wytypowanych do przeprowadzenia badań. Utworzona baza danych o budynkach oraz wpływach eksploatacji górnicznej zawiera 26 zmiennych oraz 594 przypadki.

Przeprowadzono analizę danych z wykorzystaniem czterech metod inteligencji obliczeniowej. Najlepsze wyniki do zaproponowanych autorskich kryteriów oceny uzyskano dla modelu utworzonego z wykorzystaniem sieci Bayesa (BN). Zaprezentowano struktury działania różnych sieci BN oraz analizę wpływu zmiennych wejściowych na dokładność klasyfikacji uszkodzeń. Przeprowadzono symulację wykorzystania utworzonego modelu w trzech wariantach: prognozie powstania uszkodzeń w budynku, diagnozowaniu przyczyn uszkodzeń oraz przypadku dysponowania niepełną bazą danych.

W podsumowaniu przedstawiono informacje uzyskane za pomocą stworzonego modelu, podkreślono możliwość jego wykorzystania w ocenie ryzyka uszkodzeń budynków murowanych poddanych wpływom eksploatacji górnicznej, a także zaproponowano kierunki dalszych badań.

APPLICATION OF THE COMPUTATIONAL INTELLIGENCE OF THE BAYESIAN NETWORK TO THE ASSESSMENT OF THE RISK OF DAMAGE TO BUILDINGS IN MINING AREAS

Summary

Underground mining exploitation causes mining tremors as well as deformation of the ground surface, which in engineering practice is described as a depression basin. One of the most important indicators of this deformation are horizontal deformations, which often contribute with damages in buildings. So far, no effective and universal tool has been developed that would make it possible to assess the possibility of damages in such buildings.

Methods that use computational intelligence allow you to simulate complex phenomena in many fields of science. Among the available methods, the ones that allow to obtain results with the indication of the probability of the event occurrence have been selected. Such probability can be interpreted as an assessment of the risk of an event, which in this dissertation are damages in buildings.

The criteria for selecting a group of 207 buildings for research were described. The collected database of buildings and mining exploitation impacts contains 26 variables and 594 cases.

Data analysis was performed using 4 computational intelligence methods. The best results for the proposed original evaluation criteria were obtained for the model created with the Bayesian Network (BN). The structure of various BN network and the analysis of the influence of input variables on the state of damage were presented. A simulation of the created model usage was carried out in three variants: forecast of damage occurrence in the building, diagnosis of the causes of damage and the case of having an incomplete database.

The summary presents the information obtained with the use of the prepared model, the possibility of its use in the assessment of the risk of damage to buildings subject to mining exploitation and the directions of further research.

OD AUTORA

Monografię opracowano na podstawie rozprawy doktorskiej [1], z uwzględnieniem uwag recenzentów oraz dyskusji w trakcie jej publicznej obrony. W monografii szczególną uwagę poświęcono modelowi oceny ryzyka przygotowanemu z zastosowaniem sieci Bayesa (BN), który okazał się najbardziej perspektywiczny w prowadzonych badaniach. W pracy zredukowano natomiast informacje dotyczące pozostałych analizowanych metod inteligencji obliczeniowej.

Wykorzystując zapisy rozprawy, która stanowiła podstawę ubiegania się o nadanie stopnia doktora nauk technicznych, chciałem przygotować praktyczne kompendium wiedzy poświęcone problematyce uszkodzania budynków na terenach górniczych. Wiedza ta jest wykorzystywana przede mną w praktyce zawodowej, a dzięki niniejszej monografii będzie mogła służyć projektantom, inżynierom lub służbom kopalnianym zajmującym się tematyką deformacji i uszkodzeń budynków na terenach górniczych.

Pragnę wyrazić podziękowania Dyrekcji Instytutu Techniki Budowlanej za pomoc, jaką otrzymałem w trakcie realizowania badań przedstawionych w niniejszej pracy oraz w przygotowaniu rozprawy doktorskiej.

Wielkie wyrazy wdzięczności kieruję w stronę promotora pracy – dr. hab. inż. Janusza Ruska, prof. AGH, który wprowadził mnie w tematykę wykorzystywania metod sztucznej inteligencji na terenach górniczych. Rady otrzymane od prof. J. Ruska okazały się bardzo wartościowe i pozwoliły na sprawne wykorzystanie wyników prowadzonych badań oraz napisanie rozprawy doktorskiej w 2020 r. Pragnę także podziękować recenzentom – prof. dr. hab. inż. Łukaszowi Drobcowi oraz prof. dr. hab. inż. Krzysztofowi Tajdusiowi – za szczegółową analizę pracy oraz wskazanie racjonalnych kierunków prowadzenia przyszłych badań.

Leszek Chomacki

1. WPROWADZENIE

1.1. Budownictwo na terenach górniczych i oddziaływania górnicze

1.1.1. Budownictwo na terenach górniczych

Światowy rozwój gospodarki w dużym stopniu uzależniony jest od wydobywania i wykorzystywania surowców energetycznych. Najbardziej popularne surowce energetyczne to ropa naftowa, gaz ziemny oraz węgiel kamienny i brunatny.


W Polsce powszechnie wykorzystywanym surowcem jest węgiel kamienny, co wynika z faktu występowania tutaj znacznych jego złóż, wynoszących 64 mld ton [2]. Węgiel kamienny wydobywany jest w rejonach Górnośląskiego i Lubelskiego Zagłębia Węglowego [2], a jego wydobycie w 2016 r. wyniosło 70 mln ton [3].

W latach przed II wojną światową eksploatacja węgla prowadzona była głównie na niewielkich głębokościach i w oddaleniu od zabudowy [4]. Po 1945 r., wraz z postępem techniki, wydobycie prowadzone było na coraz większych głębokościach, a eksploatacja w zauważalnym stopniu zaczęła oddziaływać na obiekty budowlane. W celu ochrony istniejących budynków, w latach sześćdziesiątych XX w., sformułowano pojęcie „odporności obiektów budowlanych na wpływy eksploatacji górniczej” [5]. Właściwe stosowanie metod oceny odporności budynków na wpływ eksploatacji górniczej umożliwia prowadzenie wydobycia przy wystąpieniu akceptowalnych dla użytkowników uszkodzeń [6].

Obiekty budowlane projektowane do posadowienia na terenach górniczych i pogórniczych mogą być prawidłowo kształtowane i obliczane z wykorzystaniem wielu instrukcji wydanych przez ITB [7–11].

Schematyczne ujęcie zagadnień związanych z budownictwem na terenach górniczych znajduje się na rysunku 1.1.


Z uwagi na powszechne stosowanie instrukcji ITB przez inżynierów budowlanych oraz wynikające z nich dobre doświadczenia, w niniejszej rozprawie skupiono się na obiektach już istniejących poddanych wpływom górniczym.



Rys. 1.1. Zagadnienia dotyczące budownictwa na terenach górniczych [12]

1.1.2. Oddziaływania górnicze

Obiekty budowlane zlokalizowane na terenach górniczych mogą być poddane wpływom dodatkowych obciążeń pochodzących od deformacji powierzchni lub drgań podłoża [13]. Obok dodatkowego wyęźnienia elementów konstrukcyjnych ustroju nośnego, eksploatacja górnicza może powodować również uciążliwości w użytkowaniu. Negatywne wpływy na powierzchnię oraz w obiektach budowlanych, które mogą wystąpić w warunkach eksploatacji górniczej, przedstawiono schematycznie na rysunku 1.2.




Rys. 1.2. Elementy kształtujące wpływ podziemnej eksploatacji górniczej na powierzchnię [13, 14]

1.1.3. Ciągłe deformacje powierzchni – obniżeniowa niecka górnicza

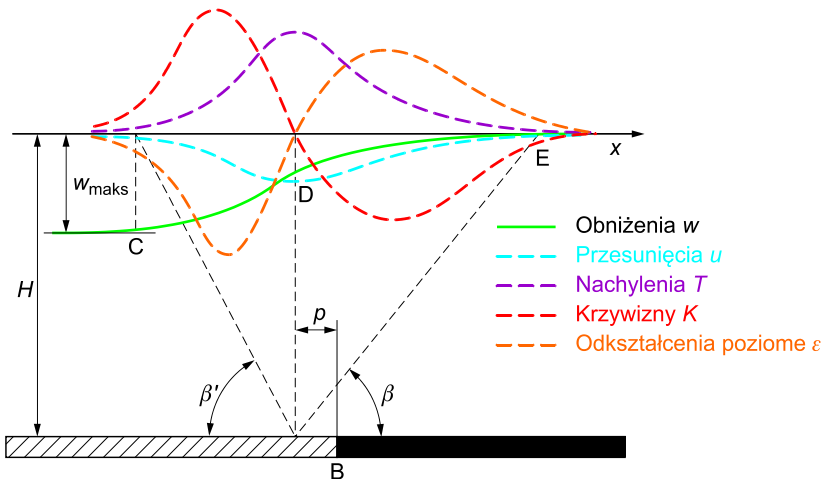
Najbardziej powszechnym skutkiem prowadzenia podziemnej eksploatacji górniczej są ciągłe deformacje powierzchni, które ujawniają się w postaci obniżeniowej niecki górniczej. Przykład regularnej niecki wywołanej eksploatacją przedstawiono na rysunku 1.3.

Do opisu niecki obniżeniowej wykorzystywane są wskaźniki deformacji, a wśród nich: obniżenie, nachylenia, krzywizny, poziome przemieszczenia i odkształcenia. Wartości wskaźników są związane z odległością od krawędzi eksploatacji. Wszystkie wskaźniki osiągają ekstremalne wartości w pobliżu krawędzi eksploatacji, z wyjątkiem obniżień, które są największe nad środkową częścią wybranego pola eksploatacyjnego.



Rys. 1.3. Niecka normalna (regularna) wywołana poziomym wyrobiskiem pokładu
 a – wyrobisko, b – niecka, c – linia obniżenia terenu
 (opracowanie własne na podstawie [15])

Profil przekroju niecki obniżeniowej wraz z przybliżonym przebiegiem opisujących ją wskaźników deformacji (w , u , T , K , ε) przedstawiono na rysunku 1.4.



Rys. 1.4. Przebieg wskaźników deformacji w rejonie krawędzi dużego pola eksploatacji według teorii Knothe'go
 p – obrzeże niecki, H – głębokość zalegania pokładu, β , β' – kąty wpływów,
 w_{maks} – maksymalne obniżenie, B, C, D, E – punkty charakterystyczne
 (opracowanie własne na podstawie [16, 17])

Przy prowadzonej obecnie eksploatacji górniczej, z uwagi na jej znaczne głębokości, wpływ krzywizny terenu jest coraz mniej wyraźny, rośnie natomiast znaczenie poziomych odkształceń terenu, co zostało zasygnalizowane w [18].


1.1.4. Nieciągłe deformacje powierzchni

Podziemna eksploatacja górnicza może również powodować powstanie nieciągłych deformacji terenu typu powierzchniowego i liniowego.

Wśród deformacji powierzchniowych można wyróżnić: zapadliska, osuwiska i tzw. nieciągłe deformacje lokalne, mające kształt mało rozległych i głębokich niecek obniżeń. Przykłady typów deformacji liniowych przedstawiono na rysunku 1.5.

Deformacje nieciągłe powstają zazwyczaj w sposób nagły, a proces ich uformowania trwa najczęściej od kilku minut do kilku godzin, rzadziej dni. Zazwyczaj przyczynami powstawania deformacji nieciągłych są [20]:


- ruchy górotworu wywołane płytką eksploatacją górniczą,
- aktywacja naturalnych uskoków tektonicznych przez prowadzoną eksploatację,
- aktywacja starych, głównie płytko zalegających wyrobisk górniczych lub zlikwidowanych szybów,
- nakładające się krawędzie eksploatacyjne w kilku pokładach,
- zmiany stosunków wodnych w starych zrobach/wyrobiskach.



Rys. 1.5. Rodzaje deformacji nieciągłych typu liniowego [19]
a) pęknięcie, b) szczelina, c) próg (uskok) terenowy, d) garb terenowy, e) rów

1.1.5. Wstrząsy górnicze

Wstrząsy górotworu powstałe na skutek prowadzonej eksploatacji górniczej (tzw. wstrząsy górnicze) wynikają z nagłego wyzwolenia się energii potencjalnej nagromadzonej w skałach górotworu i ujawniają się na powierzchni w postaci drgań podłoża [21, 22]. Uproszczony schemat oddziaływania drgań powierzchniowych na konstrukcję budynku przedstawiono na rysunku 1.6.



Rys. 1.6. Schemat działania drgań powierzchniowych na budynek
 H – hipocentrum, E – epicentrum, a – przyspieszenie drgań gruntu,
 B – siła bezwładności [23]

Intensywność wstrząsów zależy od [24]:

- właściwości fizyko-mechanicznych skał zalegających nad wybranym pokładem,
- głębokości zalegania skał,
- geometrii przestrzennej calizn (pokładów nienaruszonych przez roboty górnicze) i wybranych przestrzeni w górotworze,
- warunków geologiczno-górnich prowadzonych robót, a także (częściowo) od sposobu eksploatacji.

Ponadto wstrząsy podziemne mogą być wywołane robotami strzałowymi związanymi z prowadzoną eksploatacją górniczą.

1.1.6. Zmiana stosunków wodnych w podłożu

Eksploatacja górnicza niejednokrotnie ma również wpływ na zmianę stosunków wodnych. Obniżenia terenu mogą powodować pozorne podniesienie swobodnego poziomu lustra wody. Czasami na skutek prowadzonej eksploatacji górniczej dochodzi do drenażu wód powierzchniowych i podziemnych wód nadkładowych. Znane są również przypadki, gdy w efekcie stałego odwadniania górotworu, obserwowane obniżenia terenu górniczego sięgają znacznie poza granice eksploatacji złoża. Występują wtedy wielkopowierzchniowe niecki obniżeniowe [25].


Wyżej wymienione oddziaływania górnicze mogą negatywnie wpływać na budynki znajdujące się na powierzchni terenu górniczego.

1.2. Wpływ eksploatacji górniczej na budynki

1.2.1. Uszkodzenia budynków

Opis wpływu oddziaływań górniczych na stan uszkodzeń budynków wykonano na podstawie monografii [12].

W przypadku usytuowania budynku na wypukłej części niecki górniczej, konstrukcja obiektu ulega wygięciu do strzałki a_b , wynikającej z promienia krzywizny budynku R_b (rys. 1.7). W górnych partiach ścian mogą wystąpić siły rozciągające, a w ich następstwie rysy oznaczone na rysunku 1.7 jako (A). Natomiast w dolnych partiach budynku na skutek poziomych, rozluźniających ruchów terenu ($\varepsilon > 0$), w fundamentach powstają siły rozciągające, co może powodować wystąpienie rys pionowych oznaczonych jako (B). Wystąpienie tych rys jest zależne od konstrukcji fundamentów obiektu i wynika ze zwiększenia długości konstrukcji o wartość ΔL .




Rys. 1.7. Schemat deformacji i uszkodzeń ściany na wypukłej części niecki [12]

W ścianach na skutek naprężeń głównych mogą powstać także rysy ukośne, oznaczone na rysunku 1.7 jako (C), których przebieg wznosi się od środka budynku ku jego krawędziom. Intensywność rys ukośnych jest zależna głównie od odkształcenia postaciowego ścian θ_b [12].

Rozmiary i charakter zarysowań konstrukcji są zależne od sposobu jej przystosowania do przejmowania oddziaływań pochodzenia górniczego. Uszkodzenia ścian oraz innych niezbrojonych elementów konstrukcyjnych (np. ceglanych fundamentów, nadproży ceglanych) w budynkach niezabezpieczonych przed tymi oddziaływaniami są zazwyczaj dużo większe niż uszkodzenia w obiektach projektowanych na przejście wpływów górniczych.

Analogicznie można opisać stan ogólnej deformacji i uszkodzeń budynku położonego na wklęsłej części niecki (rys. 1.8). Na skutek wygięcia a_b konstrukcji ku dołowi układ rys ukośnych oznaczonych na rysunku 1.8 jako (C) ma przebieg wznoszący się od zewnętrznych krawędzi budynku ku środkowi. Krzywizna terenu ma w takich przypadkach mniejszy wpływ na ogólną deformację budynku i jego odkształcenie postaciowe Θ_b . W ścianie podlegającej oddziaływaniu wklęsłego obrzeża niecki dominujące są normalne siły ściskające, dlatego można uznać, że pracuje ona w bardziej korzystnych warunkach niż przy wystąpieniu oddziaływań wypukłej niecki [12].




Rys. 1.8. Schemat deformatacji i uszkodzeń ściany na wklęsłej części niecki [12]

We wklęsłej części niecki należy zwrócić uwagę na wpływ poziomych odkształceń gruntu, powodujących jego zagęszczenie ($\varepsilon < 0$). Występujące wtedy dodatkowe parcie gruntu sumuje się z parciem spoczynkowym i negatywnie oddziałuje na zewnętrzne, zagłębione elementy konstrukcji.

Efekt oddziaływań wynikających z zagęszczenia podłoża górniczego jest zauważalny szczególnie w obiektach znacznie zagłębionych w gruncie [12].

W budynkach o sztywnym schemacie konstrukcyjnym możliwy efekt poziomych odkształceń terenu górniczego $\varepsilon < 0$, zwiększających istniejące parcie na ściany zewnętrzne, jest przedstawiony schematycznie na rysunku 1.9. W takim przypadku występują głównie uszkodzenia ścian piwnicznych w postaci poziomego ścięcia ścian usytuowanych prostopadle do kierunku deformacji terenu, które oznaczono na rysunku 1.9 jako (A). Powszechnie również są ścięcia ścian w rejonie otworów okiennych w ścianach równoległych do kierunku odkształceń poziomych, które oznaczono jako (B). Mogą wystąpić także przemieszczenia części fundamentowych budynku do jego wnętrza, oznaczone jako (C). Doświadczenia wykazują, że tego rodzaju skutki mają miejsce głównie w budynkach niezabezpieczonych na wpływy eksploatacji górniczej, zwykle zagłębionych co najmniej 1,5 m poniżej poziomu terenu [26, 27]. Przy mniejszym zagłębieniu podobne skutki można obserwować w budynkach posadowionych w gruntach spoistych lub znajdujących się w niekorzystnej sytuacji górniczej, umożliwiającej sumowanie się poziomych ściskających odkształceń gruntu $\varepsilon < 0$ od eksploatacji kilku pokładów. Występujący efekt zależy od konstrukcji budynku oraz intensywności poziomych odkształceń terenu.



Rys. 1.9. Schemat deformacji budynku spowodowany parciem gruntu na ściany zewnętrzne [12]

W celu uniknięcia powstawania uszkodzeń oraz ochrony budynków sformułowano pojęcie „odporności obiektów budowlanych na wpływy eksploatacji górniczej” [5], wykorzystywane następnie w ocenie konstrukcji budynków położonych na terenach górniczych.

1.2.2. Ocena odporności

Odporność obiektów budowlanych na ciągłe deformacje powierzchni definiowana jest jako zdolność obiektów do przenoszenia krzywizn $K = R^{-1}$ i poziomych odkształceń powierzchni ε , przy zachowaniu bezpieczeństwa obiektów i zapewnieniu możliwości ich użytkowania zgodnie z przeznaczeniem, w warunkach co najwyżej małej uciążliwości [28]. Graniczne wartości wskaźników deformacji terenu dla kategorii terenu górniczego przedstawiono w tablicy 1.1.

Tablica 1.1. Kategorie terenu górniczego [28]

Kategoria	Graniczne wartości wskaźników deformacji terenu		
	nachylenie T [‰]	promień krzywizny R [km]	odkształcenie poziome ε [‰]
0	$T \leq 0,5$	$ R \geq 40$	$ \varepsilon \leq 0,3$
I	$0,5 < T \leq 2,5$	$40 > R \geq 20$	$0,3 < \varepsilon \leq 1,5$
II	$2,5 < T \leq 5$	$20 > R \geq 12$	$1,5 < \varepsilon \leq 3$
III	$5 < T \leq 10$	$12 > R \geq 6$	$3 < \varepsilon \leq 6$
IV	$10 < T \leq 15$	$6 > R \geq 4$	$6 < \varepsilon \leq 9$
V	$T > 15$	$ R < 4$	$ \varepsilon > 9$

Poziomy uciążliwości związane z użytkowaniem budynku i przypisane im efekty w budynku, z wyróżnieniem wychylenia, szerokości rys w ścianach oraz odkształcenia postaciowego ścian, zostały przedstawione w tablicy 1.2.

Tablica 1.2. Uciążliwość użytkowania budynków przy uwzględnieniu wartości efektów oddziaływań górniczych [28]

Efekty w budynku		Uciążliwość użytkowania			
		nieodczuwalna	mała	średnia	duża
Wychylenie	T_b [‰]	≤ 10	10 do 15	15 do 20	> 20
Szerokość rys w ścianach	a_w [mm]	≤ 1	1 do 3	3 do 8	> 8
Odształcenie postaciowe ścian	$\vartheta_b \cdot 10^{-3}$	≤ 1	1 do 2	2 do 3	> 3

W przypadku gdy odporność budynku jest niższa od prognozowanej kategorii wpływów górniczych, uznaje się taki budynek za nieodporny i zaleca się podjęcie przez przedsiębiorcę górniczego działań mających na celu dostosowanie konstrukcji obiektu do przejścia prognozowanych wpływów. Praktykowane jest również prowadzenie nadzorów budowlanych nad takimi budynkami, w trakcie których formułowane są zalecenia z zakresu profilaktyki budowlanej, mające na celu zminimalizowanie zagrożenia jakie niesie eksploatacja górnicza [29].

Zgodnie z [30] przed każdą eksploatacją górniczą wymagane jest wykonanie oceny odporności obiektów budowlanych stanowiących zabudowę powierzchni, na które oddziaływać będą wpływy górnicze. Do oceny odporności stosuje się obecnie metody przybliżone (w tym tzw. metodę punktową), ocenę eksperta oraz procedurę diagnostyczną [31].

Wyżej wymienione metody pozwalają na uzyskanie informacji o odporności obiektu. Niestety z ich pomocą nie można otrzymać informacji o intensywności potencjalnych uszkodzeń, jakie mogą wystąpić na skutek prowadzonej eksploatacji górniczej, co byłoby cenną informacją dla inżyniera oceniającego bezpieczeństwo obiektu. W związku z powyższym, zasadne jest naukowe opracowanie metody, która powinna pozwolić na uzyskanie informacji o ryzyku wystąpienia uszkodzeń w istniejących budynkach poddanych wpływom górniczym wraz z ilościową informacją o intensywności uszkodzeń.

1.3. Ocena ryzyka powstania uszkodzeń

Zgodnie z Eurokodem 1 [32] ryzyko definiuje się jako *miarę kombinacji (zwykle iloczyn) prawdopodobieństwa lub częstotliwości zdarzenia o zdefiniowanym zagrożeniu i wielkości konsekwencji zdarzenia*. Natomiast ocenę ryzyka definiuje się jako *porównanie wyników analizy ryzyka z kryteriami akceptacji ryzyka i innymi kryteriami decyzyjnymi*.

Zatem ocena ryzyka powstania uszkodzeń powinna skupiać się na prognozowaniu ilościowej miary, którą można byłoby odnieść do zakładanych kryteriów akceptacji ryzyka z uwzględnieniem prawdopodobieństwa. Kryterium akceptacji ryzyka może dotyczyć różnych sposobów klasyfikacji intensywności uszkodzeń w budynkach, jak te zaproponowane w [31] oraz [33], lub dotyczyć uciążliwości użytkowania (tabl. 1.2).

Z analizy literatury wynika, że narzędziami pozwalającymi na budowę modelu oceny ryzyka powstania uszkodzeń są zaawansowane narzędzia eksploracji danych, a w szczególności metody inteligencji obliczeniowej. Najważniejszym czynnikiem pozwalającym na ocenę ryzyka jest możliwość określenia prawdopodobieństwa wystąpienia zdarzenia, jakim w analizowanym przypadku jest powstanie uszkodzeń. W obszarze metod inteli-

gencji obliczeniowej istnieje wiele takich, które pozwalają na uszczegółowienie wyników predykcji o wartość prawdopodobieństwa wystąpienia danego zdarzenia [34].

W ocenie ryzyka szczególnie ważne wydaje się uwzględnienie wielu zmiennych (kryteriów decyzyjnych) mogących mieć wpływ na powstawanie uszkodzeń w budynkach na skutek oddziaływań górniczych. Proces kształtowania się uszkodzeń w budynkach poddanych negatywnym wpływom deformującego się podłoża jest zależny od wielu czynników, takich jak: geometria budynku, zastosowane rozwiązania konstrukcyjne i materiałowe, zabezpieczenia na wpływy górnicze, stan techniczny czy jakość utrzymania. Z rozeznania literaturowego wynika, że dostępne obecnie metody inteligencji obliczeniowej, na podstawie wielu zmiennych wejściowych, pozwalają na skuteczne przewidywanie zmiennej wyjściowej [35].

Dodatkową trudnością w obiektywnej ocenie ryzyka powstania uszkodzeń jest brak pewności co do wartości niektórych zmiennych, a także subiektywność ocen osób oceniających. Wskazane jest, aby model oceny ryzyka umożliwiał uwzględnianie niepewnych (przyjętych na podstawie doświadczenia) lub niepełnych (brakujących) danych wejściowych. Jest to wysoce pożądana cecha, która pozwala na powszechność stosowania takiego modelu [36]. Tę niewątpliwą zaletę posiadają m.in. metody wykorzystujące twierdzenie Bayesa, takie jak Naiwny Klasyfikator Bayesowski (NBC), czy sieć Bayesa (BN) [37, 38].

Ponadto, jak wynika z analizy literatury światowej [39] i krajowej [40, 41], w ostatnim czasie podejmuje się próby budowy modeli z wykorzystaniem inteligencji obliczeniowej, które pozwalają ocenić ryzyko powstania uszkodzeń w zależności od zmiennych wejściowych.

1.4. Najnowsze doświadczenia dotyczące powstawania uszkodzeń w budynkach na skutek eksploatacji górniczej

Od 2010 r. powstało wiele publikacji dotyczących uszkodzeń budynków poddanych wpływom eksploatacji górniczej, a także oddziaływań zblizonych do górniczych.

Badacze z Turcji opisali przypadek wpływu osiadań terenu górniczego na uszkodzenia budynków w zagłębiu węglowym Kozlu [42]. W omawianym przypadku osiadania terenu wynosiły do 7,1 m, a obszar oddziaływań obejmował powierzchnię 0,88 km². Odnotowano, że deformacje miały negatywny wpływ na wiele budynków murowanych. Znaczna część budynków została silnie uszkodzona, co spowodowało ich wyłączenie z dalszego użytkowania. We wnioskach autorzy raportu zalecili monitoring analizowanej zabudowy, przeprowadzenie obliczeń możliwych do wystąpienia osiadań, odpowiednie zabezpieczanie budynków oraz zastosowa-

nie profilaktyki górniczej w celu redukcji wielkości wpływów górniczych w dzielnicach mieszkaniowych.

Inny przypadek znacznych uszkodzeń budynków został zaobserwowany przez badaczy hiszpańskich [43, 44] w miejscowości La Unión. Osiedlenia terenu dochodziły do 0,5 m, a budynki dodatkowo poddawane były wpływom wstrząsów parasejsmicznych. Wpływy górnicze spowodowały uszkodzenia w 99 budynkach, których intensywność zwiększała się wraz z upływem czasu.

Obserwacja zachowania się konstrukcji murowanych poddanych wpływom górniczym była przedmiotem badań zaprezentowanych w [45]. Doświadczenia francuskie wskazały na możliwość powstania uszkodzeń w budynkach, co wynikało z analizy utworzonych modeli numerycznych obciążonych pionowymi przemieszczeniami. W efekcie wskazano miejsca występowania uszkodzeń oraz opisano charakter ich powstania wynikający z przekroczenia wytrzymałości na rozciąganie konstrukcji murowej.

Ocena uszkodzeń budynków była przedmiotem analiz przeprowadzonych w [46, 47]. Porównano dostępne w literaturze metody oceny stanu uszkodzeń budynków poddanych wpływom górniczym i wskazano ich różnice. Dla wybranego miasta składającego się z ponad 1500 budynków przeprowadzono analizę uszkodzeń z wykorzystaniem wybranych 5 metod, które następnie porównano z obserwacjami. Sklasyfikowano metody pod kątem największej zgodności w analizowanym przypadku.

Natomiast w publikacji [48] autorzy opisali oryginalną analizę numeryczną wpływu krzywizny terenu górniczego na wyężenie konstrukcji ścian typowego budynku w Chinach. Uzyskane wartości naprężeń w elementach ściennych porównano z wytrzymałością muru, w efekcie czego otrzymano mapy naprężeń wskazujące rejony szczególnie narażone na wystąpienie uszkodzeń.

Wybrana eksploatacja górnicza prowadzona w wielu pokładach pod terenem zabudowanym została opisana również w [49]. Przedstawiono przykładowe uszkodzenia budynków oraz sposób ich klasyfikacji. Przeprowadzono analizy numeryczne zachowania się górotworu i porównano je z wynikami geodezyjnymi. Oceniono, że w zabudowie powierzchni mogą powstać nieznaczne uszkodzenia.

Nietypowy przykład powstania deformacji nieciągłej w formie zapadliśka, także na skutek prowadzonej eksploatacji górniczej, przedstawili badacze chińscy w [50]. W efekcie podziemnej eksploatacji węgla na powierzchni terenu zaobserwowano zapadliśko o wymiarach $83 \times 45 \times 9,5$ m, które uniemożliwiło ruch autostradowy. Rozpoznano warunki gruntowe i przeprowadzono badania modelowe, które z dużą dokładnością pokazały, że przyczyną tego zdarzenia była niewystarczająca wytrzymałość warstw

piaskowca. W podsumowaniu zalecono prowadzenie dalszej eksploatacji w tym rejonie w systemie z podsadzką [16], prowadzenie wydobywania ścianami o niższej wysokości, wybieranie pokładów kilkoma warstwami lub wydobywanie tylko części złoża.

Skutki, podobne do wyżej wymienionych efektów eksploatacji górniczej, a wynikające z tunelowania, zaobserwowali Holendrzy [51]. Przeprowadzili oni analizy numeryczne z wykorzystaniem zaawansowanych modeli materiałowych dla dwóch usytuowań budynku względem osiadań od tunelowania. Dzięki tym analizom zaobserwowano i opisano różne mechanizmy powstawania uszkodzeń konstrukcji murowanych poddanych wpływom osiadania podłoża gruntowego.

Tematyka wpływu eksploatacji górniczej na uszkodzenia budynków murowanych jest popularna zarówno wśród rodzimych autorów, jak i wśród autorów zagranicznych. Spośród najnowszych polskich publikacji w tej tematyce przywołano poniżej kilkanaście wybranych pozycji.

Znacznie uszkodzone budynki mieszkalne były przedmiotem rozważań opisanych w [52]. Scharakteryzowano warunki górnicze oraz liczne poważne uszkodzenia ścian budynków. W publikacji podjęto próbę numerycznej analizy przyczyn zaobserwowanych uszkodzeń, która wykazała, że decydujące znaczenie miały odkształcenia poziome o charakterze ściskania.

Natomiast w publikacji [53] przeprowadzone zostały obliczenia numeryczne ścian murowanych z zaawansowanymi parametrami materiałowymi umożliwiającymi analizę w zakresie sprężysto-plastycznym. Oceniono zachowanie się ścian pełnych oraz ścian osłabionych otworami. Ustalono miejsca występowania uszkodzeń i ich prawdopodobny przebieg.

Przedmiotem innych analiz był wybrany budynek znacznie uszkodzony na skutek wpływów górniczych [54]. Przeprowadzono obliczenia numeryczne i analityczne dla kilku wariantów obliczeniowych, uwzględniających wykonanie dodatkowych dylatacji w konstrukcji. W podsumowaniu, jako najlepszy sposób zabezpieczenia obiektu na wpływy górnicze, zaproponowano jego podział na 4 niezależne segmenty. Rozwiązanie to miało pozwolić na znaczną redukcję sił wewnętrznych, które mogły wystąpić w konstrukcji budynku.

Ocena wpływu działalności górniczej na budynek była również przedmiotem analizy przedstawionej w [55]. Wykonano geodezyjne pomiary deformacji budynku i terenu w jego sąsiedztwie w trakcie prowadzenia podziemnej eksploatacji górniczej. Analiza numeryczna zachowania się obiektów wskazała na miejsca, w których podwyższone są naprężenia w konstrukcji murowej ścian. Zwrócono uwagę na bardzo istotny czynnik w analizie ciągów zabudowy poddanych wpływom górniczym, jakim są dylatacje i ich szerokości.

Inny przykład budynku znacznie uszkodzonego na skutek deformacyjnych wpływów górniczych przedstawiono w [56]. Opisano sytuację górnictwa i stan uszkodzeń budynku oraz podjęto się oceny wpływu eksploatacji górniczej na zaobserwowane spękania.

Natomiast w publikacji [27] opisano wpływ oddziaływań górniczych, głównie w postaci odkształceń poziomych, na stan uszkodzeń murowanych budynków mieszkalnych. Opisano i wskazano najbardziej narażone i najczęściej uszkodzane miejsca w budynkach. W celu usunięcia zaobserwowanych spękań zaproponowano działania o charakterze profilaktyki budowlanej.

Uszkodzone konstrukcje murowe były także przedmiotem artykułu [57]. Wskazano najbardziej charakterystyczne uszkodzenia spowodowane wpływami górniczymi. W celu naprawy spękań zaproponowano stosowanie polimerowego złącza podatnego, dla którego wykazano jego wysoką skuteczność.

Przedmiotem innych analiz zamieszczonych w publikacjach [58, 59] była również ocena zagrożenia budynków poddanych wpływom górniczym. W części 1. przeprowadzono przegląd krajowych i zagranicznych metod oceny możliwości uszkodzeń budynków. W części 2. dokonano analizy wyników uzyskiwanych różnymi metodami dla wybranej grupy budynków. Otrzymane wyniki porównano z rzeczywistymi danymi o uszkodzeniach i wskazano, które metody wykazały najwyższą skuteczność.

Również ocena zagrożenia budynków poddanych wpływom eksploatacji górniczej została opisana w publikacji [60]. Autorzy dysponowali danymi dotyczącymi przemieszczeń, uzyskanymi z GIS (*Geographic Information System*), informacją o odporności 421 budynków, a także wiedzą o zgłaszanych uszkodzeniach. W publikacji przedstawiono ocenę zagrożenia wystąpienia uszkodzeń budynków wynikającą z ich zbyt małej odporności. Analizy przeprowadzono z uwzględnieniem czasu występowania uszkodzeń w budynkach. Wzięto również pod uwagę zagrożenie podtopieniem budynków, które mogło wystąpić w wyniku osiadania terenu górniczego.

Inny przykład wykorzystania GIS został przedstawiony w [61]. Przeanalizowano wartości poszczególnych wskaźników deformacji górniczej i ich usytuowanie względem zabudowy o charakterze mieszkalnym. Pozytywnie oceniono skuteczność tej metody w analizie wpływów górniczych i stwierdzono, że badane budynki nie powinny ulec uszkodzeniom o charakterze konstrukcyjnym.

Ciekawy przykład zminimalizowania negatywnego wpływu eksploatacji górniczej na ważne obiekty budowlane opisano w [62], gdzie zaproponowano jedno z przykładowych rozwiązań o charakterze górniczym. Przeprowadzona analiza wykazała, że ograniczenie prędkości prowadzenia eks-

ploatacji górniczej pozwoliło na redukcję oddziaływania wpływów górniczych, w efekcie której na badanych obiektach wystąpiły tylko pojedyncze uszkodzenia o charakterze konstrukcyjnym.

Wieloletnie badania dotyczące wpływu wstrząsów górniczych na budynki zlokalizowane w Górnośląskim Zagłębiu Węglowym (GZW) zostały po raz kolejny zweryfikowane i opisane w skali GSIS-2017 [63]. Zaproponowano dodanie dwóch stopni intensywności drgań względem skali z 2012 r. Rozpatrzono wpływ wstrząsów na obiekty o konstrukcji murej, szkieletowej i prefabrykowanej. Wskazano możliwość oceny odporności dynamicznej budynków, którą uwarunkowano spodziewanymi dopuszczalnymi skutkami widocznymi w uszkodzeniach obiektów.

Podobne badania prowadzone są w Legnicko-Głogowskim Okręgu Miedziowym (LGOM), a ich najnowsze wydanie to skala GSI-2004/18 [64]. Wśród podstawowych zmian można wymienić korekty odnoszące się do uogólnionych opisów uszkodzeń oraz korektę krzywych funkcji czasu trwania pomiędzy granicami poszczególnych stopni intensywności drgań.

Wpływ wstrząsów w GZW oraz LGOM na uszkodzenia budynków został opisany również w [65]. Przedstawiono tam charakterystyki obserwowanych wstrząsów. Oceniono szkodliwość wstrząsów, wykorzystując dostępne skale GSI i SWD [66]. Ukazano charakterystyczne uszkodzenia budynków murowanych na skutek wstrząsów pochodzenia górniczego. Wpływ wstrząsów górniczych i deformacji nieciągłych w formie uskoków był natomiast przedmiotem analizy w publikacji [67]. Przedstawiono przebieg i charakterystykę wybranych uskoków. Przywołano parametry wysokoenergetycznego wstrząsu z 18 kwietnia 2015 r. i zaobserwowane po wstrząsie uszkodzenia w budynkach. Dodatkowo przeprowadzono ocenę usytuowania budynków względem uskoków w stosunku do prędkości drgań gruntu.

Wyjątkowym rodzajem budynków murowanych poddanych wpływom górniczym, które zazwyczaj objęte są indywidualnym podejściem, są obiekty o charakterze sakralnym. Z uwagi na niską sztywność przestrzenną często ulegają one uszkodzeniom. W publikacjach [68, 69] opisano przypadek uszkodzonego kościoła, który z powodu planowanej eksploatacji górniczej miał być poddany dodatkowym wpływom górniczym. W związku z powyższym zaproponowano i zrealizowano dodatkowe zabezpieczenia konstrukcji sklepień. W publikacjach [70, 71] opisano przykład innego kościoła, w stosunku do którego istniała potrzeba przeanalizowania zaobserwowanych uszkodzeń. W celu zachowania bezpieczeństwa konstrukcji i użytkowników podczas prowadzenia kolejnych eksploatacji górniczych zaproponowano szereg działań zabezpieczających. Ponadto deformacje tego obiektu precyzyjnie przedstawiono w publikacji [72].

Wpływ 77-letniej eksploatacji górniczej, również na budynki sakralne, przedstawiono w [73]. Opisano tam narastanie wpływów górniczych na podstawie pomiarów i obliczeń teoretycznych. Przedstawiono liczne uszkodzenia obiektów i sposoby ich naprawy. Przykład kolejnego kościoła znacznie uszkodzonego i wychylonego na skutek wpływów górniczych przedstawiono w [74, 75]. Dokładny opis warunków górniczych oraz stanu uszkodzeń obiektu znajdujemy w [74]. W celu usunięcia wychylenia kościoła niezbędne było wykonanie dodatkowych wzmocnień konstrukcji, które zaproponowano w kilku wariantach [75]. Wykonano jedną z koncepcji wzmocnienia, a budynek został zrektyfikowany i naprawiony.

Wpływ prowadzonej eksploatacji górniczej w LGOM na budynek kościoła został także opisany w [76]. Obiekt zabezpieczono na wpływy górnicze, wyremontowano i objęto pomiarami geodezyjnymi. Przeanalizowano wpływ oddziaływań górniczych na kościół i jego stan uszkodzeń.

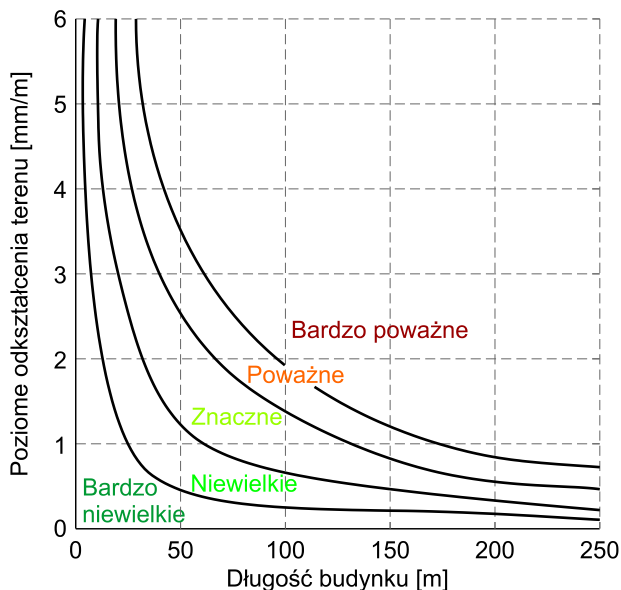
Wymienione powyżej najnowsze doświadczenia w zakresie powstawania uszkodzeń w budynkach murowanych poddanych wpływom górniczym niejednokrotnie wykorzystują opracowane wcześniej metody oceny możliwości powstania w nich uszkodzeń, które opisano w rozdziale 2.

2. PROBLEMATYKA USZKODZONYCH BUDYNKÓW PODDANYCH WPŁYWOM GÓRNICZYM

2.1. Metody oceny możliwości powstania uszkodzeń budynków na terenach górniczych

2.1.1. Metody empiryczne

Brytyjskie wytyczne oceny możliwości powstania uszkodzeń [77] uzależniają ten proces od długości budynku (ew. niedylatowanego ciągu budynków) oraz poziomych odkształceń terenu. Zrealizowane badania objęły pomiary 165 linii obserwacyjnych i pomiary zlokalizowanych przy nich obiektów budowlanych. Zależność pomiędzy długością obiektu (do 250 m) i odkształceniami poziomymi (do 6 mm/m), a spodziewanymi uszkodzeniami budynku, przedstawiono w postaci funkcji hiperbolicznej (rys. 2.1).

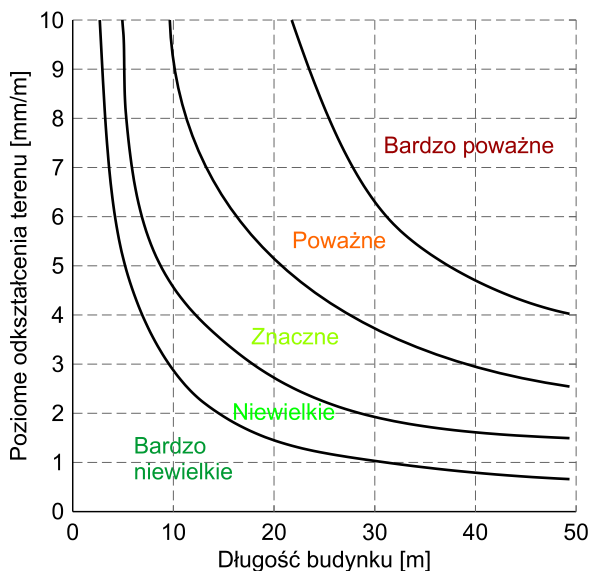


Rys. 2.1. Prognozowane kategorie uszkodzeń w zależności od poziomych odkształceń terenu i długości budynku (opracowanie własne na podstawie [77])

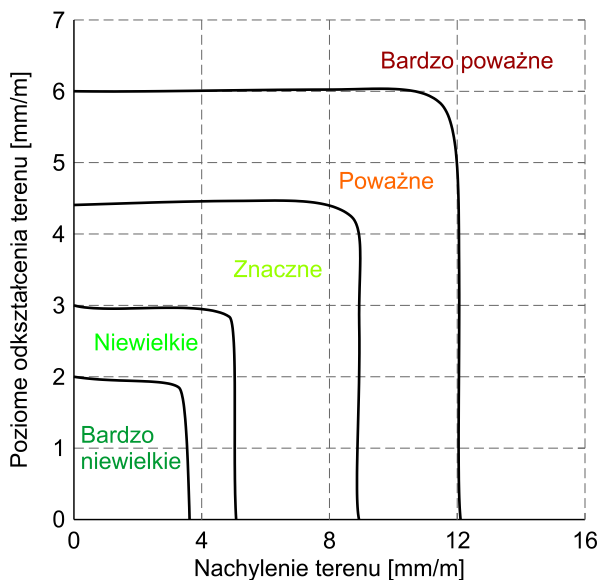
Autorzy metody opisali 5 kategorii uszkodzeń, jakie mogą powstać, od małych pęknięć niewidocznych na zewnątrz budynku, przez uszkodzenia widoczne na zewnątrz i powodujące utrudnienia w użytkowaniu, aż do uszkodzeń wymagających częściowej lub kompleksowej przebudowy obiektu.

Niestety powyższa metoda nie rozróżnia wpływu odkształceń poziomych o charakterze ściskań od odkształceń poziomych powodujących rozluźnienie podłoża budowlanego. Z uwagi na wykorzystanie zaledwie jednego parametru dotyczącego ocenianego obiektu (długości), metoda ta przysparza wiele problemów w ocenie budynków o niewielkich wymiarach rzutu poziomego, a także w przypadkach, gdy zachodzi konieczność uwzględnienia szczegółowej informacji o konstrukcji analizowanego obiektu.

Metodę zbliżoną do brytyjskiej, lecz wynikającą z doświadczeń południowoafrykańskich, przedstawili H. Wagner i E. Schümann [78]. W metodzie tej o uszkodzeniach w budynku decydują: długość obiektu (do 50 m) i odkształcenia poziome (do 10 mm/m) – rysunek 2.2. Ponadto zaobserwowano negatywny wpływ nachylenia powierzchni terenu (do 16 mm/m), które towarzyszy odkształceniom poziomym, na kategorie uszkodzeń obiektu (rys. 2.3). Granice pomiędzy poszczególnymi kategoriami uszkodzeń stanowią krzywe o kształcie przypominającym hiperbole. Spodziewane pęknięcia elementów budynku dla poszczególnych kategorii opisano analogicznie, jak dla uszkodzeń przedstawionych w [77].



Rys. 2.2. Prognozowane kategorie uszkodzeń w zależności od poziomych odkształceń terenu i długości budynku (opracowanie własne na podstawie [78])



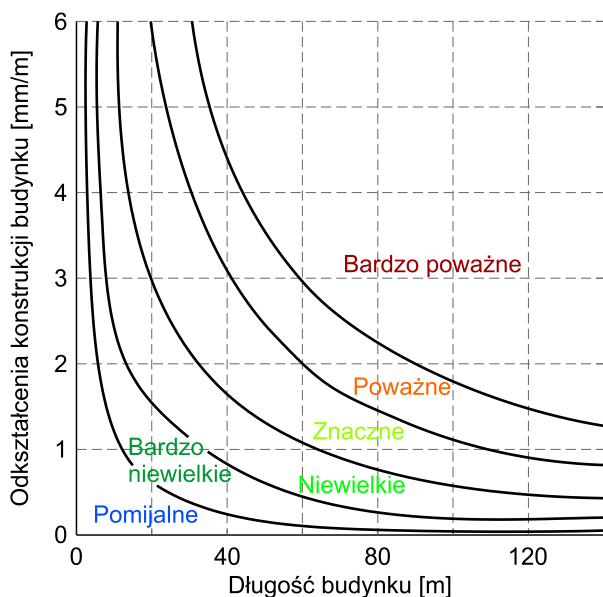
Rys. 2.3. Prognozowane kategorie uszkodzeń w zależności od poziomych odkształceń terenu i nachyleń terenu (opracowanie własne na podstawie [78])

Uwzględnienie nachyleń terenu w ocenie kategorii uszkodzeń ma znaczenie szczególnie dla obiektów wysokich. Metoda ta jest łatwiejsza do stosowania w odniesieniu do obiektów o niewielkich długościach. Niestety również w tej metodzie parametrem reprezentującym obiekt jest jedynie jego długość. Czyni to ją nieefektywną w przypadku konieczności uwzględnienia większej liczby zmiennych dotyczących konstrukcji.

Kolejną metodą empiryczną, zbliżoną do poprzednich, jest metoda zaproponowana w Australii przez MSEC [79]. Z uwagi na odmienny, lokalny charakter oddziaływań górniczych, autorzy zaproponowali wykorzystanie parametru *Structure Strain* (odkształcenia konstrukcji), który jest sumą lub różnicą poziomych odkształceń terenu ε i ilorazu H/R , tj. wysokości obiektu oraz wpływu promienia krzywizny profilu niecki górniczej. W związku z powyższym, parametrami niezbędnymi do oceny możliwych uszkodzeń budynku są: odkształcenia poziome i promień krzywizny terenu oraz wysokość i długość obiektu (rys. 2.4). Wyróżniono 6 kategorii uszkodzeń, którym, poza słownym opisem prognozowanych uszkodzeń, przypisano również spodziewane szerokości spękań (do 0,1 mm; 1 mm; 5 mm; 15 mm; 25 mm; powyżej 25 mm).

Metoda uwzględnia promień krzywizny niecki górniczej oraz wysokość budynku w wyznaczaniu kategorii uszkodzeń, a także daje możliwość prognozy szerokości rozwarcia pęknięcia elementu konstrukcyjnego. Nie-

stety znacznych trudności przysparza wykonanie dobrej i trafnej prognozy krzywizny niecki górniczej, która w wielu przypadkach mogłaby prowadzić do uzyskania wyniku niezgodnego ze stanem faktycznym. Ponadto, pomimo obserwacji autorów dotyczących odmiennego zachowania się budynków o różnych konstrukcjach, obiekt reprezentują zaledwie dwie zmienne – długość i wysokość.




Rys. 2.4. Prognozowane kategorie uszkodzeń w zależności od odkształceń konstrukcji budynku i długości budynku (opracowanie własne na podstawie [79])

Rodzimą propozycję oceny zachowania się budynku poddanego wpływom górniczym zaproponowali H. Przybyła i W. Świądrowski [5]. Uwzględniłi oni kilkanaście parametrów geometryczno-konstrukcyjnych, których różne wartości umieścili w tablicy i przypisali im odpowiednie liczby punktów. Suma uzyskanych punktów pozwalała na otrzymanie odpowiedzi, czy oceniany budynek bezpiecznie przeniesie prognozowane wpływy górnicze. Metoda ta była wielokrotnie modyfikowana i rozszerzana, a obecnie najczęściej stosowana jest metoda punktowa zaproponowana w monografii pod redakcją prof. J. Kwiatka [13].

Zaletą metody punktowej jest możliwość dokonania oceny dużej grupy budynków, które są lub będą poddane wpływom górniczym. W efekcie przeprowadzonej oceny otrzymuje się informację o niewystarczającej odporności wybranych budynków, w stosunku do których należy podjąć

działania interwencyjne w formie profilaktyki budowlanej lub górniczej. Niestety metoda ta nie pozwala na uzyskanie informacji o uszkodzeniach, które mogą wystąpić w budynku, jeśli jego odporność jest niższa od prognozowanej kategorii terenu górniczego.

Inną metodę, polegającą na klasyfikacji budynków do jednej z 4 kategorii, opracował Z. Yu [80, 81]. Na podstawie kategorii można ocenić zachowanie się budynku pod wpływem osiadań. Parametry brane pod uwagę, to: rodzaj fundamentów, materiał konstrukcji nadziemnej oraz stosunki L/R i H/L , gdzie L i H to odpowiednio długość oraz wysokość budynku, a R to promień krzywizny terenu. Dla poszczególnych charakterystyk z tabeli odczytuje się sumę punktów, która decyduje o klasie budynku. Zdefiniowano możliwość powstania uszkodzeń trzech typów, uzależnionych od klasy budynku oraz prognozowanych odkształceń poziomych terenu (rys. 2.5).




Rys. 2.5. Prognozowane kategorie uszkodzeń w zależności od odkształceń poziomych terenu i klasy budynku (opracowanie własne na podstawie [81])

Powyższa metoda uwzględnia długość i wysokość ocenianego obiektu oraz sposób jego posadowienia i materiał zastosowany do konstrukcji nadziemnej. Niestety metoda ta wymaga prognozowania promienia krzywizny terenu górniczego, a możliwość powstania uszkodzeń architektonicznych i funkcjonalnych dopuszcza tylko w budynkach zaliczonych do 1 klasy.

2.1.2. Metody analityczne

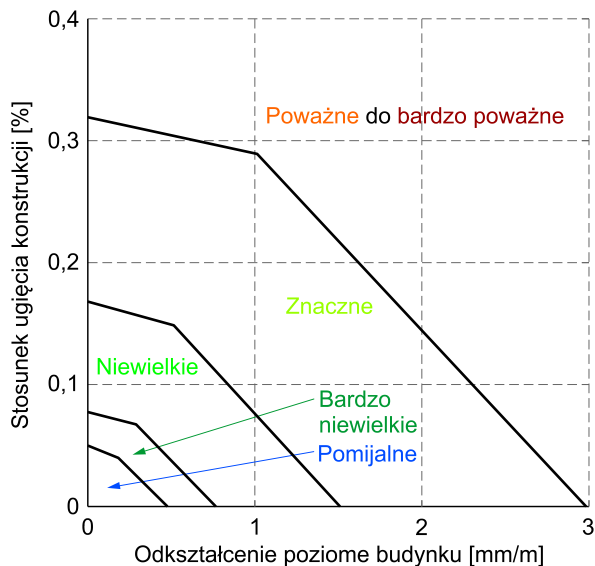
Alternatywne podejście do oceny ryzyka uszkodzenia budynków zaprezentowali amerykańscy badacze M. Boscardin i E. Cording [82]. Przeprowadzili oni analizę obiektów budowlanych, sprowadzonych do schematu statycznego belki o znanych parametrach wytrzymałościowo-geometrycznych. Obliczenia analityczne zostały zweryfikowane na podstawie 18 obiektów różnej konstrukcji i wysokości, poddanych obciążeniom wynikającym z dodatkowego osiadania. Klasyfikację uszkodzeń do jednej z pięciu kategorii uzależnili od dwóch zmiennych: odkształcenia poziomego obiektu ε_h i odkształcenia kąowego β (rys. 2.6).



Rys. 2.6. Prognozowane kategorie uszkodzeń w zależności od odkształcenia poziomego budynku i odkształcenia kąowego (opracowanie własne na podstawie [82])

Zaproponowana metoda wykazała wysoką skuteczność w przypadku obiektów o różnej konstrukcji – murowanej ścianowej, szkieletowej stalowej, szkieletowej drewnianej. Dodatkową zaletą jest uwzględnianie przez model podstawowych parametrów geometrycznych (długość, wysokość) oraz wytrzymałościowych (moduł odkształcenia, moduł ścinania). Niestety stosowanie tej metody bazuje na wiedzy o trudnych do jednoznacznego ustalenia w warunkach *in situ* parametrach materiałowych, a także wymaga sprowadzenia przestrzennego obiektu budowlanego do belkowego schematu statycznego, co może być mało efektywne w przypadku skomplikowanych obiektów.

Podobne badania, polegające na sprowadzeniu budynku do postaci belki, realizowali naukowcy brytyjscy R. Mair i inni [83]. Zaproponowali oni skalę w sześciu kategoriach uwzględniających łatwość naprawy uszkodzeń budynków. Parametrami determinującymi powstanie uszkodzeń są odkształcenia poziome budynku oraz stosunek ugięcia konstrukcji Δ/L , gdzie Δ to maksymalne względne osiadanie, a L to długość belki. Przykładowy wykres dla tej metody przedstawiono na rysunku 2.7.

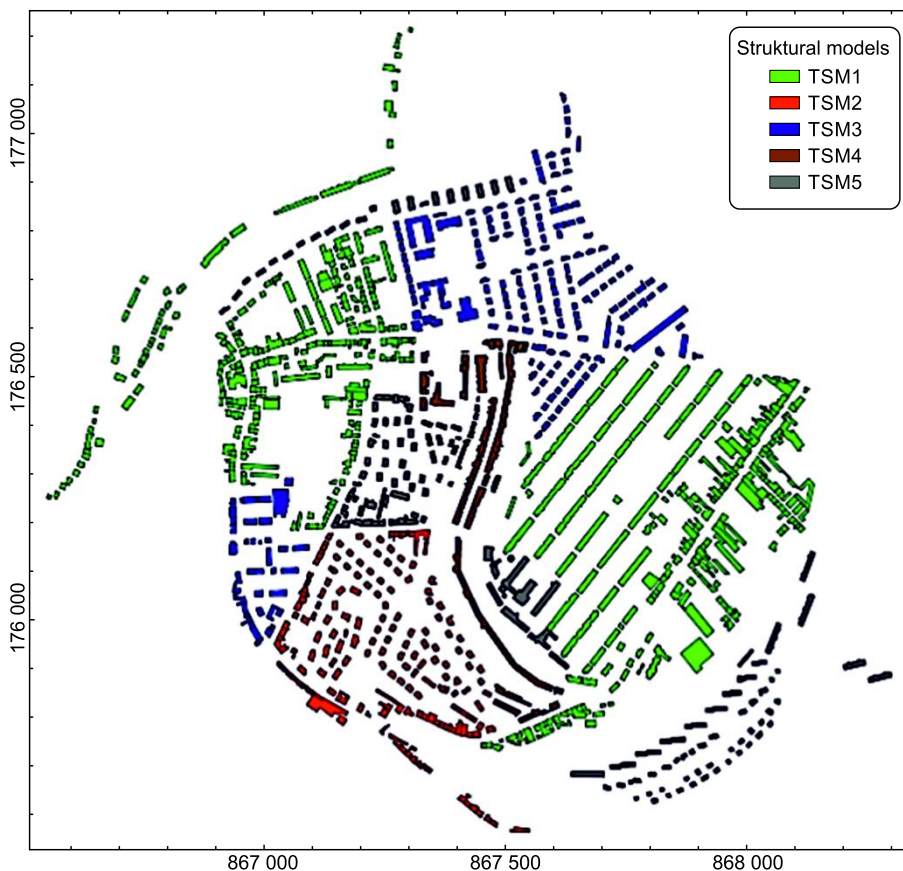


Rys. 2.7. Prognozowane kategorie uszkodzeń w zależności od stosunku ugięcia konstrukcji i odkształcenia poziomego budynku (opracowanie własne na podstawie [83])

Zasadniczą zaletą metody brytyjskiej jest uwzględnianie przez model parametrów geometrycznych, takich jak: długość, wysokość, moment bezwładności belki oraz wytrzymałościowych – modułów odkształcenia i ściana. Wady tej metody są podobne do tych dotyczących metody amerykańskiej [82].

2.1.3. Metody numeryczne

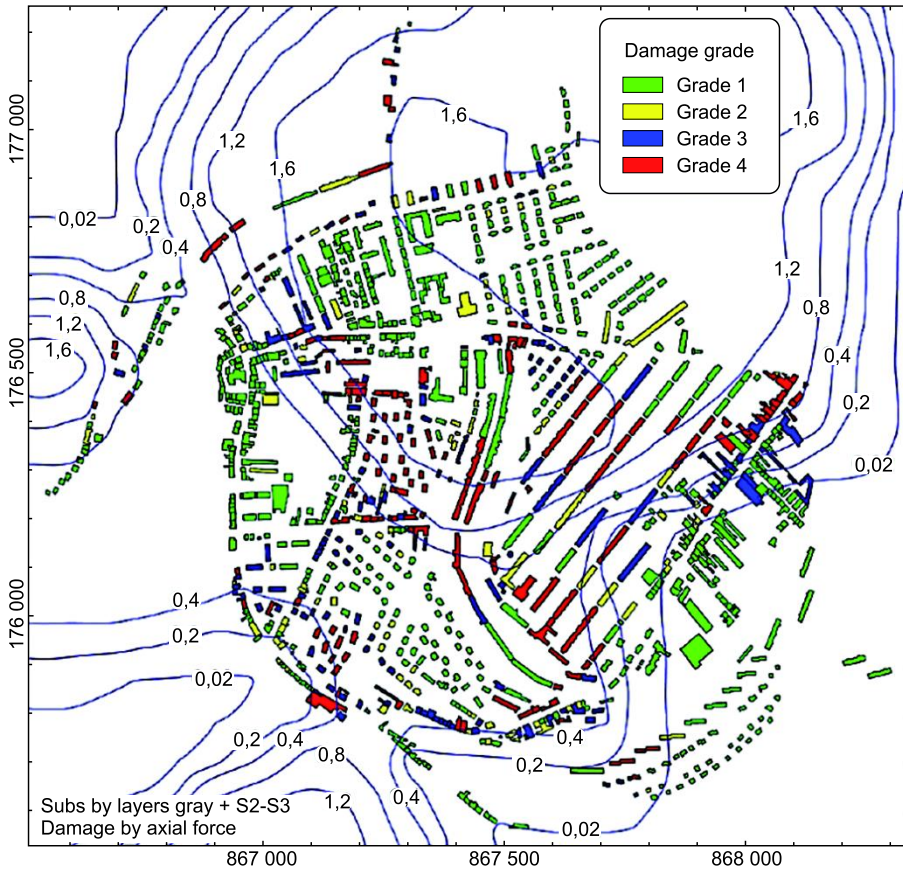
Nowsze podejście z wykorzystaniem obliczeń numerycznych zaprezentowali badacze francuscy Y. Cai, A. Saeidi i inni [84, 85]. Na podstawie przeprowadzonej analizy zabudowy miasta Joeuf (rys. 2.8) wyznaczyli oni 5 typów konstrukcji (od TSM 1 do TSM 5), które zamodelowali w postaci układów prętowych.



Rys. 2.8. Zabudowa miasta Joeuf z podziałem na typy budynków [85]

Dla wyznaczonych wartości osiadań terenu górniczego przeprowadzili oni analizę naprężeń w modelach numerycznych MES. Na podstawie uzyskanych wyników wytypowano 4 kategorie uszkodzeń, które wynikają z sił wewnętrznych w elementach konstrukcji analizowanych obiektów. Przykład zakwalifikowania do kategorii uszkodzeń przedstawiono na rysunku 2.9.

Zaproponowana została metodyka przewidywania uszkodzeń budynków, która uzależniona jest od sił występujących w utworzonych modelach numerycznych. Niestety autorzy nie dokonali generalizacji uzyskanych wyników badań, tak aby można było je wykorzystać również w przypadku innej zabudowy.



Rys. 2.9. Przewidywane kategorie uszkodzeń wynikające z sił osiowych w konstrukcji obiektów dla wyznaczonych wartości osiadań [m] wg [85]

Z kolei badacze chińscy H. Hu i inni [86] przeprowadzili analizę typowych budynków o konstrukcji murowej, które ulegają uszkodzeniu głównie na skutek krzywizny terenu górniczego. Zbudowano dwa modele deformacji ścian, uwzględniające wpływ krzywizny wypukłej i wklęsłej. W połączeniu z przyjętym mechanizmem przewidywania uszkodzeń pozwoliło to na wyznaczanie szerokości pęknięcia powstałego na skutek wpływów górniczych. Zaproponowano podział uszkodzeń na 4 kategorie: od A dla niewielkich uszkodzeń (o rozwarości 1 – 2 mm) do D dla poważnych uszkodzeń (o rozwarości powyżej 20 mm). Ustalono, że dla wypukłej krzywizny niecki górniczej uszkodzenia konstrukcji murowej są w kształcie litery „V”, a kąt z linią poziomą wynosi od 61° do 66°. Natomiast dla wklęsłej niecki górniczej uszkodzenia konstrukcji murowej są w kształcie „Λ”, a kąt z linią poziomą wynosi około 53°.

Utworzone modele pozwalają na wyznaczenie rozwartości uszkodzeń dla dowolnej geometrii ściany poddanej określonym wpływom eksploatacji górniczej. Niestety dotyczą one tylko ścian, a nie całych budynków, a wpływy górnicze ograniczają się do krzywizny terenu górniczego, przez co zaproponowane rozwiązanie nie jest w pełni uniwersalne.

Powyżej wymieniono i krótko opisano dostępne metody służące do oceny możliwości powstania uszkodzeń. Znajdują się wśród nich metody empiryczne, analityczne i numeryczne. W ostatnich latach natomiast obserwuje się coraz większe zainteresowanie badaczy metodami wykorzystującymi inteligencję obliczeniową w rozwiązywaniu zagadnień dotyczących budownictwa na terenach górniczych.

2.2. Doświadczenia ze stosowania metod inteligencji obliczeniowej w budownictwie na terenach górniczych

2.2.1. Tereny górnicze

Przykład wykorzystania jednej z metod inteligencji obliczeniowej w zagadnieniu dotyczącym terenów górniczych został opisany w [87], gdzie autorka zastosowała metodę wektorów podtrzymujących (SVM – *Support Vector Machine*). W badaniach analizowano przemieszczenia pionowe terenu górniczego, bazując na wynikach pomiarów geodezyjnych dla 218 punktów referencyjnych, powiązanych ze sobą 302 obserwacjami. W przeprowadzonych badaniach sprawdzano radialne oraz liniowe funkcje jąder, a także wpływ wartości parametru regularizacyjnego C na wyniki klasyfikacji. Najkorzystniejsze wyniki klasyfikacji otrzymano z zastosowaniem jądra radialnego o dużej wartości parametru regularizacyjnego C wynoszącej 1000.

Zagadnienie zagrożenia wystąpienia osiadań terenu górniczego była analizowane również przez badaczy koreańskich H.-J. Oh i S. Lee [88]. W celu oceny zagrożenia zebrali dane o przestrzennym zachowaniu się terenu górniczego, relacjach pomiędzy osiadaniem i siedmioma wybranymi wskaźnikami. Dane pozwoliły im na przeprowadzenie analizy w oparciu o cztery niezależne modele, tj.: wskaźnika częstotliwości (FR – *frequency ratio*), sztucznych sieci neuronowych (ANN – *Artificial Neural Networks*), prawdopodobieństwa Bayesa (WoE – *Weight of Evidence*) oraz regresji logistycznej (LR – *logistic regression*). Uzyskane wyniki umożliwiły sporządzenie map oraz wyznaczenie wskaźników zagrożenia osiadaniem gruntu, których dokładność wyniosła ponad 94%.

Inny przykład zastosowania sztucznych sieci neuronowych do modelowania deformacji górniczych został przedstawiony w [89]. Sieci neuronowe wykorzystano bezpośrednio przy modelowaniu obniżen terenu gór-

niczego. Do badań wykorzystano 14 pomiarowych linii obserwacyjnych. Wyniki 11 linii pomiarowych, zawierających dane z 481 punktów, służyły do trenowania i walidacji sieci, natomiast dane z pozostałych 3 linii pomiarowych, zawierających 95 punktów, służyły do testowania modelu. Uzyskane wyniki charakteryzowały się wysoką dokładnością aproksymacji wskaźników deformacji, dokładnością wyższą niż przy zastosowaniu oryginalnej metody S. Knothego [17].

Sztuczne sieci neuronowe są wykorzystywane także do prognozy zagrożenia sejsmicznego [90]. Dla wybranego terenu górniczego i danych o czasoprzestrzennym przebiegu eksploatacji górniczej obliczono zmiany energii właściwej odkształcenia sprężystego, które posłużyły do przygotowania sieci neuronowej. W kolejnym etapie przeprowadzono prognozę wartości wydatku energetycznego wstrząsów dla innej eksploatacji górniczej, którą porównano z wartościami obserwowanymi. Zgodnie z ustaleniami podanymi przez autorów, uzyskane w toku badań wyniki wskazały na zasadność stosowania tej metodologii do prognozy takich zjawisk.

Również w kwestii obiektów budowlanych, stanowiących zabudowę terenu górniczego, można znaleźć liczne przykłady uzasadniające stosowanie zaawansowanych metod zaliczanych do inteligencji obliczeniowej.

2.2.2. Uszkodzenia budynków

Przykład wykorzystania zbiorów rozmytych do oceny uszkodzeń budynków poddanych wpływom eksploatacji górniczej został opisany w rozprawie [91]. Uwzględniając czynniki górnicze i wykorzystując regresyjną aproksymację stopnia uszkodzeń, kwalifikowano przyjęte miary uszkodzeń do pięciu zbiorów rozmytych, które wyrażały oceny lingwistyczne przyznawane przez ekspertów.

Z wykorzystaniem podobnego eksperckiego systemu rozmytego w pracy [92] podjęto próbę szacowania wskaźnika zagrożenia uszkodzeniami budynków zlokalizowanych na terenach górniczych. Badanie uwzględniało dane z ponad 1000 budynków. Zaproponowana została nowa punktowa skala zagrożeń, która uwzględniała wpływ ciągłych deformacji terenu górniczego oraz odporność obiektu na oddziaływania górnicze.

Natomiast w monografii [93] utworzono model opisujący przebieg zużycia technicznego budynków na terenach górniczych, przyjmując go za miarę tzw. szkód górniczych. W tym celu wykorzystano systemy wnioskowania rozmytego typu MISO (*Multiple Input Single Output*) oraz metodę SVM. Badania przeprowadzono dla zbioru 1726 budynków. Uzyskano wyniki dotyczące wpływu poszczególnych zmiennych wejściowych, a także ustalono optymalny zestaw zmiennych, pozwalających na opis przebiegu zużycia technicznego budynków. Analizy przeprowadzono z uwzględnie-

niem niepewności, jaka może wystąpić w trakcie oceny stanu technicznego budynków.

Oceny podobnej do zużycia technicznego, a dotyczącej wskaźnika intensywności uszkodzeń, podjął się zespół badaczy z AGH [33, 94]. Na podstawie zgromadzonych wieloletnich danych o uszkodzeniach budynków poddanych wpływowi eksploatacji górniczej oraz korzystając z metody cząstkowych najmniejszych kwadratów w ujęciu regresyjnym (PLSR – *Partial Least Squares Regression*), wyznaczono wskaźniki intensywności uszkodzeń dla poszczególnych typów budynków. Uzyskane wyniki potwierdziły zasadność stosowania metody PLSR do wstępnej analizy zgromadzonych danych. Stwierdzono istotną statystycznie korelację pomiędzy wskaźnikami uszkodzeń wyznaczonymi dla poszczególnych budynków, a wpływami górniczymi reprezentowanymi przez odkształcenia poziome ϵ i wskaźnik wpływów dynamicznych [95].

W celu oceny wskaźnika intensywności uszkodzeń dla budynków prefabrykowanych poddanych wpływowi górniczym, w ramach odrębnych badań wykorzystano sieć Bayesa (BN – *Bayesian Network*) [96–98]. Przeprowadzone analizy wykazały wysoką skuteczność sieci z dokładnością przekraczającą 85% w przewidywaniu wskaźnika intensywności uszkodzeń budynków. Zaprezentowano również możliwość zastosowania sieci do diagnozy przyczyn zaobserwowanych uszkodzeń.

Z kolei wpływ wstrząsów górniczych na budynki był przedmiotem publikacji [40]. Zastosowano tam Probabilistyczne Sieci Neuronowe (PNN – *Probabilistic Neural Network*), wykorzystując dane o około 500 budynkach i kilku zmiennych geometryczno-konstrukcyjnych. Dla przygotowanych sieci uzyskano dokładność klasyfikacji na poziomie 70% – 75%. Zaprezentowano możliwość zastosowania modelu do oceny prawdopodobieństwa wystąpienia uszkodzenia na skutek wysokoenergetycznego wstrząsu w budynku o zadanej konstrukcji.

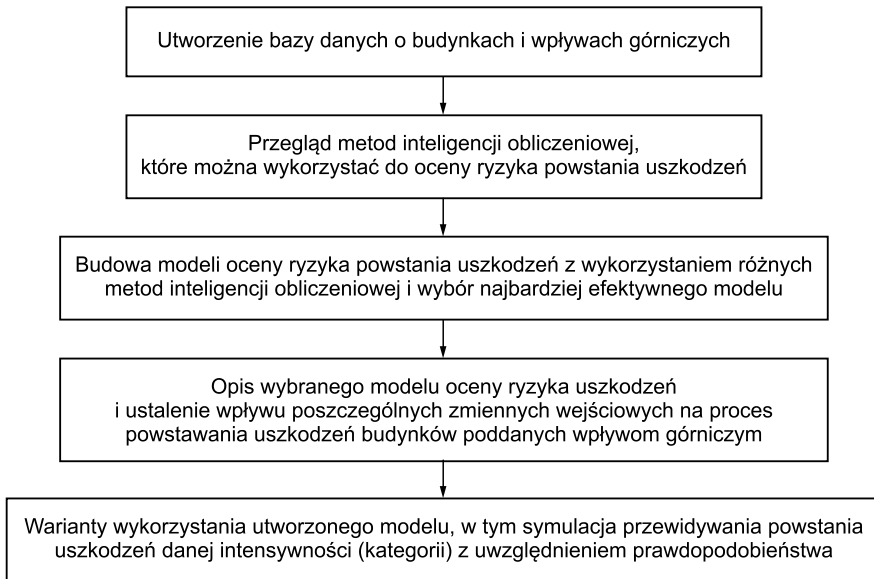
Szerszy opis powyższych badań znajduje się w monografii [41]. Wykorzystując metody inteligencji obliczeniowej (m.in. SVM i PNN), przedstawiono tam wyniki analizy wpływu wstrząsów górniczych na uszkodzenia budynków. Utworzono model oceny ryzyka wystąpienia szkody górniczej, model pozwalający na prognozowanie wartości wskaźnika uszkodzeń oraz model pozwalający na oszacowanie nakładów finansowych niezbędnych do naprawy szkód górniczych.

2.3. Wnioski z analizy źródeł literaturowych

Przeprowadzona w rozdziale 2.1 i 2.2 analiza źródeł literaturowych wykazała, że powstawanie uszkodzeń w budynkach murowanych jest problemem aktualnym w wielu krajach, w których prowadzona jest eksploa-

tacja kopalnin. Obecnie stosowane sposoby oceny możliwości powstania uszkodzeń budynków są wartościowe, lecz nie pozwalają na ocenę ryzyka powstania uszkodzeń z uwzględnieniem prawdopodobieństwa. Metodami, które mogą umożliwić przeprowadzenie takiej oceny, są metody inteligencji obliczeniowej.

W związku z powyższym, aby zrealizować założone w monografii cele badawcze, przyjęto następujący schemat postępowania (rys. 2.10).



Rys. 2.10. Przyjęty w badaniach schemat postępowania do oceny ryzyka powstania uszkodzeń budynków na terenach górniczych

3. CHARAKTERYSTYKA UTWORZONEJ BAZY DANYCH

3.1. Uwagi ogólne

Spełnienie postawionych celów badawczych wymagało na wstępie zgromadzenia danych o zachowaniu się obiektów poddanych wpływom eksploatacji górniczej. Najbardziej istotnym czynnikiem były zaobserwowane uszkodzenia w budynkach przed podjęciem eksploatacji i aktualizacja uszkodzeń po jej zakończeniu. Pozwoliło to na przeprowadzenie oceny, czy powstały nowe uszkodzenia lub czy zinwentaryzowane wcześniej uszkodzenia nie uległy powiększeniu (intensyfikacji).

W celu budowy bazy danych przeprowadzono przegląd 10 prac badawczo-rozwojowych zrealizowanych w Instytucie Techniki Budowlanej przy współudziale autora monografii. Dotyczyły one oceny możliwości prowadzenia eksploatacji górniczej w aspekcie ochrony powierzchni wybranych kopalń GZW w latach 2011 – 2017. W toku przeprowadzonych prac analizą objęto grupę 450 budynków w Bytomiu oraz 350 budynków w Rudzie Śląskiej. Następnie podjęto decyzję o przyjęciu do badań grupy budynków, w stosunku do których wykonane były co najmniej dwie oceny stanu uszkodzeń, pomiędzy którymi prowadzona była eksploatacja górnicza oddziałująca na wyodrębnioną zabudowę. Na tej podstawie wyselekcjonowano grupę 207 budynków spełniających powyższy warunek, zlokalizowanych w Bytomiu. Następnie przeprowadzono prace terenowe, w trakcie których zebrano informacje o zabudowie, które finalnie zgromadzono w bazie danych.

3.2. Charakterystyka badanej zabudowy

Terenowe prace badawcze dla wybranej grupy budynków dotyczyły określenia m.in. parametrów geometrycznych, zastosowanych rozwiązań konstrukcyjnych, występujących zabezpieczeń na wpływy górnicze oraz zakresu i intensywności istniejących uszkodzeń.

Widok zabudowy na mapie sytuacyjno-wysokościowej został przedstawiony poglądowo na rysunku 3.1.

Budynki mieszkalne wielorodzinne o konstrukcji tradycyjnej wzniesione zostały od końca XIX w. do lat czterdziestych XX w. Zostały realizowane w zabudowie zwartej, półzwartej oraz jako wolno stojące, całkowicie lub częściowo podpiwniczone. Obiekty wzniesione zostały jako dwu-, trzy- lub czterokondygnacyjne.



*Rys. 3.1. Fragment mapy sytuacyjno-wysokościowej z widoczną lokalizacją
przebadanych budynków (opracowanie własne)*

Posadowienie zrealizowano zazwyczaj jako bezpośrednie na fundamentach kamiennych lub ceglanych. Ściany w poziomie kondygnacji piwnic wykonano z kamienia lub cegły, natomiast ściany wyższych kondygnacji zazwyczaj z cegły. Stropy nad piwnicami są w przeważającej części odcinkowe na belkach stalowych, rzadziej w postaci sklepień. Sporadycznie

zaobserwowano występowanie stropu betonowego na belkach stalowych. W poziomach kondygnacji nadziemnych wykonano stropy drewniane, odcinkowe w klatkach schodowych i sporadycznie betonowe na belkach stalowych. Zdecydowana większość nadproży drzwiowych i okiennych jest ceglana o łukowym lub płaskim kształcie. Konstrukcja schodów w obrębie klatek schodowych wykonana jest z reguły jako drewniana lub stalowa, rzadziej betonowa.

Większość analizowanych budynków została zabezpieczona na wpływy eksploatacji górniczej w trakcie ich użytkowania. Takie wzmocnienie polegało na całkowitym bądź częściowym skotwieniu budynków stalowymi prętami w poziomach stropów.


Budynki jednorodzinne mają charakter zabudowy niskiej o wysokości do dwóch kondygnacji nadziemnych. Budynki te zostały wzniesione do 2017 r. w technologii tradycyjnej murowanej, z reguły jako wolno stojące lub w zabudowie półzwartej.

Konstrukcja budynków jednorodzinnych jest bardziej zróżnicowana i wynika z okresu ich wznoszenia. Starsze obiekty zostały wzniesione na fundamentach z kamienia i/lub z cegły, a nowsze na fundamentach żelbetonowych. Ściany piwnic wykonano z kamienia lub cegły, a w późniejszym okresie z bloczków betonowych. Ściany nadziemia murowano z cegły lub z pustaków betonowych, bądź ceramicznych. Nad kondygnacją piwniczną starszych obiektów wykonano zazwyczaj stropy odcinkowe, betonowe na belkach stalowych lub żelbetowe. Na wyższych kondygnacjach budynków znajdują się stropy drewniane, betonowe na belkach stalowych, gęstożebrowe lub żelbetowe. Stropy nowszych budynków są żelbetowe bądź gęstożebrowe. Nadproża otworów okiennych i drzwiowych są ceglane o łukowym lub płaskim kształcie, miejscami na płaskownikach stalowych lub żelbetowe w budynkach nowych.

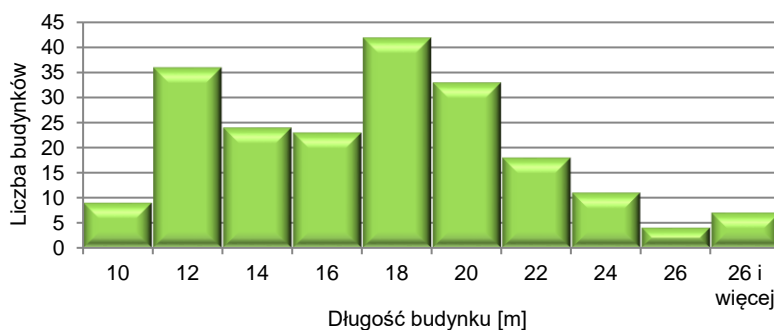
Zabezpieczenie większości starszych budynków jednorodzinnych było zrealizowane w fazie ich użytkowania przez zastosowanie skotwienia w poziomie stropów. Wyróżnić można również budynki, dla których w poziomie fundamentów wykonano obwodową opaskę żelbetową. Obiekty nowsze wykonano z zabezpieczeniem na III lub IV kategorię terenu górniczego z dodatkowo zbrojonymi żelbetowymi ławami i ściągami, stropami gęstożebrowymi lub płytowymi oraz stropami z obwodowymi wieńcami żelbetowymi.

W przygotowanej bazie danych nie znalazły się informacje dotyczące warunków gruntowych, jakie występują w miejscach lokalizacji budynków. Zebranie takich danych wymagałoby wykonania wielu otworów geotechnicznych, co niestety wiązałoby się z wysokimi kosztami i czasochłonnością prac.


Na rysunkach 3.2 – 3.17 przedstawiono przykładowe rozkłady zgromadzonych danych w postaci histogramów (rys. 3.2 – 3.7) i wykresów kołowych (3.8 – 3.17). Kategoryzację poszczególnych zmiennych i ich opis zamieszczono w załączniku 1.




Rys. 3.2. Liczbowy rozkład danych dla zmiennej dotyczącej roku budowy budynków




Rys. 3.3. Liczbowy rozkład danych dla zmiennej dotyczącej długości budynków [m]




Rys. 3.4. Liczbowy rozkład danych dla zmiennej dotyczącej szerokości budynków [m]




Rys. 3.5. Liczbowy rozkład danych dla zmiennej dotyczącej pola powierzchni budynków [m²]




Rys. 3.6. Liczbowy rozkład danych dla zmiennej dotyczącej kubatury budynków [m³]




Rys. 3.7. Liczbowy rozkład danych dla zmiennej dotyczącej liczby kondygnacji




Rys. 3.8. Liczbowy rozkład danych dla zmiennej dotyczącej podpiwniczenia




Rys. 3.9. Liczbowy rozkład danych dla zmiennej dotyczącej rodzaju fundamentów




Rys. 3.10. Liczbowy rozkład danych dla zmiennej dotyczącej materiału ścian piwnic



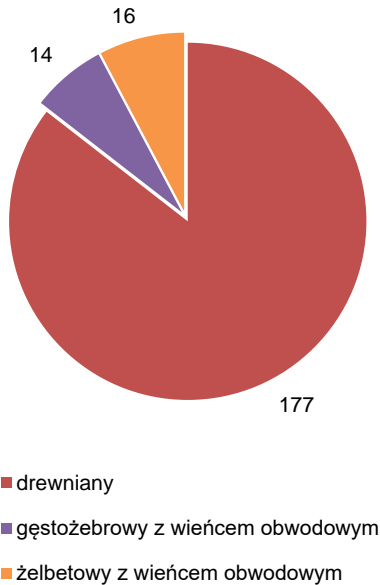
Rys. 3.11. Liczbowy rozkład danych dla zmiennej dotyczącej materiału ścian parteru i wyższych kondygnacji



Rys. 3.12. Liczbowy rozkład danych dla zmiennej dotyczącej kształtu bryły



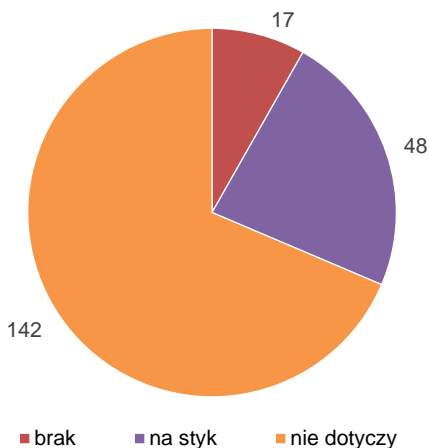
Rys. 3.13. Liczbowy rozkład danych dla zmiennej dotyczącej stropu nad piwnicą



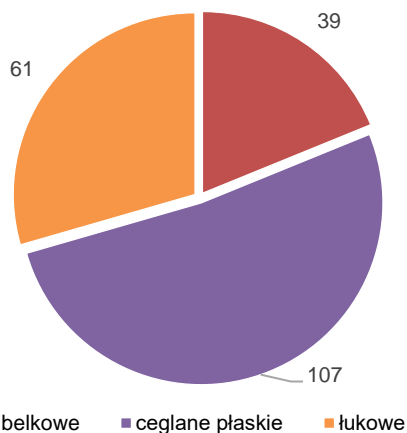
Rys. 3.14. Liczbowy rozkład danych dla zmiennej dotyczącej stropu nad parterem i wyżej



Rys. 3.15. Liczbowy rozkład danych dla zmiennej dotyczącej zabezpieczenia na wpływy górnicze



Rys. 3.16. Liczbowy rozkład danych dla zmiennej dotyczącej dylatacji z sąsiednimi budynkami



Rys. 3.17. Liczbowy rozkład danych dla zmiennej dotyczącej nadproży okiennych i drzwiowych

3.3. Uszkodzenia budynków

Badania stanu uszkodzenia budynków, uwzględniające ich zakres i intensywność oraz zagrożenie dla bezpieczeństwa konstrukcji i użytkowników, pozwoliły na sklasyfikowanie każdego przypadku do jednej z czterech kategorii [31].

Opis przyjętych kategorii uszkodzeń budynków wygląda następująco:

1. kategoria uszkodzeń – brak uszkodzeń o charakterze konstrukcyjnym, możliwe jest występowanie uszkodzeń w postaci nieznacznych zarysowań tynków ścian i stropów.

2. kategoria uszkodzeń – uszkodzenia o większej intensywności w elementach niekonstrukcyjnych oraz w elementach wykończeniowych, takie jak zarysowanie lub/i lokalne odspojenia podsufitek stropowych, okrojenia tynków stropów i ścian, zarysowania tynków ścian elewacyjnych i ścian wewnętrznych.

3. kategoria uszkodzeń – uszkodzenia w elementach konstrukcyjnych, których zakres, intensywność i lokalizacja w przypadku oddziaływania dalszych wpływów deformacji podłoża mogą doprowadzić do lokalnej utraty nośności lub stateczności elementów konstrukcji.

4. kategoria uszkodzeń – uszkodzenia zagrażające lokalnej nośności elementów konstrukcji (w niektórych z nich podjęto już doraźne prace zabezpieczające), lub budynki, w których występuje duże naturalne zużycie elementów konstrukcyjnych, przejawiające się rozległą i zaawansowaną erozją murów lub betonu oraz zbrojenia.

Przyjęte kategorie uszkodzeń budynków stanowiły zasadnicze kryterium akceptacji ryzyka omawianego w rozdziale 1.3.

Przykładowe, a jednocześnie reprezentatywne formy uszkodzeń dla poszczególnych kategorii, zostały przedstawione na rysunkach 3.18 – 3.21.



Rys. 3.18. Przykład uszkodzenia w budynku zakwalifikowanym do 1. kategorii uszkodzeń



Rys. 3.19. Przykład uszkodzenia w budynku zakwalifikowanym do 2. kategorii uszkodzeń




Rys. 3.20. Przykład uszkodzenia w budynku zakwalifikowanym do 3. kategorii uszkodzeń



Rys. 3.21. Przykład uszkodzenia w budynku zakwalifikowanym do 4. kategorii uszkodzeń

Rozkład intensywności uszkodzeń według przyjętej kategoryzacji dla grupy budynków badanej w latach 2011 – 2017 przedstawiono na rysunku 3.22.



Rys. 3.22. Liczbowy rozkład danych dla zmiennych dotyczących kategorii uszkodzeń budynków ustalonych podczas inwentaryzacji w latach 2011 – 2017

3.4. Oddziaływania górnicze w rejonie badanej zabudowy

Badana zabudowa poddawana była wpływom eksploatacji górniczej od 1937 r. w 18 warstwach, głównie systemem z zawalem stropu, a maksymalne pomierzone obniżenia terenu od 1965 r. wyniosło 22,1 m.


W okresie prowadzonych badań, czyli w latach 2011 – 2017, przedmiotowa zabudowa poddana była wpływom eksploatacji górniczej prowadzonej systemem z zawalem stropu, której charakterystyczne parametry zestawiono w tabelicy 3.1.

Tablica 3.1. Podstawowe parametry eksploatacji górniczej przeprowadzonej w obszarze badań

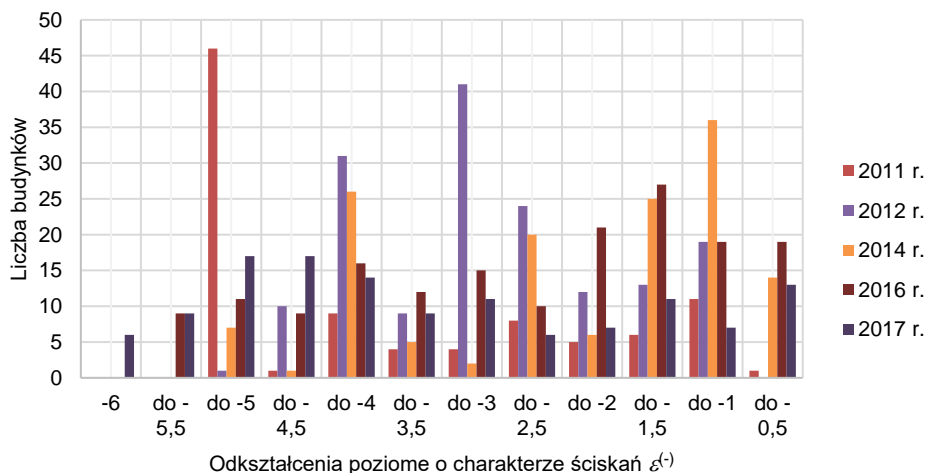
Pokład	Ściana	Wysokość [m]	Głębokość [m]	Okres prowadzenia eksploatacji
503	4	2,6 – 3,3	625 – 720	2011 – 2013
510wg	30a i 31a	2,0 – 2,4	725 – 805	2013 – 2015
503	5 i 6	2,0 – 2,3	670 – 680	2015 – 2017

W trakcie budowania bazy danych zebrano informacje dotyczące wpływu poziomych odkształceń terenu od dokonanej eksploatacji górniczej

na przedmiotowe obiekty. Liczba budynków, na które oddziaływały odkształcenia poziome o charakterze rozciągania $\varepsilon^{(+)}$, wraz z podaniem ich wartości z dokładnością do 0,5 mm/m, została przedstawiona na rysunku 3.23. Natomiast liczba budynków, na które oddziaływały odkształcenia poziome o charakterze ściskań $\varepsilon^{(-)}$ została przedstawiona na rysunku 3.24.

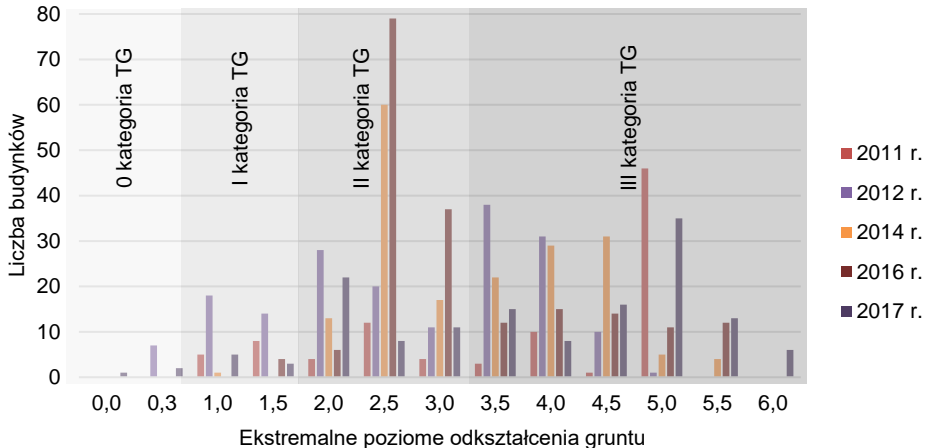


Rys. 3.23. Liczbowy rozkład danych dotyczących wpływu odkształceń poziomych o charakterze rozciągania $\varepsilon^{(+)}$ [mm/m] w latach 2011 – 2017



Rys. 3.24. Liczbowy rozkład danych dotyczących wpływu odkształceń poziomych o charakterze ściskań $\varepsilon^{(-)}$ [mm/m] w latach 2011 – 2017

Na podstawie zgromadzonych informacji o wpływach odkształceń poziomych ustalono wynikające z nich kategorie terenu górniczego (tabl. 1.1) i przedstawiono na rysunku 3.25.



Rys. 3.25. Liczbowy rozkład danych dotyczących wpływu ekstremalnych odkształceń poziomych [mm/m] w latach 2011 – 2017

Pominięcie w przeprowadzonych badaniach wpływu krzywizny terenu K oraz nachyleń T wynika z charakteru przedmiotowej zabudowy, która obejmowała budynki o niewielkich wymiarach rzutu poziomego oraz wysokości do 15 m. Ponadto, prognozowane wartości krzywizny terenu charakteryzowały się wartościami niższymi o co najmniej jedną kategorię terenu górniczego od kategorii wynikającej z odkształcenia poziomego. Zgodnie z literaturą dotyczącą budynków wychylonych, której przegląd znajduje się w [24], pomierzone w analizowanych obiektach wychylenia nie miały wpływu na ich stan uszkodzeń, w związku z czym pominięto ich znaczenie. Pominięto również wpływ wstrząsów generowanych eksploatacją górniczą z uwagi na ich wartości przyspieszeń nieprzekraczające $a = 300 \text{ mm/s}^2$ i prędkości nieprzekraczające $v = 12 \text{ mm/s}$. Takie parametry wstrząsów górniczych pozwalają na sklasyfikowanie ich do I stopnia w skali GSIS-2017 [63], które traktowane są jako *całkowicie nieszkodliwe dla wszystkich elementów konstrukcyjnych oraz niekonstrukcyjnych budynków*.

Zgromadzone w bazie danych liczne informacje o budynkach, intensywności i zakresie uszkodzeń oraz wpływach górniczych stanowiły podstawę do dalszych badań z wykorzystaniem wyselekcjonowanych metod inteligencji obliczeniowej.

4. CHARAKTERYSTYKA METOD INTELIGENCJI OBLICZENIOWEJ

4.1. Podstawy metodyczne dotyczące inteligencji obliczeniowej

Inteligencja obliczeniowa (*CI – Computational intelligence*) obejmuje teorię i metody rozwiązywania problemów, które nie mogą być efektywnie zalgorytmizowane przez człowieka [99]. Popularnymi metodami rozwiązywania takich zagadnień są np.: sztuczne sieci neuronowe (*ANN – Artificial Neural Networks*), algorytmy ewolucyjne (*EA – Evolutionary Algorithm*), metody wektorów podtrzymujących (*SVM – Support Vector Machine*), wnioskowanie rozmyte (*ANFIS – Adaptive Neuro-Fuzzy Inference System*).

Grupę metod CI można podzielić na 4 kategorie w kontekście zastosowanego podejścia do uczenia [35]:

- uczenie nadzorowane (*Supervised Learning*); dane uczące przekazywane algorytmowi zawierają rozwiązania problemu,

- uczenie nienadzorowane (*Unsupervised Learning*); dane uczące są nieoznakowane, a system próbuje uczyć się bez nauczyciela,

- półnadzorowane (*Semi-supervised Learning*); większość danych uczących jest nieoznakowana, a tylko niektóre są oznaczone,

- uczenie ze wzmocnieniem (*Reinforcement Learning*); system reaktywnie oddziałuje ze środowiskiem zewnętrznym, a następnie na podstawie oceny jego działań obiera kolejne czynności, tak aby zmaksymalizować kryterium nagrody. Przez nagrodę rozumie się tutaj pozytywną ocenę ustalonego na wstępie kryterium, tzw. sukcesu jego działania.

W ramach prowadzonych badań, do realizacji zadań postulowanych w tematyce rozprawy, podjęto decyzję o wyborze uczenia nadzorowanego jako optymalnej metody osiągnięcia zakładanego celu.

W trakcie uczenia wiedza o problemie przekazywana jest w zestawie danych uczących. To na ich podstawie możliwa jest kalibracja modelu czy to w formie ilościowej (np. wartości wag synaptycznych), czy jakościowej (np. struktura w sieciach Bayesa). Ostatecznie definiowany jest model, który ma za zadanie jak najlepiej odwzorować relację pomiędzy danymi, przy zachowaniu jak najwyższego poziomu uogólniania nabytej wiedzy. Uogólnianie, inaczej generalizacja, polega na zdolności do prawidłowego odwzorowania relacji pomiędzy danymi, nawet w przypadkach

niereprezentowanych w wejściowym zbiorze danych uczących na etapie treningu lub walidacji [100].

Metody inteligencji obliczeniowej można podzielić na dwie zasadnicze grupy z uwagi na charakter rozwiązywanego problemu, służące do przewidywania estymowanej funkcji wartości (regresja) lub przewidywania klas (klasyfikacja) [35]. Mając na uwadze realizację założonych celów pracy, w dalszych rozważaniach skupiono się na metodach klasyfikacji, ponieważ pozwalają one na uzyskanie wyników predykcji zgodnie z przyjętym kryterium intensywności uszkodzeń budynków, opisanym w rozdziale 3.3.

W zadaniu klasyfikacji dysponujemy zbiorem danych składających się z wielu cech klasyfikowanych obiektów (zmiennie wejściowe) oraz informacją reprezentującą etykietę klasy tych obiektów (zmienna wyjściowa) tak, że każda obserwacja (przypadek) w bazie danych posiada określone wartości zmiennych wejściowych oraz ustaloną klasę. Mając na uwadze powyższe, od modelu oczekuje się jak najwyższej dokładności klasyfikacji uzyskanej dla zbioru testowego, a także wysokich zdolności generalizacyjnych.

Istotnym atutem wybranych i opisanych poniżej metod jest możliwość zaadoptowania notacji probabilistycznej na etapie wnioskowania danego systemu, jak również przedstawienia wyników obliczeń w notacji probabilistycznej, co może być interpretowane jako ryzyko wystąpienia danego zdarzenia.

Systemy inteligencji obliczeniowej, szczególnie te oparte na formalizmie wnioskowania Bayesa, traktuje się często jako tzw. systemy wspierające podejmowanie decyzji (*decision support system*) [101].

Wykorzystując powyższe informacje, przeprowadzono przegląd różnych metod inteligencji obliczeniowej, spośród których wybrano cztery mogące zostać wykorzystane w budowie modelu oceny ryzyka powstania uszkodzeń. W rozprawie [1] zastosowano następujące metody inteligencji obliczeniowej: probabilistycznej sieci neuronowej (*PNM*), wektorów podtrzymujących (*SVM*), naiwnego klasyfikatora bayesowskiego (*NBC*) oraz sieci Bayesa (*BM*). Z uwagi na otrzymanie najlepszych wyników przy wykorzystaniu metody sieci Bayesa, w niniejszej monografii skupiono się tylko na tej metodzie.

4.2. Sieć Bayesa (BN – Bayesian Network)

Sieć Bayesa można interpretować jako acykliczny graf skierowany (*DAG* – *Directed Acyclic Graph*), który składa się z węzłów (zmiennych) i łączących je krawędzi [102, 103].

W strukturze grafu (G) zakodowana jest informacja o wzajemnych zależnościach między poszczególnymi zmiennymi $X = \{X_1, \dots, X_N\}$, którą reprezentują krawędzie grafu (E) oraz węzły (V). W sensie znaczeniowym BN przedstawia łączny rozkład prawdopodobieństwa nad zbiorem zmiennych losowych X , który można opisać jako [104]:

$$P(X|G, \Theta) = \prod_{i=1}^N P(X_i | \Pi_{X_i}, \Theta_{X_i}) \quad (1)$$

gdzie:

$G = G(X, E, V)$ – struktura acyklicznego grafu skierowanego,

$X = \{X_1, \dots, X_N\}$ – zbiór wszystkich zmiennych występujących w węzłach grafu,

$X = \{x_i^{(1)}, \dots, x_i^{(k)}\}$ – stany i -tej zmiennej,

E – zbiór wszystkich krawędzi,

V – zbiór wszystkich węzłów,

$\Pi_{X_i} = \{x_i^{(q_1)}, \dots, x_i^{(q_l)}\}$ – zbiór rodziców, czyli wszystkich węzłów grafu warunkujących stan węzła X_i ,

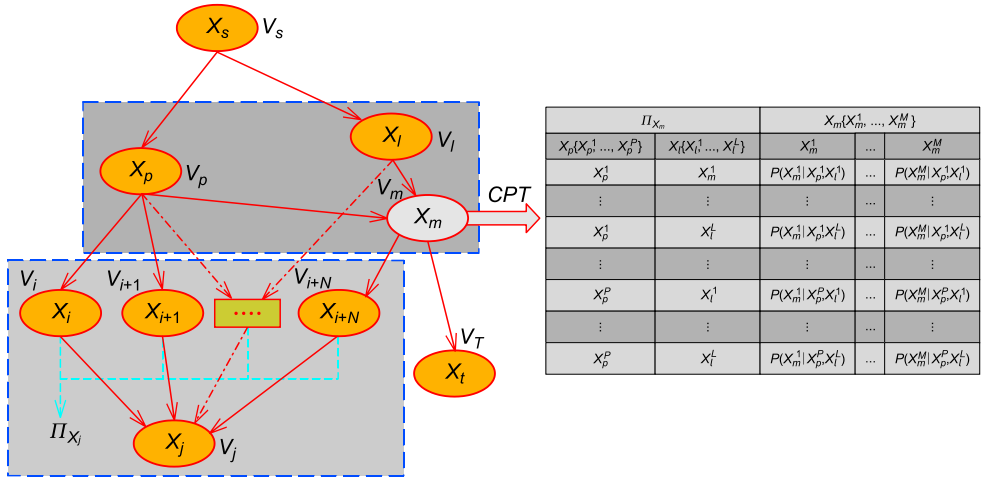
$\Theta = \{\Theta_{X_1}, \dots, \Theta_{X_N}\}$ – zbiór wszystkich parametrów relacji warunkowych między poszczególnymi węzłami X_i , a zbiorem ich rodziców Π_{X_i} .

W przypadku zmiennych dyskretnych parametry modelu $\theta_{X_j} = \{\theta_{ijk}\}$ są reprezentowane w postaci wielonominalnej tablicy prawdopodobieństwa warunkowego CPT (*Conditional Probability Table*), której elementy wyraża się jako [105, 106]:

$$\theta_{ijk} = P(X_j = x_j^{(i)} | \Pi_{X_j} = \pi_j^{(k)}) \quad (2)$$

Zgodnie z zależnością (1) łączny rozkład $P(X|G, \Theta)$ podlega dekompozycji w oparciu o warunkowe rozkłady lokalne $P(X_i | \Pi_{X_i}, \Theta_{X_i})$, opisane nad każdą zmienną losową X_i względem odpowiadającego jej zbioru zmiennych warunkujących, tzw. rodziców Π_{X_i} . Takie sformułowanie jest możliwe dzięki pojęciu warunkowej niezależności wprowadzonej przez J. Pearlą [107, 108]. Pozwala to na znaczne zredukowanie liczby powiązań niewykazujących zależności przyczynowo-skutkowych. Wprowadzenie zaproponowanej redukcji powiązań umożliwia znaczne uproszczenie obliczeń związanych z modelowaniem łącznego rozkładu prawdopodobieństwa i ułatwia późniejszą interpretację struktury przez użytkownika.

Schemat struktury przykładowej sieci Bayesa został przedstawiony na rysunku 4.1.



Rys. 4.1. Schemat struktury acyklicznego grafu skierowanego (DAG) jako sieci Bayesa z tablicami prawdopodobieństw warunkowych dla poszczególnych węzłów [109]

W ogólności łączne prawdopodobieństwo reprezentowane przez sieć Bayesa można zapisać w postaci [110]:

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i | x_{i-1}, x_n) = \prod_{i=1}^n P(x_i | \text{par}(x_i)) \quad (3)$$

gdzie: $\text{par}(x_i)$ – wierzchołki grafu będące bezpośrednimi poprzednikami (rodzicami) wierzchołka x_i .

Procedura uczenia BN z danych składa się z dwóch wzajemnie połączonych etapów: uczenia struktury (*Structure Learning*) i uczenia parametrów sieci (*Parameter Learning*) [103, 104, 111], co można zapisać jako:

$$\underbrace{P(\text{Model} | D) = P(G, \Theta | D)}_{\text{uczenie}} = \underbrace{P(G | D)}_{\text{uczenie struktury}} \cdot \underbrace{P(\Theta | G, D)}_{\text{uczenie parametrów}} \quad (4)$$

Samoistne wyodrębnianie struktury sieci Bayesa z danych jest zdecydowanie trudniejszym zagadnieniem niż implementacja ustalonego w arbitralny sposób modelu. Podejście to jest przeważnie stosowane tam, gdzie wymagane jest wyłonienie powiązań wśród dużej liczby zmiennych wchodzących do opisu danego procesu. W takich sytuacjach ustalanie struktury sieci z danych na podstawie wiedzy eksperta jest niemożliwe. Jest to podyktowane ograniczoną percepcją człowieka w kwestii analizy problemów wielowymiarowych.

W odniesieniu do uczenia struktury BN na podstawie danych, niewiadomymi są zarówno struktura sieci (G), jak i parametry wielonomialnych tablic rozkładu prawdopodobieństwa (θ). Generalnie istnieją trzy różne podejścia w ramach uczenia struktury sieci BN z danych: *constraint-based structure learning*, *score-based structure learning* oraz *hybrid algorithms* [104, 112, 113].

W ramach podejścia *constraint-based* do wykrywania istotnych powiązań w BN są stosowane testy warunkowej niezależności między poszczególnymi zmiennymi [114, 115]. Taka reprezentacja umożliwia łatwą interpretację powiązań przyczynowo-skutkowych zawartych w strukturze BN, a tym samym dostarcza informacji nt. relacji między zmiennymi wchodzącymi do opisu modelowanego zjawiska. Niestety podejście to jest wrażliwe na błędy wynikające ze stosowania statystycznych testów niezależności, które w konsekwencji mogą wpływać na całą strukturę BN [116]. Może to prowadzić do obniżenia wynikowej zgodności modelu z danymi uczącymi na rzecz wyeksponowania najbardziej znaczących (*relevant*) powiązań między węzłami sieci. Z uwagi na powyższe, podejście to nie jest stosowane do uczenia struktury BN, mającej opisywać łączne rozkłady prawdopodobieństwa.

Głównym celem podjętych w monografii badań jest budowa modelu oceny ryzyka powstania uszkodzeń, rozumianego jako łączny rozkład prawdopodobieństwa, gdzie podstawowym kryterium jest uzyskanie jak najlepszej zgodności modelowanego rozkładu ze zbiorem danych uczących. Mając na uwadze ten cel badań uznano, że metody uczenia *constraint-based* raczej nie pozwolą na jego osiągnięcie, lecz mogą udzielić informacji na temat drugiego z przyjętych celów badań, dotyczącego wpływu poszczególnych zmiennych na proces powstawania uszkodzeń. W związku z powyższym wzięto je pod uwagę przy budowie modelu oceny ryzyka powstania uszkodzeń.

Drugie podejście, w którym stosowane są algorytmy *score-based structure learning*, polega na przeszukiwaniu przestrzeni hipotez (potencjalnych struktur sieci BN – G^h) w oparciu o zdefiniowaną funkcję celu (*score function*) dla całego modelu [106, 112, 116]. Tym samym, w odróżnieniu do podejścia *constraint-based structure learning*, algorytmy stosowane w podejściu *score-based* dążą do uzyskania jak najlepszej zgodności modelu z danymi uczącymi. Powoduje to, że wyłonione powiązania między węzłami w strukturze BN nie ograniczają się jedynie do tych najbardziej znaczących z punktu widzenia testów statystycznych. Daje to możliwość ujęcia w modelu również powiązań słabszych, lecz wpływających na podniesienie jego zgodności z danymi uczącymi względem przyjętej funkcji celu. Potwierdzono to badaniami wstępnymi, w których odnotowano, że

podejście *score-based* prowadzi do uzyskania struktury BN, reprezentującej rozkład prawdopodobieństwa nad szerszą dziedziną zmiennych, niż w przypadku stosowania algorytmów *constraint-based*. Stanowi to bardzo istotną zaletę w kwestii analizowanego problemu, ponieważ ryzyko uszkodzeń istniejących budynków zależy częściej od wielu czynników o subtelnym wkładzie, a rzadziej od kilku silnie wyeksponowanych zmiennych [117, 118].

Trzecią grupę stanowią metody hybrydowe, będące kombinacją wyżej opisanych podejść [104, 112]. Przebieg procedury w ujęciu hybrydowym składa się z dwóch etapów. W pierwszym zostaje zawężona przestrzeń poszukiwań do nieuporządkowanego szkieletu BN, natomiast w drugim etapie ustalany jest porządek oraz kierunki połączeń na drodze optymalizacji z wykorzystaniem podejścia *score-based structure learning* [119]. Mając na uwadze fakt, że w pierwszym etapie stosowane jest podejście *constraint-based*, które już na starcie może prowadzić do utraty części informacji istotnych dla całego modelu na rzecz jedynie najbardziej znaczących powiązań, metody hybrydowe nie pozwolą na osiągnięcie głównego celu badań. Dodatkowo, jak wynika z literatury [104], dostępne obecnie metody hybrydowe nie pozwalają na uzyskanie wyższej dokładności klasyfikacji od metod *constraint-based*, w związku z czym nie zostały one wzięte pod uwagę w badaniach.

Ryzyko uszkodzenia budynków opisywane jest przez wiele czynników o subtelnym wkładzie, co wykazano w ramach wieloletnich badań opisanych m.in. w [120–122]. Dlatego istotne jest, aby w trakcie wyodrębniania struktury BN jak najwięcej zmiennych zostało ujętych w modelu. Z kolei podstawowym kryterium jest, aby reprezentowany przez BN rozkład prawdopodobieństwa cechował się możliwie największą zgodnością względem zbioru danych uczących. Biorąc to pod uwagę oraz opisaną wyżej charakterystykę wszystkich metod uczenia BN z danych, zdecydowano o zastosowaniu również podejścia *score-based*.

Podejście *score-based structure learning* polega na iteracyjnym przeszukiwaniu przestrzeni potencjalnych rozwiązań zgodnie z zadanym algorytmem. Podstawę stanowi kryterium optymalizacyjne, którym jest odpowiednio zdefiniowana funkcja celu w ogólnej postaci [123]:

$$\text{Score}(G|D) = \sum_{i=1}^N \text{Score}(X_i, \Pi_{X_i}, D) \quad (5)$$

Taka postać funkcji celu świadczy o jej dekompozycyjności (*decomposability*), za sprawą której możliwe jest wyznaczanie wartości funkcji celu w każdym węźle sieci.

Zgodnie z aktualnym stanem wiedzy funkcjonują dwa podejścia, w ramach których wyłaniane są funkcje celu [111, 124, 125]. W pierwszym z nich funkcje celu konstruowane są na gruncie *frequentist statistical approach* i teorii informacji (*Information-Theoretic Scores*), gdzie punktem wyjścia jest *Maximum Likelihood Estimation Framework* [34]. Do grona tych funkcji należą [125]: *Log-Likelihood* (loglik), *Akaike Information Criterion* (AIC) [126], *Bayesian Information Criterion* (BIC), *Minimum Description Length Criterion* (MDL), *Normalized Maximum Likelihood* (NML) oraz *Mutual Information Test* (MIT). Zbiór ten poszerzają kryteria, takie jak: *Quotient Normalized Maximum Likelihood* (qNML) [127] i *Factorized Normalized Maximum Likelihood* (fNML) [128]. Drugie podejście prowadzi do rodziny *Bayesian Dirichlet score functions* (BD) [103], gdzie najpopularniejsze są *Bayesian Dirichlet equivalent uniform* (BDeu) oraz K2 [106, 129, 130].

Z tego grona do dalszych analiz przyjęto następujące funkcje celu: *Log-Likelihood* (loglik), *Akaike Information Criterion* (AIC) i *Bayesian Information Criterion* (BIC). Równania (6), (7) i (8) przedstawiają ich opis matematyczny [111, 125].

Log-Likelihood (loglik)

$$SC_{\text{loglik}}(G|D) = \sum_{i=1}^n \sum_{j=1}^{q_i} \sum_{k=1}^{r_i} N_{ijk} \log \left(\frac{N_{ijk}}{N_{ij}} \right) \quad (6)$$

Akaike Information Criterion (AIC)

$$SC_{\text{AIC}}(G|D) = SC_{\text{LL}}(G|D) - \sum_{i=1}^n (r_i - 1) q_i \quad (7)$$

Bayesian Information Criterion (BIC)

$$SC_{\text{BIC}}(G|D) = SC_{\text{LL}}(G|D) - \frac{1}{2} \log(N) \sum_{i=1}^n (r_i - 1) q_i \quad (8)$$

gdzie:

r_i – liczba stanów losowej zmiennej X_i ,

$q_i = \prod_{X_j \in \Pi_{X_i}} r_j$ – liczba możliwych konfiguracji rodziców w Π_{X_i} dla zmiennej X_i ,

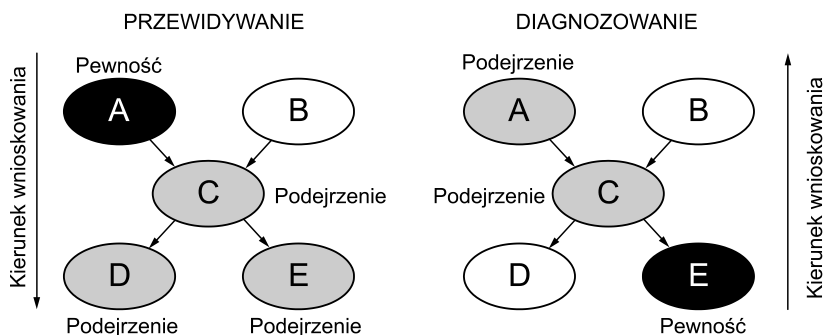
N_{ijk} – liczba przypadków w zbiorze danych D , gdzie zmienna X_i przyjmuje k -tą wartość x_{ik} i zmienne w Π_{X_i} przyjmują ich j -tą konfigurację w_{jk} ,

$N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$ – liczba przypadków w zbiorze danych D , gdzie zmienne w Π_{X_i} przyjmują ich j -tą konfigurację w_{ik} ,

N – łączna liczba przypadków w D .

Drugim etapem tworzenia sieci Bayesa jest uczenie parametrów, które wynika z kształtu sieci ustalonego na etapie uczenia struktury. Zasadniczo dla struktury sieci (G), ustalenie θ wynika z prawdopodobieństwa wystąpienia zmiennej wyjściowej dla zadanych zmiennych wejściowych. Można to interpretować jako zliczanie liczby rekordów dla różnych warunków kombinacji stanów parametryzowanego wierzchołka i jego poprzedników. Parametry te są zwykle wyznaczone na podstawie algorytmu maksymalizacji oczekiwań EM (*Expectation Maximization Algorithm*), który polega na określeniu lokalnie optymalnego estymatora największej wiarygodności parametrów [131].

Dodatkowym bardzo istotnym atutem metody BN jest możliwość wnioskowania w dwóch kierunkach i tym sposobem wykorzystania sieci Bayesa do diagnozowania lub przewidywania, co schematycznie zostało przedstawione na rysunku 4.2.



Rys. 4.2. Schemat możliwych kierunków wnioskowania w sieci Bayesa
 A, B – zmienne reprezentujące przyczyny; C, D, E – zmienne reprezentujące skutki
 (opracowanie własne na podstawie [132])

Wnioskowanie w dwóch kierunkach stanowi zaletę BN, niespotykaną w innych metodach inteligencji obliczeniowej. W przedmiotowych badaniach może ona pozwolić na uzyskanie informacji o wpływach górniczych, które spowodowały obserwowany na obiekcie stan uszkodzeń.

Podsumowując, do podstawowych zalet sieci Bayesa można zaliczyć [133]:

- interpretowalną strukturę modelu,
- notację probabilistyczną,

- skuteczność działania w przypadku niekompletnych zbiorów danych,
- możliwość wnioskowania o dowolnym węźle grafu, umożliwiającą w ogólności przeprowadzenie predykcji lub diagnozy.

Przegląd wybranych czterech metod inteligencji obliczeniowej wskazał na ich zalety, a także wykazał możliwość ich wykorzystania do budowy modelu oceny ryzyka powstania uszkodzeń. Niewątpliwie największy potencjał mają sieci BN pod kątem ich interpretowalności, a także możliwości zastosowania do predykcji i diagnozy. W związku z tym, że metodyka budowy tego typu modeli dalej jest intensywnie rozwijana pod kątem uczenia struktury sieci, zdecydowano o przetestowaniu i ostatecznym porównaniu wyników dla wszystkich wytypowanych czterech metod inteligencji obliczeniowej.

5. MODEL OCENY RYZYKA POWSTANIA USZKODZEŃ JAKO SIEĆ BAYESA

5.1. Informacje ogólne i przygotowanie danych do analiz

W celu wyboru optymalnej metody budowy modelu oceny ryzyka powstania uszkodzeń przygotowano bazę danych do analiz, a następnie zbudowano różne modele z wykorzystaniem czterech wybranych metod inteligencji obliczeniowej: PNN, SVM, NBC i BN. Spośród utworzonych modeli na podstawie autorskich kryteriów wybrano optymalny model oceny ryzyka powstania uszkodzeń.

Budowę klasyfikatorów przeprowadzono w środowisku programistycznym R [134] z wykorzystaniem pakietów: *yap* [135], *e1071* [136], *bnlearn* [110, 137], *naivebayes* [138], *bnclassify* [139], *gRain* [140, 141] oraz *caret* [142]. Zgromadzone dane o 207 budynkach murowanych, które opisane zostały w rozdziale 3.2 oraz dane o ich stanie uszkodzeń (rozdz. 3.3) i wpływach górniczych (roz. 3.4) pozwoliły na przygotowanie bazy danych z 594 przypadkami. Przed etapem budowy i testowania poszczególnych modeli dokonano jakościowej oceny danych pod kątem przypadków odstających [143]. Na tej podstawie odrzucono przypadki skrajne, których względna częstość pojawiania się w zbiorze danych nie przekraczała 5%.

W procesie przygotowania danych do analizy dokonano również dyskretyzacji wszystkich zmiennych pod kątem dalszego ich wykorzystania w procesie uczenia [133]. Kategorie zmiennych liczbowych dobrano tak, aby liczba przypadków w każdej kategorii nie była mniejsza od 5% liczebności całego zbioru. Takie dobranie kategorii miało wpływ na zachowanie jednorodności bazy danych pod kątem uczenia poszczególnych modeli. W tablicy 5.1 przedstawiono zestawienie zgromadzonych danych z podziałem na zmienne.

Tak uporządkowane dane podzielono na zbiory treningowy i testowy w proporcjach 80:20 zgodnie z zasadami proponowanymi w literaturze przedmiotu [144]. Dodatkowo, aby zachować kompletność wzorców dla procesów uczenia i testowania, zastosowano podejście *Stratified Sampling* [145]. W ogólności wymusza ono występowanie wzorców o tej samej kategorii w zbiorze treningowym i testowym.

Tablica 5.1. Zestawienie zgromadzonych danych z podziałem na typy zmiennych, zmienne, przypisane kody i przypadające liczby kategorii

Typ zmiennej	Zmienna	Kod	Liczba kategorii
Geometria	długość	Dług	8
	szerokość	Szer	6
	powierzchnia zabudowy	Powi	10
	liczba kondygnacji nadziemnych	LiKon	5
	kubatura	Kubat	11
	długość ciągu zabudowy zwartej	DluCi	12
	sposób dylatowania	Dylat	3
	kształt bryły budynku	Kszta	4
	podpiwniczenie	Podpi	3
	zmienny poziom posadowienia	ZmPos	2
	zmienna wysokość budynku	ZmWys	2
Konstrukcja	rodzaj fundamentu	RoFun	3
	materiał ścian piwnic	Msp	3
	materiał ścian parteru i wyżej	Mspiw	2
	strop nad piwnicą	Snp	5
	strop nad parterem i wyżej	Snpiw	3
	nadproża	Nadpr	3
	zabezpieczenia na wpływy górnicze	Zabez	4
	zabezpieczenia – dane uzupełniające dotyczące kotwienia	ZabUz	3
Inne dane techniczne	rok budowy	Rok	8
	zużycie naturalne (stan techniczny)	ZuNat	5
	współczynnik remontowy	Rem	2
	kategoria odporności statycznej (deformacyjnej)	KOS	3

Typ zmiennej	Zmienna	Kod	Liczba kategorii
Dane górnicze	kategoria terenu górniczego	KTG	3
Uszkodzenia	kategoria stanu uszkodzeń przed wpływami	KsuPrz	4
	kategoria stanu uszkodzeń po wpływach	KsuPo	4

Zachowano kompletność informacji, zarówno dla procesu uczenia, jak i późniejszego testowania. W tym celu w przeprowadzonych analizach wykorzystano funkcję *createDataPartition* z pakietu *caret* [142, 146] w środowisku R.

Funkcja ta wymaga wybrania zmiennych, dla których wymusza się podział w zakładanych proporcjach. Mając na uwadze cel pracy, podjęto decyzję o wyborze zmiennych dotyczących uszkodzeń (**KsuPrz** i **KsuPo**), jako determinujących podział w wybranych proporcjach. Ostatecznie liczność wydzielonych zbiorów wyniosła odpowiednio: 478 przypadków dla zbioru treningowego oraz 116 przypadków dla zbioru testowego. Uzyskane proporcje podziału wynoszące 80,5:19,5 ocenia się jako wystarczająco bliskie zakładanym. Zestawienie zgromadzonych danych z podziałem na kategorie, ich licznosci oraz udziały w zbiorach zostały przedstawione w załączniku 1 (tabl. Z1.1). Zaproponowany podział był analogiczny dla wszystkich metod, które zastosowano w badaniach.

Zbiór treningowy był wykorzystywany do uczenia, zgodnie z wymogami dla poszczególnych metod ujętych w badaniach. Zbiór testowy, który nie brał udziału w procesie uczenia, jako nieobciążony posłużył do oceny utworzonych modeli w kontekście własności generalizacyjnych [147].

5.2. Interpretacja wyników oraz przyjęty sposób ich weryfikacji

W celu efektywnego porównania wyników poszczególnych metod wykorzystano uniwersalną miarę oceny poprawności klasyfikacji, jaką jest macierz pomyłek (*confusion matrix*) [148]. Przykład takiej macierzy w klasyfikacji binarnej został przedstawiony w tablicy 5.2.

Tablica 5.2. Macierz pomylek dla klasyfikatora binarnego

		Klasa rzeczywista	
		pozytywna	negatywna
Klasa przewidywana	pozytywna	prawdziwie pozytywna (TP)	falszywie pozytywna (FP)
	negatywna	falszywie negatywna (FN)	prawdziwie negatywna (TN)

Podstawowym parametrem porównawczym jest dokładność klasyfikacji (*overall accuracy*), która jest ilorazem sumy przypadków poprawnie sklasyfikowanych oraz ich całkowitej liczby

$$ACC = \frac{TP + TN}{TP + FP + FN + TN} \quad (9)$$

Wskazane jest, aby wybrana metoda charakteryzowała się również możliwie wysoką precyzją i czułością [149], których miarą jest również wartość F_1 (*F-score*) [150, 151]. Dodatkowymi parametrami porównawczymi są:

precyzja (*positive predictive value*):

$$PPV = \frac{TP}{TP + FP} \quad (10)$$

czułość (*true positive rate*):

$$TPR = \frac{TP}{TP + FN} \quad (11)$$

oraz wartość F_1

$$F_1 = 2 \frac{PPV \cdot TPR}{PPV + TPR} \quad (12)$$

Opisowa ocena dokładności klasyfikacji (ACC), precyzji (PPV) i czułości (TPR) została przeprowadzona w następującej autorskiej gradacji:

- bardzo dobra (co najmniej 90%),
- dobra (80 – 90%),
- zadowalająca (70 – 80%),
- średnia (60 – 70%),
- niewystarczająca (poniżej 60%).

Postawiono zatem rygorystyczne wymagania, które powinny pozwolić na wyłonienie najlepszego podejścia z grona wszystkich testowanych metod.

W wyborze najlepszej metody równoznaczne znaczenie, jak jej dokładność, mają także zdolności generalizacyjne. Definiuje się je jako zdolność modelu do przewidywania właściwej odpowiedzi dla przypadków niebiorących udziału w procesie uczenia [152].

Aby porównać zdolności generalizacyjne poszczególnych modeli, obliczono różnicę dokładności klasyfikacji dla zbioru trenującego i testowego ΔACC . Opisowa ocena zdolności generalizacyjnych modeli została przeprowadzona w następującej autorskiej gradacji:

- bardzo dobra (poniżej 3%),
- dobra (3 – 6%),
- zadowalająca (6 – 9%),
- średnia (9 – 12%),
- niewystarczająca (powyżej 12%).

Do wszystkich metod wybranych wstępnie i opisanych w rozdziale 4, w rozdziale 5.3 zaprezentowano macierze pomyłek z uwzględnieniem podziału na zbiory trenujący oraz testowy. Zgodnie ze wzorami (9) – (11) w macierzach zestawiono również wyniki dotyczące dokładności klasyfikacji oraz średniej precyzji i czułości.

5.3. Wyniki obliczeń otrzymane dla sieci Bayesa z wykorzystaniem różnych metod uczenia struktury sieci

5.3.1. Uwagi ogólne

Założenie możliwego wzajemnego wpływu poszczególnych zmiennych [153] pozwoliło na uzyskanie dla metody BN innych wyników niż w przypadku metody NBC.

Podejście wykorzystujące BN daje wynikowo strukturę sieci, która jest zależna od wybranej metody uczenia klasyfikatora. Przeanalizowano wyniki dla wybranych ośmiu metod nauki struktury sieci: *Chow-Liu's tree augmented naive Bayes* (TAN-CL), *hill-climbing* (HC), *TABU*, *Forward sequential selection and joining* (FSSJ), *Backward sequential elimination and joining* (BSEJ), *Hill-climbing tree augmented naive Bayes* (HC-TAN), *Hill-climbing k-dependence Bayesian classifier* (k-DB) oraz *Hill-climbing super-parent tree augmented naive Bayes* (HC-SP-TAN). Część z wyżej wymienionych metod można kwalifikować do podejścia *score-based structure learning*, a część do podejścia *constraint-based*. Metody te dostępne są

w pakietach *bnlearn* [110, 137] oraz *bnclassify* [139], a uzyskane za ich pomocą wyniki zostały przedstawione poniżej.

Przeprowadzone w rozdziale 5.3 i 5.4 analizy wyników mają na celu wyjaśnienie zależności przyczynowo-skutkowych w strukturze modelu oraz potwierdzenie możliwości jego wykorzystania w celu prognozy lub diagnozy (rozdz. 4.2) oceny ryzyka powstania uszkodzeń w budynkach. Pozwala to na lepsze zrozumienie jego funkcjonowania i łatwiejszą interpretację uzyskanych wyników. Jest to istotne z punktu widzenia użytkownika, aby rozumiał jak model funkcjonuje [154], a tym samym mógł go z powodzeniem wykorzystywać w praktyce.

Jedną z zalet podejścia z zastosowaniem BN jest możliwość reprezentacji modelu w postaci struktury grafu (*DAG*), co zwiększa interpretowalność samego modelu, a także stanowi wsparcie dla użytkownika w podejmowaniu decyzji (*decision support tool*) [116]. W analizowanym przypadku węzły będą reprezentowane przez zmienne opisane w rozdziale 3.2 i 5.1.

Metody uczenia struktury BN z danych pozwalają na definiowanie wybranych połączeń pomiędzy węzłami grafu poprzez implementowanie tzw. białych i czarnych list [112]. Pary węzłów grafu (zmiennych), znajdujące się na białej liście, zmuszają klasyfikator do brania pod uwagę połączeń pomiędzy nimi. Pary węzłów umieszczone na czarnej liście uniemożliwiają zdefiniowanie połączenia. W celu sprawdzenia samodzielnego ustalania połączeń pomiędzy węzłami reprezentującymi poszczególne zmienne zrezygnowano z definiowania tych list, dając tym samym pełną autonomię przyjętej metodzie uczenia struktury BN (rozdz. 4.2).

5.3.2. Struktura BN z metodą uczenia TAN-CL i funkcją celu AIC

Wyniki przedstawione poniżej otrzymano przy wykorzystaniu metody uczenia *Chow-Liu's tree augmented naive Bayes* (TAN-CL). Wybrana metoda uczenia sieci TAN-CL jest wynikiem połączenia dwóch metod: *tree augmented naive Bayes* (TAN) [155], która aproksymuje interakcje pomiędzy zmiennymi z wykorzystaniem struktury o kształcie drzewa oraz algorytmu wykrywania połączeń *Chow-Liu* [156], który opisuje łączny rozkład prawdopodobieństwa jako iloczyn rozkładów warunkowych i krańcowych drugiego rzędu [157].

Parametrem sterującym w budowie modelu jest wskaźnik dopasowania modelu nazywany także funkcją celu (rozdz. 4.2). Przeanalizowano wpływ trzech wybranych funkcji: *Akaike Information Criterion* (AIC), *Bayesian Information Criterion* (BIC) oraz *Log-Likelihood* (loglik), zaś wyniki przedstawione w tablicy 5.3 dotyczą funkcji celu AIC.

Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych

zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tabelicy 5.3.

Tablica 5.3. Macierz pomyłek klasyfikatora BN z metodą uczenia TAN-CL i funkcją celu AIC

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	40	15	0	0	55	72,73%
	2	1	220	29	5	255	86,27%
	3	0	15	118	3	136	86,76%
	4	0	3	6	23	32	71,88%
Σ		41	253	153	31	478	śr. prec. 79,41%
Czułość (TPR)		97,56%	86,96%	77,12%	74,19%	śr. czuł. 83,96%	dokł. klas. 83,89%
Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	11	2	0	0	13	84,62%
	2	0	58	4	0	62	93,55%
	3	0	5	22	3	30	73,33%
	4	0	1	0	10	11	90,91%
Σ		11	66	26	13	116	śr. prec. 85,60%
Czułość (TPR)		100,00%	87,88%	84,62%	76,92%	śr. czuł. 87,35%	dokł. klas. 87,07%

Z tablicy 5.3 wynika, że zbudowany model charakteryzuje się dobrą dokładnością klasyfikacji wynoszącą 83,89% dla zbioru trenującego. Wyniki dla zbioru testowego są również dobre, a dokładność klasyfikacji wyniosła 87,07%. Świadczy to o dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 3,18\%$).

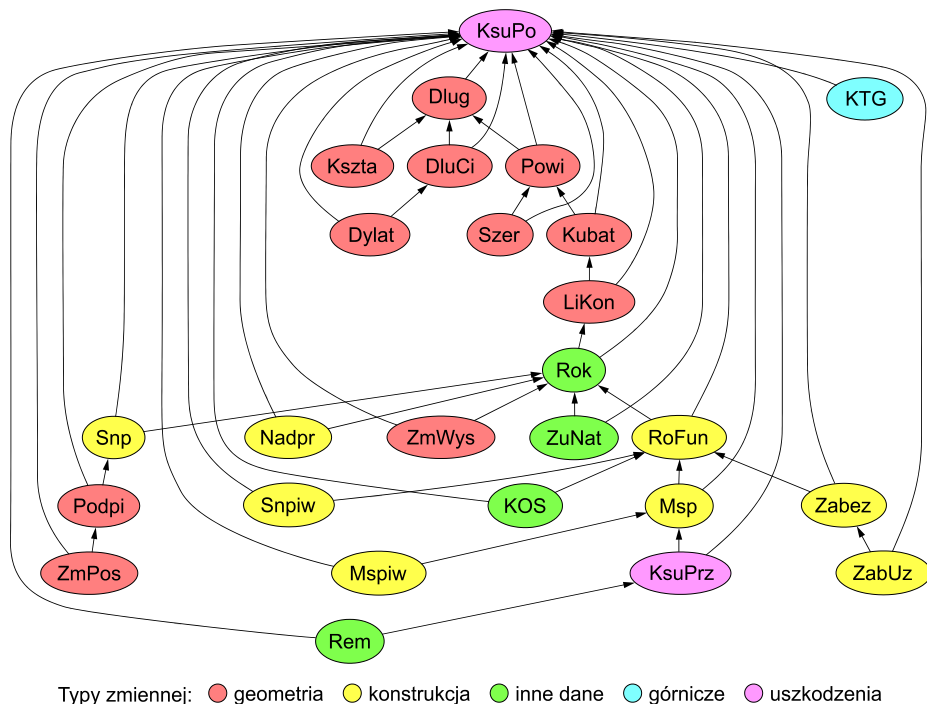
Dla zbioru testowego sieć Bayesa charakteryzuje się:

- bardzo dobrą precyzją (PPV) w przypadku wskazywania na 2. i 4. kategorię uszkodzeń oraz czułością (TPR) w przypadku wskazywania na 1. kategorię uszkodzeń,

- dobrą precyzją (PPV) w przypadku wskazywania na 1. kategorię uszkodzeń oraz czułością (TPR) w przypadku wskazywania na 2. i 3. kategorię uszkodzeń,

- zadowalającą precyzją (PPV) w przypadku wskazywania na 3. kategorię uszkodzeń i czułością (TPR) w przypadku wskazywania na 4. kategorię uszkodzeń.

Na rysunku 5.1 przedstawiono strukturę BN z widocznym kierunkiem wnioskowania oraz zaprezentowano zmiennebrane pod uwagę w procesie decyzyjnym. Z uwagi na złożoność tablic warunkowych dla poszczególnych zmiennych zrezygnowano z ich prezentacji na rysunku 5.1 i umieszczono je w załączniku 2 (tabl. Z2.1 – Z2.26).



Rys. 5.1. Struktura sieci dla klasyfikatora BN z metodą uczenia TAN-CL i funkcją celu AIC

Analiza struktury sieci przedstawionej na rysunku 5.1 wskazuje na logiczne i uzasadnione połączenia między węzłami:

- podpiwniczenia (**Podpi**) ze zmiennym poziomem posadowienia (**ZmPos**),
- kategorii stanu uszkodzeń przed eksploatacją (**KsuPrz**) ze zmienną remontową (**Rem**),
- materiału ścian piwnic (**Msp**) z materiałem ścian parteru i wyższych kondygnacji (**Mspiw**),
- zabezpieczenia na wpływy górnicze (**Zabez**) z danymi uzupełniającymi dotyczącymi zabezpieczenia na wpływy górnicze (**ZabUz**),
- rodzaju stropu nad piwnicą (**Snp**) z podpiwniczeniem (**Podpi**),
- rodzaju fundamentu (**RoFun**) ze stropem nad parterem i na wyższych kondygnacjach (**Snpiw**), kategorią odporności statycznej (**KOS**), materiałem ścian piwnic (**Msp**) i zabezpieczeniem (**Zabez**),
- roku budowy (**Rok**) z rodzajem stropu nad piwnicą (**Snp**), rodzajem nadproży (**Nadpr**), zużyciem naturalnym (**ZuNat**) i rodzajem fundamentu (**RoFun**),
- kubatury (**Kubat**) z liczbą kondygnacji (**LiKon**),
- powierzchni (**Powi**) z szerokością (**Szer**) i kubaturą (**Kubat**),
- długości ciągu (**DluCi**) z dylatacją (**Dylat**),
- długości (**Dług**) z kształtem (**Kszta**), długością ciągu (**DluCi**) i powierzchnią (**Powi**),
- kategorii stanu uszkodzeń po eksploatacji (**KsuPo**) z kategorią terenu górniczego (**KTG**).

Wśród wskazanych przez klasyfikator połączeń można znaleźć również takie, dla których bezpośrednie powiązania nie wydają się w pełni uzasadnione. Przykładami takich połączeń są:

- rok budowy (**Rok**) ze zmienną wysokością budynku (**ZmWys**),
- liczba kondygnacji (**LiKon**) z rokiem budowy (**Rok**),
- materiał ścian piwnic (**Msp**) z kategorią stanu uszkodzeń przed eksploatacją (**KsuPrz**).

Powiązania te wynikają prawdopodobnie z faktu występowania w zgromadzonej bazie danych starszych budynków o większej liczbie kondygnacji i zmiennej wysokości budynku, a także wyższych kategorii stanu uszkodzeń ścian piwnic murowanych z kamienia.

Ocenia się, że wyodrębniona struktura BN, która została utworzona za pomocą implementacji algorytmu uczenia struktury TAN-CL i funkcji celu AIC (rys. 5.1), jest spójna i logiczna, a otrzymane połączenia zmiennych dość dobrze oddają ich powiązanie obserwowane w rzeczywistości.

5.3.3. Struktura BN z metodą uczenia TAN-CL i funkcją celu BIC

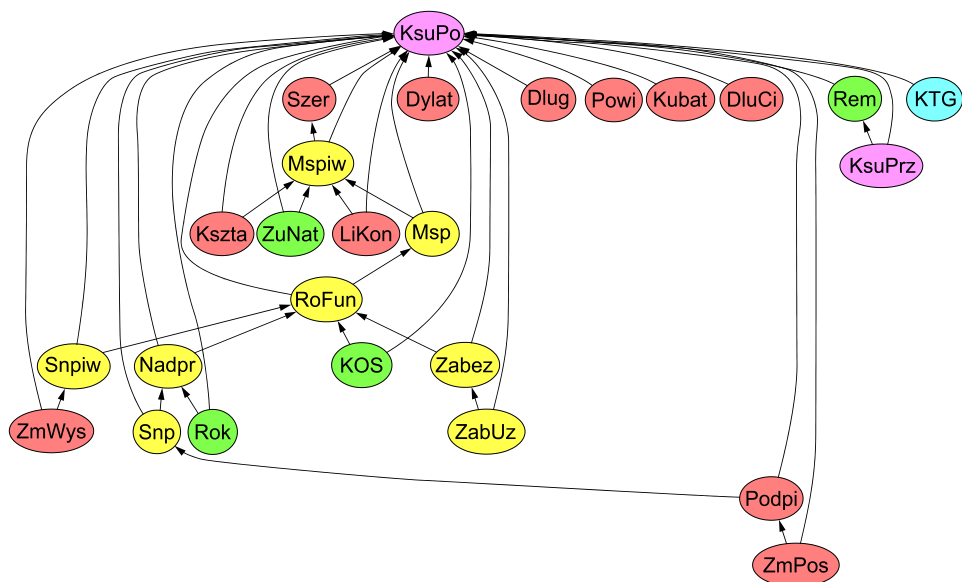
Poniższe wyniki uzyskano przy wykorzystaniu metody uczenia *Chow-Liu's tree augmented naïve Bayes* (TAN-CL) oraz funkcji celu *Bayesian Information Criterion* (BIC).

Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tabelicy 5.4.

Tablica 5.4. Macierz pomyłek klasyfikatora BN z metodą uczenia TAN-CL i funkcją celu BIC

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	37	15	1	0	53	69,81%
	2	4	209	42	6	261	80,08%
	3	0	28	105	4	137	76,64%
	4	0	1	5	21	27	77,78%
Σ		41	253	153	31	478	76,08%
Czułość (TPR)		90,24%	82,61%	68,63%	67,74%	77,31%	77,82%
Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	10	3	0	0	13	76,92%
	2	1	58	6	1	66	87,88%
	3	0	4	20	3	27	74,07%
	4	0	1	0	9	10	90,00%
Σ		11	66	26	13	116	82,22%
Czułość (TPR)		90,91%	87,88%	76,92%	69,23%	81,24%	83,62%

Z tablicy 5.4 wynika, że zbudowany model charakteryzuje się zadowalającą dokładnością klasyfikacji wynoszącą 77,82% dla zbioru trenującego. Wyniki dla zbioru testowego są dobre, a dokładność klasyfikacji wyniosła 83,62%. Świadczy to o dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 5,8\%$). Na rysunku 5.2 przedstawiono strukturę sieci Bayesa, wskazując kierunek wnioskowania oraz zmiennebrane pod uwagę w procesie decyzyjnym.



Rys. 5.2. Struktura sieci dla klasyfikatora BN z metodą uczenia TAN-CL i funkcją celu BIC

Powyższa struktura sieci zbliżona jest do uzyskanej metodą uczenia TAN-CL i funkcją celu AIC (rys. 5.1). Największą różnicą jest zdecydowanie mniejsza liczba powiązań zmiennych geometrycznych ze sobą.

5.3.4. Struktura BN z metodą uczenia TAN-CL i funkcją celu loglik

Poniższe wyniki uzyskano przy wykorzystaniu metody uczenia *Chow-Liu's tree augmented naive Bayes* (TAN-CL) oraz funkcji celu *Log-Likelihood* (loglik).

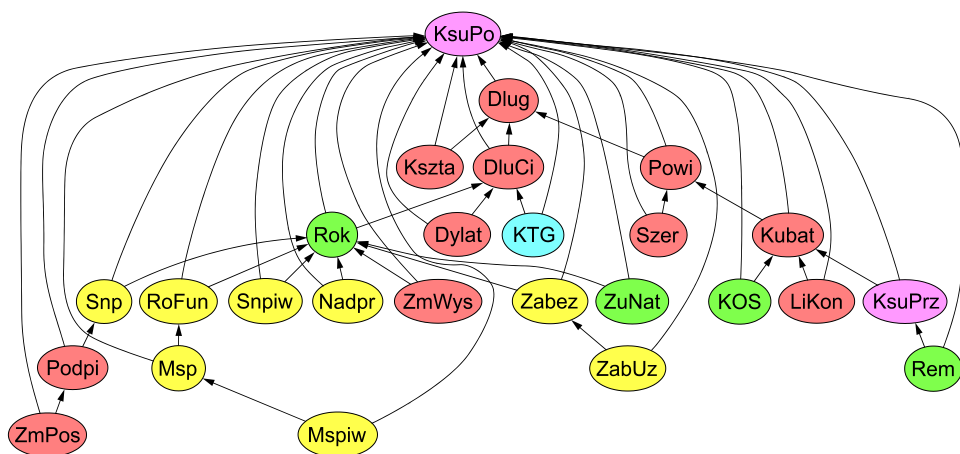
Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tablicy 5.5.

Tablica 5.5. Macierz pomyłek klasyfikatora BN z metodą uczenia TAN-CL i funkcją celu loglik

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	41	15	0	0	56	73,21%
	2	0	213	20	1	234	91,03%
	3	0	18	125	3	146	85,62%
	4	0	7	8	27	42	64,29%
Σ		41	253	153	31	478	78,54%
Czułość (TPR)		100,00%	84,19%	81,70%	87,10%	88,25%	84,94%
Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	11	2	0	0	13	84,62%
	2	1	56	4	0	61	91,80%
	3	0	4	23	2	29	79,31%
	4	0	2	1	10	13	76,92%
Σ		12	64	28	12	116	83,16%
Czułość (TPR)		91,67%	87,50%	82,14%	83,33%	86,16%	86,21%

Z tablicy 5.5 wynika, że zbudowany model charakteryzuje się dobrą dokładnością klasyfikacji wynoszącą 84,94% dla zbioru trenującego. Wyniki dla zbioru testowego są dobre, a dokładność klasyfikacji wyniosła 86,21%. Świadczy to o bardzo dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 1,27\%$).

Na rysunku 5.3 przedstawiono strukturę sieci Bayesa, wskazując kierunek wnioskowania oraz zmienne brane pod uwagę w procesie decyzyjnym. Poniższa struktura sieci zbliżona jest do tej uzyskanej metodą uczenia TAN-CL i funkcją celu AIC (rys. 5.1). Zastanawiające i trudne do jednoznacznego uzasadnienia jest połączenie zmiennej dotyczącej terenu górniczego **KTG** ze zmiennymi dotyczącymi geometrii analizowanego budynku.



Rys. 5.3. Struktura sieci dla klasyfikatora BN z metodą uczenia TAN-CL i funkcją celu loglik

5.3.5. Struktura BN z metodą uczenia BSEJ

Poniższe wyniki otrzymano przy wykorzystaniu metody uczenia *Backward sequential elimination and joining* (BSEJ). Metoda uczenia sieci BSEJ do selekcji atrybutów wykorzystuje algorytm wstecznej sekwencyjnej eliminacji [158].

Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tabelicy 5.6.

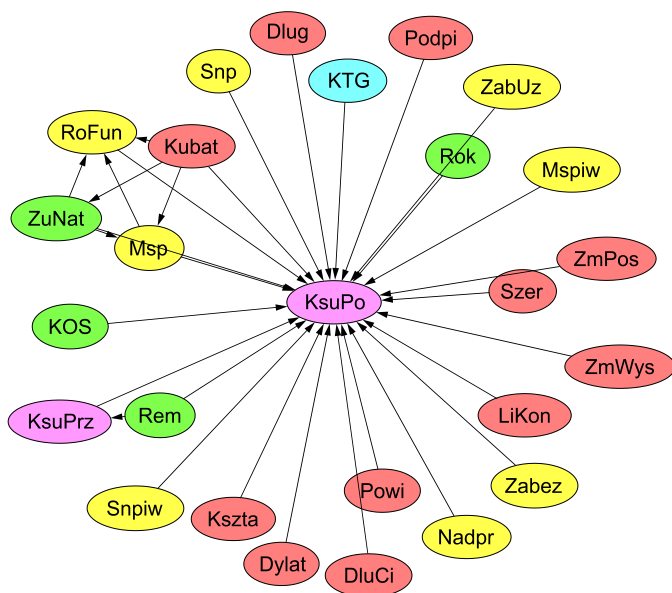
Tabela 5.6. Macierz pomyłek klasyfikatora BN z metodą uczenia BSEJ

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	33	28	1	0	62	53,23%
	2	8	197	34	6	245	80,41%
	3	0	25	112	3	140	80,00%
	4	0	3	6	22	31	70,97%
Σ		41	253	153	31	478	71,15%
Czułość (TPR)		80,49%	77,87%	73,20%	70,97%	75,63%	76,15%

Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)	zaobserwowana				Σ	Precyzja (PPV)	
	1	2	3	4			
Przewidywana	1	9	6	0	0	15	60,00%
	2	2	54	5	1	62	87,10%
	3	0	3	20	2	25	80,00%
	4	0	3	1	10	14	71,43%
Σ	11	66	26	13	116	74,63%	
Czułość (TPR)	81,82%	81,82%	76,92%	76,92%	79,37%	80,17%	

Z tablicy 5.6 wynika, że zbudowany model charakteryzuje się zadowalającą dokładnością klasyfikacji wynoszącą 76,15% dla zbioru trenującego. Wyniki dla zbioru testowego są dobre, a dokładność klasyfikacji wyniosła 80,17%. Świadczy to o dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 4,02\%$).

Na rysunku 5.4 przedstawiono strukturę sieci Bayesa, wskazując kierunek wnioskowania oraz zmienne brane pod uwagę w procesie decyzyjnym.



Rys. 5.4. Struktura sieci dla klasyfikatora BN z metodą uczenia BSEJ

Powyższa struktura sieci Bayesa zbliżona jest do sieci odpowiadającej Naiwnemu Klasyfikatorowi Bayesowskiemu (NBC), który zakłada wzajemną niezależność wszystkich zmiennych względem siebie. Widoczne jest odstępstwo od tych zasad jedynie dla zmiennych: **Kubat – RoFun – ZuNat – Msp**.

5.3.6. Struktura BN z metodą uczenia HC-TAN

Wyniki otrzymano przy wykorzystaniu metody uczenia *Hill-climbing tree augmented naive Bayes* (HC-TAN). Metoda uczenia sieci HC-TAN jest wynikiem połączenia dwóch metod: *tree augmented naive Bayes* (TAN) [155] z chciwym algorytmem wykrywania połączeń *Hill Climbing* (HC) [153].

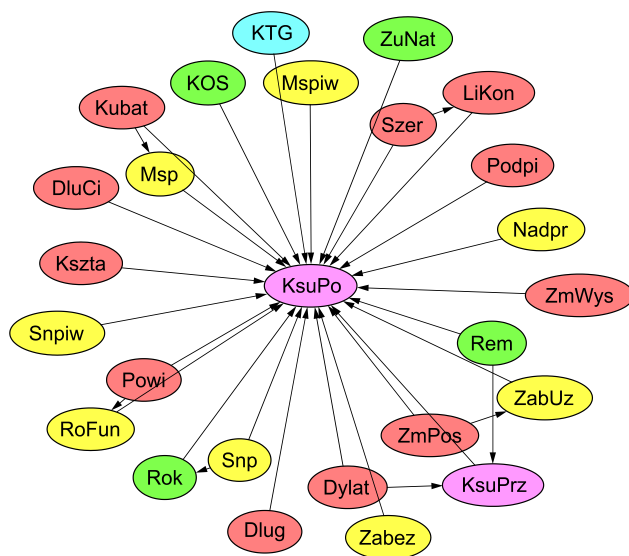
Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tablicy 5.7.

Tablica 5.7. Macierz pomyłek klasyfikatora BN z metodą uczenia HC-TAN

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	37	31	2	0	70	52,86%
	2	3	193	30	6	232	83,19%
	3	0	24	113	4	141	80,14%
	4	1	5	8	21	35	60,00%
Σ		41	253	153	31	478	69,05%
Czułość (TPR)		90,24%	76,28%	73,86%	67,74%	77,03%	76,15%
Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	10	6	0	0	16	62,50%
	2	0	57	6	1	64	89,06%
	3	0	2	20	3	25	80,00%
	4	1	1	0	9	11	81,82%
Σ		11	66	26	13	116	78,35%
Czułość (TPR)		90,91%	86,36%	76,92%	69,23%	80,86%	82,76%

Z tablicy 5.7 wynika, że zbudowany model charakteryzuje się zadowalającą dokładnością klasyfikacji wynoszącą 76,15% dla zbioru trenującego. Wyniki dla zbioru testowego są dobre, a dokładność klasyfikacji wyniosła 82,76%. Świadczy to o zadowalających zdolnościach generalizacyjnych modelu ($\Delta ACC = 6,61\%$).

Na rysunku 5.5 przedstawiono strukturę sieci Bayesa, wskazując kierunek wnioskowania oraz zmienne brane pod uwagę w procesie decyzyjnym.



Rys. 5.5. Struktura sieci dla klasyfikatora BN z metodą uczenia HC-TAN

Powyższa struktura sieci Bayesa również zbliżona jest do sieci odpowiadającej Naiwnemu Klasyfikatorowi Bayesowskiemu. Natomiast zauważalne jest odstępstwo od tej struktury dla kilku mniejszych grup zmiennych: **Kubat – Msp**, **RoFun – Powi**, **Rok – Snp**, **Dylat – KsuPrz – Rem**, **ZmPos – ZabUz**, **Szer – LiKon**. Niektóre z tych połączeń wydają się jak najbardziej uzasadnione, np. **Rem – KsuPrz**, a niektóre ocenia się jako nieoczywiste, jak np. **Kubat – Msp**.

5.3.7. Struktura BN z metodą uczenia HC-SP-TAN

Omawiane wyniki otrzymano przy wykorzystaniu metody uczenia *Hill-climbing super-parent tree augmented naive Bayes* (HC-SP-TAN). Wybrana metoda uczenia sieci HC-TAN jest wynikiem połączenia aż trzech metod: *tree augmented naive Bayes* (TAN) [155], z chciwym algorytmem wy-

krywania połączeń *Hill Climbing* (HC) oraz wyszukiwania i uwzględniania, tzw. Super Rodzica *Super Parent* (SP) [153].

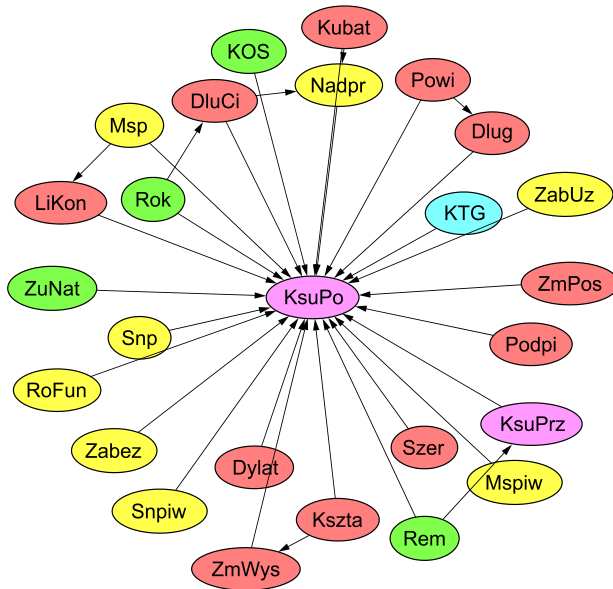
Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tabelicy 5.8.

Tablica 5.8. Macierz pomyłek klasyfikatora BN z metodą uczenia HC-SP-TAN

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	37	31	2	0	70	52,86%
	2	4	199	33	6	242	82,23%
	3	0	20	113	3	136	83,09%
	4	0	3	5	22	30	73,33%
Σ		41	253	153	31	478	72,88%
Czułość (TPR)		90,24%	78,66%	73,86%	70,97%	78,43%	77,62%
Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	9	3	0	0	12	75,00%
	2	2	59	6	0	67	88,06%
	3	0	3	18	2	23	78,26%
	4	0	1	2	11	14	78,57%
Σ		11	66	26	13	116	79,97%
Czułość (TPR)		81,82%	89,39%	69,23%	84,62%	81,26%	83,62%

Z tablicy 5.8 wynika, że zbudowany model charakteryzuje się zadowalającą dokładnością klasyfikacji wynoszącą 77,62% dla zbioru trenującego. Wyniki dla zbioru testowego są dobre, a dokładność klasyfikacji wyniosła 83,62%. Świadczy to o dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 6,0\%$).

Na rysunku 5.6 przedstawiono strukturę sieci Bayesa, wskazując kierunek wnioskowania oraz zmiennebrane pod uwagę w procesie decyzyjnym.



Rys. 5.6. Struktura sieci dla klasyfikatora BN z metodą uczenia HC-SP-TAN

Powyższa struktura sieci Bayesa również zbliżona jest do sieci odpowiadającej Naiwnemu Klasyfikatorowi Bayesowskiemu. Natomiast zauważalne jest odstępstwo od tej struktury dla kilku mniejszych grup zmiennych: **Msp – LiKon, Rok – DluCi – Nadpr – Kubat, Powi – Dlug, KsuPrz – Rem, ZmWys – Kszta**. Niektóre z tych połączeń wydają się jak najbardziej uzasadnione, np. **Powi – Dlug**, a niektóre ocenia się jako nieoczywiste, jak np. **DluCi – Nadpr**.

5.3.8. Struktura BN z metodą uczenia k-DB

Poniższe wyniki otrzymano przy wykorzystaniu metody uczenia *Hill-climbing k-dependence Bayesian classifier* (k-DB). Wybrana metoda uczenia sieci k-DB jest wynikiem połączenia dwóch metod: pozwalającej zmiennym na posiadanie maksymalnie k-krotności rodziców *k-dependence Bayesian classifier* (TAN) [159], z chciwym algorytmem wykrywania połączeń *Hill Climbing* (HC) [153].

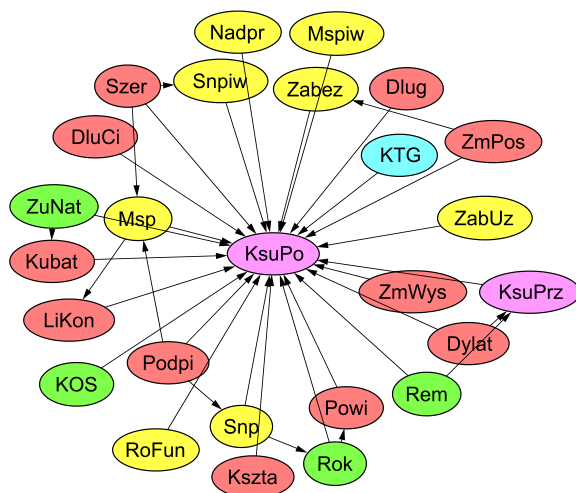
Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tabelicy 5.9.

Tablica 5.9. Macierz pomyłek klasyfikatora BN z metodą uczenia k-DB

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	37	18	0	0	55	67,27%
	2	4	211	29	6	250	84,40%
	3	0	18	118	4	140	84,29%
	4	0	6	6	21	33	63,64%
Σ		41	253	153	31	478	74,90%
Czułość (TPR)		90,24%	83,40%	77,12%	67,74%	79,63%	80,96%
Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	10	2	0	0	12	83,33%
	2	1	59	5	0	65	90,77%
	3	0	2	20	2	24	83,33%
	4	0	3	1	11	15	73,33%
Σ		11	66	26	13	116	82,69%
Czułość (TPR)		90,91%	89,39%	76,92%	84,62%	85,46%	86,21%

Z tablicy 5.9 wynika, że zbudowany model charakteryzuje się dobrą dokładnością klasyfikacji wynoszącą 80,96% dla zbioru trenującego. Wyniki dla zbioru testowego są dobre, a dokładność klasyfikacji wyniosła 86,21%. Świadczy to o dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 5,25\%$).

Na rysunku 5.7 przedstawiono strukturę sieci Bayesa, wskazując kierunek wnioskowania oraz zmienne brane pod uwagę w procesie decyzyjnym.



Rys. 5.7. Struktura sieci dla klasyfikatora BN z metodą uczenia *k-DB*

Powyższa struktura sieci Bayesa również zbliżona jest do wcześniej opisanych sieci. W strukturze powstało kilka mniejszych grup zmiennych: **Podpi – Snp – Rok – Powi**, **Podpi – Msp – LiKon**, **Szer – Snpiw – Msp**, **ZmPos – Zabez**, **KsuPrz – Dylat – Rem**.

Nieoczywiste jest duże znaczenie zmiennej **Podpi**, która w tej sieci ma bezpośredni lub pośredni wpływ na aż pięć innych zmiennych wejściowych: **Snp, Rok, Powi, Msp, LiKon**.

5.3.9. Struktura BN z metodą uczenia FSSJ

Wyniki otrzymano przy wykorzystaniu metody uczenia *Forward sequential selection and joining* (FSSJ). Wybrana metoda uczenia sieci FSSJ wykorzystuje algorytm sekwencyjnej selekcji i późniejszego łączenia [158].

Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tabelicy 5.10.

Z tabelicy 5.10 wynika, że zbudowany model charakteryzuje się dobrą dokładnością klasyfikacji wynoszącą 80,75% dla zbioru trenującego.

Wyniki dla zbioru testowego są dobre, a dokładność klasyfikacji wyniosła 83,62%. Świadczy to o bardzo dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 2,87\%$).

Zauważalna jest znaczna redukcja liczby zmiennych branych pod uwagę w procesie decyzyjnym, która zmniejszyła się z 25 do zaledwie 9. Dokładność klasyfikacji przy tak istotnej redukcji liczby zmiennych względem metod opisanych w rozdziale 5.3.2 zmniejszyła się jedynie o około 3%.

5.3.10. Struktura BN z metodą uczenia HC

Poniższe wyniki otrzymano przy wykorzystaniu metody uczenia *Hill-climbing* (HC). Wybrana metoda uczenia sieci HC do budowy struktury sieci wykorzystuje chciwy algorytm wykrywania połączeń *Hill Climbing* (HC) [156].

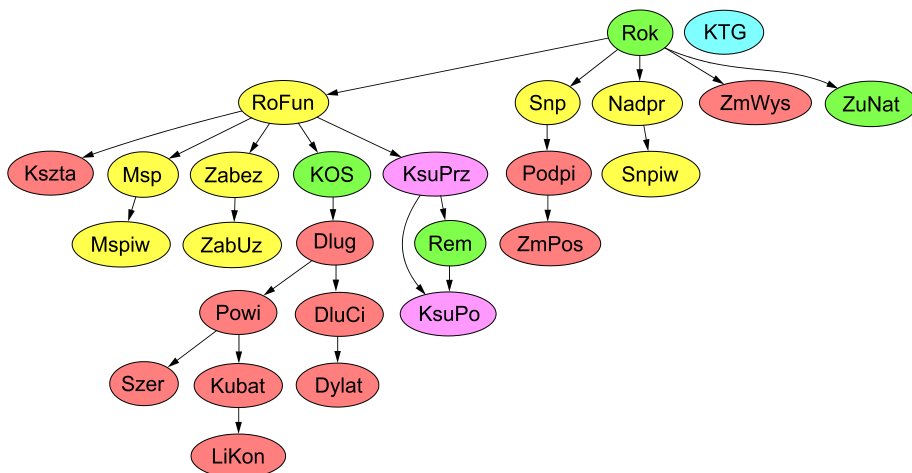
Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tabelicy 5.11.

Tabela 5.11. Macierz pomyłek klasyfikatora BN z metodą uczenia HC

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	39	21	3	1	64	60,94%
	2	2	232	67	8	309	75,08%
	3	0	0	83	10	93	89,25%
	4	0	0	0	12	12	100,00%
Σ		41	253	153	31	478	81,32%
Czułość (TPR)		95,12%	91,70%	54,25%	38,71%	69,94%	76,57%
Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	11	3	0	0	14	78,57%
	2	0	63	14	6	83	75,90%
	3	0	0	12	3	15	80,00%
	4	0	0	0	4	4	100,00%
Σ		11	66	26	13	116	83,62%
Czułość (TPR)		100,00%	95,45%	46,15%	30,77%	68,09%	77,59%

Z tablicy 5.11 wynika, że zbudowany model charakteryzuje się zadowalającą dokładnością klasyfikacji wynoszącą 76,57% dla zbioru trenującego. Wyniki dla zbioru testowego są zadowalające, a dokładność klasyfikacji wyniosła 77,59%. Świadczy to o bardzo dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 1,02\%$).

Na rysunku 5.9 przedstawiono strukturę sieci Bayesa, wskazując kierunek wnioskowania oraz zmienne brane pod uwagę w procesie decyzyjnym.



Rys. 5.9. Struktura sieci dla klasyfikatora BN z metodą uczenia HC

Ocenia się, że powyższa struktura sieci jest nie do zaakceptowania. Najbardziej istotną wadą jest brak wpływu kategorii terenu górniczego **KTG** na kategorii stanu uszkodzeń (**KsuPrz**, **KsuPo**), podczas gdy doświadczenia (rozdz. 2) jednoznacznie wskazują, że taki wpływ występuje. Interesujące jest, że na wynikową kategorię uszkodzeń **KsuPo** mają wpływ zaledwie cztery zmienne: **Rem**, **KsuPrz**, **RoFun** oraz **Rok**, a mimo to uzyskano dokładności klasyfikacji wynoszące ponad 76% dla zbiorów treningowego i testowego.

5.3.11. Struktura BN z metodą uczenia TABU

Omawiane wyniki otrzymano, wykorzystując metodę uczenia *TABU*. Metoda uczenia sieci *TABU* do budowy struktury sieci wykorzystuje algorytm przeszukiwania przestrzeni z uwzględnieniem ruchów niedozwolonych, ruchów tabu [156].

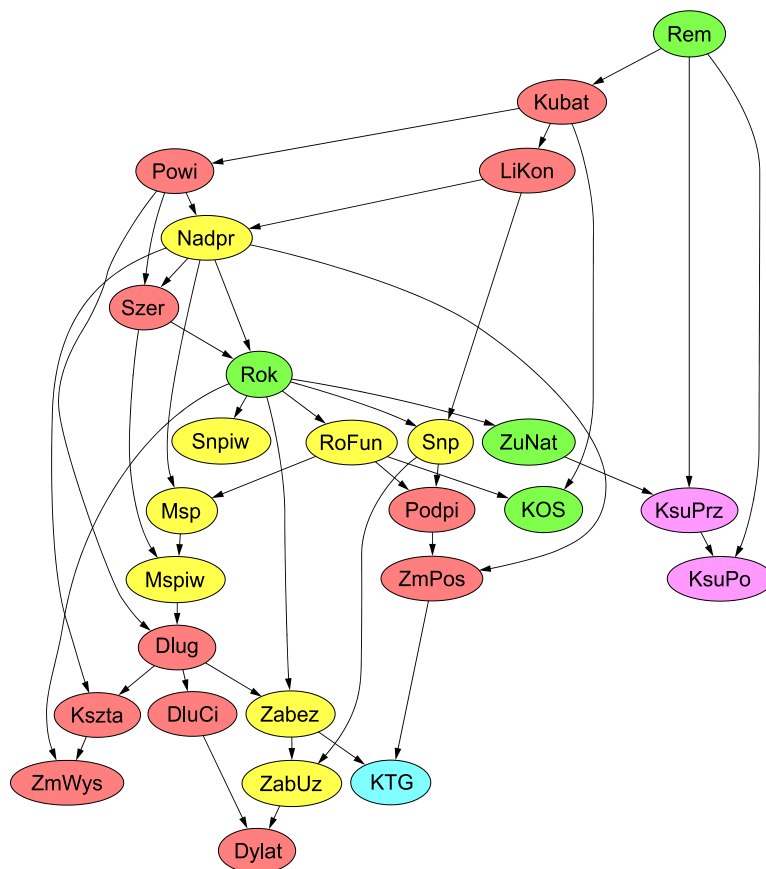
Utworzony model poddano ocenie w kontekście poprawności klasyfikacji na zbiorach trenującym i testowym oraz własności generalizacyjnych zgodnie z kryteriami podanymi w rozdziale 5.2. Wyniki w formie macierzy pomyłek przedstawiono w tabelicy 5.12.

Tablica 5.12. Macierz pomyłek klasyfikatora BN z metodą uczenia TABU

Zbiór trenujący – 478 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	39	21	3	1	64	60,94%
	2	2	232	67	8	309	75,08%
	3	0	0	83	10	93	89,25%
	4	0	0	0	12	12	100,00%
Σ		41	253	153	31	478	81,32%
Czułość (TPR)		95,12%	91,70%	54,25%	38,71%	69,94%	76,57%
Zbiór testowy – 116 przypadków							
Kategoria uszkodzeń (KsuPo)		zaobserwowana				Σ	Precyzja (PPV)
		1	2	3	4		
Przewidywana	1	11	3	0	0	14	78,57%
	2	0	63	14	6	83	75,90%
	3	0	0	12	3	15	80,00%
	4	0	0	0	4	4	100,00%
Σ		11	66	26	13	116	83,62%
Czułość (TPR)		100,00%	95,45%	46,15%	30,77%	68,09%	77,59%

Z tablicy 5.12 wynika, że zbudowany model charakteryzuje się zadowalającą dokładnością klasyfikacji wynoszącą 76,57% dla zbioru trenującego. Wyniki dla zbioru testowego są zadowalające, a dokładność klasyfikacji wyniosła 77,59%. Świadczy to o bardzo dobrych zdolnościach generalizacyjnych modelu ($\Delta ACC = 1,02\%$). Uzyskano takie same wyniki, jak dla metody uczenia HC.

Na rysunku 5.10 przedstawiono strukturę sieci Bayesa, wskazując kierunek wnioskowania oraz zmiennebrane pod uwagę w procesie decyzyjnym.



Rys. 5.10. Struktura sieci dla klasyfikatora BN z metodą uczenia TABU

Powyższa struktura sieci również nie jest akceptowalna. Najistotniejszą wadą jest brak wpływu kategorii terenu górniczego **KTG** na kategorie stanu uszkodzeń (**KsuPrz**, **KsuPo**). Natomiast na wynikową kategorię uszkodzeń **KsuPo** ma wpływ dziewięć zmiennych: **Rem**, **KsuPrz**, **Kubat**, **LiKon**, **Nadpr**, **Powi**, **Szer**, **ZuNat** oraz **Rok**. Pomimo znacznej redukcji zmiennych wejściowych uzyskano dokładności klasyfikacji wynoszące ponad 76% dla zbiorów treningowego i testowego.

5.3.12. Porównanie wyników dla różnych metod uczenia struktury sieci

Otrzymane wyniki, które zestawiono w formie macierzy pomyłek w rozdziale 5.3, pozwoliły na wybór optymalnej metody do budowy modelu ryzyka powstania uszkodzeń w nawiązaniu do autorskich kryteriów oceny opisanych w rozdziale 5.2.

W celu porównania wszystkich wyników uzyskanych różnymi metodami uczenia struktury sieci Bayesa zestawiono je w tablicy 5.13.

Mając na uwadze fakt, że wszystkie modele osiągnęły wysoki, co najmniej dobry, stopień poprawnej klasyfikacji dla zbioru trenującego, głównym kryterium wyboru optymalnej metody do dalszych badań była dokładność klasyfikacji dla zbioru testowego. Dodatkowo zwrócono uwagę na to, aby wybrana metoda charakteryzowała się możliwie wysokimi zdolnościami generalizacyjnymi, a także wysoką precyzją (PPV) i czułością (TPR), których miarą jest również wartość F_1 (F -score) [150, 151].

Tablica 5.13. Porównanie parametrów klasyfikacyjnych dla różnych metod uczenia sieci BN

Metoda uczenia sieci BN	ACC	PPV _{śr.}	TPR _{śr.}	ACC	PPV _{śr.}	TPR _{śr.}	F_1	Δ ACC
	zbiór treningowy			zbiór testowy				
TAN-CL AIC	83,89%	79,41%	83,96%	87,07%	85,60%	87,35%	86,47%	3,18%
TAN-CL BIC	77,82%	76,08%	77,31%	83,62%	82,22%	81,24%	81,73%	5,80%
TAN-CL loglik	84,94%	78,54%	88,25%	86,21%	83,16%	86,16%	84,63%	1,27%
BSEJ	76,15%	71,15%	75,63%	80,17%	74,63%	79,37%	76,93%	4,02%
HC-TAN	76,15%	69,05%	77,03%	82,76%	78,35%	80,86%	79,59%	6,61%
HC-SP-TAN	77,62%	72,88%	78,43%	83,62%	79,97%	81,26%	80,61%	6,00%
k-DB	80,96%	74,90%	79,63%	86,21%	82,69%	85,46%	84,05%	5,25%
FSSJ	80,75%	81,10%	76,05%	83,62%	88,43%	76,17%	81,84%	2,87%
HC	76,57%	81,32%	69,94%	77,59%	83,62%	68,09%	75,06%	1,02%
TABU	76,57%	81,32%	69,94%	77,59%	83,62%	68,09%	75,06%	1,02%

Z porównania wyników wyciągnięto następujące wnioski:

- najwyższe wyniki dla zbioru treningowego uzyskano dla metod PNN oraz SVM, ale wyniki dla zbioru testowego były niekorzystne; jako niewystarczające należy ocenić wyniki czułości (TPR) [1],

- wyniki dla metody NBC były bardzo nieregularne i zależały od zastosowanego pakietu; najlepsze z nich pozwalały na uzyskanie dokładności klasyfikacji porównywalnej z wynikami uzyskiwanymi metodami BN dla zbioru treningowego lub testowego; niestety wyniki żadnej z metod NBC nie były równie dobre jednocześnie dla zbioru treningowego i testowego [1],

- metody BN pozwalają na uzyskanie najlepszych wyników na zbiorze testowym, wynoszących powyżej 80% dla 8 z 10 metod uczenia sieci, a ich wyniki dla zbioru treningowego są dobre,

- wyniki uzyskane dla metod uczenia BN, uwzględniających wpływ wszystkich zmiennych wejściowych, są lepsze od wyników uzyskiwanych dla metod pozwalających na redukcję liczby zmiennych wejściowych, tj. FSSJ, HC, TABU.

Na podstawie przeprowadzonej analizy porównawczej otrzymanych wyników w postaci: dokładności klasyfikacji, średnich precyzji (PPV) i czułości (TPV) oraz wartości F_1 , do dalszych badań zakwalifikowano model BN wyłoniony z wykorzystaniem metody uczenia struktury sieci TAN-CL oraz funkcji celu AIC. Charakteryzuje się on najwyższą dokładnością klasyfikacji dla zbioru testowego, najwyższą średnią czułością oraz wartością F_1 . Również dla tej metody uzyskano dobre zdolności generalizacyjne, co potwierdza zasadność jej wyboru do dalszej analizy (rozd. 5.4 i 6).

5.4. Analiza wpływu zmiennych wejściowych na prognozowaną kategorię uszkodzeń

Przeprowadzona powyżej analiza wybranych sieci Bayesa wskazała na logiczne i uzasadnione połączenia przyczynowo-skutkowe poszczególnych zmiennych. Niestety ze struktury sieci nie wynika, jaki wpływ na prognozowane kategorie uszkodzeń mają poszczególne zmienne wejściowe, co jest przedmiotem analizy opisaną w rozdziale 5.4.

W celu lepszego zrozumienia wpływu zmiennych wejściowych na funkcjonowanie utworzonego modelu podjęto decyzję o przeprowadzeniu oceny wpływu tych zmiennych na dokładność klasyfikacji kategorii uszkodzeń. Analiza wpływu zmiennych wejściowych na stan uszkodzeń polegała na iteracyjnej eliminacji pojedynczych zmiennych (VE – *Variable Elimination*) ze struktury BN, a następnie symulacji jej działania w zmienionym zbiorze danych [116, 160]. Niestety, pakiet *bnclassify* nie pozwala na predykcję w przypadkach braku pełnej informacji o zestawie zmien-

nych wejściowych. W związku z tym zdecydowano o wykorzystaniu w tym celu pakietu *gRain* [140, 141]. Wyniki otrzymane po eliminacji zmiennych porównano z wynikami uzyskanymi dla wyjściowej struktury uwzględniającej wszystkie 25 zmiennych wejściowych.

Jako kryterium oceny istotności zmiennych zaproponowano cztery miary porównania wyników: dokładność klasyfikacji (ACC) dla zbiorów trenującego i testowego, precyzję (PPV) oraz czułość (TPR) dla zbioru testowego. Wyniki uzyskane dla każdej z eliminowanych osobno zmiennych zestawiono w tablicy 5.14, w której bazę porównawczą stanowi pierwszy wiersz z wynikami otrzymanymi dla oryginalnej struktury sieci (rozd. 5.3).

Tablica 5.14. Wpływ eliminacji zmiennych wejściowych na miary ACC, PPV_{Śr.}, TPR_{Śr.}

Eliminowana zmienna	Kod	ACC _{tren}	ACC _{test}	PPV _{Śr.}	TPR _{Śr.}
Wyniki wzorcowe dla wszystkich zmiennych	-	83,89%	87,07%	85,60%	87,35%
Długość	Dług	83,68%	87,93%	87,90%	87,73%
Szerokość	Szer	83,47%	87,07%	85,60%	87,35%
Powierzchnia zabudowy	Powi	83,68%	86,21%	85,00%	86,39%
Liczba kondygnacji nadziemnych	LiKon	84,31%	86,21%	84,06%	86,98%
Kubatura	Kubat	84,10%	87,93%	86,56%	88,69%
Długość ciągu zabudowy zwartej	DluCi	83,89%	87,93%	87,90%	87,73%
Sposób dylatowania	Dylat	84,52%	87,07%	85,60%	87,35%
Kształt bryły budynku	Kszta	84,10%	87,07%	85,60%	87,35%
Podpiwniczenie	Podpi	84,10%	87,07%	85,60%	87,35%
Zmienny poziom posadowienia	ZmPos	83,89%	87,07%	85,60%	87,35%
Zmienna wysokość budynku	ZmWys	83,89%	87,07%	85,60%	87,35%
Rodzaj fundamentu	RoFun	84,10%	87,07%	85,60%	87,35%
Materiał ścian piwnic	Msp	83,89%	87,07%	85,60%	87,35%
Materiał ścian parteru i wyżej	Mspiw	83,89%	86,21%	83,48%	86,39%
Strop nad piwnicą	Snp	83,68%	87,93%	86,26%	87,73%

Eliminowana zmienna	Kod	ACC _{tren}	ACC _{test}	PPV _{Sr.}	TPR _{Sr.}
Strop nad parterem i wyżej	Snpiw	83,89%	87,07%	85,60%	87,35%
Nadproża	Nadpr	84,10%	87,93%	86,26%	87,73%
Zabezpieczenia na wpływy górnicze	Zabez	84,31%	87,07%	85,60%	87,35%
Zabezpieczenia (dane uzupełniające dotyczące kotwienia)	ZabUz	84,10%	87,07%	85,60%	87,35%
Rok budowy	Rok	84,10%	87,07%	85,60%	87,35%
Zużycie naturalne (stan techniczny)	ZuNat	83,47%	85,34%	81,57%	87,56%
Współczynnik remontowy	Rem	75,10%	80,17%	76,79%	80,68%
Kategoria odporności statycznej (deformacyjnej)	KOS	84,52%	88,79%	86,84%	88,69%
Kategoria terenu górniczego	KTG	84,73%	86,21%	83,33%	85,43%
Kategoria stanu uszkodzeń przed wpływami	KsuPrz	78,45%	83,62%	79,52%	83,36%

W tablicy 5.15 przedstawiono wpływ eliminacji poszczególnych zmiennych na zmianę (Δ) miar ACC, PPV i TPR. Głównym kryterium uporządkowania ważności zmiennych była dokładność klasyfikacji dla zbioru testowego (por. rozdz. 5.3.4). Kolejność zmiennych została uporządkowana od najistotniejszej do zmiennej o najmniejszej istotności według przyjętej metodyki oceny.

Tablica 5.15. Wpływ eliminacji zmiennych wejściowych na zmiany miar ACC, PPV_{Sr.}, TPR_{Sr.}

Eliminowana zmienna	Kod	Δ ACC _{tren.}	Δ ACC _{test}	Δ PPV _{Sr.}	Δ TPR _{Sr.}
Współczynnik remontowy	Rem	-8,79%	-6,90%	-8,81%	-6,67%
Kategoria stanu uszkodzeń przed wpływami	KsuPrz	-5,44%	-3,45%	-6,09%	-3,99%
Zużycie naturalne (stan techniczny)	ZuNat	-0,42%	-1,72%	-4,03%	0,20%
Kategoria terenu górniczego	KTG	0,84%	-0,86%	-2,27%	-1,92%
Materiał ścian parteru i wyżej	Mspiw	0,00%	-0,86%	-2,12%	-0,96%

Eliminowana zmienna	Kod	$\Delta ACC_{tren.}$	ΔACC_{test}	$\Delta PPV_{\bar{s}r.}$	$\Delta TPR_{\bar{s}r.}$
Liczba kondygnacji nadziemnych	LiKon	0,42%	-0,86%	-1,54%	-0,38%
Powierzchnia zabudowy	Powi	-0,21%	-0,86%	-0,60%	-0,96%
Szerokość	Szer	-0,42%	0,00%	0,00%	0,00%
Sposób dylatowania	Dylat	0,63%	0,00%	0,00%	0,00%
Kształt bryły budynku	Kszta	0,21%	0,00%	0,00%	0,00%
Podpiwniczenie	Podpi	0,21%	0,00%	0,00%	0,00%
Zmienny poziom posadowienia	ZmPos	0,00%	0,00%	0,00%	0,00%
Zmienna wysokość budynku	ZmWys	0,00%	0,00%	0,00%	0,00%
Rodzaj fundamentu	RoFun	0,21%	0,00%	0,00%	0,00%
Materiał ścian piwnic	Msp	0,00%	0,00%	0,00%	0,00%
Strop nad parterem i wyżej	Snpiw	0,00%	0,00%	0,00%	0,00%
Zabezpieczenia na wpływy górnicze	Zabez	0,42%	0,00%	0,00%	0,00%
Zabezpieczenia (dane uzupełniające dotyczące kotwienia)	ZabUz	0,21%	0,00%	0,00%	0,00%
Rok budowy	Rok	0,21%	0,00%	0,00%	0,00%
Strop nad piwnicą	Snp	-0,21%	0,86%	0,66%	0,38%
Nadproża	Nadpr	0,21%	0,86%	0,66%	0,38%
Kubatura	Kubat	0,21%	0,86%	0,96%	1,34%
Długość	Dług	-0,21%	0,86%	2,30%	0,38%
Długość ciągu zabudowy zwartej	DluCi	0,00%	0,86%	2,30%	0,38%
Kategoria odporności statycznej (deformacyjnej)	KOS	0,63%	1,72%	1,24%	1,34%

Analiza uzyskanych wyników pozwala na sformułowanie następujących wniosków:

1. Najistotniejsze są zmienne **Rem** i **KsuPrz**. Po eliminacji każdej z nich ze struktury modelu zauważalna jest znaczna ($\Delta ACC > 3\%$) utrata do-

kładności klasyfikacji na zbiorze testowym; wiąże się z tym również pogorszenie dokładności klasyfikacji na zbiorze trenującym oraz średnich wartości precyzji (PPV) i czułości (TPR).

2. Istotne są zmienne **ZuNat, KTG, Mspiw, LiKon, Powi**. Po eliminacji każdej z nich zauważalna jest utrata dokładności klasyfikacji na zbiorze testowym o wartości rzędu $0\% < \Delta ACC < 2\%$. Dla większości zmiennych z tej grupy stwierdza się również pogorszenie średniej precyzji (PPV) i czułości (TPR). Zmiana dokładności klasyfikacji na zbiorze trenującym w przypadku eliminacji tych zmiennych nie wykazuje wyraźnych tendencji wzrostowych lub spadkowych.

3. Zmienne o niewielkiej istotności w modelu to **Szer, Dylat, Kszta, Podpi, ZmPos, ZmWys, RoFun, Msp, Snpiw, Zabez, ZabUz, Rok**. Po eliminacji każdej z nich następuje znikoma wręcz zmiana parametrów ACC, PPV, TPR na zbiorze testowym. Dla większości zmiennych z tej grupy stwierdza się również niewielką poprawę dokładności klasyfikacji na zbiorze trenującym.

4. Stwierdzono, że w strukturze modelu występuje sześć zmiennych (**Snp, Nadpr, Kubat, Dług, DluCi, KOS**), których eliminacja poprawia parametry ACC, PPV i TPR na zbiorze testowym. Dla większości zmiennych z tej grupy zaobserwowano również niewielką poprawę dokładności klasyfikacji na zbiorze trenującym. Na podstawie uzyskanych wyników nie zaleca się jednak rezygnacji z wykorzystania tych zmiennych. Uzyskane zaburzenie może być spowodowane nieproporcjonalnym udziałem tych zmiennych w zbiorach trenującym i testowym.

5. Podsumowując, największe znaczenie dla stopnia uszkodzeń mają zmienne wynikające z użytkowania obiektu **Rem, ZuNat** oraz jego stopnia uszkodzeń zaobserwowanego przed eksploatacją górniczą **KsuPrz**. Ze zmiennych konstrukcyjnych największe znaczenie ma **Mspiw**, a ze zmiennych geometrycznych **LiKon** i **Powi**.

Przeprowadzone badania pozwoliły zidentyfikować zmienne wyjściowe o największym wpływie na dokładność klasyfikacji kategorii uszkodzeń budynku, tj. zmienne **Rem** i **KsuPrz**. Uzyskane informacje pozwalają na lepsze zrozumienie działania utworzonego modelu oceny ryzyka powstania uszkodzeń.

Zbudowany i przeniezalizowany w rozdziale 5 model oceny ryzyka powstania uszkodzeń może zostać wykorzystany zarówno w przypadku predykcji kategorii uszkodzeń budynku, jak również w celu diagnozowania przyczyn uszkodzeń (rozdz. 4.2); warianty jego wykorzystania przedstawiono w rozdziale 6.

6. WARIANTY WYKORZYSTANIA UTWORZONEGO MODELU OCENY RYZYKA POWSTANIA USZKODZEŃ W BUDOWNICTWIE NA TERENACH GÓRNICZYCH

6.1. Uwagi ogólne

Opisany w rozdziale 5 model oceny ryzyka powstania uszkodzeń w postaci sieci Bayesa pozwala na jego stosowanie w wielu wariantach (rozd. 4.2). Wszelchność wykorzystania modelu BN jest rzadko spotykana w przypadku innych metod inteligencji obliczeniowej, ale jest często doceniana przez jego użytkowników [112, 161–164]. W niniejszym rozdziale przedstawiono możliwe warianty wykorzystania utworzonego modelu oceny ryzyka powstania uszkodzeń:

- symulację działania modelu do predykcji powstania uszkodzeń dla czterech wyselekcjonowanych budynków z bazy danych,
- możliwość wykorzystania utworzonego modelu w sytuacji diagnostycznej, tj. do ustalenia przyczyn zaobserwowanych uszkodzeń,
- symulację działania modelu w przypadku niepełnych danych o budynku bądź wpływach eksploatacji górniczej.

6.2. Symulacja działania modelu do predykcji powstania uszkodzeń danej kategorii

W celu prezentacji działania utworzonego modelu dokonano symulacji dla czterech reprezentatywnych budynków wybranych z bazy danych. Zostały one przedstawione na rysunkach 6.1 – 6.4.

Przykładowe budynki wyselekcjonowano spośród wszystkich obiektów poddanych analizie, a ich parametry zostały zestawione w tablicy 6.1. W tablicy podano rzeczywiste wartości dla poszczególnych zmiennych liczbowych, a także w nawiasach numery kategorii, do których przypisano je na etapie dyskretyzacji danych (rozd. 5.1) [133].



Rys. 6.1. Widok budynku 1 wybranego do symulacji działania modelu



Rys. 6.2. Widok budynku 2 wybranego do symulacji działania modelu



Rys. 6.3. Widok budynku 3 wybranego do symulacji działania modelu



Rys. 6.4. Widok budynku 4 wybranego do symulacji działania modelu

Tablica 6.1. Dane dla czterech wybranych budynków

Zmienna	Kod	Budynek 1	Budynek 2	Budynek 3	Budynek 4
Długość [m]	Dług	22,1 (7)	19,8 (6)	12,2 (2)	16,7 (4)
Szerokość [m]	Szer	11,0 (3)	11,8 (4)	12,2 (5)	10,6 (3)
Powierzchnia zabudowy [m ²]	Powi	243,1 (8)	233,64 (8)	148,84 (3)	177,02 (5)
Liczba kondygnacji nadziemnych	LiKon	3,5	2,5	1,5	2,5

Zmienna	Kod	Budynek 1	Budynek 2	Budynek 3	Budynek 4
Kubatura [m ³]	Kubat	2431,00 (9)	2102,76 (8)	744,20 (2)	1593,18 (6)
Długość ciągu zabudowy [m]	DluCi	22,1 (7)	22,2 (7)	12,2 (2)	16,7 (4)
Sposób dylatowania	Dylat	nie dotyczy	na styk z budynkiem sąsiednim	nie dotyczy	nie dotyczy
Kształt bryły budynku	Kszta	rzut prosty, bryła wydłużona	rzut prosty, bryła zwarta	rzut prosty, bryła zwarta	rzut prosty, bryła wydłużona
Podpiwniczenie	Podpi	całkowite	całkowite	brak	całkowite
Zmienny poziom posadowienia	ZmPos	nie	nie	nie	nie
Zmienna wysokość budynku	ZmWys	nie	nie	nie	nie
Rodzaj fundamentu	RoFun	kamienne	kamienne	żelbetowe	murowane z cegieł
Materiał ścian piwnic	Msp	murowane z cegieł	murowane z kamienia	murowane z bloczków betonowych	murowane z cegieł
Materiał ścian parteru i wyżej	Mspiw	murowane z cegieł	murowane z cegieł	murowane z pustaków	murowane z cegieł
Strop nad piwnicą	Snp	odcinkowy na dźwigarach stalowych	odcinkowy na dźwigarach stalowych	brak	betonowy na belkach stalowych
Strop nad parterem i wyżej	Snpiw	drewniany	drewniany	drewniany	drewniany
Nadproża	Nadpr	łukowe	łukowe	belkowe	ceglane płaskie
Zabezpieczenia na wpływy górnicze	Zabez	w poziomie wszystkich stropów	w poziomie wszystkich stropów	w poziomie fundamentów i wszystkich stropów	w poziomie wszystkich stropów

Zmienna	Kod	Budynek 1	Budynek 2	Budynek 3	Budynek 4
Zabezpieczenia – dane uzupełniające dotyczące kotwienia	ZabUz	długie elementy oporowe	krótkie elementy oporowe	brak	długie elementy oporowe
Rok budowy	Rok	1898 (1)	1900 (1)	2007 (8)	1940 (5)
Zużycie naturalne (stan techniczny)	ZuNat	średni	zły	dobry	zadowalający
Współczynnik remontowy	Rem	0	0	0	1
Kategoria odporności statycznej	KOS	1	3	3	2
Kategoria terenu górniczego	KTG	II (2)	II (2)	III (3)	II (2)
Kategoria stanu uszkodzeń przed wpływami	KsuPrz	2	2	1	3
Kategoria stanu uszkodzeń po wpływach	KsuPo	2	4	2	2

Biorąc pod uwagę fakt, że możliwe jest uszczegółowienie wyników o wartość prawdopodobieństwa wystąpienia uszkodzeń danej kategorii, przeprowadzono symulacje działania modelu, którego wyniki zostały zestawione w tabelicy 6.2.

Tablica 6.2. Prawdopodobieństwo wystąpienia kategorii uszkodzeń (**KsuPo**) dla wybranych czterech budynków

Przewidywana kategoria uszkodzeń (KsuPo)	Prawdopodobieństwo dla			
	budynku 1	budynku 2	budynku 3	budynku 4
1	0,00%	0,00%	0,02%	0,00%
2	100,00%	0,01%	99,98%	90,34%

Przewidywana kategoria uszkodzeń (KsuPo)	Prawdopodobieństwo dla			
	budynku 1	budynku 2	budynku 3	budynku 4
3	0,00%	0,00%	0,00%	9,66%
4	0,00%	99,99%	0,00%	0,00%

Model przewiduje konkretną kategorię uszkodzeń budynku murowanego dla wyniku o największym prawdopodobieństwie wystąpienia. Uzyskane wyniki wskazują na prawidłową predykcję wystąpienia:

- 2. kategorii uszkodzeń dla budynku 1 z prawdopodobieństwem wynoszącym 100,00%,
- 4. kategorii uszkodzeń dla budynku 2 z prawdopodobieństwem wynoszącym 99,99%,
- 2. kategorii uszkodzeń dla budynku 3 z prawdopodobieństwem wynoszącym 99,98%,
- 2. kategorii uszkodzeń dla budynku 4 z prawdopodobieństwem wynoszącym 90,34%.

Takie wyniki, zapisane w notacji probabilistycznej podającej prawdopodobieństwo wystąpienia uszkodzenia o danej intensywności, można utożsamiać z oceną ryzyka wystąpienia uszkodzeń w analizowanym budynku. Znając geometryczno-konstrukcyjne dane budynku, jego kategorię uszkodzeń przed eksploatacją górnictwem i prognozowane wpływy górnicze, za pomocą utworzonego modelu można przewidzieć jakie jest prawdopodobieństwo wystąpienia danej kategorii uszkodzeń, co należy rozumieć jako **ocenę ryzyka powstania uszkodzeń danej intensywności**.

6.3. Wykorzystanie sieci w przypadku diagnozy przyczyn zaobserwowanych uszkodzeń

Ustalona BN reprezentująca model ryzyka powstania uszkodzeń pozwala nie tylko na przewidywanie negatywnego wpływu eksploatacji górniczej na stan uszkodzeń, ale również na diagnozę przyczyny ich powstania. W przypadku diagnozy uszkodzeń rozstrzygająca będzie ocena ilościowa istotności wpływów górniczych podana w notacji probabilistycznej.

Przeprowadzono diagnozę wpływu odkształceń poziomych odpowiadających kategorii terenu górniczego (**KTG**) dla wytypowanych wcześniej czterech budynków. Wyniki analizy zestawiono w tablicy 6.3.

Tablica 6.3. Prawdopodobieństwo wystąpienia kategorii terenu górniczego (**KTG**) dla wybranych czterech budynków

Diagnozowana kategoria terenu górniczego (KTG)	Prawdopodobieństwo dla			
	budynku 1	budynku 2	budynku 3	budynku 4
I	8,79%	11,40%	8,79%	8,79%
II	44,51%	40,89%	44,51%	44,51%
III	46,71%	47,71%	46,71%	46,71%

Uzyskane wyniki wskazują dla wszystkich 4 analizowanych budynków jako przyczynę wystąpienia zaobserwowanego stanu uszkodzeń:

- III kategorię terenu górniczego z prawdopodobieństwem w przedziale od 46% do 48%,
- II kategorię terenu górniczego z prawdopodobieństwem w przedziale od 40% do 45%,
- I kategorię terenu górniczego z prawdopodobieństwem w przedziale od 8% do 12%.

W analizowanych przypadkach model diagnozuje **prawidłową** kategorię terenu górniczego z prawdopodobieństwem wynoszącym od 40% do 48%. Właściwa diagnoza przyczyn zaobserwowanych uszkodzeń jest już mniej precyzyjna. Może to wynikać ze zbliżonych skutków wpływu oddziaływań górnich charakteryzowanych przez II i III kategorię terenu górniczego w zabudowie będącej przedmiotem badań, gdyż sumaryczne prawdopodobieństwo wpływu tych oddziaływań na stan uszkodzeń wynosi około 90%. Należy jednak zaznaczyć, że w przyjętej metodyce interpretacja wartości prawdopodobieństwa jest odmienna i wskazuje raczej na pewność w ujęciu subiektywnym, niż możliwość wystąpienia danego zdarzenia, w przeciwieństwie do założeń klasycznego ujęcia probabilistyki [34].

6.4. Wykorzystanie sieci w przypadku niepełnych danych

Sieć Bayesa utworzona do oceny ryzyka pozwala również na przeprowadzenie oceny w przypadku posiadania niepełnych (lub niepewnych) danych [36]. Dane niepełne to te, których nie udało się ustalić na etapie gromadzenia danych i nie ma ich w bazie danych. Przykładami takich danych są: rok budowy, rodzaj fundamentu bez wykonywania jego odkrywki, rodzaj stropu nad piwnicą, do wnętrza której nie było dostępu, zabezpieczenie budynku na wpływy górnice, czy kategoria stanu uszko-

dzeń przed eksploatacją górnictw. W przypadku braku danych dla wybranej zmiennej i przyjęcia jej wartości np. na podstawie wiedzy i doświadczeń eksperta, to taką wartość nazywa się niepewną.

Podczas inwentaryzacji budynków, które poddane będą wpływow eksploatacji górnictw, niejednokrotnie trudno jest jednoznacznie ustalić wartości pewnych zmiennych. Niżej przedstawiono symulację wartości zmiennych niepełnych na podstawie pozostałych danych. Weryfikacji poddano prawdopodobne wartości dwóch zmiennych niepełnych dla wszystkich czterech budynków, której wyniki zostały zestawione w tablicach 6.4 i 6.5. Dodatkowo dla budynku 1 przeprowadzono symulację kilku danych niepełnych, której wyniki przedstawiono w tablicy 6.6.

Tablica 6.4. Wyniki analizy zmiennej dotyczącej zabezpieczeń budynku na wpływy górnictw dla czterech budynków

Brakująca (niepełna) dana – zabezpieczenie na wpływy górnictw (Zabez)		Prawdopodobieństwo dla			
		budynku 1	budynku 2	budynku 3	budynku 4
1	brak wzmocnień	0,02%	15,41%	12,77%	40,25%
2	w poziomie fundamentów i wszystkich stropów	1,63%	0,08%	78,68%	1,81%
3	w poziomie niektórych stropów	20,97%	0,08%	0,02%	4,82%
4	w poziomie wszystkich stropów	77,39%	84,43%	8,52%	53,11%

Uzyskane wyniki wskazują na **prawidłową** ocenę zabezpieczenia budynków 1, 2 i 4 w poziomie wszystkich stropów z prawdopodobieństwem wynoszącym odpowiednio 77,39; 84,43 i 53,11% oraz prawidłową ocenę zabezpieczenia budynku 3 w poziomie fundamentów i wszystkich stropów wynoszącą 78,68%.

Tablica 6.5. Wyniki analizy zmiennej dotyczącej konstrukcji stropu nad piwnicą dla czterech budynków

Brakująca (niepełna) dana – rodzaj stropu nad piwnicą (Snp)		Prawdopodobieństwo dla			
		budynku 1	budynku 2	budynku 3	budynku 4
1	betonowy na belkach stalowych	0,02%	0,13%	0,00%	23,30%
2	brak	0,00%	0,10%	99,99%	0,00%

Brakująca (niepełna) dana – rodzaj stropu nad piwnicą (Snp)		Prawdopodobieństwo dla			
		budynku 1	budynku 2	budynku 3	budynku 4
3	Kleina	17,00%	12,86%	0,00%	49,53%
4	odcinkowy na dźwigarach stalowych	82,96%	86,80%	0,00%	24,48%
5	żelbetowy lub gęstożebrowy z wieńcem	0,02%	0,13%	0,01%	2,69%

Wyniki z tablicy 6.5 wskazują na **prawidłową** klasyfikację rodzaju stropu nad piwnicą budynków 1 i 2 z prawdopodobieństwem wynoszącym ponad 82% oraz brak stropu nad piwnicą budynku 3 z 99,99% prawdopodobieństwem. Model **błędnie** ocenił strop nad piwnicą w budynku 4 jako Kleina z 49,53% prawdopodobieństwem, gdy w rzeczywistości jest to strop betonowy na belkach stalowych (23,30%).

Tablica 6.6. Wyniki analizy danych niepełnych dotyczących wybranych pięciu zmiennych dla budynku 1

Nr kategorii dla wybranej zmiennej	Prawdopodobieństwo wybranych danych niepełnych				
	Rok	RoFun	Zabez	Snp	KsuPrz
1	23,46%	7,98%	0,02%	12,37%	0,01%
2	15,19%	92,02%	1,63%	0,00%	0,01%
3	6,06%	0,00%	20,97%	36,88%	84,60%
4	9,15%	–	77,39%	49,23%	15,38%
5	46,14%	–	–	1,52%	–
6	0,00%	–	–	–	–
7	0,00%	–	–	–	–

Uzyskane wyniki wskazują na znaczne pogorszenie efektów działania zbudowanego modelu w przypadku braku aż 5 zmiennych (danych niepełnych). **Prawidłowo** oceniono zmienne **Zabez** z 77,39% prawdopodobieństwem i **Snp** z prawdopodobieństwem wynoszącym 49,23%. Tworzony model **błędnie** ocenił zmienne **Rok**, **RoFun** i **KsuPrz**.

Przeprowadzona analiza wskazuje na dość dobre i skuteczne funkcjonowanie modelu w przypadku niepełnej informacji dotyczącej wartości pojedynczych zmiennych (tabl. 6.4 i 6.5). W przypadku braku informacji o aż 5 wybranych danych (zmiennych) uzyskiwane wyniki charakteryzują się zdecydowanie większą rozbieżnością w odniesieniu do wartości zaobserwowanych (tabl. 6.6). Na podstawie wyników powyższych analiz można stwierdzić, że nie jest zalecane stosowanie utworzonego modelu w przypadkach braku danych o więcej niż jednej zmiennej.

7. PODSUMOWANIE, WNIOSKI ORAZ DALSZY KIERUNKI BADAŃ

1. Podziemna eksploatacja górnicza powoduje deformacje powierzchni terenu, które w praktyce inżynierskiej opisuje się jako nieckę obniżen. Jednym z najważniejszych wskaźników tej deformacji są odkształcenia poziome ε , które niejednokrotnie przyczyniają się do powstania uszkodzeń budynków. Dotychczas nie opracowano skutecznego i uniwersalnego narzędzia umożliwiającego ocenę ryzyka powstania uszkodzeń budynków murowanych z możliwością ilościowego wskazania ich zakresu i intensywności.

2. Metody wykorzystujące inteligencję obliczeniową pozwalają na symulację skomplikowanych wielowymiarowych procesów w różnych dziedzinach nauki. Spośród wielu metod wybrano takie, które pozwalają na uzyskanie wyników wskazujących na prawdopodobieństwo wystąpienia konkretnego zdarzenia związanego z powstaniem uszkodzeń o danej intensywności. Takie prawdopodobieństwo można interpretować jako ocenę ryzyka, którym w niniejszej rozprawie jest wystąpienie uszkodzeń budynków przyporządkowanych do jednej z czterech kategorii.

3. W celu wskazania optymalnego sposobu rozwiązania problemu przeprowadzone zostały badania z wykorzystaniem czterech wybranych metod inteligencji obliczeniowej (rozd. 5). Spośród wszystkich uzyskanych rezultatów w analizowanym przypadku najlepszymi wynikami wykazał się model zbudowany z wykorzystaniem sieci Bayesa (BN). Otrzymane za jego pomocą wyniki charakteryzują się najwyższą dokładnością klasyfikacji (ACC) zbioru testowego, najwyższą średnią czułością (TPR) oraz najlepszą wartością F_1 . Również dla tej metody uzyskano najlepsze zdolności generalizacyjne.

4. Stworzone z wykorzystaniem sieci Bayesa i różnych metod uczenia modele oceny ryzyka powstania uszkodzeń zostały opisane i przeanalizowane pod kątem ich struktury oraz wpływu poszczególnych zmiennych wejściowych na kategorię uszkodzeń (rozd. 5.3 i 5.4).

A. Najlepsze wyniki uzyskano dla sieci zbudowanej z wykorzystaniem metody uczenia TAN-CL i funkcji celu AIC. W trakcie wyłaniania struktury sieci nie wymuszano ani nie blokowano konkretnych połączeń pomiędzy węzłami reprezentującymi zmienne wejściowe. Spośród 48 połą-

czeń węzłów w uzyskanej strukturze sieci pozytywnie oceniono 45 połączeń, a 3 połączenia oceniono neutralnie.

B. Ocena wpływu zmiennych wejściowych na stan uszkodzeń została wykonana poprzez tzw. eliminację zmiennych. W wyniku przeprowadzonych wielokrotnych eliminacji stwierdzono, że największe znaczenie dla działania modelu mają zmienne **Rem** i **KsuPrz**. Nieznacznie mniejsze, ale również istotne znaczenie mają zmienne **ZuNat**, **KTG**, **Mspiw**, **LiKon**, **Powi**. Ocenia się, że model prawidłowo wskazuje na duży udział wyżej wymienionych zmiennych w ocenie ryzyka powstania uszkodzeń.

Zastanawiający jest niewielki wpływ zmiennych **Dług**, **Zabez**, **KOS**, **Rok** na prognozowanie kategorii uszkodzeń. Po przeprowadzonym rozpoznaniu literaturowym (rozdz. 2) spodziewano się większego ich wpływu na stan uszkodzeń budynków.

5. W rozdziale 6 monografii zaprezentowano możliwe sytuacje wykorzystania zbudowanego modelu.

A. Wykazano jego wysoką skuteczność w prognozie kategorii stanu uszkodzeń dla wybranych 4 budynków, która wystąpi po ujawnieniu się wpływów eksploatacji górniczej. Za pomocą utworzonego modelu można przewidzieć jakie jest prawdopodobieństwo wystąpienia uszkodzeń danej kategorii po ujawnieniu się wpływów górniczych, co należy rozumieć jako **ocenę ryzyka powstania uszkodzeń** w budynku murowanym.

B. Przedstawiono możliwość zastosowania utworzonego modelu do diagnozy przyczyn zaobserwowanej kategorii uszkodzeń. W analizowanych przypadkach model diagnozuje prawidłową kategorię terenu z prawdopodobieństwem wynoszącym od 40% do 48%. Taki stan rzeczy najpewniej wynika z podobnych skutków wpływu oddziaływań górniczych charakteryzowanych przez II i III kategorię terenu górniczego w zabudowie będącej przedmiotem badań.

C. Przeprowadzono symulację działania modelu w przypadku bazy danych zawierającej niepełne informacje o wartościach zmiennych, tj. brakujących informacji odnośnie do poszczególnych zmiennych wejściowych. Wskazuje ona na możliwe stosowanie modelu z wysoką skutecznością w przypadku braku pojedynczych danych. W przypadku braku aż 5 wybranych danych (zmiennych) uzyskiwane wyniki charakteryzują się zdecydowanie większą rozbieżnością od rzeczywistych wartości.

6. Zbudowany został model BN wykorzystujący inteligencję obliczeniową i pozwalający na ocenę ryzyka powstania uszkodzeń w notacji probabilistycznej. Wyniki przeprowadzonych analiz jednoznacznie wskazały na możliwość prognozy powstania uszkodzeń budynku murowanego z wysoką skutecznością, opisywaną przez dokładność klasyfikacji wynoszącą ponad 87%.

7. Uzyskane wyniki mogą mieć zastosowanie przy diagnozowaniu budynków zlokalizowanych na terenach górniczych. Zaproponowana metodologia może być stosowana w kontekście zachowania bezpieczeństwa powszechnego w budynkach poddanych wpływowi ciągłych deformacji terenu. Pozwala ona na wybiegającą w przód ocenę zachowania się konstrukcji budynku, w odniesieniu do konkretnych uwarunkowań górniczych, przy uwzględnieniu tych wszystkich zmiennych, które omówiono w monografii.

W toku przeprowadzonych analiz zaobserwowano kilka kierunków do dalszych badań związanych z podjętym tematem.

1. Zachowanie uniwersalności modelu determinuje rezygnację z podziału wpływów górniczych na odkształcenia poziomie o charakterze rozciągań $\varepsilon^{(+)}$ i ściskań $\varepsilon^{(-)}$. Na podstawie zgromadzonej bazy danych możliwe jest przeprowadzenie analizy z uwzględnieniem tego podziału. Uzyskane rezultaty mogłyby wykazać, jakie oddziaływanie ma większy wpływ na stan uszkodzeń budynku poddanego wpływowi górniczym. Zdaniem autora może się to przyczynić do bardziej precyzyjnego opisu modelowanego procesu związanego z powstawaniem uszkodzeń w budynkach murowanych.

2. Możliwość wykorzystania metod inteligencji obliczeniowej wymaga skategoryzowanych danych wejściowych, a więc przeprowadzenia procesu dyskretyzacji. Zaproponowane w rozprawie kategorie zmiennych liczbowych uznano za miarodajne i reprezentatywne. Jednakże widzi się możliwość przygotowania innego zestawu danych wejściowych dla zmienionych kategorii i ponownego dostrojenia modelu oceny ryzyka. Uzyskane w ten sposób wyniki mogą dostarczyć więcej informacji o optymalnej dyskretyzacji danych wejściowych. W tym celu widzi się zasadność wykorzystania metod bazujących na eksploracji danych (*DM – data mining*).

3. Przeprowadzono analizę połączeń wyłonionej struktury BN. Analiza sieci uzyskanych przy wykorzystaniu różnych metod uczenia mogłaby dostarczyć wielu informacji o istotności poszczególnych zmiennych w ocenie powstania uszkodzeń budynków.

4. Zastosowanie utworzonego modelu w celu diagnozowania górniczych przyczyn dla zaobserwowanych uszkodzeń wykazało jego nieprecyzyjność. Widzi się zasadność w poszerzeniu zbioru analizowanych przypadków o obiekty poddane wpływowi odkształceń poziomych odpowiadających I kategorii terenu górniczego. Niestety w zgromadzonej bazie danych budynki poddane takim wpływom nie są dostatecznie licznie reprezentowane, gdyż stanowią zaledwie 10% przypadków. Z pewnością ma to wpływ na prawdopodobieństwa wyznaczone przez utworzony model.

5. W przeprowadzonych badaniach zgromadzono i wykorzystano bazę danych wynoszącą 594 przypadki. Zgromadzenie nowych informacji i rozszerzenie przygotowanego dotychczas zbioru danych z pewnością korzystnie wpłynęłoby na uniwersalność modelu opracowanego na powiększonej bazie.

6. Alternatywnym podejściem do analizowanego zagadnienia byłoby ujęcie możliwości powstania uszkodzeń w budynkach poddanych wpływom górniczym pod kątem niezawodności konstrukcji.

7. Widzi się możliwość wykorzystania przygotowanej ścieżki budowy modelu oceny ryzyka powstania uszkodzeń w badaniach budynków poddanych wpływom dynamicznym i jednocześnie przeprowadzenie weryfikacji skali GSIS-2017 [63].

8. Uzasadniona jest weryfikacja stworzonego modelu na rzeczywistych budynkach murowanych poddanych wpływom górniczym, zinwentaryzowanych w wytypowanej zabudowie w warunkach *in situ*. Taka weryfikacja jest celem pracy badawczej prowadzonej w latach 2021 – 2023 w ramach działalności naukowej Instytutu Techniki Budowlanej.

9. Wskazany kierunkiem rozszerzenia bazy o dodatkowe zmienne byłoby uwzględnienie warunków gruntowych, jakie występują w obszarze posadowienia poszczególnych budynków.

10. Każda dokonana eksploatacja górnicza może negatywnie oddziaływać na sztywność przestrzenną budynku przez powstawanie w nim uszkodzeń. Pomocne w wykazaniu wpływu wielu eksploatacji górniczych byłoby uwzględnienie nowej zmiennej w bazie danych, związanej z historią oddziaływań wpływów górniczych na budynek.

11. Z uwagi na duże znaczenie zmiennej remontowej **Rem**, ciekawym kierunkiem dalszych prac badawczych byłoby rozszerzenie możliwych do przyjęcia wartości tej zmiennej, które uwzględniałyby sposób, zakres i technologię wykonywanych remontów.

BIBLIOGRAFIA

- [1] CHOMACKI L.: Ocena ryzyka powstania uszkodzeń w budynkach murowanych poddanych wpływom eksploatacji górniczej z zastosowaniem metod inteligencji obliczeniowej. Instytut Techniki Budowlanej, Warszawa 2021 (rozprawa doktorska, mps)
- [2] Bilans zasobów złóż kopalin w Polsce. Praca zbiorowa pod red. M. Szuflickiego, A. Malon, M. Tymińskiego. Państwowy Instytut Geologiczny, Warszawa 2018
- [3] Rocznik statystyki międzynarodowej 2018. Główny Urząd Statystyczny, Warszawa 2018
- [4] KOWALSKI A.: Deformacja powierzchni w Górnośląskim Zagłębiu Węglowym. Główny Instytut Górnictwa, Katowice 2015
- [5] PRZYBYŁA H., ŚWIĄDROWSKI W.: Określenie kategorii odporności istniejących obiektów budownictwa powszechnego na wpływy eksploatacji górniczej. *Ochrona Terenów Górniczych* 1968, nr 6, pp. 26–30
- [6] KAWULOK M.: Procedura postępowania w zakresie ochrony istniejących obiektów budowlanych na terenach górniczych. *WUG: Bezpieczeństwo Pracy i Ochrona Środowiska w Górnictwie* 2007, nr 1, pp. 9–14
- [7] NIEWIADOMSKI J., KAZEK M., KUCZ P.: Projektowanie hal stalowych na terenach górniczych wraz z komentarzem i przykładami. Instytut Techniki Budowlanej, Warszawa 1994 (seria: Instrukcje, Wytyczne, Poradniki nr 332)
- [8] KAWULOK M.: Projektowanie budynków na terenach górniczych. Instytut Techniki Budowlanej, Warszawa 2006 (seria: Instrukcje, Wytyczne, Poradniki nr 416)
- [9] CHOLEWICKI A., CHYŻY T., SZULC J.: Projektowanie budynków podlegających wpływom wstrząsów górniczych. Instytut Techniki Budowlanej, Warszawa 2003 (seria: Instrukcje, Wytyczne, Poradniki nr 391)
- [10] KAWULOK M., CHOLEWICKI A., LIPSKA B., ZAWORA J.: Wymagania techniczne dla obiektów budowlanych wznoszonych na terenach górniczych. Instytut Techniki Budowlanej, Warszawa 2007 (seria: Instrukcje, Wytyczne, Poradniki nr 364)

- [11] CHOLEWICKI A., KAWULOK M., LIPSKI Z., SZULC J.: Zasady ustalania obciążeń i sprawdzania stanów granicznych budynków zlokalizowanych na terenach górniczych w nawiązaniu do Eurokodów. Instytut Techniki Budowlanej, Warszawa 2012
- [12] KAWULOK M.: Szkody górnicze w budownictwie. Instytut Techniki Budowlanej, Warszawa 2015
- [13] KWIATEK J., KOWALSKI A., JĘDRZEJEC E., KASZOWSKA O., ROGUSZ Z., FROLIK A. i inni: Ochrona obiektów budowlanych na terenach górniczych. Pod red. J. Kwiatka. Główny Instytut Górnictwa, Katowice 1997
- [14] KWIATEK J.: Obiekty budowlane na terenach górniczych. Główny Instytut Górnictwa, Katowice 2007
- [15] LEDWOŃ J. A.: Budownictwo na terenach górniczych. Arkady, Warszawa 1983
- [16] POPIOŁEK E.: Ochrona terenów górniczych. Akademia Górniczo-Hutnicza, Kraków 2009
- [17] KNOTHE S.: Prognozowanie wpływów eksploatacji górniczej. Wydawnictwo Śląsk, Katowice 1984
- [18] BORECKI M., CHUDEK M., ZYCH J., PODGÓRSKI K., SZCZEPANIAK Z.: Podstawy analityczne i górniczo-techniczne bezfilarowego wybierania złoża przy założeniu minimalizacji wpływów na obiekty chronione. *Zeszyty Naukowe Politechniki Śląskiej. Górnictwo* 1977, z. 77, nr 501
- [19] CHUDEK M.: Geomechanika z podstawami ochrony środowiska górniczego i powierzchni terenu. Wydawnictwo Politechniki Śląskiej, Gliwice 2002
- [20] TAJDUŚ K., SROKA A., MISA R., DUDEK M.: Przykłady zagrożeń powierzchni terenu deformacjami nieciągłymi typu powierzchniowego ujawniające się nad zlikwidowanymi podziemnymi wyrobiskami górniczymi. *Prace Instytutu Mechaniki Górotworu PAN* 2017, vol. 19, pp. 3–10
- [21] TATAR A.: Odporność dynamiczna obiektów budowlanych w warunkach wstrząsów górniczych. Politechnika Krakowska, Kraków 2012
- [22] MACIĄG E.: Ocena wpływów wstrząsów górniczych na budynki. [W:] Materiały sympozjum *Warsztaty 2000 „Zagrożenia naturalne w górnictwie”*, Kraków 2000, pp. 297–317
- [23] MROZEK D.: Nieliniowa analiza numeryczna dynamicznej odpowiedzi uszkodzonych budynków. Politechnika Śląska, Gliwice 2010 (rozprawa doktorska, mps)

- [24] SŁOWIK L.: Wpływ nachylenia terenu spowodowanego podziemną eksploatacją górniczą na wychylenie obiektów budowlanych. ITB, Warszawa 2015 (rozprawa doktorska, mps)
- [25] POPIOŁEK E., HEJMANOWSKI R., KRAWCZYK A., PERSKI Z.: Application of Satellite Radar Interferometry to the examination of the areas of mining exploitation. *Surface Mining Braunkohle and other Minerals* 2002, vol. 54, pp. 74–82
- [26] CHOMACKI L., SŁOWIK L.: Wyniki nadzoru budowlanego nad budynkami w Bytomiu – Miechowicach. *Bezpieczeństwo Pracy i Ochrona Środowiska w Górnictwie* 2015, nr 4, pp. 22–27
- [27] SŁOWIK L., GRUCLIK P., CHOMACKI L.: Destrukcyjny wpływ odkształceń poziomych powodujących zagęszczenie podłoża na ściany budynków zagłębione w gruncie. *Przegląd Górniczy* 2017, vol. 73, pp. 15–21
- [28] KWIATEK J., DUBIŃSKI J., FROLIK A., GIL-KLECZEŃSKA B., JĘDRZEJEC E., KOWALSKI A. i inni: Zasady oceny możliwości prowadzenia podziemnej eksploatacji górniczej z uwagi na ochronę obiektów budowlanych. Główny Instytut Górnictwa, Katowice 2000
- [29] MIKA W., CHOMACKI L., SŁOWIK L.: Zasady oceny odporności budynków na ciągłe deformacje terenu. *Przegląd Górniczy* 2017, vol. 73, pp. 78–84
- [30] Rozporządzenie Ministra Środowiska z dnia 8 grudnia 2017 r. w sprawie planów ruchu zakładów górniczych (Dz. U. z 2017 r., poz. 2293)
- [31] KAWULOK M.: Osąd eksperta w ochronie istniejących obiektów budowlanych na terenach górniczych. *Przegląd Górniczy* 2015, vol. 71, pp. 38–43
- [32] PN-EN 1991-1-7:2008P Oddziaływania na konstrukcje. Część 1-7: Oddziaływania ogólne. Oddziaływania wyjątkowe
- [33] FIREK K.: Ocena intensywności uszkodzeń budynków o konstrukcji murowanej usytuowanych na terenie górniczym. *Przegląd Górniczy* 2017, vol. 73, pp. 39–43
- [34] MURPHY K.: *Machine Learning A Probabilistic Perspective*. Massachusetts Institute of Technology, Cambridge 2012
- [35] GÉRON A.: *Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow*. Wydawnictwo HELION, Gliwice 2018
- [36] KULCZYCKI P., HRYNIEWICZ O., KACPRZYK J.: *Techniki informacyjne w badaniach systemowych*. Wydawnictwo Naukowo-Techniczne, Warszawa 2007

- [37] APOLLO M., MISZEWSKA-URBAŃSKA E.: Podejmowanie decyzji w warunkach niepewności przy użyciu sieci Bayesa – przykład zastosowania. *Logistyka* 2014, vol. nr 6, pp. 1496–1504
- [38] SUCHACKA G., ZGRZYWA A.: Charakterystyka sieci Bayesa jako metody wnioskowania w warunkach niepełnych i niepewnych danych. *Zeszyty Naukowe. Informatyka. Politechnika Opolska* 2001, vol. 282, pp. 29–52
- [39] PALTRINIERI N., COMFORT L., RENIERS G.: Learning about risk: Machine learning for risk assessment. *Safety Science* 2019, vol. 118, pp. 475–486 (doi.org/10.1016/j.ssci.2019.06.001)
- [40] WITKOWSKI M., RUSEK J.: Wykorzystanie probabilistycznych sieci neuronowych do wyznaczania ryzyka powstania szkód w budynkach poddanych wstrząsom górniczym. *Przegląd Górniczy* 2017, vol. 73, pp. 44–47
- [41] WITKOWSKI M.: Ocena wpływu wieloletnich oddziaływań górniczych na intensywność uszkodzeń tradycyjnej zabudowy LGOM. Akademia Górniczo-Hutnicza, Kraków 2018
- [42] CAN E., KUŞCU Ş., KARTAL M.E.: Effects of mining subsidence on masonry buildings in Zonguldak hard coal region in Turkey. *Environmental Earth Sciences* 2012, vol. 66, pp. 2503–2518 (doi.org/10.1007/s12665-011-1473-2)
- [43] LÓPEZ GAYARRE F., ÁLVAREZ-FERNÁNDEZ M.I., GONZÁLEZ-NICIEZA C., ÁLVAREZ-VIGIL A., HERRERA G.: Forensic analysis of buildings affected by mining subsidence. *Engineering Failure Analysis* 2010, vol. 17, pp. 270–285 (doi.org/10.1016/j.engfailanal.2009.06.008)
- [44] ÁLVAREZ-FERNÁNDEZ M.I., ÁLVAREZ-VIGIL A., GONZÁLEZ-NICIEZA C., LÓPEZ GAYARRE F.: Forensic evaluation of building damage using subsidence simulations. *Engineering Failure Analysis* 2011, vol. 18, pp. 1295–1307 (doi.org/10.1016/j.engfailanal.2011.03.017)
- [45] ABDALLAH M., VERDEL T.: Behavior of a masonry wall subjected to mining subsidence, as analyzed by experimental designs and response surfaces. *International Journal of Rock Mechanics and Mining Sciences* 2017, vol. 100, pp. 199–206 (doi.org/10.1016/j.ijrmms.2017.10.003)
- [46] SAEIDI A., DECK O., VERDEL T.: Development of building vulnerability functions in subsidence regions from empirical methods. *Engineering Structures* 2009, vol. 31, pp. 2275–2286 (doi.org/10.1016/j.engstruct.2009.04.010)
- [47] SAEIDI A., DECK O., VERDEL T.: Comparison of Building Damage Assessment Methods for Risk Analysis in Mining Subsidence

- Regions. *Geotechnical and Geological Engineering* 2013, vol. 31, pp. 1073–1088 (doi.org/10.1007/s10706-013-9633-7)
- [48] LIU X., GUO G., LI H.: Study on Damage of Shallow Foundation Building caused by Surface Curvature Deformation in Coal Mining Area. *KSCE Journal of Civil Engineering* 2019, vol. 23, pp. 4601–4610 (doi.org/10.1007/s12205-019-1525-9)
- [49] ZHANG J., SUN Q., FOURIE A., JU F., DONG X.: Risk assessment and prevention of surface subsidence in deep multiple coal seam mining under dense above-ground buildings: Case study. *Human and Ecological Risk Assessment* 2019, vol. 25, pp. 1579–1593 (doi.org/10.1080/10807039.2018.1471579)
- [50] JU J., XU J.: Surface stepped subsidence related to top-coal caving longwall mining of extremely thick coal seam under shallow cover. *International Journal of Rock Mechanics and Mining Sciences* 2015, vol. 78, pp. 27–35 (doi.org/10.1016/j.ijrmms.2015.05.003)
- [51] GIARDINA G., HENDRIKS M.A.N., ROTS J.G.: Numerical analysis of tunnelling effects on masonry buildings: The influence of tunnel location on damage assessment. *Advanced Materials Research* 2010, vol. 133–134, pp. 289–294 (doi.org/10.4028/www.scientific.net/amr.133-134.289)
- [52] KAWULOK M., CHOMACKI L., PARKASIEWICZ B., SŁOWIK L.: Wyburzenie 25 budynków mieszkalnych spowodowane intensywnymi wpływami eksploatacji górniczej. [W:] Materiały XXVI Konferencji Naukowo-Technicznej „Awarie budowlane”, Szczecin – Międzyzdroje 2013, pp. 347–354
- [53] KADELA M., BARTOSZEK M., FEDOROWICZ J.: Behaviour of Masonry Walls under Horizontal Shear in Mining Areas. *IOP Conference Series: Earth and Environmental Science* 2017, vol. 95, pp. 1–11 (doi.org/10.1088/1755-1315/95/2/022047)
- [54] FEDOROWICZ J., MROZEK M., MROZEK D.: Ochrona budynków murowych na terenie górniczym. Porównanie analiz klasycznych i współczesnych. *Modelowanie Inżynierskie* 2014, t. 22, nr 53, pp. 45–51
- [55] KAPUSTA Ł., SZOJDA L.: Analiza numeryczna dwusegmentowego budynku mieszkalnego dla zmiennej krzywizny terenu pochodzenia górniczego. *Przegląd Górniczy* 2020, vol. 76, pp. 11–17
- [56] BRYT-NITARSKA I., FLORKOWSKA L.: Analiza wsteczna przyczyn uszkodzeń budynku znajdującego się w zasięgu oddziaływania deformacji górniczych. *Prace Instytutu Mechaniki Górotworu Polskiej Akademii Nauk* 2016, t. 18, nr 4, pp. 73–80

- [57] KWIECIEŃ A., TATARA T.: O możliwości napraw obiektów budowlanych na terenach górniczych. *Przegląd Górniczy* 2014, vol. 70, pp. 35–41
- [58] MALINOWSKA A.: Analysis of methods used for assessing damage risk of buildings under the influence of underground exploitation in the light of world's experience. Part 1. *Archives of Mining Sciences* 2013, vol. 58, pp. 843–853 (doi.org/10.2478/amsc-2013-0058)
- [59] MALINOWSKA A.: Accuracy estimation of the approximated methods used for assessing risk of buildings damage under the influence of underground exploitation in the light of world's and polish experience. Part 2. *Archives of Mining Sciences* 2013, vol. 58, pp. 855–865 (doi.org/10.2478/amsc-2013-0059)
- [60] MALINOWSKA A., HEJMANOWSKI R.: Building damage risk assessment on mining terrains in Poland with GIS application. *International Journal of Rock Mechanics and Mining Sciences* 2010, vol. 47, pp. 238–245 (doi.org/10.1016/j.ijrmms.2009.09.009)
- [61] BLACHOWSKI J., CHRZANOWSKI A., SZOSTAK-CHRZANOWSKI A.: Application of GIS methods in assessing effects of mining activity on surface infrastructure. *Archives of Mining Sciences* 2014, vol. 59, pp. 307–321 (doi.org/10.2478/amsc-2014-0022)
- [62] BIAŁEK J., MIELIMAKA R., ORWAT J.: Selektywne ograniczenie postępu ścian jako sposób zmniejszenia szkodliwych wpływów pod ważnymi obiektami budowlanymi. Selective restriction of wall advance as a method of reducing negative mining. *Przegląd Górniczy* 2014, vol. 70, pp. 31–37
- [63] MUTKE G., BARAŃSKI A., CHODACKI J., DUBIŃSKI J., LURKA A., KOWAL T.: Zasady stosowania górniczej skali intensywności sejsmicznej GSIS-2017. Główny Instytut Górnictwa, Katowice 2017
- [64] STOLECKI J., GRZEBYK W., JAŚKIEWICZ K., JAŚKIEWICZ-PROĆ I., MINCH M.Y.: Weryfikacja skal GSI-2004/11. Skala GSI-2004/18. KGHM Cuprum – CBR, Wrocław 2018
- [65] TATARA T., PACHLA F.: Uszkodzenia w obiektach budowlanych w warunkach wstrząsów górniczych. *Przegląd Górniczy* 2012, t. 68, nr 7, pp. 1–10
- [66] CIESIELSKI R.: Ujęcie obliczeniowe oraz ocena wpływu drgań i wstrząsów pochodzących ze źródeł zewnętrznych na niektóre typy budowli. *Zeszyt Naukowy Politechniki Krakowskiej* 1961, vol. 1, nr 4
- [67] PILECKA E., STEC K., SZERMER-ZAUCHA R.: The influence of the Kłodnica fault tectonic zone on the degree of damage to buildings resulting from high magnitude tremors. *Czasopismo Techniczne* 2017, vol. 7, pp. 53–64 (doi.org/10.4467/2353737xct.17.108.6649)

- [68] DROBIEC Ł., NIEMIEC T., KAWULOK M., SŁOWIK L., CHOMACKI L.: The method of strengthening the church building in terms of the planned mining exploitation. *MATEC Web of Conferences* 2019, vol. 284, pp. 05003 (doi.org/10.1051/mateconf/201928405003)
- [69] KAWULOK M., CHOMACKI L., RUTKOWSKI T.: Cracking of the Vault in a Church Building and Activities Undertaken in the View of the Further Mining Exploitation. *MATEC Web of Conferences* 2019, vol. 284, pp. 05006 (doi.org/10.1051/mateconf/201928405006)
- [70] SŁOWIK L., CHOMACKI L., SZOŁTYSEK D.: Doświadczenia z eksploatacji górniczej pod obiektem kościoła pw Św. Krzyża w Bytomiu – Miechowicach. *Przegląd Górniczy* 2015, vol. 71, pp. 25–31
- [71] KAWULOK M., CHOMACKI L., SŁOWIK L.: Ocena możliwości przejścia wpływów górniczych przez konstrukcję kościoła pw. Św. Krzyża w Bytomiu – Miechowicach, spowodowanych wydłużeniem parceli eksploatacyjnej. *Przegląd Górniczy* 2017, vol. 73, pp. 93–101
- [72] LIPECKI T., LIGARSKA H., ZAWADZKA M.: The influence of mining activities on the Church of St. Cross in Bytom-Miechowice. *Reports on Geodesy and Geoinformatics* 2018, vol. 105, pp. 7–18 (doi.org/10.2478/rgg-2018-0002)
- [73] KOWALSKI A.: Historia eksploatacji górniczej, deformacji powierzchni i ich skutków w budynku kościoła. *Przegląd Górniczy* 2016, vol. 72, pp. 1–12
- [74] FLORKOWSKA L.: Example Building Damage Caused By Mining Exploitation in Disturbed Rock Mass. *Studia Geotechnica et Mechanica* 2014, vol. 35, pp. 19–37 (doi.org/10.2478/sgem-2013-0021)
- [75] GROMYSZ K.: Koncepcje wzmocnienia zabytkowego budynku neogotyckiego kościoła w związku z planowanym prostowaniem obiektu. *Przegląd Górniczy* 2015, vol. 71, pp. 21–29
- [76] BARYCZ S., FIREK K., KOCOT W., MALINOWSKA A.: The Effect of Preventive Conservation Measures on the Technical Condition of A Religious Building Located in the Mining Area. *Archives of Mining Sciences* 2016, vol. 61, pp. 351–364 (doi.org/10.1515/amsc-2016-0026)
- [77] Subsidence Engineer's Handbook. National Coal Board, London 1975
- [78] WAGNER H., SCHUEMANN E.H.R.: Surface effects of total coal-seam extraction by underground mining methods. *Journal of The South African Institute of Mining and Metallurgy* 1991, vol. 91, pp. 221–231 (doi.org/10.1016/0148-9062(92)92608-f)
- [79] Mine Subsidence Damage to Building Structures. Mine Subsidence Engineering Consultants, Chatswood 2007

- [80] YU Z., KARMIS M., JAROSZ A., HAYCOCKS C.: Development of damage criteria for buildings affected by mining subsidence. *Sixth Annual Workshop on Mining Systems Design and Ground Control* 1988, pp. 83–92
- [81] KARMIS M., YU Z., JAROSZ A.: Design considerations for subsidence control. *International Journal of Mining and Geological Engineering* 1990, vol. 8, pp. 357–368 (doi.org/10.1007/bf00920647)
- [82] BOSCARDIN M., CORDING E.: Building response to excavation-induced settlement. *Journal of Geotechnical Engineering* 1989, vol. 115, pp. 1–21
- [83] MAIR R., TAYLOR N., BURLAND J.: Prediction of ground movements and assessment of risk of building damage due to bored tunnelling. [In:] *Geotechnical Aspects of Underground Construction in Soft Ground*. Mair and Taylor, Rotterdam 1996, pp. 536–537
- [84] SAEIDI A., DECK O., AL HEIB M., VERDEL T.: Development of a damage simulator for the probabilistic assessment of building vulnerability in subsidence areas. *International Journal of Rock Mechanics and Mining Sciences* 2015, vol. 73, pp. 42–53 (doi.org/10.1016/j.ijrmms.2014.10.007)
- [85] CAI Y.: Simulation of underground mining subsidence and its induced damages on buildings. Université de Lorraine, Nancy 2015
- [86] HU H., LIAN X., CHEN S.: Effects on buildings of surface curvature caused by underground coal mining. *Journal of Engineering and Technological Sciences* 2016, vol. 48, pp. 254–275 (doi.org/10.5614/j.eng.technol.sci.2016.48.3.2)
- [87] MRÓWCZYŃSKA M.: Klasyfikatory neuronowe typu SVM w zastosowaniu do klasyfikacji przemieszczeń pionowych na obszarze LGOM. *Zeszyty Naukowe Polskiej Akademii Nauk* 2014, vol. 86, pp. 69–82
- [88] OH H.-J., LEE S.: Integration of ground subsidence hazard maps of abandoned coal mines in Samcheok, Korea. *International Journal of Coal Geology* 2011, vol. 86, pp. 58–72 (doi.org/10.1016/j.coal.2010.11.009)
- [89] GRUSZCZYŃSKI W.: Zastosowanie sieci neuronowych do modelowania deformacji górniczych. *Przegląd Górniczy* 2010, vol. 66, pp. 7–11
- [90] BAŃKA P., CICHY T., KOŁODZIEJCZYK P.: Wykorzystanie sieci neuronowych do prognozy zagrożenia sejsmicznego. *Przegląd Górniczy* 2016, vo. 72, pp. 1–6
- [91] BRYT-NITARSKA I.: Wpływ górniczych deformacji podłoża na powstawanie uszkodzeń w budynkach murowanych. Instytut Techniki Budowlanej, Warszawa 2008 (rozprawa doktorska, mps)

- [92] MALINOWSKA A.: Ocena zagrożenia uszkodzeniami obiektów budowlanych na terenach górniczych z wykorzystaniem wnioskowania rozmytego. IGSMiE PAN, Kraków 2009 (rozprawa doktorska, mps)
- [93] RUSEK J.: Modelowanie stopnia zużycia technicznego budynków na terenach górniczych z wykorzystaniem metod sztucznej inteligencji. Wydawnictwa AGH, Kraków 2010
- [94] FIREK K., RUSEK J., WODYŃSKI A.: Wybrane metody eksploracji danych i uczenia maszynowego w analizie stanu uszkodzeń oraz zużycia technicznego zabudowy terenów górniczych. Selected methods of data mining and machine learning in risk analysis. *Przegląd Górniczy* 2016, vol. 72, pp. 50–55
- [95] WODYŃSKI A., LASOCKI S.: Badanie wpływu wstrząsów górniczych na zużycie techniczne budynków murowanych. *Przegląd Górniczy* 2003, vol. 59, pp. 1–6
- [96] RUSEK J., FIREK K.: Bayesian Belief Network in the analysis of damage to prefabricated large-panel building structures in mining areas. *Polish Journal of Environmental Studies* 2016, vol. 25, pp. 77–82
- [97] RUSEK J., TAJDUŚ K., FIREK K., JĘDRZEJCZYK A.: Score-based Bayesian belief network structure learning in damage risk modeling of mining areas building development. *Journal of Cleaner Production* 2021, vol. 296, p. 126528 (doi.org/10.1016/j.jclepro.2021.126528)
- [98] RUSEK J., TAJDUS K., FIREK K., JĘDRZEJCZYK A.: Bayesian networks and Support Vector Classifier in damage risk assessment of RC prefabricated building structures in mining areas. [In:] *Proceedings of the 5th International Conference on Smart and Sustainable Technologies*. IEEE, Split 2020, p. 1–8 (doi.org/10.23919/splitech.49282.2020.9243718)
- [99] DUCH W., MANDZIUK J.: *Challenges for Computational Intelligence*. Pod red. W. Duchy, J. Mandziuka. Springer, Berlin – Heidelberg 2007 (doi.org/10.1007/978-3-540-71984-7)
- [100] HORZYK A.: *Sztuczna Inteligencja. Wstęp*. Akademia Górniczo-Hutnicza, Kraków 2015. Dostęp: <https://home.agh.edu.pl/~horzyk/lectures/ai/SztucznaInteligencja-Wst%C4%99p.ppsx>
- [101] WIERZBICKI A. P.: *Teoria i praktyka wspomagania decyzji*. Wydawnictwa Uniwersytetu Warszawskiego, Warszawa 2018 (doi.org/10.31338/uw.9788323533610)
- [102] CICHOSZ P.: *Systemy uczące się*. Wydawnictwo Naukowo-Techniczne, Warszawa 2000

- [103] SCUTARI M.: Dirichlet Bayesian network scores and the maximum relative entropy principle. *Behaviormetrika* 2018, vol. 45, pp. 337–362 (doi.org/10.1007/s41237-018-0048-x)
- [104] SCUTARI M., GRAAFLAND C.E., GUTIÉRREZ J.M.: Who learns better Bayesian network structures: Accuracy and speed of structure learning algorithms. *International Journal of Approximate Reasoning* 2019, vol. 115, pp. 235–253 (doi.org/10.1016/j.ijar.2019.10.003)
- [105] HECKERMAN D., GEIGER D., CHICKERING D.: Learning Bayesian networks: The combination of knowledge and statistical data. *Machine Learning* 1995, vol. 20, pp. 197–243
- [106] KOSKI T., NOBLE J.: Bayesian networks: an introduction. John Wiley & Sons, Chichester 2011
- [107] PEARL J.: Probabilistic reasoning in intelligent systems: networks of plausible inference. Elsevier, Burlington 2014
- [108] PEARL J.: Probabilistic Reasoning in Intelligent Systems. Morgan Kaufmann Publishers, San Francisco 1988 (doi.org/10.1016/c2009-0-27609-4)
- [109] CHOMACKI L., RUSEK J., SŁOWIK L.: Selected artificial intelligence methods in the risk analysis of damage to masonry buildings subject to long-term underground mining exploitation. *Minerals* 2021, vol. 11, pp. 1–20 (doi.org/10.3390/min11090958)
- [110] SCUTARI M.: Learning Bayesian Networks with the bnlearn R Package. *Journal of Statistical Software* 2010, vol. 35, pp. 1–22 (doi.org/10.18637/jss.v035.i03)
- [111] KRATZER G., FURRER R.: Information-Theoretic Scoring Rules to Learn Additive Bayesian Network Applied to Epidemiology. arXiv, New York 2018
- [112] NAGARAJAN R., SCUTARI M., LÈBRE S.: Bayesian Networks in R. Springer, New York 2013 (doi.org/10.1007/978-1-4614-6446-4)
- [113] KOSKI T., NOBLE J.: A review of Bayesian networks and structure learning. *Mathematica Applicanda* 2012, vol. 40, pp. 53–103
- [114] NATORI K., UTO M., UENO M.: Consistent Learning Bayesian Networks with Thousands of Variables. [In:] The Third International Workshop on Advanced Methodologies for Bayesian Networks (AMBN 2017). Proceedings of Machine Learning Research (PMLR). Kyoto 2017
- [115] NANDY P., HAUSER A., MAATHUIS M.H.: High-dimensional consistency in score-based and hybrid structure learning. *Annals of Statistics* 2018, vol. 46, pp. 3151–3183 (doi.org/10.1214/17-aos1654)

- [116] KOLLER D., FRIEDMAN N.: Probabilistic Graphical Models: Principles and Techniques. The MIT Press, Cambridge 2009 (doi.org/10.2307/478142)
- [117] RUSEK J., FIREK K.: Assessment of technical condition of prefabricated large-block building structures located in mining area using the Naive Bayes classifier. [In:] International Multidisciplinary Scientific GeoConference Surveying Geology and Mining Ecology Management. Albena, Bulgaria 2016 (doi.org/10.5593/sgem2016/b52/s20.015)
- [118] FIREK K., RUSEK J., WODYŃSKI A.: Decision Trees in the Analysis of the Intensity of Damage to Portal Frame Buildings in Mining Areas. *Archives of Mining Sciences* 2015, vol. 60, pp. 847–857 (doi.org/10.1515/amsc-2015-0055)
- [119] GASSE M., AUSSEM A., ELGHAZEL H.: A hybrid algorithm for Bayesian network structure learning with application to multi-label learning. *Expert Systems with Applications* 2014, vol. 41, pp. 6755–6772
- [120] FIREK K., RUSEK J.: Partial Least Squares Method in the Analysis of the Intensity of Damage in Prefabricated Large-Block Building Structures. *Archives of Mining Sciences* 2017, vol. 62, pp. 269–277 (doi.org/10.1515/amsc-2017-0020)
- [121] RUSEK J.: Creating a model of technical wear of building in mining area, with utilization of regressive SVM approach. *Archives of Mining Sciences* 2009, vol. 54, pp. 455–466
- [122] RUSEK J.: Application of Support Vector Machine in the analysis of the technical state of development in the LGOM mining area. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2016, vol. 19, pp. 54–61 (doi.org/10.17531/ein.2017.1.8)
- [123] SCUTARI M., VITOLO C., TUCKER A.: Learning Bayesian networks from big data with greedy search: computational complexity and efficient implementation. *Statistics and Computing* 2019, vol. 29, pp. 1–14
- [124] EGGELING R., VIINIKKA J., VUOKSENMAA A., KOIVISTO M.: On Structure Priors for Learning Bayesian Networks. [In:] Proceedings of the 22nd International Conference on Artificial Intelligence and Statistics. Naha 2019, pp. 1687–1695
- [125] CARVALHO A.M.: Scoring functions for learning Bayesian networks. *Inesc-Id Tec Rep* 2009, vol. 12, pp. 1–37
- [126] HONG Y., XIA X., LE J., ZHOU X.: Learning Bayesian Network Structure from Large-Scale Datasets. [In:] Proceedings of the International Conference on Advanced Cloud and Big Data (CBD). Chengdu 2016, pp. 258–264

- [127] SILANDER T., LEPPÄ-AHO J., JÄÄSAARI E., ROOS T.: Quotient normalized maximum likelihood criterion for learning bayesian network structures. [In:] Proceedings of the International Conference on Artificial Intelligence and Statistics. Playa Blanca 2018, pp. 948–957
- [128] SILANDER T., ROOS T., MYLLYMÄKI P.: Learning locally minimax optimal Bayesian networks. *International Journal of Approximate Reasoning* 2010, vol. 51, pp. 544–557
- [129] KARSHENAS H., NIKANJAM A., HELMI B.H., RAHMANI A.T.: Combinatorial effects of local structures and scoring metrics in Bayesian optimization algorithm. [In:] Proceedings of the First ACM/SIGEVO Summit on Genetic and Evolutionary Computation. Shanghai 2009, pp. 263–270
- [130] NATORI K., UTO M., NISHIYAMA Y., KAWANO S., UENO M.: Constraint-based learning Bayesian networks using Bayes factor. [In:] Workshop on Advanced Methodologies for Bayesian Networks. Yokohama 2015, pp. 15–31
- [131] GADOWSKA-DOS SANTOS D.: Sieć Bayesa jako narzędzie wspomagające zarządzanie ryzykiem operacyjnym w banku. *Problemy Zarządzania* 2017, vol. 15, pp. 125–144 (doi.org/10.7172/1644-9584.66.8)
- [132] KORB K., NICHOLSON A.: Bayesian Artificial Intelligence. CRC Press, London 2010 (doi.org/10.1198/tech.2005.s836)
- [133] UUSITALO L.: Advantages and challenges of Bayesian networks in environmental modelling. *Ecological Modelling* 2007, vol. 203, pp. 312–318 (doi.org/10.1016/j.ecolmodel.2006.11.033)
- [134] R CORE TEAM: R: A Language and Environment for Statistical Computing [Internet]. Vienna, Austria 2019. Dostęp: <https://www.R-project.org/>
- [135] LIU W.: Package ‘yap’. Yet Another Probabilistic Neural Network [Internet]. 2020. Dostęp: <https://cran.r-project.org/web/packages/yap/yap.pdf>
- [136] MEYER D., DIMITRIADOU E., HORNIK K., LEISCH F., MEYER D., MAINTAINER A. i inni: The e1071 package. 2006. Dostęp: <https://cran.r-project.org/web/packages/e1071/e1071.pdf>
- [137] SCUTARI M., NESS R.: Package ‘bnlearn’ 2019. <https://cran.r-project.org/web/packages/bnlearn/bnlearn.pdf>
- [138] MAJKA M.: Package naivebayes: High Performance Implementation of the Naive Bayes Algorithm in R [Internet]. 2019. Dostęp: <https://cran.r-project.org/web/packages/naivebayes/naivebayes.pdf>

- [139] MIHALJEVIĆ B., BIELZA C., LARRAÑAGA P.: bnclassify: Learning Bayesian Network Classifiers. *The R Journal* 2019, vol. 10, p. 455 (doi.org/10.32614/rj-2018-073)
- [140] HØJSGAARD S.: Graphical Independence Networks with the gRain Package for R. *Journal of Statistical Software* 2012, vol. 46, pp. 37–44 (doi.org/10.18637/jss.v046.i10)
- [141] HØJSGAARD S.: Bayesian networks in R with the gRain package [Internet]. 2020. Dostęp: <https://cran.r-project.org/web/packages/gRain/vignettes/grain-intro.pdf>
- [142] KUHN M., WING J., WESTON S., WILLIAMS A., KEEFER C., ENGELHARDT A. i inni: Package ‘ caret ’ R topics documented: [Internet]. 2020. Dostęp: <https://cran.r-project.org/web/packages/caret/caret.pdf>
- [143] JANKOWSKI N.: Ontogeniczne sieci neuronowe. Akademicka Oficyna Wydawnicza Exit, Warszawa 2003
- [144] HASTIE T., TIBSHIRANI R., FRIEDMAN J.: The Elements of Statistical Learning. Springer, New York 2009 (doi.org/10.1007/978-0-387-84858-7)
- [145] SHAHROKH ESFAHANI M., DOUGHERTY E.: Effect of separate sampling on classification accuracy. *Bioinformatics* 2014, vol. 30, pp. 242–250 (doi.org/10.1093/bioinformatics/btt662)
- [146] KUHN M.: Building predictive models in R using the caret package. *Journal of Statistical Software* 2008, vol. 28, pp. 1–26 (doi.org/10.18637/jss.v028.i05)
- [147] JAMES G., WITTEN D., HASTIE T., TIBSHIRANI R.: An Introduction to Statistical Learning. Springer, New York 2013 (doi.org/10.1007/978-1-4614-7138-7)
- [148] Internetowy Podręcznik Statystyki [Internet]. Statsoft, 2011 Dostęp: <https://www.statsoft.pl/textbook/stathome.html>
- [149] KORONACKI J., ĆWIK J.: Statystyczne systemy uczące się. Akademicka Oficyna Wydawnicza Exit, Warszawa 2008
- [150] HAND D., CHRISTEN P.: A note on using the F-measure for evaluating record linkage algorithms. *Statistics and Computing* 2018, vol. 28, pp. 539–547 (doi.org/10.1007/s11222-017-9746-6)
- [151] CHINCHOR N.: MUC-4 evaluation metrics. [In:] Proceedings of the 4th Conference on Message Understanding – MUC4’92. Association for Computational Linguistics, USA, Morristown 1992, p. 22 (doi.org/10.3115/1072064.1072067)
- [152] OSOWSKI S.: Sieci neuronowe do przetwarzania informacji. Politechnika Warszawska, Warszawa 2006
- [153] KEOGH E., PAZZANI M.: Learning the Structure of Augmented Bayesian Classifiers. *International Journal on Artificial Intelligence Tools*

- 2002, vol. 11, no 4, p. 587–601 (doi.org/10.1142/s021821300201052)
- [154] BIECEK P.: DALEX: Explainers for Complex Predictive Models in R. *Journal of Machine Learning Research* 2018, vol. 19, pp. 1–5
- [155] FRIEDMAN N., GEIGER D., GOLDSZMIDT M.: Bayesian Network Classifiers. *Machine Learning* 1997, vol. 29, pp. 131–163 (doi.org/10.1023/a:1007465528199)
- [156] RUSSELL S., NORVIG P.: Artificial Intelligence: A Modern Approach. Prentice Hall, New Jersey 2020
- [157] CHOW C., LIU C.: Approximating discrete probability distributions with dependence trees. *Information Theory, IEEE Transactions On* 1968, vol. 14, pp. 462–467 (doi.org/10.1109/isita.2010.5649470)
- [158] PAZZANI M.J.: Searching for Dependencies in Bayesian Classifiers. *AISTATS* 1996, vol. 112, pp. 239–248 (doi.org/10.1007/978-1-4612-2404-4_23)
- [159] DUAN Z., WANG L.: K-Dependence Bayesian Classifier Ensemble. *Entropy* 2017, vol. 19, p. 651 (doi.org/10.3390/e19120651)
- [160] STRACUZZI D.J., UTGOFF P.E.: Randomized variable elimination. *Journal of Machine Learning Research* 2004, vol. 5, pp. 1331–1362
- [161] GOGOSHIN G., BOERWINKLE E., RODIN A.S.: New algorithm and software (BNomics) for inferring and visualizing bayesian networks from heterogeneous big biological and genetic data. *Journal of Computational Biology* 2017, vol. 24, pp. 340–356
- [162] SALZMAN P., ALMUDEVAR A.: Using complexity for the estimation of Bayesian networks. *Statistical Applications in Genetics and Molecular Biology* 2006, vol. 5, no. 1 (doi.org/10.2202/1544-6115.1208)
- [163] FUSTER-PARRA P., TAULER P., BENNASAR-VENY M., LIGEZA A., LÓPEZ-GONZÁLEZ A., AGUILÓ A.: Bayesian network modeling: A case study of an epidemiologic system analysis of cardiovascular risk. *Computer Methods and Programs in Biomedicine* 2016, vol. 126, pp. 128–142 (doi.org/10.1016/j.cmpb.2015.12.010)
- [164] RUSEK J.: The point nuisance method as a decision-support system based on Bayesian inference approach. *Archives of Mining Sciences* 2020, vol. 65, pp. 117–127 (doi.org/10.24425/ams.2020.132710)

Załącznik 1

**Zestawienie danych z podziałem na zmienne,
ich stany i liczności w zbiorach**

Tablica Z1.1. Zestawienie danych z podziałem na zmienne, ich stany, liczności w zbiorach i proporcje podziału

Kod zmiennej	Kategoria zmiennej i jej stan		Liczność kategorii w zbiorze			Proporcje podziału
			trenującym	testowym	Σ	
Dług	1	od 9 do 11	50	10	60	0,83
	2	od 11 do 13	68	19	87	0,78
	3	od 13 do 15	70	19	89	0,79
	4	od 15 do 17	77	16	93	0,83
	5	od 17 do 19	82	26	108	0,76
	6	od 19 do 21	68	13	81	0,84
	7	od 21 do 23	23	6	29	0,79
	8	powyżej 23	40	7	47	0,85
Szer	1	od 6 do 9	34	11	45	0,76
	2	od 9 do 10	112	28	140	0,80
	3	od 10 do 11	152	37	189	0,80
	4	od 11 do 12	85	20	105	0,81
	5	od 12 do 13	45	7	52	0,87
	6	powyżej 13	50	13	63	0,79
Powi	1	od 60 do 110	64	16	80	0,80
	2	od 110 do 130	58	17	75	0,77
	3	od 130 do 150	65	19	84	0,77
	4	od 150 do 170	40	7	47	0,85
	5	od 170 do 190	84	21	105	0,80
	6	od 190 do 210	51	10	61	0,84
	7	od 210 do 230	32	8	40	0,80
	8	od 230 do 250	23	7	30	0,77
	9	od 250 do 290	28	4	32	0,88
	10	powyżej 290	33	7	40	0,83
LiKon	1	do 1,5	68	17	85	0,80
	2	2	78	23	101	0,77
	3	3	65	13	78	0,83
	4	2,5	163	36	199	0,82
	5	od 3,5 do 4,5	104	27	131	0,79

Kod zmiennej	Kategoria zmiennej i jej stan		Liczność kategorii w zbiorze			Proporcje podziału
			trenującym	testowym	Σ	
Kubat	1	od 200 do 700	45	13	58	0,78
	2	od 700 do 900	56	18	74	0,76
	3	od 900 do 1100	77	17	94	0,82
	4	od 1100 do 1300	30	7	37	0,81
	5	od 1300 do 1500	50	14	64	0,78
	6	od 1500 do 1700	45	8	53	0,85
	7	od 1700 do 1900	43	9	52	0,83
	8	od 1900 do 2100	27	6	33	0,82
	9	od 2100 do 2500	46	12	58	0,79
	10	od 2500 do 2900	21	3	24	0,88
	11	powyżej 2900	38	9	47	0,81
DluCi	1	od 9 do 11	33	6	39	0,85
	2	od 11 do 13	58	14	72	0,81
	3	od 13 do 15	55	11	66	0,83
	4	od 15 do 17	58	16	74	0,78
	5	od 17 do 19	42	14	56	0,75
	6	od 19 do 21	43	9	52	0,83
	7	od 21 do 23	21	7	28	0,75
	8	od 23 do 27	31	9	40	0,78
	9	od 27 do 31	23	3	26	0,88
	10	od 31 do 35	46	12	58	0,79
	11	od 35 do 41	33	3	36	0,92
	12	powyżej 41	35	12	47	0,74
Dylat	1	brak	42	13	55	0,76
	2	na styk	121	29	150	0,81
	3	nie dotyczy	315	74	389	0,81

Kod zmiennej	Kategoria zmiennej i jej stan		Liczność kategorii w zbiorze			Proporcje podziału
			trenującym	testowym	Σ	
Kszta	1	rzut prosty, bryła wydłużona	62	15	77	0,81
	2	rzut prosty, bryła zwarta	317	77	394	0,80
	3	rzut słabo rozcłonkowany, bryła wydłużona	28	7	35	0,80
	4	rzut słabo rozcłonkowany, bryła zwarta	71	17	88	0,81
Podpi	1	brak	70	14	84	0,83
	2	całkowite	355	87	442	0,80
	3	częściowe	53	15	68	0,78
ZmPos	0	nie	431	101	532	0,81
	1	tak	47	15	62	0,76
ZmWys	0	nie	445	108	553	0,80
	1	tak	33	8	41	0,80
RoFun	1	kamienne	77	33	110	0,70
	2	murowane z cegieł	312	65	377	0,83
	3	żelbetowe	89	18	107	0,83
Msp	1	murowane z bloczków betonowych	75	14	89	0,84
	2	murowane z cegieł	373	88	461	0,81
	3	murowane z kamienia	30	14	44	0,68
Mspiw	1	murowane z cegieł	420	106	526	0,80
	2	murowane z pustaków	58	10	68	0,85
Snp	1	betonowy na belkach stalowych	46	16	62	0,74
	2	brak	68	13	81	0,84
	3	Kleina	113	24	137	0,82
	4	odcinkowy na dźwigarach stalowych	213	53	266	0,80
	5	żelbetowy lub gęstożebrowy z wieńcem	38	10	48	0,79

Kod zmiennej	Kategoria zmiennej i jej stan		Liczność kategorii w zbiorze			Proporcje podziału
			trenującym	testowym	Σ	
Snpiw	1	drewniany	396	99	495	0,80
	2	gęstożebrowy z wieńcem	38	10	48	0,79
	3	żelbetowy z wieńcem	44	7	51	0,86
Nadpr	1	belkowe	98	21	119	0,82
	2	ceglane płaskie	260	58	318	0,82
	3	łukowe	120	37	157	0,76
Zabez	1	brak wzmocnień	142	22	164	0,87
	2	w poziomie fundamentów i wszystkich stropów	80	14	94	0,85
	3	w poziomie niektórych stropów	23	11	34	0,68
	4	w poziomie wszystkich stropów	233	69	302	0,77
ZabUz	1	brak	36	36	72	0,50
	2	długie elementy oporowe	77	64	141	0,55
	3	krótkie elementy oporowe	365	16	381	0,96
Rok	1	od 1873 do 1900	67	21	88	0,76
	2	od 1901 do 1910	76	24	100	0,76
	3	od 1911 do 1920	83	15	98	0,85
	4	od 1921 do 1930	77	16	93	0,83
	5	od 1931 do 1940	74	18	92	0,80
	6	od 1941 do 1970	19	6	25	0,76
	7	od 1971 do 1990	25	6	31	0,81
	8	od 1999 do 2010	57	10	67	0,85

Kod zmiennej	Kategoria zmiennej i jej stan		Liczność kategorii w zbiorze			Proporcje podziału
			trenującym	testowym	Σ	
ZuNat	1	dobry	31	6	37	0,84
	2	zadowolający	30	6	36	0,83
	3	średni	275	74	349	0,79
	4	nieodpowiedni	115	22	137	0,84
	5	zły	27	8	35	0,77
Rem	0	nie	402	99	501	0,80
	1	tak	76	17	93	0,82
KOS	1	1	81	21	102	0,79
	2	2	238	59	297	0,80
	3	3	159	36	195	0,82
KTG	1	I (od $\pm 0,4$ do $\pm 1,5$ mm/m)	42	9	51	0,82
	2	II (od $\pm 1,6$ do $\pm 3,0$ mm/m)	208	56	264	0,79
	3	III (od $\pm 3,1$ do $\pm 6,0$ mm/m)	228	51	279	0,82
KsuPrz	1	1	55	12	67	0,82
	2	2	270	70	340	0,79
	3	3	124	27	151	0,82
	4	4	29	7	36	0,81
KsuPo	1	1	42	11	53	0,79
	2	2	270	66	336	0,80
	3	3	134	26	160	0,84
	4	4	32	13	45	0,71

Załącznik 2

**Tablice prawdopodobieństw warunkowych (CPT)
dla struktury BN, metody uczenia TAN-CL
i funkcji celu AIC**

Tablica Z2.1. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Dług**

Długość Dług	Kategoria uszkodzeń KsuPo			
	1	2	3	4
1	0,220	0,095	0,137	0,065
2	0,341	0,146	0,085	0,065
3	0,195	0,123	0,111	0,258
4	0,098	0,198	0,105	0,097
5	0,073	0,158	0,190	0,097
6	0,000	0,166	0,183	0,290
7	0,049	0,051	0,072	0,097
8	0,024	0,063	0,118	0,032

Tablica Z2.2. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Szer**

Kategoria uszkodzeń KsuPo = 1										
Szerokość Szer	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
1	0,417	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,167
2	0,583	0,200	0,400	0,000	0,000	0,000	0,000	0,000	0,000	0,167
3	0,000	0,700	0,000	0,000	0,333	1,000	0,000	0,000	1,000	0,167
4	0,000	0,100	0,200	0,500	0,000	0,000	0,000	0,000	0,000	0,167
5	0,000	0,000	0,400	0,500	0,000	0,000	0,000	0,000	0,000	0,167
6	0,000	0,000	0,000	0,000	0,667	0,000	1,000	1,000	0,000	0,167
Kategoria uszkodzeń KsuPo = 2										
Szerokość Szer	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
1	0,344	0,120	0,105	0,000	0,000	0,026	0,000	0,000	0,000	0,000
2	0,469	0,200	0,105	0,217	0,370	0,368	0,000	0,077	0,000	0,273
3	0,188	0,600	0,237	0,130	0,522	0,395	0,000	0,077	0,176	0,000

Kategoria uszkodzeń KsuPo = 2										
Szerokość Szer	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
4	0,000	0,080	0,184	0,348	0,065	0,079	0,800	0,692	0,294	0,455
5	0,000	0,000	0,342	0,304	0,022	0,079	0,100	0,154	0,353	0,000
6	0,000	0,000	0,026	0,000	0,022	0,053	0,100	0,000	0,176	0,273
Kategoria uszkodzeń KsuPo = 3										
Szerokość Szer	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
1	0,304	0,091	0,077	0,250	0,000	0,000	0,000	0,000	0,000	0,000
2	0,652	0,182	0,000	0,313	0,250	0,300	0,000	0,077	0,000	0,056
3	0,043	0,727	0,692	0,188	0,500	0,400	0,125	0,077	0,111	0,000
4	0,000	0,000	0,077	0,188	0,208	0,200	0,813	0,615	0,333	0,111
5	0,000	0,000	0,077	0,063	0,042	0,000	0,063	0,077	0,222	0,000
6	0,000	0,000	0,077	0,000	0,000	0,100	0,000	0,154	0,333	0,833
Kategoria uszkodzeń KsuPo = 4										
Szerokość Szer	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
1	0,000	1,000	0,091	0,000	0,167	0,167	0,000	0,000	0,000	0,167
2	0,500	0,000	0,273	0,000	0,167	0,000	0,000	0,000	0,000	0,167
3	0,500	0,000	0,455	1,000	0,167	0,667	0,200	0,000	0,000	0,167
4	0,000	0,000	0,182	0,000	0,167	0,167	0,600	1,000	1,000	0,167
5	0,000	0,000	0,000	0,000	0,167	0,000	0,200	0,000	0,000	0,167
6	0,000	0,000	0,000	0,000	0,167	0,000	0,000	0,000	0,000	0,167

Tablica Z2.3. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Powi**

Kategoria uszkodzeń KsuPo = 1								
Powierzchnia Powi	długość Dług							
	1	2	3	4	5	6	7	8
1	1,000	0,214	0,000	0,000	0,000	0,100	0,000	0,000
2	0,000	0,714	0,000	0,000	0,000	0,100	0,000	0,000
3	0,000	0,071	0,250	0,500	0,000	0,100	0,000	0,000
4	0,000	0,000	0,250	0,500	0,000	0,100	0,000	0,000
5	0,000	0,000	0,250	0,000	0,333	0,100	0,000	0,000
6	0,000	0,000	0,000	0,000	0,333	0,100	0,000	0,000
7	0,000	0,000	0,250	0,000	0,000	0,100	1,000	0,000
8	0,000	0,000	0,000	0,000	0,333	0,100	0,000	0,000
9	0,000	0,000	0,000	0,000	0,000	0,100	0,000	1,000
10	0,000	0,000	0,000	0,000	0,000	0,100	0,000	0,000
Kategoria uszkodzeń KsuPo = 2								
Powierzchnia Powi	długość Dług							
	1	2	3	4	5	6	7	8
1	0,875	0,243	0,065	0,000	0,000	0,000	0,000	0,000
2	0,125	0,486	0,097	0,000	0,025	0,000	0,000	0,000
3	0,000	0,270	0,355	0,320	0,000	0,024	0,000	0,000
4	0,000	0,000	0,387	0,180	0,050	0,000	0,000	0,000
5	0,000	0,000	0,065	0,440	0,550	0,000	0,000	0,000
6	0,000	0,000	0,000	0,060	0,300	0,452	0,308	0,000
7	0,000	0,000	0,032	0,000	0,050	0,167	0,000	0,000
8	0,000	0,000	0,000	0,000	0,000	0,262	0,077	0,063
9	0,000	0,000	0,000	0,000	0,025	0,095	0,615	0,250
10	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,688

Kategoria uszkodzeń KsuPo = 3								
Powierzchnia Powi	długość Dług							
	1	2	3	4	5	6	7	8
1	0,762	0,385	0,000	0,000	0,069	0,000	0,000	0,000
2	0,238	0,231	0,118	0,000	0,034	0,000	0,000	0,000
3	0,000	0,385	0,353	0,125	0,000	0,000	0,000	0,000
4	0,000	0,000	0,353	0,250	0,138	0,000	0,000	0,111
5	0,000	0,000	0,176	0,500	0,276	0,179	0,000	0,000
6	0,000	0,000	0,000	0,000	0,207	0,071	0,182	0,000
7	0,000	0,000	0,000	0,000	0,172	0,393	0,000	0,000
8	0,000	0,000	0,000	0,000	0,069	0,321	0,091	0,056
9	0,000	0,000	0,000	0,125	0,034	0,036	0,273	0,111
10	0,000	0,000	0,000	0,000	0,000	0,000	0,455	0,722
Kategoria uszkodzeń KsuPo = 4								
Powierzchnia Powi	długość Dług							
	1	2	3	4	5	6	7	8
1	1,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
2	0,000	0,000	0,000	0,333	0,000	0,000	0,000	0,000
3	0,000	1,000	1,000	0,000	0,000	0,111	0,000	0,000
4	0,000	0,000	0,000	0,667	0,000	0,000	0,000	0,000
5	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
6	0,000	0,000	0,000	0,000	1,000	0,222	0,333	0,000
7	0,000	0,000	0,000	0,000	0,000	0,556	0,000	0,000
8	0,000	0,000	0,000	0,000	0,000	0,111	0,000	0,000
9	0,000	0,000	0,000	0,000	0,000	0,000	0,667	1,000
10	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000

Tablica Z2.4. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **LiKon**

Kategoria uszkodzeń KsuPo = 1											
Liczba kondygnacji LiKon	kubatura Kubat										
	1	2	3	4	5	6	7	8	9	10	11
1	0,78	0,62	0,20	0,17	0,00	0,00	0,20	0,20	0,20	0,20	0,20
2	0,22	0,00	0,33	0,33	0,50	0,00	0,20	0,20	0,20	0,20	0,20
3	0,00	0,00	0,00	0,00	0,00	0,00	0,20	0,20	0,20	0,20	0,20
4	0,00	0,37	0,47	0,00	0,00	0,00	0,20	0,20	0,20	0,20	0,20
5	0,00	0,00	0,00	0,50	0,50	1,00	0,20	0,20	0,20	0,20	0,20
Kategoria uszkodzeń KsuPo = 2											
Liczba kondygnacji LiKon	kubatura Kubat										
	1	2	3	4	5	6	7	8	9	10	11
1	0,78	0,36	0,06	0,06	0,00	0,00	0,00	0,00	0,00	0,00	0,00
2	0,18	0,36	0,16	0,00	0,32	0,06	0,10	0,00	0,09	0,00	0,12
3	0,00	0,00	0,19	0,12	0,06	0,00	0,00	0,61	0,22	0,00	0,19
4	0,04	0,27	0,56	0,75	0,52	0,58	0,52	0,38	0,04	0,00	0,00
5	0,00	0,00	0,03	0,06	0,10	0,35	0,38	0,00	0,65	1,00	0,69
Kategoria uszkodzeń KsuPo = 3											
Liczba kondygnacji LiKon	kubatura Kubat										
	1	2	3	4	5	6	7	8	9	10	11
1	0,29	0,29	0,00	0,00	0,00	0,00	0,05	0,00	0,00	0,00	0,19
2	0,57	0,14	0,11	0,38	0,62	0,07	0,05	0,36	0,00	0,00	0,00
3	0,00	0,29	0,06	0,08	0,12	0,14	0,10	0,18	0,23	0,00	0,37
4	0,14	0,29	0,83	0,38	0,12	0,64	0,25	0,27	0,04	0,00	0,00
5	0,00	0,00	0,00	0,15	0,12	0,14	0,55	0,18	0,73	1,00	0,44

Kategoria uszkodzeń KsuPo = 4											
Liczba kondygnacji LiKon	kubatura Kubat										
	1	2	3	4	5	6	7	8	9	10	11
1	1,00	0,00	0,00	0,00	0,00	0,00	0,33	0,00	0,00	0,00	0,20
2	0,00	0,00	0,00	0,00	0,25	0,00	0,00	0,00	0,00	0,00	0,20
3	0,00	0,00	0,00	0,25	0,37	0,00	0,00	0,00	0,00	0,00	0,20
4	0,00	1,00	1,00	0,75	0,12	0,50	0,67	1,00	0,00	0,00	0,20
5	0,00	0,00	0,00	0,00	0,25	0,50	0,00	0,00	1,00	1,00	0,20

Tablica Z2.5. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Kubat**

Kategoria uszkodzeń KsuPo = 1										
Kubatura Kubat	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
1	0,417	0,000	0,400	0,500	0,000	0,000	0,000	0,000	0,000	0,091
2	0,250	0,000	0,200	0,500	0,000	0,000	0,500	0,000	0,000	0,091
3	0,083	0,900	0,400	0,000	0,000	1,000	0,500	0,000	0,000	0,091
4	0,250	0,000	0,000	0,000	0,667	0,000	0,000	1,000	0,000	0,091
5	0,000	0,100	0,000	0,000	0,000	0,000	0,000	0,000	1,000	0,091
6	0,000	0,000	0,000	0,000	0,333	0,000	0,000	0,000	0,000	0,091
7	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,091
8	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,091
9	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,091
10	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,091
11	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,091
Kategoria uszkodzeń KsuPo = 2										
Kubatura Kubat	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
1	0,344	0,040	0,368	0,043	0,000	0,000	0,000	0,000	0,000	0,000
2	0,188	0,400	0,053	0,130	0,000	0,026	0,000	0,000	0,000	0,000
3	0,375	0,360	0,158	0,130	0,000	0,026	0,100	0,000	0,000	0,000
4	0,094	0,120	0,105	0,087	0,087	0,000	0,000	0,000	0,000	0,000
5	0,000	0,080	0,105	0,000	0,348	0,158	0,000	0,000	0,176	0,000
6	0,000	0,000	0,211	0,261	0,304	0,026	0,000	0,154	0,000	0,000
7	0,000	0,000	0,000	0,348	0,152	0,237	0,100	0,154	0,118	0,000
8	0,000	0,000	0,000	0,000	0,109	0,132	0,100	0,154	0,000	0,000
9	0,000	0,000	0,000	0,000	0,000	0,342	0,300	0,385	0,118	0,000
10	0,000	0,000	0,000	0,000	0,000	0,053	0,400	0,154	0,294	0,000
11	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,294	1,000

Kategoria uszkodzeń KsuPo = 3										
Kubatura Kubat	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
1	0,261	0,000	0,077	0,000	0,000	0,000	0,000	0,000	0,000	0,000
2	0,261	0,455	0,000	0,000	0,125	0,000	0,000	0,000	0,000	0,000
3	0,348	0,364	0,308	0,125	0,000	0,000	0,000	0,000	0,000	0,000
4	0,130	0,182	0,000	0,188	0,125	0,000	0,000	0,154	0,000	0,000
5	0,000	0,000	0,462	0,000	0,042	0,100	0,000	0,000	0,000	0,000
6	0,000	0,000	0,154	0,250	0,292	0,000	0,000	0,077	0,000	0,000
7	0,000	0,000	0,000	0,438	0,250	0,300	0,125	0,077	0,111	0,000
8	0,000	0,000	0,000	0,000	0,167	0,100	0,063	0,077	0,000	0,222
9	0,000	0,000	0,000	0,000	0,000	0,400	0,500	0,615	0,222	0,000
10	0,000	0,000	0,000	0,000	0,000	0,100	0,313	0,000	0,444	0,000
11	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,222	0,778
Kategoria uszkodzeń KsuPo = 4										
Kubatura Kubat	powierzchnia Powi									
	1	2	3	4	5	6	7	8	9	10
1	0,000	0,000	0,182	0,000	0,091	0,000	0,000	0,000	0,000	0,091
2	0,000	1,000	0,000	0,000	0,091	0,000	0,000	0,000	0,000	0,091
3	0,500	0,000	0,000	0,000	0,091	0,000	0,000	0,000	0,000	0,091
4	0,500	0,000	0,273	0,000	0,091	0,000	0,000	0,000	0,000	0,091
5	0,000	0,000	0,455	0,500	0,091	0,333	0,000	0,000	0,000	0,091
6	0,000	0,000	0,091	0,500	0,091	0,000	0,000	0,000	0,000	0,091
7	0,000	0,000	0,000	0,000	0,091	0,333	0,400	0,000	0,667	0,091
8	0,000	0,000	0,000	0,000	0,091	0,000	0,000	1,000	0,000	0,091
9	0,000	0,000	0,000	0,000	0,091	0,333	0,600	0,000	0,000	0,091
10	0,000	0,000	0,000	0,000	0,091	0,000	0,000	0,000	0,333	0,091
11	0,000	0,000	0,000	0,000	0,091	0,000	0,000	0,000	0,000	0,091

Tablica Z2.6. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **DluCi**

Kategoria uszkodzeń KsuPo = 1								
Długość ciągu DluCi	długość Dług							
	1	2	3	4	5	6	7	8
1	0,778	0,000	0,000	0,000	0,000	0,083	0,000	0,000
2	0,000	0,929	0,000	0,000	0,000	0,083	0,000	0,000
3	0,111	0,000	1,000	0,000	0,000	0,083	0,000	0,000
4	0,000	0,000	0,000	1,000	0,000	0,083	0,000	0,000
5	0,000	0,000	0,000	0,000	1,000	0,083	0,000	0,000
6	0,111	0,000	0,000	0,000	0,000	0,083	0,000	0,000
7	0,000	0,000	0,000	0,000	0,000	0,083	1,000	0,000
8	0,000	0,071	0,000	0,000	0,000	0,083	0,000	1,000
9	0,000	0,000	0,000	0,000	0,000	0,083	0,000	0,000
10	0,000	0,000	0,000	0,000	0,000	0,083	0,000	0,000
11	0,000	0,000	0,000	0,000	0,000	0,083	0,000	0,000
12	0,000	0,000	0,000	0,000	0,000	0,083	0,000	0,000
Kategoria uszkodzeń KsuPo = 2								
Długość ciągu DluCi	długość Dług							
	1	2	3	4	5	6	7	8
1	0,833	0,000	0,000	0,000	0,000	0,000	0,000	0,000
2	0,000	0,784	0,000	0,000	0,000	0,000	0,000	0,000
3	0,083	0,000	0,903	0,000	0,000	0,000	0,000	0,000
4	0,000	0,000	0,000	0,700	0,000	0,000	0,000	0,000
5	0,000	0,081	0,000	0,000	0,400	0,000	0,000	0,000
6	0,042	0,000	0,000	0,000	0,000	0,571	0,000	0,000
7	0,000	0,000	0,000	0,000	0,000	0,024	0,769	0,000
8	0,000	0,108	0,000	0,000	0,000	0,000	0,000	0,625

Kategoria uszkodzeń KsuPo = 2								
Długość ciagu DluCi	długość Dlug							
	1	2	3	4	5	6	7	8
9	0,000	0,027	0,032	0,000	0,025	0,071	0,000	0,000
10	0,000	0,000	0,032	0,200	0,300	0,000	0,154	0,250
11	0,000	0,000	0,000	0,040	0,175	0,310	0,000	0,000
12	0,042	0,000	0,032	0,060	0,100	0,024	0,077	0,125
Kategoria uszkodzeń KsuPo = 3								
Długość ciagu DluCi	długość Dlug							
	1	2	3	4	5	6	7	8
1	0,524	0,000	0,000	0,000	0,000	0,000	0,000	0,000
2	0,000	0,846	0,000	0,000	0,000	0,000	0,000	0,000
3	0,000	0,000	0,588	0,000	0,000	0,000	0,000	0,000
4	0,048	0,000	0,000	0,625	0,000	0,000	0,000	0,000
5	0,000	0,000	0,000	0,000	0,552	0,000	0,000	0,000
6	0,190	0,000	0,000	0,000	0,000	0,571	0,000	0,000
7	0,000	0,000	0,000	0,000	0,000	0,000	0,727	0,000
8	0,000	0,077	0,000	0,000	0,000	0,000	0,000	0,500
9	0,143	0,000	0,235	0,000	0,103	0,107	0,000	0,167
10	0,000	0,077	0,176	0,063	0,172	0,071	0,000	0,056
11	0,095	0,000	0,000	0,125	0,000	0,179	0,000	0,000
12	0,000	0,000	0,000	0,188	0,172	0,071	0,273	0,278
Kategoria uszkodzeń KsuPo = 4								
Długość ciagu DluCi	długość Dlug							
	1	2	3	4	5	6	7	8
1	0,500	0,000	0,000	0,000	0,000	0,000	0,000	0,000
2	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
3	0,500	0,000	0,375	0,000	0,000	0,000	0,000	0,000

Kategoria uszkodzeń KsuPo = 4								
Długość ciągu DluCi	długość Dług							
	1	2	3	4	5	6	7	8
4	0,000	0,000	0,000	0,333	0,000	0,000	0,000	0,000
5	0,000	0,000	0,000	0,333	1,000	0,000	0,000	0,000
6	0,000	0,000	0,000	0,000	0,000	0,333	0,000	0,000
7	0,000	0,000	0,000	0,000	0,000	0,111	1,000	0,000
8	0,000	1,000	0,625	0,000	0,000	0,000	0,000	0,000
9	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
10	0,000	0,000	0,000	0,333	0,000	0,111	0,000	0,000
11	0,000	0,000	0,000	0,000	0,000	0,111	0,000	0,000
12	0,000	0,000	0,000	0,000	0,000	0,333	0,000	1,000

Tablica Z2.7. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Dylat**

Kategoria uszkodzeń KsuPo = 1												
Dylata- cja Dylat	długość ciągu DluCi											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0,00	0,00	0,11	0,00	0,00	1,00	0,00	0,00	0,33	0,33	0,33	0,33
2	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,50	0,33	0,33	0,33	0,33
3	1,00	1,00	0,89	1,00	1,00	0,00	1,00	0,50	0,33	0,33	0,33	0,33
Kategoria uszkodzeń KsuPo = 2												
Dylata- cja Dylat	długość ciągu DluCi											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0,00	0,00	0,03	0,03	0,16	0,04	0,00	0,00	0,67	0,34	0,00	0,08
2	0,00	0,03	0,13	0,03	0,05	0,12	0,09	0,29	0,33	0,38	1,00	0,92
3	1,00	0,97	0,83	0,94	0,79	0,84	0,91	0,71	0,00	0,28	0,00	0,00
Kategoria uszkodzeń KsuPo = 3												
Dylata- cja Dylat	długość ciągu DluCi											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0,00	0,00	0,00	0,09	0,00	0,20	0,00	0,00	0,06	0,15	0,22	0,06
2	0,00	0,18	0,00	0,18	0,06	0,00	0,00	0,20	0,75	0,77	0,78	0,94
3	1,00	0,82	1,00	0,73	0,94	0,80	1,00	0,80	0,19	0,08	0,00	0,00
Kategoria uszkodzeń KsuPo = 4												
Dylata- cja Dylat	długość ciągu DluCi											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0,00	0,33	0,25	0,00	0,00	0,00	0,00	0,29	0,33	0,50	0,00	0,25
2	0,00	0,33	0,00	0,00	0,25	0,00	0,25	0,71	0,33	0,50	1,00	0,75
3	1,00	0,33	0,75	1,00	0,75	1,00	0,75	0,00	0,33	0,00	0,00	0,00

Tablica Z2.8. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Kszta**

Kategoria uszkodzeń KsuPo = 1								
Kształt Kszta	długość Dług							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,000	0,000	0,000	0,250	0,000	0,000
2	1,000	0,786	0,625	0,000	0,333	0,250	0,000	0,000
3	0,000	0,000	0,000	0,000	0,000	0,250	0,000	1,000
4	0,000	0,214	0,375	1,000	0,667	0,250	1,000	0,000
Kategoria uszkodzeń KsuPo = 2								
Kształt Kszta	długość Dług							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,065	0,040	0,050	0,286	0,692	0,563
2	0,833	0,892	0,677	0,640	0,850	0,690	0,154	0,000
3	0,000	0,081	0,032	0,080	0,025	0,024	0,000	0,313
4	0,167	0,027	0,226	0,240	0,075	0,000	0,154	0,125
Kategoria uszkodzeń KsuPo = 3								
Kształt Kszta	długość Dług							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,000	0,063	0,207	0,214	0,364	0,444
2	1,000	0,923	0,824	0,750	0,552	0,786	0,545	0,000
3	0,000	0,000	0,059	0,000	0,034	0,000	0,000	0,111
4	0,000	0,077	0,118	0,188	0,207	0,000	0,091	0,444
Kategoria uszkodzeń KsuPo = 4								
Kształt Kszta	długość Dług							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,000	0,000	0,000	0,000	0,333	0,000
2	1,000	1,000	1,000	1,000	1,000	0,778	0,667	0,000
3	0,000	0,000	0,000	0,000	0,000	0,222	0,000	1,000
4	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000

Tablica Z2.9. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Podpi**

Kategoria uszkodzeń KsuPo = 1					
Podpiwniczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
1	0,000	1,000	0,000	0,000	0,000
2	1,000	0,000	1,000	1,000	1,000
3	0,000	0,000	0,000	0,000	0,000
Kategoria uszkodzeń KsuPo = 2					
Podpiwniczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
1	0,040	1,000	0,000	0,000	0,000
2	0,840	0,000	0,960	0,850	0,778
3	0,120	0,000	0,040	0,150	0,222
Kategoria uszkodzeń KsuPo = 3					
Podpiwniczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
1	0,000	1,000	0,000	0,000	0,000
2	1,000	0,000	1,000	0,771	1,000
3	0,000	0,000	0,000	0,229	0,000
Kategoria uszkodzeń KsuPo = 4					
Podpiwniczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
1	0,000	1,000	0,000	0,000	0,000
2	1,000	0,000	1,000	0,960	1,000
3	0,000	0,000	0,000	0,040	0,000

Tablica Z2.10. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **ZmPos**

Kategoria uszkodzeń KsuPo = 1			
Zmienny poziom posadowienia ZmPos	podpiwniczenie Podpi		
	1	2	3
0	1,000	1,000	0,500
1	0,000	0,000	0,500
Kategoria uszkodzeń KsuPo = 2			
Zmienny poziom posadowienia ZmPos	podpiwniczenie Podpi		
	1	2	3
0	1,000	1,000	0,115
1	0,000	0,000	0,885
Kategoria uszkodzeń KsuPo = 3			
Zmienny poziom posadowienia ZmPos	podpiwniczenie Podpi		
	1	2	3
0	1,000	1,000	0,158
1	0,000	0,000	0,842
Kategoria uszkodzeń KsuPo = 4			
Zmienny poziom posadowienia ZmPos	podpiwniczenie Podpi		
	1	2	3
0	1,000	1,000	0,000
1	0,000	0,000	1,000

Tablica Z2.11. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **ZmWys**

Kategoria uszkodzeń KsuPo = 1								
Zmienna wysokość ZmWys	rok budowy Rok							
	1	2	3	4	5	6	7	8
0	1,000	0,500	1,000	0,500	1,000	1,000	0,429	0,941
1	0,000	0,500	0,000	0,500	0,000	0,000	0,571	0,059
Kategoria uszkodzeń KsuPo = 2								
Zmienna wysokość ZmWys	rok budowy Rok							
	1	2	3	4	5	6	7	8
0	0,944	0,964	1,000	1,000	0,980	0,900	0,167	0,958
1	0,056	0,036	0,000	0,000	0,020	0,100	0,833	0,042
Kategoria uszkodzeń KsuPo = 3								
Zmienna wysokość ZmWys	rok budowy Rok							
	1	2	3	4	5	6	7	8
0	0,926	1,000	1,000	1,000	1,000	0,500	0,000	0,600
1	0,074	0,000	0,000	0,000	0,000	0,500	1,000	0,400
Kategoria uszkodzeń KsuPo = 4								
Zmienna wysokość ZmWys	rok budowy Rok							
	1	2	3	4	5	6	7	8
0	1,000	0,833	1,000	1,000	1,000	0,500	0,500	0,500
1	0,000	0,167	0,000	0,000	0,000	0,500	0,500	0,500

Tablica Z2.12. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **RoFun**

Kategoria uszkodzeń KsuPo = 1								
Rodzaj fundamentu RoFun	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,333	0,000	0,333	0,000	0,000	0,000	0,000
2	1,000	0,333	1,000	0,333	1,000	0,500	0,000	0,000
3	0,000	0,333	0,000	0,333	0,000	0,500	1,000	1,000
Kategoria uszkodzeń KsuPo = 2								
Rodzaj fundamentu RoFun	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,500	0,286	0,109	0,087	0,157	0,000	0,000	0,000
2	0,500	0,714	0,891	0,913	0,843	0,500	0,000	0,000
3	0,000	0,000	0,000	0,000	0,000	0,500	1,000	1,000
Kategoria uszkodzeń KsuPo = 3								
Rodzaj fundamentu RoFun	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,593	0,273	0,130	0,118	0,091	0,000	0,000	0,000
2	0,407	0,727	0,870	0,882	0,909	1,000	0,000	0,000
3	0,000	0,000	0,000	0,000	0,000	0,000	1,000	1,000
Kategoria uszkodzeń KsuPo = 4								
Rodzaj fundamentu RoFun	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,556	0,500	0,000	0,000	0,000	0,333	0,333	0,333
2	0,444	0,500	1,000	1,000	1,000	0,333	0,333	0,333
3	0,000	0,000	0,000	0,000	0,000	0,333	0,333	0,333

Tablica Z2.13. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Msp**

Kategoria uszkodzeń KsuPo = 1			
Materiał ścian piwnic Msp	rodzaj fundamentu RoFun		
	1	2	3
1	0,333	0,000	0,808
2	0,333	1,000	0,192
3	0,333	0,000	0,000
Kategoria uszkodzeń KsuPo = 2			
Materiał ścian piwnic Msp	rodzaj fundamentu RoFun		
	1	2	3
1	0,000	0,000	0,805
2	0,605	1,000	0,195
3	0,395	0,000	0,000
Kategoria uszkodzeń KsuPo = 3			
Materiał ścian piwnic Msp	rodzaj fundamentu RoFun		
	1	2	3
1	0,000	0,000	0,833
2	0,857	1,000	0,167
3	0,143	0,000	0,000
Kategoria uszkodzeń KsuPo = 4			
Materiał ścian piwnic Msp	rodzaj fundamentu RoFun		
	1	2	3
1	0,000	0,000	0,333
2	0,500	1,000	0,333
3	0,500	0,000	0,333

Tablica Z2.14. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Mspiw**

Kategoria uszkodzeń KsuPo = 1			
Materiał ścian parteru i wyższych kondygnacji Mspiw	materiał ścian piwnic Msp		
	1	2	3
1	0,333	1,000	0,500
2	0,667	0,000	0,500
Kategoria uszkodzeń KsuPo = 2			
Materiał ścian parteru i wyższych kondygnacji Mspiw	materiał ścian piwnic Msp		
	1	2	3
1	0,152	1,000	1,000
2	0,848	0,000	0,000
Kategoria uszkodzeń KsuPo = 3			
Materiał ścian parteru i wyższych kondygnacji Mspiw	materiał ścian piwnic Msp		
	1	2	3
1	0,300	1,000	1,000
2	0,700	0,000	0,000
Kategoria uszkodzeń KsuPo = 4			
Materiał ścian parteru i wyższych kondygnacji Mspiw	materiał ścian piwnic Msp		
	1	2	3
1	0,500	1,000	1,000
2	0,500	0,000	0,000

Tablica Z2.15. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Snp**

Kategoria uszkodzeń KsuPo = 1								
Strop nad parterem Snp	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,200	0,000	0,200	1,000	0,000	0,000	0,000
2	0,000	0,200	0,000	0,200	0,000	0,000	0,143	0,765
3	0,000	0,200	1,000	0,200	0,000	0,000	0,000	0,000
4	1,000	0,200	0,000	0,200	0,000	0,000	0,000	0,000
5	0,000	0,200	0,000	0,200	0,000	1,000	0,857	0,235
Kategoria uszkodzeń KsuPo = 2								
Strop nad parterem Snp	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,071	0,152	0,022	0,196	0,500	0,000	0,000
2	0,083	0,000	0,000	0,000	0,000	0,000	0,250	0,917
3	0,167	0,143	0,239	0,565	0,529	0,100	0,000	0,000
4	0,750	0,786	0,565	0,413	0,255	0,000	0,000	0,000
5	0,000	0,000	0,043	0,000	0,020	0,400	0,750	0,083
Kategoria uszkodzeń KsuPo = 3								
Strop nad parterem Snp	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,023	0,130	0,000	0,364	0,250	0,000	0,000
2	0,185	0,000	0,000	0,000	0,045	0,000	1,000	0,900
3	0,333	0,114	0,043	0,471	0,364	0,750	0,000	0,000
4	0,481	0,864	0,783	0,529	0,227	0,000	0,000	0,000
5	0,000	0,000	0,043	0,000	0,000	0,000	0,000	0,100

Kategoria uszkodzeń KsuPo = 4								
Strop nad parterem Snp	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,000	0,000	0,200	0,200	0,200	0,200
2	0,222	0,000	0,000	0,000	0,000	0,200	0,200	0,200
3	0,000	0,167	0,000	0,167	0,000	0,200	0,200	0,200
4	0,778	0,833	0,800	0,833	0,800	0,200	0,200	0,200
5	0,000	0,000	0,200	0,000	0,000	0,200	0,200	0,200

Tablica Z2.16. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Snpiw**

Kategoria uszkodzeń KsuPo = 1			
Strop nad parterem i powyżej Mspiw	rodzaj fundamentu RoFun		
	1	2	3
1	0,333	0,867	0,154
2	0,333	0,000	0,269
3	0,333	0,133	0,577
Kategoria uszkodzeń KsuPo = 2			
Strop nad parterem i powyżej Mspiw	rodzaj fundamentu RoFun		
	1	2	3
1	1,000	0,988	0,146
2	0,000	0,012	0,366
3	0,000	0,000	0,488
Kategoria uszkodzeń KsuPo = 3			
Strop nad parterem i powyżej Mspiw	rodzaj fundamentu RoFun		
	1	2	3
1	1,000	1,000	0,000
2	0,000	0,000	0,583
3	0,000	0,000	0,417
Kategoria uszkodzeń KsuPo = 4			
Strop nad parterem i powyżej Mspiw	rodzaj fundamentu RoFun		
	1	2	3
1	1,000	1,000	0,333
2	0,000	0,000	0,333
3	0,000	0,000	0,333

Tablica Z2.17. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Nadpr**

Kategoria uszkodzeń KsuPo = 1								
Nadproża Nadpr	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,333	0,000	0,333	0,000	1,000	1,000	0,941
2	0,000	0,333	1,000	0,333	1,000	0,000	0,000	0,059
3	1,000	0,333	0,000	0,333	0,000	0,000	0,000	0,000
Kategoria uszkodzeń KsuPo = 2								
Nadproża Nadpr	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,028	0,036	0,043	0,000	0,000	0,800	1,000	0,958
2	0,306	0,214	0,870	0,826	1,000	0,200	0,000	0,042
3	0,667	0,750	0,087	0,174	0,000	0,000	0,000	0,000
Kategoria uszkodzeń KsuPo = 3								
Nadproża Nadpr	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,000	0,000	0,000	0,250	1,000	1,000
2	0,593	0,205	0,783	1,000	1,000	0,750	0,000	0,000
3	0,407	0,795	0,217	0,000	0,000	0,000	0,000	0,000
Kategoria uszkodzeń KsuPo = 4								
Nadproża Nadpr	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,000	0,000	0,000	0,333	0,333	0,333
2	0,111	0,167	0,800	1,000	1,000	0,333	0,333	0,333
3	0,889	0,833	0,200	0,000	0,000	0,333	0,333	0,333

Tablica Z2.18. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Zabez**

Kategoria uszkodzeń KsuPo = 1			
Zabezpieczenia Zabez	rodzaj fundamentu RoFun		
	1	2	3
1	0,250	0,200	0,000
2	0,250	0,000	1,000
3	0,250	0,000	0,000
4	0,250	0,800	0,000
Kategoria uszkodzeń KsuPo = 2			
Zabezpieczenia Zabez	rodzaj fundamentu RoFun		
	1	2	3
1	0,000	0,444	0,122
2	0,023	0,024	0,780
3	0,186	0,036	0,000
4	0,791	0,497	0,098
Kategoria uszkodzeń KsuPo = 3			
Zabezpieczenia Zabez	rodzaj fundamentu RoFun		
	1	2	3
1	0,171	0,358	0,000
2	0,029	0,000	1,000
3	0,086	0,047	0,000
4	0,714	0,594	0,000
Kategoria uszkodzeń KsuPo = 4			
Zabezpieczenia Zabez	rodzaj fundamentu RoFun		
	1	2	3
1	0,250	0,304	0,250
2	0,000	0,000	0,250
3	0,000	0,087	0,250
4	0,750	0,609	0,250

Tablica Z2.19. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **ZabUz**

Kategoria uszkodzeń KsuPo = 1				
Zabezpieczenia dane uzupełniające ZabUz	zabezpieczenia Zabez			
	1	2	3	4
1	1,000	1,000	0,333	0,167
2	0,000	0,000	0,333	0,500
3	0,000	0,000	0,333	0,333
Kategoria uszkodzeń KsuPo = 2				
Zabezpieczenia dane uzupełniające ZabUz	zabezpieczenia Zabez			
	1	2	3	4
1	1,000	0,865	0,000	0,016
2	0,000	0,135	0,786	0,730
3	0,000	0,000	0,214	0,254
Kategoria uszkodzeń KsuPo = 3				
Zabezpieczenia dane uzupełniające ZabUz	zabezpieczenia Zabez			
	1	2	3	4
1	1,000	0,923	0,000	0,000
2	0,000	0,077	1,000	0,727
3	0,000	0,000	0,000	0,273
Kategoria uszkodzeń KsuPo = 4				
Zabezpieczenia dane uzupełniające ZabUz	zabezpieczenia Zabez			
	1	2	3	4
1	1,000	0,333	0,000	0,000
2	0,000	0,333	1,000	0,900
3	0,000	0,333	0,000	0,100

Tablica Z2.20. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Podpi**

Kategoria uszkodzeń KsuPo = 1					
Podpiwnczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
1	0,000	0,000	0,125	0,000	0,400
2	0,000	0,000	0,125	0,000	0,000
3	0,000	0,300	0,125	0,000	0,000
4	0,000	0,000	0,125	0,000	0,000
5	0,000	0,000	0,125	0,500	0,600
6	0,000	0,200	0,125	0,200	0,000
7	0,000	0,400	0,125	0,300	0,000
8	1,000	0,100	0,125	0,000	0,000
Kategoria uszkodzeń KsuPo = 2					
Podpiwnczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
1	0,156	0,162	0,038	0,109	0,212
2	0,000	0,054	0,154	0,065	0,242
3	0,031	0,162	0,115	0,315	0,106
4	0,000	0,216	0,462	0,174	0,152
5	0,000	0,081	0,231	0,250	0,288
6	0,125	0,135	0,000	0,011	0,000
7	0,000	0,189	0,000	0,054	0,000
8	0,688	0,000	0,000	0,022	0,000
Kategoria uszkodzeń KsuPo = 3					
Podpiwnczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
1	0,300	0,167	0,042	0,182	0,216
2	0,000	0,042	0,292	0,205	0,529

Kategoria uszkodzeń KsuPo = 3					
Podpiwniczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
3	0,000	0,125	0,292	0,182	0,098
4	0,400	0,083	0,292	0,068	0,020
5	0,100	0,167	0,000	0,227	0,137
6	0,000	0,083	0,000	0,136	0,000
7	0,000	0,083	0,000	0,000	0,000
8	0,200	0,250	0,083	0,000	0,000
Kategoria uszkodzeń KsuPo = 4					
Podpiwniczenie Podpi	strop nad piwnicą Snp				
	1	2	3	4	5
1	0,500	1,000	0,000	0,167	0,333
2	0,000	0,000	0,000	0,083	0,556
3	0,000	0,000	0,250	0,333	0,000
4	0,500	0,000	0,000	0,333	0,000
5	0,000	0,000	0,750	0,083	0,111
6	0,000	0,000	0,000	0,000	0,000
7	0,000	0,000	0,000	0,000	0,000
8	0,000	0,000	0,000	0,000	0,000

Tablica Z2.21. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **ZuNat**

Kategoria uszkodzeń KsuPo = 1								
Zużycie naturalne ZuNat	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,200	0,000	0,200	0,000	0,000	0,000	0,882
2	0,000	0,200	0,000	0,200	0,250	1,000	0,286	0,059
3	0,500	0,200	1,000	0,200	0,750	0,000	0,714	0,059
4	0,500	0,200	0,000	0,200	0,000	0,000	0,000	0,000
5	0,000	0,200	0,000	0,200	0,000	0,000	0,000	0,000
Kategoria uszkodzeń KsuPo = 2								
Zużycie naturalne ZuNat	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,056	0,000	0,000	0,000	0,000	0,000	0,000	0,333
2	0,000	0,107	0,000	0,000	0,118	0,100	0,000	0,333
3	0,556	0,714	0,565	0,522	0,882	0,900	1,000	0,208
4	0,333	0,143	0,435	0,478	0,000	0,000	0,000	0,125
5	0,056	0,036	0,000	0,000	0,000	0,000	0,000	0,000
Kategoria uszkodzeń KsuPo = 3								
Zużycie naturalne ZuNat	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,400
2	0,000	0,023	0,000	0,000	0,045	0,000	0,000	0,500
3	0,296	0,477	0,609	0,882	0,909	1,000	1,000	0,000
4	0,481	0,250	0,391	0,118	0,000	0,000	0,000	0,100
5	0,222	0,250	0,000	0,000	0,045	0,000	0,000	0,000
Kategoria uszkodzeń KsuPo = 4								
Zużycie naturalne ZuNat	rok budowy Rok							
	1	2	3	4	5	6	7	8
1	0,000	0,000	0,000	0,000	0,000	0,200	0,200	0,200

Kategoria uszkodzeń KsuPo = 4								
Zużycie naturalne ZuNat	rok budowy Rok							
	1	2	3	4	5	6	7	8
2	0,000	0,000	0,000	0,000	0,000	0,200	0,200	0,200
3	0,111	0,167	0,600	0,333	0,400	0,200	0,200	0,200
4	0,333	0,167	0,400	0,667	0,600	0,200	0,200	0,200
5	0,556	0,667	0,000	0,000	0,000	0,200	0,200	0,200

Tablica Z2.22. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **Rem**

Kategoria uszkodzeń KsuPo = 1				
Remonty Rem	kategoria uszkodzeń KsuPrz			
	1	2	3	4
0	1,000	0,000	0,000	0,000
1	0,000	1,000	1,000	1,000
Kategoria uszkodzeń KsuPo = 2				
Remonty Rem	kategoria uszkodzeń KsuPrz			
	1	2	3	4
0	1,000	1,000	0,000	0,000
1	0,000	0,000	1,000	1,000
Kategoria uszkodzeń KsuPo = 3				
Remonty Rem	kategoria uszkodzeń KsuPrz			
	1	2	3	4
0	1,000	1,000	1,000	0,000
1	0,000	0,000	0,000	1,000
Kategoria uszkodzeń KsuPo = 4				
Remonty Rem	kategoria uszkodzeń KsuPrz			
	1	2	3	4
0	1,000	1,000	1,000	1,000
1	0,000	0,000	0,000	0,000

Tablica Z2.23. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **KOS**

Kategoria uszkodzeń KsuPo = 1											
Kategoria odporności KOS	kubatura Kubat										
	1	2	3	4	5	6	7	8	9	10	11
1	0,00	0,00	0,00	0,00	0,00	0,00	0,33	0,33	0,33	0,33	0,33
2	0,00	0,25	0,07	0,00	0,00	1,00	0,33	0,33	0,33	0,33	0,33
3	1,00	0,75	0,93	1,00	1,00	0,00	0,33	0,33	0,33	0,33	0,33
Kategoria uszkodzeń KsuPo = 2											
Kategoria odporności KOS	kubatura Kubat										
	1	2	3	4	5	6	7	8	9	10	11
1	0,00	0,04	0,03	0,00	0,00	0,06	0,21	0,38	0,39	0,31	0,62
2	0,11	0,09	0,31	0,44	0,68	0,58	0,76	0,54	0,61	0,69	0,37
3	0,89	0,86	0,66	0,56	0,32	0,35	0,03	0,08	0,00	0,00	0,00
Kategoria uszkodzeń KsuPo = 3											
Kategoria odporności KOS	kubatura Kubat										
	1	2	3	4	5	6	7	8	9	10	11
1	0,00	0,00	0,06	0,00	0,00	0,14	0,00	0,09	0,23	0,40	0,81
2	0,43	0,64	0,67	0,69	0,87	0,71	0,85	0,54	0,54	0,60	0,19
3	0,57	0,36	0,28	0,31	0,12	0,14	0,15	0,36	0,23	0,00	0,00
Kategoria uszkodzeń KsuPo = 4											
Kategoria odporności KOS	kubatura Kubat										
	1	2	3	4	5	6	7	8	9	10	11
1	0,00	0,00	0,00	0,00	0,12	0,00	0,17	0,00	0,60	1,00	0,33
2	0,00	0,00	1,00	1,00	0,62	1,00	0,83	0,00	0,40	0,00	0,33
3	1,00	1,00	0,00	0,00	0,25	0,00	0,00	1,00	0,00	0,00	0,33

Tablica Z2.24. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **KsuPrz**

Kategoria uszkodzeń KsuPo = 1			
Kategoria uszkodzeń KsuPrz	materiał ścian piwnic Msp		
	1	2	3
1	0,667	0,800	0,250
2	0,333	0,100	0,250
3	0,000	0,050	0,250
4	0,000	0,050	0,250
Kategoria uszkodzeń KsuPo = 2			
Kategoria uszkodzeń KsuPrz	materiał ścian piwnic Msp		
	1	2	3
1	0,455	0,025	0,059
2	0,485	0,709	0,824
3	0,061	0,222	0,000
4	0,000	0,044	0,118
Kategoria uszkodzeń KsuPo = 3			
Kategoria uszkodzeń KsuPrz	materiał ścian piwnic Msp		
	1	2	3
1	0,000	0,014	0,200
2	0,300	0,399	0,400
3	0,700	0,543	0,200
4	0,000	0,043	0,200
Kategoria uszkodzeń KsuPo = 4			
Kategoria uszkodzeń KsuPrz	materiał ścian piwnic Msp		
	1	2	3
1	0,250	0,037	0,000
2	0,250	0,259	0,250
3	0,250	0,333	0,250
4	0,250	0,370	0,500

Tablica Z2.25. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **KTG**

Kategoria terenu górniczego KTG	Kategoria uszkodzeń KsuPo			
	1	2	3	4
1	0,159	0,066	0,138	0,072
2	0,364	0,435	0,528	0,422
3	0,477	0,499	0,334	0,506

Tablica Z2.26. Tablica prawdopodobieństw warunkowych (CPT) dotycząca zmiennej **KsuPo**

Kategoria uszkodzeń KsuPo			
1	2	3	4
0,086	0,529	0,320	0,065

INSTYTUT TECHNIKI BUDOWLANEJ (ITB)

Podstawowym celem badań naukowych i prac rozwojowych prowadzonych w Instytucie Techniki Budowlanej od początku jego działalności (1945) było i jest zapewnienie jakości polskiego budownictwa oraz ochrona interesów użytkowników obiektów budowlanych. Badania naukowe i prace rozwojowe wykonywane przez Instytut na potrzeby budownictwa obejmują szeroki zakres zagadnień związanych z podstawowymi wymaganiami dotyczącymi obiektów budowlanych, w szczególności:

- bezpieczeństwo konstrukcji • bezpieczeństwo pożarowe obiektów budowlanych • bezpieczeństwo i dogodność użytkowania • bezpieczeństwo instalacji elektrycznych • zrównoważone budownictwo • racjonalizacja użytkowania energii i wody • ochrona przed hałasem i drganiami oraz wpływ drgań na człowieka i konstrukcje • środowisko (w tym oddziaływanie materiałów na zdrowie oraz warunki sanitarne w pomieszczeniach) • wzajemne oddziaływanie środowiska, użytkowanie obiektów i działalność budowlana • trwałość (w tym ochrona przed wilgocią oraz korozją chemiczną i biologiczną) • podłoże budowlane • użytkowanie instalacji sanitarnych, przemysłowych i przeciwpożarowych • skuteczność instalacji wykrywania, powiadamiania i sygnalizacji pożaru • utrzymanie elementów wyposażenia obiektów budowlanych (w tym zabezpieczeń przeciwpożarowych oraz okuć budowlanych).

W wyniku prowadzonych prac Instytut opracowuje:

- podstawy wymagań techniczno-użytkowych stawianych budynkom i wyrobom budowlanym,
- metody obliczania i projektowania budynków oraz elementów budowli,
- metody badań i kryteria oceny obiektów, ich elementów i wyrobów budowlanych,
- techniczne podstawy polityki budowlanej państwa.

Oprócz dwóch lokalizacji w Warszawie, ITB posiada trzy oddziały zamiejscowe. Oddział Śląski w Katowicach specjalizuje się w zagadnieniach z zakresu budownictwa na terenach poddanych wpływowi górniczej deformacji terenu oraz badaniach zamocowań konstrukcyjnych i instalacyjnych. Oddział Wielkopolski w Poznaniu prowadzi działalność badawczą i aprobacyjną związaną z okuciami budowlanymi i ślusarką budowlaną oraz elementami wyposażeniowymi i wykończeniowymi, w tym do technicznego zabezpieczenia budynków i pomieszczeń przed włamaniem. Oddział Mazowiecki w Pionkach wykonuje badania wyrobów, elementów konstrukcji i instalacji w warunkach pożaru.

BUILDING RESEARCH INSTITUTE (ITB)

The basic aim of research and development works carried out at the ITB, from the very beginning of its activity (1945), was to ensure the quality of the Polish building industry and to protect the interests of users of the construction works. The research and development works carried out by the Institute for the purposes of construction embrace a wide scope of issues related to fundamental requirements of building law that should be met by building facilities, in particular the following:

- safety of structures • fire safety of building objects • safety in use • sustainable construction • safety of electric installations • rationalization of energy and water use in buildings • protection against noise and vibrations and the impact of vibrations on humans and buildings • environment (including the impact of materials on health and sanitary indoor conditions) • interaction between the environment, the use of buildings and construction • durability of civil engineering works (including protection against moisture as well as chemical and biological corrosion) • foundation soil • use of installation systems • maintenance of building components (including fire-protection systems and those related to evacuation of people and construction fittings).

As a result of the works carried out, the Institute develops:

- the bases of technical and functional requirements for buildings and building products,
- methods for calculation and designing of building elements,
- test methods and assessment criteria for construction works, their elements and building products,
- technical bases for the building policy of the State.

Besides two locations in Warsaw, the ITB has three remote branches. The Silesian Branch in Katowice deals with construction upon mining exploitation areas and with testing of joint elements. The Wielkopolska Branch in Poznań is concerned with research and approval activities related to the constructions fittings, metal-work and finishing and auxiliary products, including building burglary protection. The Mazovian Branch in Pionki deals with testing durability and tightness of construction products and building components under fire condition.

Adres / Address: ul. Filtrowa 1, 00-611 Warszawa, tel/fax: 22 825-13-03



Dr inż. Leszek Chomacki

Absolwent Wydziału Inżynierii Lądowej i Środowiska Politechniki Gdańskiej, gdzie w 2011 r. ukończył studia magisterskie na kierunku budownictwo w specjalności geotechnika. W tym samym roku rozpoczął pracę w Instytucie Techniki Budowlanej w Warszawie. Obecnie jest pracownikiem Zakładu Konstrukcji Budowlanych, Geotechniki i Betonu. W 2021 r. uzyskał w ITB stopień naukowy doktora nauk inżynieryjno-technicznych w dyscyplinie inżynieria lądowa i transport.

Członek Komisji Ochrony Terenów Górniczych Polskiej Akademii Nauk (oddział w Katowicach). Posiada uprawnienia budowlane do projektowania w specjalności konstrukcyjno-budowlanej bez ograniczeń.

Autor lub współautor ponad 50 artykułów (opublikowanych m.in. w *Energies*, *Minerals*) oraz referatów naukowo-technicznych wygłoszonych na kilkunastu konferencjach krajowych i międzynarodowych (m.in. w Międzyzdrojach i Krynicy). Recenzent kilkunastu publikacji dla renomowanych międzynarodowych czasopism naukowych (m.in. *Archives of Civil Engineering*, *Applied Sciences*, *Sustainability*). Główny referent lub współautor blisko 200 opinii i ekspertyz technicznych, przede wszystkim z zakresu budownictwa na terenach górniczych.