

# Zastosowanie wnioskowania Bayesa do oceny zagrożenia budynków wielkoblokowych na terenach górniczych

## Bayesian inference for the assessment of threats to large-block building structures in mining areas



Dr hab. inż. Janusz Rusek \*)



Dr hab. inż. Karol Firek \*)

**Treść:** W artykule przedstawiono przykłady wykorzystania modeli opartych na formalizmie wnioskowania Bayesa do analizy zagrożenia budynków zlokalizowanych na terenach górniczych. Przedmiotem badań była grupa 126 budynków wzniesionych w technologii wielkoblokowej. Przedstawiono metody wnioskowania wykorzystane w dotychczasowych badaniach ryzyka powstawania uszkodzeń w budynkach narażonych na negatywne skutki eksploatacji górniczej. Obejmowały one ocenę stanu technicznego ( $s_t$ ), w ramach której do budowy modelu zastosowano naiwną klasyfikację Bayesa, a także analizę intensywności uszkodzeń elementów składowych budynku, z wykorzystaniem Bayesowskich sieci przekonań. W konkluzji przedstawiono koncepcję uszczegółowienia wyników wcześniejszych badań. Polega ona na samoistnym generowaniu struktury sieci Bayesa w oparciu o bazę danych o intensywności uszkodzeń istniejących budynków.

**Abstract:** This research paper provides examples of the use of models based on the formalism of Bayesian inference for the analysis of the threats to building structures located in mining areas. The subject of the research study was a group of 126 buildings erected in the large-block technology. The authors presented the inference methods of the risk of the occurrence of damage to buildings exposed to the adverse effects of mining exploitation, which were used in the previous studies. They included the assessment of the technical condition ( $s_t$ ), where the naive Bayes classification was used to build the model, as well as the analysis of the intensity of damage to the components of a building structure, using the Bayesian belief networks. The conclusion presents the concept of detailing the results of the previous research. It involves the Bayesian network structure being spontaneously generated, based on the database on the intensity of damage to the existing buildings.

### Słowa kluczowe:

wnioskowanie Bayesa, szkody górnicze w budynkach, ocena ryzyka uszkodzeń, oddziaływania górnicze

### Keywords:

Bayesian inference, mining damage to buildings, damage risk assessment, mining impacts

## 1. Wstęp

Z eksploatacją górniczą związane jest ryzyko powstawania szkód w budynkach stanowiących zabudowę terenu górniczego. Jak wynika z wieloletnich badań prowadzonych w *Katedrze Geodezji Inżynierskiej i Budownictwa AGH*, uszkodzenia, które występują w zabudowie terenów górniczych obniżają walory użytkowe lub utrudniają poprawną eksploatację, lecz rzadko stanowią zagrożenie bezpieczeństwa (Wodyński 2007).

Koszty napraw szkód górniczych, lub ewentualnego wykonania zabezpieczeń profilaktycznych, ponosi zakład górniczy. Dlatego istotne jest ustalenie ryzyka powstania uszkodzeń zarówno na etapie planowania eksploatacji górniczej, jak i w sytuacji ujawnienia się wpływów górniczych na powierzchni

terenu. W pierwszym przypadku dokonywana jest predykcja intensywności potencjalnych uszkodzeń zabudowy terenu górniczego. W drugim przypadku konieczne jest wskazanie przyczyny zaistniałego stanu uszkodzeń, którą mogą być ujawnione na powierzchni terenu wpływy eksploatacji górniczej.

Ustalenie ryzyka zajścia zdarzenia polegającego na powstaniu uszkodzenia w obiekcie budowlanym jest równoważne z podaniem prawdopodobieństwa jego wystąpienia w wyniku oddziaływania na obiekt czynników zewnętrznych. Dla obiektów budowlanych usytuowanych na terenach górniczych, czynnikami warunkującymi powstanie szkód górniczych są deformacje terenu i wstrząsy górnicze np. (Kwiatkiewicz 2007).

W ocenie ryzyka powstania szkód górniczych, oprócz parametrów opisujących intensywność oddziaływań górniczych, niezbędne są również informacje na temat cech geometrycznych i technologiczno-materiałowych danego obiektu. Dlatego ocena ta stanowi złożony problem decyzyjny.

\*) AGH Akademia Górniczo-Hutnicza w Krakowie

W niniejszej pracy przedstawiono podsumowanie wyników badań przeprowadzonych w ostatnich latach w Katedrze Geodezji Inżynierskiej i Budownictwa AGH (Rusek, Firek 2016, Rusek, Firek 2016), w trakcie których zastosowano probabilistyczne modele klasyfikacyjne bazujące na twierdzeniu Bayesa (*naiwny klasyfikator Bayesa* oraz *sieci przekonań Bayesa* (Bishop 2006)). Pozwalają one uszczegółowić wynik klasyfikacji stanu technicznego ( $s_t$ ) bądź intensywności uszkodzeń ( $w_u$ ) o wartość prawdopodobieństwa. Zastosowana metodyka jest zbieżna z podejściem stosowanym do oceny niezawodności konstrukcji budowlanych (Kwiatkiewicz 2007). Dodatkowo, w przypadku *sieci przekonań Bayesa*, oprócz predykcji intensywności uszkodzeń ( $w_u$ ) możliwe jest wnioskowanie odwrotne, w którym wskazuje się przyczyny zaistnienia stanu uszkodzeń.

## 2. Metodyka badań

### 2.1. Naiwna klasyfikacja Bayesa do oceny stanu technicznego budynków poddanych wpływom górniczym

W przypadku licznych grup budynków zlokalizowanych na terenach objętych wpływami eksploatacji górniczej, analiza zależności stanu technicznego budynków ( $s_t$ ) od potencjalnych przyczyn może stanowić efektywną metodę oceny szkód górniczych.

W artykule (Rusek, Firek 2016) przedstawiono propozycję takiej oceny metodą *naiwnego klasyfikatora Bayesa* (*Naive Bayes Classifier – NBC*) (Bishop 2006). Wyniki analiz pozwoliły na wstępną ocenę przydatności tego typu metody do dalszych badań. Dodatkowo, w ramach niniejszej pracy, parametry modelu zostały dobrane na drodze optymalizacji. Procedurę tę przeprowadzono w środowisku Matlab z zastosowaniem metody  $k$ -krotnej walidacji skrojonej oraz optymalizacji Bayesowskiej (Snoek i in. 2012). Utworzony w wyniku przeprowadzonych badań model pozwala na wskazanie stanu technicznego obiektu na podstawie informacji o jego odporności na wpływy górnicze, jakości utrzymania oraz oddziaływaniach górniczych. Uzyskany wynik może zostać uszczegółowiony o odpowiadającą danej kategorii stanu technicznego wartość prawdopodobieństwa.

W badaniach wykorzystano informacje zebrane podczas inwentaryzacji przeprowadzonych z udziałem autorów. Na tej podstawie utworzono bazę danych o 126 wielokondygnacyjnych budynkach mieszkalnych i użyteczności publicznej, w wieku do 35 lat, usytuowanych na terenie górniczym

LGOM. Obiekty podlegające analizie wykonane zostały w technologii wieloblokowej, w systemach wielki blok (WBL) oraz szkolny wielki blok (SzWBL).

Do budowy modelu wykorzystano zmienne opisujące:

- wiek budynku (zmienna *WIEK*),
- intensywność ciągłych deformacji terenu w miejscu lokalizacji obiektu (zmienna *KT*),
- intensywność wstrząsów górniczych ( $a_{sg}$  zgodnie z (Wodyński, Lasocki 2003),
- odporność danego obiektu na wpływ ciągłych deformacji terenu (zmienna *KO*),
- jakość utrzymania (wskaźnik uwzględniający informacje nt. dokonanych remontów - zmienna *REM*).

Do opisu zmiennej decyzyjnej, którą był stan techniczny ( $s_t$ ), wykorzystano kategorie wynikające z wartości stopnia zużycia technicznego  $s_z$  – tabela 1.

Przed przystąpieniem do badań baza danych została podzielona na zbiór treningowy (89 wzorce) oraz testowy (37 wzorców). Przy tak wydzielonych zbiorach treningowym i testowym zbudowano model *naiwnego klasyfikatora Bayesa* (rys. 1), wykonując obliczenia w środowisku *Matlab*.

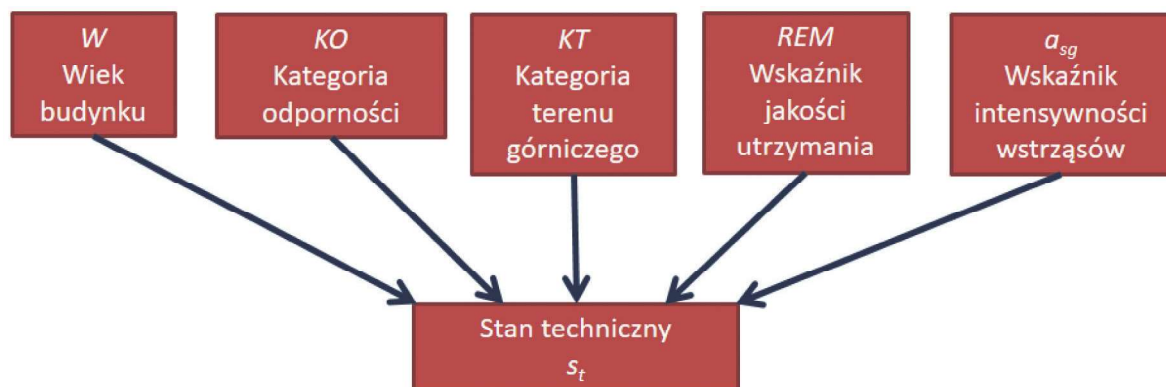
Tabela 1. Stan techniczny a zużycie techniczne budynku (Wodyński 2007)

Table 1. Technical condition and technical wear of the building (Wodyński 2007)

Stan techniczny st	Przyjęte oznaczenie dla kategorii	Stopień zużycia $s_z$ [%]
Bardzo dobry	VG	
Dobry	G	
Zadawalający	S	
Średni	M	
Zły	B	
Bardzo zły	VB	

Utworzony model poddano weryfikacji, w trakcie której stwierdzono, że posiada on zadowalający stopień trafności w stosunku do danych uczących (79,8% poprawnie sklasyfikowanych wzorców – tab. 2) oraz nie przejawia nadmiernej tendencji przeuczenia (*overfitting*), o czym świadczą podobne wartości poprawnie sklasyfikowanych wzorców dla zbioru treningowego i testowego.

W tabeli 3 przedstawiono wynik działania utworzonego modelu dla dwóch wariantów. Posłużono się tutaj przykładowym budynkiem o założonym wieku (zmienna *WIEK*),



Rys. 1. Schemat uzyskanej struktury naiwnego klasyfikatora Bayesa (NBC) (Rusek, Firek 2016)

Fig. 1. Diagram of the obtained structure of Naive Bayes Classifier (NBC) (Rusek, Firek 2016)

kategoriom odporności (zmienna  $KO$ ) oraz jakości utrzymania (zmienna  $REM$ ). Przyjęto również stały dla obydwu wariantów poziom oddziaływań wstrząsów górniczych ( $a_{sg}$ ). Zróznicowano natomiast poziom założonych wpływów deformacji ciągłych (zmienna  $KT$ ). W wyniku symulacji modelu uzyskano wartości prawdopodobieństw dla wszystkich określonych na wstępie kategorii stanu technicznego (tab. 2). Kończącym wskazaniem modelu była ta kategoria stanu technicznego ( $s$ ), dla której wartość prawdopodobieństwa była najwyższa.

Przedstawione w tabeli 3 wyniki wskazują, że wraz ze wzrostem kategorii terenu, obniża się kategoria stanu technicznego ( $s$ ). Zaletą wykorzystania metody  $NBC$  jest możliwość dodatkowej weryfikacji wyników oceny danego obiektu. Można tego dokonać na bazie informacji nt. wartości prawdopodobieństw dla poszczególnych kategorii stanu technicznego. W analizowanym przykładzie, można to odnieść do wariantu I, w którym wskazanie kategorii stanu technicznego (G), jest minimalnie wyższe niż kategorii (S) – por. tab. 3.

Z przedstawionych rezultatów wynika, że metoda *naiwnej klasyfikacji Bayesa* pozwala na wskazanie stanu technicznego badanego budynku wraz z podaniem prawdopodobieństwa takiego wyniku. Daje to możliwość uwzględnienia niepewności formalnej w ocenie stanu technicznego budynku. Należy podkreślić, że przeprowadzenie symulacji modelu na danych obejmujących całą przestrzeń zmiennych wejściowych pozwala również na oszacowanie wpływu poszczególnych zmiennych wejściowych na przebieg modelowanego procesu, co wykazano w pracy (Rusek, Firek 2016).

Z drugiej strony wszystkie zmienne są traktowane w sposób niezależny, co nie do końca odpowiada rzeczywistości. Wobec tego poszerzono zakres badań, wykorzystując bardziej zaawansowaną metodę tzw. sieci przekonań Bayesa. Pozwala ona m.in. uniknąć wymuszonego uwzględniania

poszczególnych zmiennych w modelu, jako wzajemnie od siebie niezależnych.

Pełny opis zagadnienia oceny wpływów górniczych na obiekty budowlane wymaga zarówno prognozowania potencjalnych skutków eksploatacji na etapie zatwierdzania planu ruchu zakładu górniczego, jak również konieczności rozstrzygnięcia o przyczynach uszkodzeń zgłaszanych do działu szkód górniczych po wydobyciu złoża. Dlatego wnioskowanie w oparciu o utworzony system decyzyjny powinno umożliwiać zarówno prognozę potencjalnych skutków w postaci uszkodzeń, jak i diagnozę przyczyn ich powstania. Niestety, *naiwny klasyfikator Bayesa*, może być użyteczny jedynie w przypadku prognoz obniżenia stanu technicznego na skutek oddziaływań górniczych. Natomiast metodą spełniającą postawione kryteria, zarówno w kwestii predykcji, jak i diagnozy są *sieci przekonań Bayesa* (*Bayesian Belief Network*).

## 2.2. Sieci przekonań Bayesa do oceny ryzyka powstania szkód górniczych

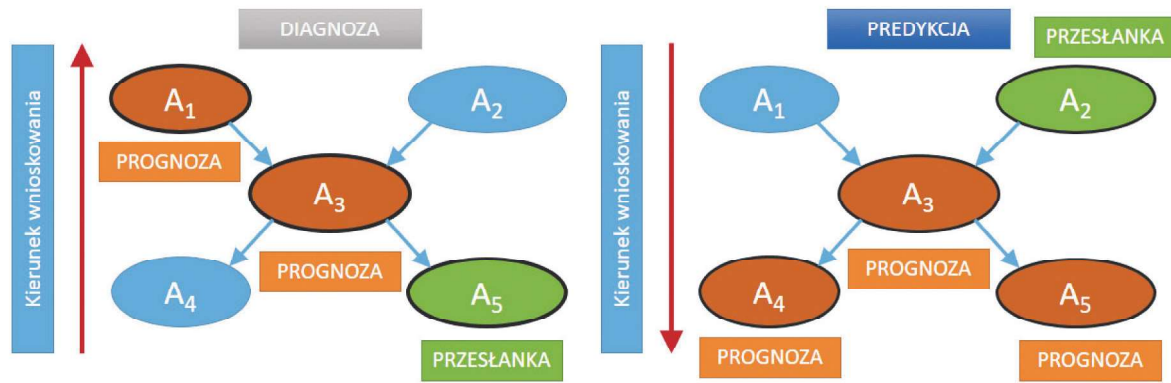
Zastosowania *sieci przekonań Bayesa* w analizie intensywności uszkodzeń budynków wieloblokowych na terenach górniczych przedstawiono w pracy (Rusek, Firek 2016). Omówiono tam szczegółowo formalizm matematyczny metody oraz jej podstawowe cechy. Najważniejszą zaletą takiego podejścia jest fakt, iż w ramach oceny stanu uszkodzeń można przeprowadzić zarówno *diagnozowanie* przyczyn dla zaobserwowanych skutków, jak i *predykcję* skutków dla założonych przyczyn, co zilustrowano schematycznie na rysunku 2. W ogólności, zgodnie z (Korb, Nicholson 2010), możliwości wnioskowania jest więcej, lecz te zobrazowane na rysunku 2. w zupełności wystarczają do opisu wpływu oddziaływań górniczych na intensywność uszkodzeń.

**Tabela 2. Procentowe wskaźniki trafnych klasyfikacji dla modelu**  
**Table 2. Percentage indices of relevant classifications for the model**

Procent poprawnie sklasyfikowanych przypadków dla zbioru treningowego (89 wzorców)	Procent poprawnie sklasyfikowanych przypadków dla zbioru testowego (37 wzorców)
79,8%	73,0%

**Tabela 3. Wyniki symulacji utworzonego modelu dla dwóch wariantów**  
**Table 3. Simulation results of the created model for two variants**

Przykładowy budynek – wariant I							
		Prawdopodobieństwo danej kategorii stanu technicznego p(st)					
Zmienna	Kategoria	VG	G	S	M	B	VB
WIEK	3	0	0,39	0,33	0,28	0	0
asg	2						
KO	2						
REM	3						
KT	1						
Przykładowy budynek – wariant II							
		Prawdopodobieństwo danej kategorii stanu technicznego p(st)					
Zmienna	Kategoria	VG	G	S	M	B	VB
WIEK	3	0	0,1	0,53	0,37	0	0
asg	2						
KO	2						
REM	3						
KT	2						



Rys. 2. Schemat poglądowy kierunku wnioskowania w przypadku diagnozowania oraz przewidywania przy użyciu sieci przekonań Bayesa (Korb, Nicholson 2010)

Fig. 2. Schematic diagram of the inference direction for diagnoses and predictions using Bayesian Belief Network (Korb, Nicholson 2010)

Stosując powyższą metodykę utworzono system decyzyjny do analizy intensywności uszkodzeń budynków wieloblokowych poddanych oddziaływaniom górniczym. Strukturę sieci przekonań Bayesa zbudowano w oparciu o bazę danych o cechach konstrukcyjnych, jakości utrzymania i intensywności uszkodzeń grupy 126 budynków, uwzględniając oddziaływanie wpływów górniczych w postaci ciągłych deformacji terenu i wstrząsów górniczych.

Zestaw zmiennych wejściowych był analogiczny do tego, który posłużył do budowy *naiwnego klasyfikatora Bayesa* – por. p. 2.1. Natomiast zmienną wyjściową był wskaźnik uszkodzeń określony dla 22 składowych elementów konstrukcyjnych i drugorzędnych analizowanej grupy obiektów  $w_{ii}$  opisany w pracy (Firek 2009, Firek i in. 2016).

W wyniku wstępnej analizy, spośród wyspecyfikowanych w pracy (Firek 2009, Firek i in. 2016), 22 wskaźników intensywności  $w_{ii}$  wyłoniono zestaw 11 wskaźników, które wykorzystano w budowie modelu. Pozostałe wskaźniki wyeliminowano z dalszych analiz, ponieważ dla badanej grupy budynków nie wykazywały istotnej zmienności.

Ostateczny zestaw stanowiły wskaźniki intensywności uszkodzeń następujących elementów:

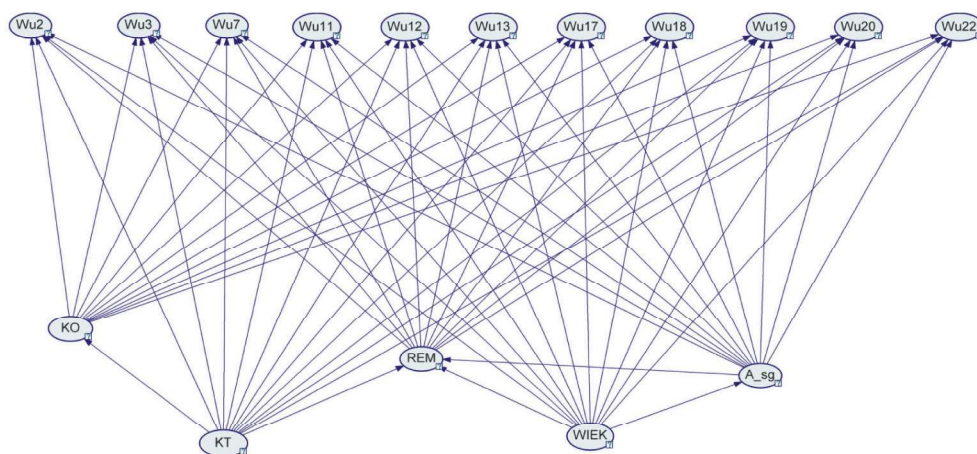
- ścian nośnych piwnic lub fundamentowych ( $w_{u2}$ ),
- ścian nośnych nadziemna ( $w_{u3}$ ),
- stropów lub stropodachu ( $w_{u7}$ ),

- ścian działowych ( $w_{u11}$ ),
- tynków wewnętrznych i okładzin ściennych ( $w_{u12}$ ),
- warstw podłogowych ( $w_{u13}$ ),
- warstw elewacyjnych ( $w_{u17}$ ),
- izolacji przeciwwilgociowych ( $w_{u18}$ ),
- pokrycia dachowego ( $w_{u19}$ ),
- obróbek blacharskich, rynien i rur spustowych ( $w_{u20}$ ),
- elementów zewnętrznych takich jak podesty, opaski betonowe itp. ( $w_{u22}$ ).

Na podstawie ustalonych zmiennych wejściowych oraz wyselekcjonowanej grupy 11 miarodajnych wskaźników intensywności uszkodzeń utworzono strukturę sieci przekonań Bayesa, którą przedstawiono na rysunku 3.

Struktura sieci w zakresie założonych powiązań między badanymi zmiennymi została utworzona w sposób ekspercki na podstawie doświadczenia autorów oraz wyników wstępnych analiz zależności między poszczególnymi zmiennymi. Parametry sieci, w postaci tablic prawdopodobieństw warunkowych dla każdego jej węzła (*CPT - Conditional Probability Table*), zostały wyznaczone metodą *EM (Expectation-Maximization Algorithm)* (Bishop 2006).

Uzyskany model poddano weryfikacji pod kątem poprawności klasyfikacji. Weryfikację przeprowadzono w dwóch wa-



Rys. 3. Schemat uzyskanej sieci przekonań Bayesa. Źródło: opracowanie własne w oparciu o program GeNie (<http://dsl.sis.pitt.edu>)

Fig. 3. Diagram of the obtained Bayesian belief network. Source: own elaboration based on Genie program (<http://dsl.sis.pitt.edu>)

riantach. Pierwszym była *predykcja* poziomu intensywności wskaźników uszkodzeń ( $w_{ui}$ ) w zależności od zadanych na wejściu oddziaływań górniczych ( $KT, a_{sg}$ ), cech konstrukcyjnych ( $KO$ ), jakości utrzymania ( $REM$ ) oraz wieku budynku ( $WIEK$ ). W drugim wariantcie, w oparciu o założone wartości wskaźników intensywności uszkodzeń, sieć wskazywała kategorie potencjalnych przyczyn (*diagnoza*). Wyniki trafności wskazań dla utworzonego modelu przedstawiono w tabeli 4.

**Tabela 4. Wyniki poprawności wskazań uzyskanej sieci przekaźników Bayesa (Rusek, Firek 2016)**

**Table 4. Results of correctness of indications of the obtained Bayesian belief network (Rusek, Firek 2016)**

Wariant I - predykcja	Wariant II - diagnoza
Średnia trafność modelu dla predykcji poszczególnych wskaźników intensywności uszkodzeń $w_{ui}$	Średnia trafność modelu w diagnozowaniu przyczyn zaobserwowanego stopnia uszkodzeń budynku $w_{ui}$
86,37 %	85,66 %

W wyniku weryfikacji jakości modelu, zarówno w przypadku przewidywania stopnia uszkodzeń poszczególnych elementów (wariant I), jak również diagnozy przyczyn uszkodzeń (wariant II), uzyskano wysokie poziomy trafności. Potwierdza to początkowe założenie o przydatności przyjętej metodyki zarówno w przypadku szacowania zakresu szkód górniczych, jak i wskazywania dominującego czynnika wpływającego na ich powstanie.

Dla zobrazowania możliwości wykorzystania *sieci przekaźników Bayesa* podano dwa przykłady. Pierwszy przykład dotyczy *predykcji* kategorii intensywności uszkodzeń (wariant I), drugi zaś *diagnozowania* przyczyn zaobserwowanego stanu uszkodzeń (wariant II).

Wyniki predykcji (wariant I) zestawiono w tabeli 5. W przykładzie tym prognozowano prawdopodobieństwo ujawnienia się uszkodzeń ( $w_{ui}$ ) o danej intensywności przy zadanych wartościach zmiennych wejściowych ( $WIEK, REM, KO, KT$  i  $a_{sg}$ ). W wyniku symulacji modelu dla wszystkich wskaźników intensywności uszkodzeń, określono ich najbardziej prawdopodobne kategorie. Na przykład dla założonych przyczyn, wartość wskaźnika  $w_{u2}$  (intensywność uszkodzeń ścian nośnych lub fundamentowych) jest na poziomie kategorii 2 przy prawdopodobieństwie równym 0,66.

W wariantcie II, dotyczącym *diagnozowania* przyczyn zaobserwowanego stanu uszkodzeń zmiennymi inicjującymi działanie sieci były ustalone kategorie poszczególnych wskaźników intensywności uszkodzeń. W tabeli 6 zestawiono wartości prawdopodobieństw warunkowych dla zmiennych, które zgodnie z opisem zjawiska mogą się przyczyniać do powstawania uszkodzeń budynków. W wyniku symulacji modelu dla zadanych wartości wskaźników uszkodzeń uzyskano w odpowiedzi wskazanie kategorii dla atrybutów opisujących wiek, jakość utrzymania, odporność budynku, ciągle deformacje terenu oraz wstrząsy górnicze. Dla założonego w przykładzie zakresu i intensywności uszkodzeń (wartości wskaźników intensywności uszkodzeń  $w_{ui}$ ) uzyskano informację, że analizowany budynek z prawdopodobieństwem 0,65 mieści się w przedziale wiekowym powyżej 25 lat (4 kategoria zmiennej  $WIEK$ ). Dodatkowo uzyskano informację, że w analizowanym przypadku, przy założonym zakresie i intensywności uszkodzeń, kategoria zagrożenia terenu ( $KT$ ) najprawdopodobniej przewyższa kategorię odporności obiektu ( $KO$ ) oraz, że na obiekt najprawdopodobniej oddziałują wstrząsy z kategorii 1 ( $a_{sg}$ ). Uzyskane wyniki dla zmiennej opisującej jakość utrzymania obiektu ( $REM$ ) nie pozwalają na jednoznaczne wskazanie, w której kategorii znajduje się budynek przy zaistniałym obrazie uszkodzeń. Relatywnie niski poziom wyodrębnienia kategorii wynikowej dla zmiennej  $REM$  może być spowodowany zależnością tego atrybutu od pozostałych zmiennych w strukturze modelu (por. rys. 3).

Na podstawie przeprowadzonych analiz stwierdzono, że zaproponowaną metodykę można wykorzystać zarówno do przewidywania skutków projektowanej eksploatacji, jak i diagnozowania dominującego czynnika zewnętrznego, stanowiącego przyczynę obserwowanego zakresu uszkodzeń. Ponadto wnioskowanie może odbywać się na bazie niepełnych informacji na temat poszczególnych czynników determinujących przebieg analizowanego zjawiska. Może to usprawnić ocenę stanu obiektów budowlanych na terenach górniczych, szczególnie w przypadku analizy grup o dużej liczebności.

### 3. Podsumowanie

Na podstawie rezultatów badań dotyczących zastosowania wnioskowania Bayesa do oceny ryzyka powstania uszkodzeń w budynkach poddanych oddziaływaniom górniczym stwierdzono, że:

**Tabela 5. Przykład predykcji wskaźnika intensywności uszkodzeń dla ustalonych zmiennych wejściowych (wariant I) (Rusek, Firek 2016)**

**Table 5. Example of damage intensity index prediction for predetermined input variables (variant I) (Rusek, Firek 2016)**

Zadane wskaźniki potencjalnych przyczyn uszkodzeń (zmiennie wejściowe)											
Nazwa wskaźnika	WIEK	REM				KO	KT	asg			
Zadana kategoria wskaźnika	4	3				2	2	1			
Wyznaczone wskaźniki intensywności uszkodzeń (zmiennie wyjściowe)											
Nazwa wskaźnika	$w_{u2}$	$w_{u3}$	$w_{u7}$	$w_{u11}$	$w_{u12}$	$w_{u13}$	$w_{u17}$	$w_{u18}$	$w_{u19}$	$w_{u20}$	$w_{u22}$
Uzyskana kategoria wskaźnika	Prawdopodobieństwa kategorii poszczególnych wskaźników										
0 (Nie występują)	0,11	0,11	0,11				0,11	0,56	0,70	0,56	0,39
1 (nieznaczone)	0,11	0,11	0,11	0,36	0,29	0,15	0,11	0,15	0,15	0,29	0,25
2 (umiarkowane)	0,66	0,52	0,66	0,64	0,56	0,70	0,39	0,29	0,15	0,15	0,11
3 (intensywne)	0,11	0,25	0,11		0,15	0,15	0,39				0,25

**Tabela 6. Przykład wnioskowania w przypadku diagnozowania przyczyn obserwowanej intensywności uszkodzeń (wariant II) (Firek, Rusek 2016)**

**Table 6. Example of inference in case of diagnosing causes of the observed damage intensity (variant II) (Firek, Rusek 2016)**

Założone wskaźniki intensywności uszkodzeń (zmiennie wejściowe)											
Nazwa wskaźnika	$w_{u2}$	$w_{u3}$	$w_{u7}$	$w_{u11}$	$w_{u12}$	$w_{u13}$	$w_{u17}$	$w_{u18}$	$w_{u19}$	$w_{u20}$	$w_{u22}$
Zadana kategoria wskaźnika	2	1	1	2	2	2	3	2	1	1	1
Uzyskane wskaźniki potencjalnych przyczyn uszkodzeń (zmiennie wyjściowe)											
Nazwa wskaźnika	WIEK		REM		KO		KT		asg		
Uzyskane kategorie wskaźników [7]	Prawdopodobieństwa kategorii poszczególnych wskaźników										
0			0,26				0,19				
1	0,02		0,30		0,51		0,34		0,64		
2	0,05		0,20		0,39		0,41		0,36		
3	0,28		0,24		0,10		0,07				
4	0,65										

- zastosowanie metod bazujących na *formalizmie wnioskowania Bayesa*, umożliwia budowę systemów decyzyjnych pozwalających na prognozowanie ryzyka powstania uszkodzeń, które podawane jest w notacji probabilistycznej,
- stosowanie metod bazujących na *formalizmie wnioskowania probabilistycznego Bayesa* może znacząco podnieść efektywność oceny intensywności uszkodzeń obiektów budowlanych oraz ich stanu technicznego w sytuacjach, gdy dokonanie tej oceny dotyczy dużej liczby obiektów oraz niepewnej informacji nt. czynników warunkujących proces powstawania uszkodzeń,
- zaproponowaną metodykę można wykorzystać zarówno do przewidywania skutków projektowanej eksploatacji, jak i diagnozowania dominującego czynnika zewnętrznego, stanowiącego przyczynę obserwowanego zakresu uszkodzeń.

Uzyskane rezultaty wyznaczają kierunek dalszych badań, w których planowane jest wykorzystanie algorytmów pozwalających na „samorozbudowę” sieci przekonań Bayesa w oparciu o dane wzorcowe (np. [Scutari 2014](#), [Tsamardinos i in. 2006](#)). Pozwoli to na wyodrębnienie ścisłych relacji przyczynowo-skutkowych między analizowanymi czynnikami oraz podniesie efektywność modelu w kwestii odwzorowania informacji zawartych w danych.

*Artykuł opracowano w ramach badań statutowych AGH nr 11.11.150.005*

## Literatura

- BISHOP C. 2006 - Pattern Recognition and Machine Learning. Springer-Verlag New York.
- FIREK K. 2009 - Proposal for classification of prefabricated panel building damage intensity rate in mining areas (Propozycja klasyfikacji intensywności uszkodzeń budynków wielkopłytkowych na terenach górniczych). Archiwum Górnictwa, Wydawnictwo Instytutu Mechaniki Górniczej PAN, Vol. 54, Iss. 3, Kraków.

FIREK K., RUSEK J., WODYŃSKA A. 2016 - Wybrane metody eksploracji danych i uczenia maszynowego w analizie zagrożenia zabudowy terenów górniczych (Selected methods of data mining and machine learning risk analysis for developments located in mining areas). „Przeegląd Górniczy”, t. 72, nr 1.

KORB K.B., NICHOLSON A.E. 2010 - Bayesian Artificial Intelligence. CRC Press.

KWIATEK J. 2007 - Obiekty budowlane na terenach górniczych. Główny Instytut Górnictwa.

RUSEK J., FIREK K. 2016 - Assessment of technical condition of prefabricated large-block building structures located in mining area using the Naive Bayes Classifier (Ocena stanu technicznego budynków wielkoblokowych z zastosowaniem klasyfikacji Naiwnego Bayesa). SGEM 2016: 16th international multidisciplinary scientific geoconference. 2016, Albena, Bulgaria. Conference proceedings. Vol. 2, Ecology and environmental protection.

RUSEK J., FIREK K. 2016 - Bayesian Belief Network in the analysis of damage to prefabricated large-block building structures in mining areas (Sieci przekonań Bayesa w analizie uszkodzeń budynków wielkoblokowych na terenach górniczych). Polish Journal of Environmental Studies, vol. 25, no. 5A, s. 77-82.

SCUTARI M. 2014 - Bayesian network constraint-based structure learning algorithms: Parallel and optimised implementations in the bnlearn r package. arXiv preprint arXiv:1406.7648.

SNOEK J., LAROCHELLE H., ADAMS R.P. 2012 - Practical bayesian optimization of machine learning algorithms. In Advances in neural information processing systems (pp. 2951-2959).

TSAMARDINOS I., BROWN LE., ALIFERIS CF. 2006 - The max-min hill-climbing Bayesian network structure learning algorithm. Machine learning. 2006 Oct 1; c65(1):31-78.

WODYŃSKI A. 2007 - Zużycie techniczne budynków na terenach górniczych (Technical wear of buildings in mining areas). Wydawnictwo AGH, Kraków.

WODYŃSKI A., LASOCKI S. 2003 - Badanie wpływu wstrząsów górniczych na zużycie techniczne budynków murowanych. „Przeegląd Górniczy” nr 12.

<http://dsl.sis.pitt.edu> - Decision Systems Laboratory. Department of Information Science and Telecommunications and the Intelligent Systems Program at the University of Pittsburgh.

Artykuł wpłynął do redakcji – październik 2018  
Artykuł akceptowano do druku 17.01.2019