

dr hab. inż. Janusz Rusek, prof. uczelni^{1*)}

ORCID: 0000-0003-0368-2580

dr inż. Leszek Chomacki²⁾

ORCID: 0000-0002-2291-3826

dr inż. Leszek Słowik²⁾

ORCID: 0000-0001-8770-1595

dr hab. inż. Karol Firek, prof. uczelni¹⁾

ORCID: 0000-0002-0985-6003

Algorytmy wykrywania struktury sieci Bayesa z danych w ocenie ryzyka powstawania uszkodzeń budynków na terenach górniczych

Bayesian network structure extraction algorithms from data in damage risk assessment of buildings in mining areas

DOI: 10.15199/33.2022.11.18

Streszczenie. W artykule zaprezentowano wyniki badań, które podjęto w celu utworzenia modelu do oceny ryzyka powstania uszkodzeń budynków poddanych wpływom statycznych i dynamicznych oddziaływań górniczych. Uzasadniono przyjętą metodykę na kanwie metod uczenia maszynowego (ML – Machine Learning). Omówiono specyfikę zagadnienia i na tej podstawie przedstawiono główne założenia stosowanego podejścia, a przede wszystkim metodykę pozwalającą na samoistne wyłanianie struktury sieci Bayesa z danych (BSL – *Bayesian Structure Learning*). Zaprezentowano rezultaty otrzymane w ramach badań w odniesieniu do wielokondygnacyjnych budynków prefabrykowanych oraz murowanych zlokalizowanych na terenie LGOM oraz GZW. W artykule wskazano również możliwość uniwersalnego stosowania przyjętej metodyki w przypadku predykcji ryzyka powstania uszkodzeń i diagnozowania przyczyn zaistniałych szkód.

Słowa kluczowe: ryzyko; uszkodzenia; wpływy górnicze; budynki; sieci Bayesa.

Abstract. The article presents the results of research that was undertaken to create a model to assess the damage risk of buildings subjected to static and dynamic mining impacts. The justification of the adopted methodology on the basis of machine learning (ML) methods is given. The specificity of the problem was discussed and, on this basis, the main assumptions of the applied approach were presented, especially the methodology allowing for autonomous extraction of the Bayesian network structure from data (BSL – *Bayesian Structure Learning*). The results obtained in the research were presented in relation to multi-storey prefabricated and masonry buildings located in LGDC and USB mining terrain. The paper also indicates the possibility of universal application of the adopted methodology in the case of damage risk prediction and diagnosis of the causes of damage.

Keywords: risk; damage; mining impacts; buildings; Bayes networks.

Zapewnienie odpowiednich właściwości użytkowych istniejących obiektów budowlanych w całym cyklu życia technicznego sprowadza się do koordynacji działań związanych odpowiednim utrzymaniem budynków oraz ich wyposażenia [1]. Do takich działań zalicza się ocenę stanu technicznego, której wynik stanowi podstawę do podejmowania decyzji o koniecznych remontach, zabezpieczeniach lub modernizacji. Jednym z podstawowych kryteriów takiej oceny, oprócz zużycia technicznego, jakości utrzymania itp. jest intensywność uszkodzeń elementów konstrukcyjnych

i drugorzędnych [2, 3]. Wynik takiej oceny stanowi zarówno miarę w kontekście użyteczności budynku, jak i jego bezpieczeństwa [4]. Ponadto wyniki oceny stanu technicznego są cennym źródłem informacji do budowy tzw. systemów decyzyjnych DSS (*Decision Support Systems* [5 – 7]), które są wykorzystywane w przypadku planowania zakresu prac remontowych oraz przewidywania kosztów itd. W przypadku uszkodzeń, zinwentaryzowanych w ramach wielokrotnych przeglądów stanu technicznego, możliwe jest również ustalenie ryzyka ich powstawania w danej grupie budynków z jednoczesnym wskazaniem najistotniejszych czynników warunkujących powstanie [8]. Tego typu system decyzyjny może być również stosowany jako narzę-

dzie do oceny zagrożenia, gdy np. następuje zmiana warunków eksploatacji budynku lub pojawiają się losowe oddziaływania środowiska zewnętrznego [9, 10].

Artykuł dotyczy przypadku, w którym, na podstawie wieloletnich przeglądów stanu technicznego budynków, zgromadzono dane związane z zakresem i intensywnością uszkodzeń ujawniających się podczas wielu lat na skutek oddziaływań antropogenicznych wynikających z podziemnej eksploatacji złóż [11]. Zgromadzone informacje pozwoliły na utworzenie modelu ryzyka powstania uszkodzeń w postaci struktury sieci Bayesowskiej. Zaprezentowano wyniki badań dotyczące zabudowy terenu górniczego LGOM (Legnicko-Głogowski Okręg Miedziowy) oraz GZW

¹⁾ AGH Akademia Górniczo-Hutnicza, Wydział Geodezji Górniczej i Ochrony Środowiska

²⁾ Instytut Techniki Budowlanej

^{*} Adres do korespondencji: rusek@agh.edu.pl

(Górnoląskie Zagłębie Węglowe). Zastosowana metoda pozwala na opracowanie systemu decyzyjnego do predykcji ryzyka powstania uszkodzeń, a także może stanowić narzędzie diagnostyczne w wielu sytuacjach roszczeniowych, w których konieczne jest wskazanie najbardziej prawdopodobnych przyczyn zaistniałego uszkodzenia.

Metoda badań


Struktura sieci Bayesa jest reprezentowana za pomocą tzw. Acyklicznych Grafów Skierowanych (DAG – *Directed Acyclic Graph* [12, 13]). W pełni interpretowalna struktura sieci pozwala na jawny i czytelny dla użytkownika proces wnioskowania. Umożliwia to weryfikację powiązań występują-

algotemu BSL (*Bayesian Structure Learning*) [14].

Wyróżnia się trzy grupy metod dedykowane uczeniu struktury sieci Bayesa z danych: **Constraint-Based** (CB); **Score-Based** (SB) oraz **podjęcie Hybrydowe** (H) [12]. W artykule zaprezentowano wyniki w przypadku podejścia SB, które sprowadza się do zastosowania odpowiedniej strategii optymalizacji gradientowej. Podejście SB jest mniej rygorystyczne w kwestii odrzucania zmiennych z modelu w trakcie uczenia niż metody bazujące na strategii CB. Pozwala to uzyskać strukturę sieci Bayesa składającą się z większej liczby zmiennych [15]. Jest to istotne, gdyż na ryzyko powstania uszkodzeń w budynkach niektóre zmienne mają subtelny wpływ,

schemat wnioskowania w przypadku hipotetycznej struktury DAG stanowiącej sieć Bayesa przedstawiono na rysunku 1. Możliwość wnioskowania w przypadku dowolnego węzła w sieci Bayesa stanowiła podstawowe kryterium wyboru tej metody do budowy modelu ryzyka powstania uszkodzeń. Taki model cechuje się wyjątkową elastycznością. W omawianym przypadku sprowadza się to do [9, 17]:

- działania sieci polegającego na predykcji zakresu i intensywności uszkodzeń na podstawie danych dotyczących prognozowanych wpływów górniczych;
- wskazywania najbardziej prawdopodobnego czynnika warunkującego zaistniały stan uszkodzeń w budynku.



Rys. 1. Uproszczony schemat wnioskowania dotyczący stanu zmiennej X_m dla hipotetycznej struktury sieci Bayesa [9]
 Fig. 1. Simplified scheme for inferring the state of the variable X_m for the hypothetical structure of the Bayes network [9]

cych w sieci oraz jej ocenę przez eksperta. Wszystko to powoduje, że wykrywanie struktury sieci Bayesa z danych cechuje duża elastyczność. Możliwe jest podejście hybrydowe, w którym w ramach działania danego algorytmu dopuszcza się ingerencję użytkownika. Z reguły polega ona na wskazaniu tych połączeń między węzłami sieci, które mają być zablokowane lub przeciwnie, których wzajemne połączenie ma być wymuszone. Pozostałe relacje między węzłami są tworzone, bądź nie, w ramach działania danego

lecz ich łączne oddziaływanie może być dominujące. W trakcie uczenia sieci Bayesa, oprócz wykrywania optymalnej struktury, dokonuje się również proces dostrajania jej parametrów. Prowadzi on do ustalenia wartości prawdopodobieństw Warunkowych (CPT – *Conditional Probability Table*) [16]. Na podstawie ustalonej struktury sieci oraz dostrajonych jej parametrów możliwe jest wnioskowanie dotyczące dowolnego węzła (zmiennej) będącego składowym elementem struktury sieci. Uproszczony

Przebieg badań i omówienie uzyskanych wyników

Podstawą badań były dwa zbiory danych dotyczące uszkodzeń budynków zlokalizowanych na terenach górniczych polskich kopalń. Pierwszy obejmował grupę 129 wielokondygnacyjnych budynków wzniesionych w technologii wielkiej płyty (z prefabrykowanych elementów betonowych), zlokalizowanych na terenie LGOM (fotografia a). Natomiast drugi zbiór stanowiły dane o 594 budynkach murowanych położonych na terenie GZW (fotografia b).



Przykładowe obiekty z bazy danych: a) wielokondygnacyjny budynek z prefabrykowanych elementów betonowych zlokalizowany na terenie LGOM; b) mурwany budynek zlokalizowany na terenie GZW

Examples of structures from the database: a) multi-storey prefabricated concrete building located in LGCD; b) masonry building located in the USB

W omawianych przypadkach stworzono bazę danych o cechach geometrycznych, konstrukcyjnych, jakości utrzymania oraz intensywności wpływów górniczych w miejscu lokalizacji danego obiektu. W przypadku grupy obiektów mурwanych zlokalizowanych na terenie GZW uwzględniono oddziaływanie górnicze objawiające się wpływem na budynki ciągłych deformacji terenu. W przypadku budynków prefabrykowanych zlokalizowanych na terenie LGOM, z uwagi na dużą aktywność sejsmiczną w tym rejonie indukowaną podziemną eksploatacją, oprócz ciągłych deformacji terenu uwzględniono również wstrząsy górnicze. Zestaw zunifikowanych zmiennych łącznie z ich uszczegółowionym opisem i niezbędnym przekierowaniem literaturowym podano w tabeli 1.

W ramach przygotowania do badań każdą z grup budynków podzielono na zbiory treningowe i testowe z za-

Tabela 1. Wykaz zmiennych przyjętych do analiz

Table 1. List of variables adopted for analysis

Oznaczenie	Charakterystyka zmiennej
Zmienne charakteryzujące zagrożenie wpływami górniczymi	
MC	kategoria zagrożenia terenu górniczego wg [18]
AH	szczytowa wartość przyspieszenia drgań gruntu od wstrząsu górniczego [19]
ASG	wskaźnik intensywności wielokrotnych wstrząsów górniczych [20]
Zmienne opisujące cechy konstrukcyjne budynku	
BT	typ podpiwniczenia
VFL	zmienny poziom posadowienia
ToF	rodzaj posadowienia
BW	ściany fundamentowe/piwniczne
BC	strop nad piwnicą
WAF_H	ściany parteru i wyższych kondygnacji
CAF_H	strop nad parterem i wyżej
SW	typ ścian osłonowych
LIN	nadproża
Zmienne opisujące cechy geometryczne budynku	
SHA	kształt budynku
LEN	dłuższy wymiar budynku, w tym długość ciągu zabudowy zwartej
WID	krótszy wymiar budynku
LoSE	długość pojedynczego segmentu
NoSE	liczba segmentów budynku
DIL	dylatacje
NoST	liczba kondygnacji budynku
CBH	zmiana wysokości budynku
BU	powierzchnia zabudowy
VOL	kubatura budynku
Przyjęte miary intensywności uszkodzeń	
DIC_A	kategoria intensywności uszkodzeń po ujawnieniu wpływów górniczych
DIC_B	kategoria intensywności uszkodzeń przed uaktywnieniem wpływów górniczych
w_u	wskaźnik intensywności uszkodzeń [2]
Zmienne opisujące jakość utrzymania budynku	
CR	remonty bieżące
FR	remonty elewacji
IR	remonty wewnątrz
RR	remonty dachu
RG	remonty ogółem
Cechy konstrukcyjne charakteryzujące budynek względem oddziaływań górniczych	
DP	projektowane zabezpieczenia przeciw wpływom górniczym
EP	istniejące zabezpieczenia przeciw wpływom górniczym (wykonane po wzniesieniu budynku)
RC	kategoria odporności na ciągłe deformacje terenu górniczego
Inne	
AGE	wiek techniczny budynku
DUR	trwałość budynku
TS	stan techniczny budynku w dziedzinie zużycia technicznego s_z [3]

chowaniem stratyfikacji zmiennych. Następnie przeprowadzono etap wykrywania struktury sieci wraz z dostrajaniem ich parametrów. W obu przypadkach zastosowano metody uczenia należące do grupy algorytmów Score-Based (SB).

Wielokrotne analizy ostatecznie dały wyniki wskazujące na najlepszą strategię uczenia (algorytm oraz kryterium optymalizacji) w odniesieniu do rozpatrywanych rozłącznie grup budynków. W przypadku wielokondygnacyjnych budynków prefabrykowanych zlokalizowanych na terenie LGOM optymalną strukturę wyłoniono, stosując algorytm Tabu oraz kryterium optymalizacyjne w postaci BDs (Bayesian Dirichlet Sparse Score) [21]. W przypadku budowy sieci Bayesa dla grupy budynków mурwanych optymalną strukturę uzyskano, stosując metodę uczenia TAN-CL (Chow-Liu's Tree Augmented Naive Bayes), przyjmując, jako kryterium optymalizacji, miarę błędu typu AIC (Akaike Information Criterion) [22]. Wyniki wskazujące procentowy poziom poprawnych klasyfikacji w przypadku zbiorów treningowych i testowych przedstawiono w tabeli 2, natomiast graficzną reprezentację utworzonych sieci Bayesa na rysunkach 2a i b. Uzyskane wyniki wskazują, że zarówno w przypadku modelu oceny ryzyka budynków na terenie górniczym LGOM, jak i zabudowy mурwanej terenu GZW wyodrębniono sieci Bayesa cechujące się bardzo wysokim poziomem poprawności wskazań klasyfikacji dla zbiorów treningowych i testowych. Można zatem uznać, że tak utworzone modele ryzyka powstania uszkodzeń cechuje akceptowalny poziom uogólniania nabytej wiedzy. Stanowi to uzasadnienie przyjętej metody badawczej i jednocześnie asumpt do dalszych badań.

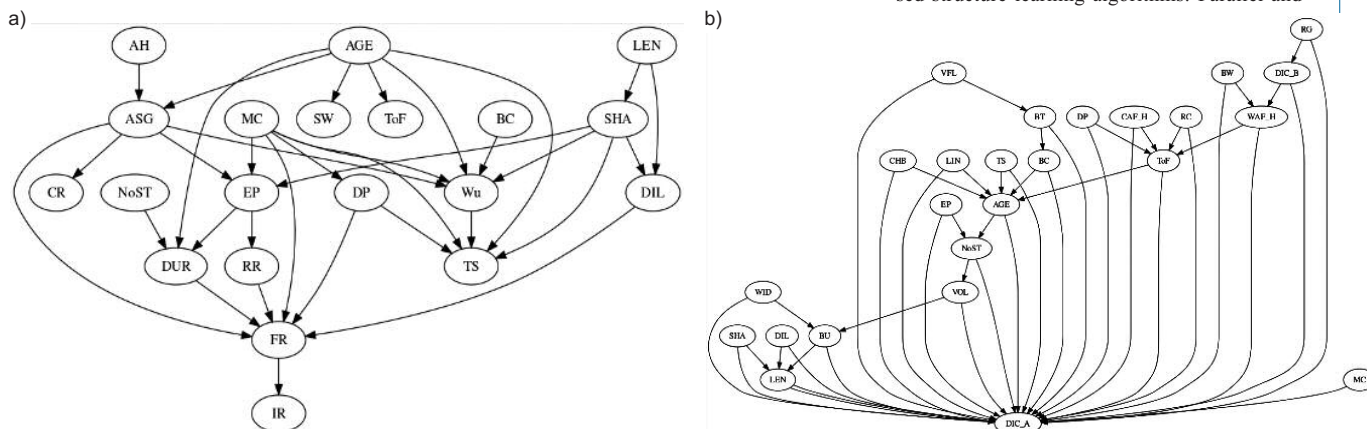
Podsumowanie i wnioski

Celem badań było przedstawienie efektywności metodyki sieci Bayesa, a przede wszystkim technik uczenia struktury takich sieci na podstawie danych, w celu budowy modelu ryzyka powstania uszkodzeń w budynkach zlokalizowanych na terenach górniczych.

Tabela 2. Wyniki jakości klasyfikacji utworzonych sieci Bayesa w przypadku analizowanych grup budynków

Table 2. Classification quality results of the created Bayes networks for the analyzed groups of buildings

Wielokondygnacyjne budynki prefabrykowane		Budynki murowane	
procentowy udział poprawnie sklasyfikowanych wzorców			
zbiór treningowy (100 wzorców) 91,11%	zbiór testowy (29 wzorców) 87,18%	zbiór treningowy (478 wzorców) 83,89%	zbiór testowy (116 wzorców) 87,07%



Rys. 2. Struktura sieci Bayesa jako model oceny ryzyka uszkodzeń uzyskana w przypadku: a) wielokondygnacyjnych budynków prefabrykowanych na terenie LGOM; b) budynków murowanych na terenie GZW

Fig. 2. Bayes network structure as damage risk assessment model obtained for: a) multi-storey prefabricated buildings in LGCD area; b) masonry buildings in USB area

Wykorzystując dane dotyczące dwóch grup budynków różnych typów i zlokalizowanych na innych terenach górniczych (LGOM i GZW), uzyskano modele pozwalające na predykcję intensywności uszkodzeń dla prognozowanych wpływów generowanych eksploatacją górniczą oraz narzędzie pozwalające na diagnozę najbardziej prawdopodobnych przyczyn powstałych szkód. Możliwość wykorzystania tego typu narzędzi w praktyce na terenach górniczych daje istotne korzyści zarówno dla przedsiębiorców górniczych, jak również inżynierów budownictwa oraz zakładów ubezpieczeniowych itd.

Celem dalszym badań jest unifikacja uzyskanych rozwiązań w ramach jednej struktury sieci Bayesa dedykowanej różnym typom budynków oraz uwzględniającej ich lokalizację na różnych terenach górniczych.

Literatura

[1] Nowogońska B, Mielczarek M. Renovation management method in neglected buildings. *Sustain.* 2021. DOI: 10.3390/su13020929.
 [2] Firek K. Proposal for classification of prefabricated panel building damage intensity rate in mining areas. *Arch. Min. Sci.* 2009; Vol. 54, no. 3: 467 – 479.

[3] Wodyński A. Zużycie techniczne budynków na terenach górniczych. Kraków. AGH Publishing House, 2007.
 [4] Knyziak P. The impact of construction quality on the safety of prefabricated multi-family dwellings. *Eng. Fail. Anal.* 2019. DOI: 10.1016/j.engfailanal.2019.02.042.
 [5] McIntosh B.S et al. Environmental decision support systems (EDSS) development – Challenges and best practices. *Environ. Model. Softw.* 2011. DOI: 10.1016/j.envsoft.2011.09.009.
 [6] Sharafi P, Rashidi M, Samali B, Ronagh H, Mortazavi M. Identification of Factors and Decision Analysis of the Level of Modularization in Building Construction. *J. Archit. Eng.* 2018. DOI: 10.1061/(asce)ae.1943-5568.0000313.
 [7] Leśniak A, Radziejowska A. Supporting bidding decision using multi-criteria analysis methods. 2017. DOI: 10.1016/j.proeng.2017.11.023.
 [8] Rusek J. Application of support vector machine in the analysis of the technical state of development in the LGOM mining area. *Eksploat. i Niezawodn.* 2017. DOI: 10.17531/ein.2017.1.8.
 [9] 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. DOI: 10.3390/min11090958.
 [10] Rusek J. Computational intelligence methods in the problem of modelling technical wear of buildings in mining areas. *Geomatics Environ. Eng.* 2013. DOI: 10.7494/geom.2012.6.3.83.
 [11] Kawulok M. Szkody górnicze w budownictwie. Warszawa. Inst. Tech. Bud. 2015.

[12] Scutari M, Graafland CE, Gutiérrez JM. Who learns better Bayesian network structures: Accuracy and speed of structure learning algorithms. *Int. J. Approx. Reason.* 2019. DOI: 10.1016/j.ijar.2019.10.003.
 [13] Koller D, Friedman N. Probabilistic graphical models: principles and techniques. USA. MIT press. 2009.
 [14] Scutari M. Bayesian network constraint-based structure learning algorithms: Parallel and

optimized implementations in the bnlearn R package. *J. Stat. Softw.* 2017. DOI: 10.18637/jss.v077.i02.
 [15] Rusek J, Firek K, Słowik L. Extracting structure of bayesian network from data in predicting the damage of prefabricated reinforced concrete buildings in mining areas. *Eksploat. i Niezawodn.* 2020. DOI: 10.17531/ein.2020.4.9.
 [16] Nagarajan R, Scutari M, Lèbre S. Bayesian Networks in R. New York. Springer. 2013.
 [17] Rusek J, Tajduś K, Firek K, Jędrzejczyk A. Score-based Bayesian belief network structure learning in damage risk modeling of mining areas building development. *J. Clean. Prod.* 2021. DOI: 10.1016/j.jclepro.2021.126528.
 [18] Kawulok M. Diagnozowanie budynków zlokalizowanych na terenach górniczych. Warszawa. Inst. Tech. Bud. 2021.
 [19] Cholewicka A, Kawulok M, Lipski Z, Szulc J. Zasady ustalania obciążeń i sprawdzania stanów granicznych budynków zlokalizowanych na terenach górniczych w nawiązaniu do Eurokodów. Warszawa. Inst. Tech. Bud. 2012.
 [20] Wodyński A, Lasocki S. Assessment of mining tremor influence on the technical wear of building. *Acta Geodyn. Geomaterialia.* 2004; vol. 50. no. 2: 187 – 194.
 [21] Scutari M. Learning Bayesian Networks with the bnlearn R Package. *J. Stat. Softw.* 2010. DOI: 10.18637/jss.v035.i03.
 [22] Long Y, Wang L., Sun M. Structure extension of tree-augmented naive bayes. *Entropy.* 2019. DOI: 10.3390/e21080721.

Przyjęto do druku: 21.09.2022 r.