

Janusz Rusek, dr hab. inż., profesor AGH

Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie
al. Mickiewicza 30, 30-059 Kraków, Polska
tel. +48 12 617 22 80, e-mail: rusek@agh.edu.pl

Karol Firek, dr hab. inż., profesor AGH

Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie
al. Mickiewicza 30, 30-059 Kraków, Polska
tel. +48 12 617 51 56, e-mail: kfirek@agh.edu.pl

Leszek Słowik, dr inż.

Instytut Techniki Budowlanej
ul. Filtrowa 1, 00-611 Warszawa, Polska
tel. +48 32 730 29 64, e-mail: l.slowik@itb.pl

Wyodrębnianie struktury sieci Bayesowskiej z danych w prognozowaniu uszkodzeń żelbetowych budynków prefabrykowanych na terenach górniczych

Słowa kluczowe: sieci Bayesowskie, uszkodzenia, ryzyko, prefabrykowane budynki żelbetowe

Streszczenie: W artykule zaprezentowano wyniki badań dotyczących budowy modelu do oceny ryzyka powstawania uszkodzeń budynków usytuowanych na terenach górniczych. Podstawą do badań była baza danych nt. konstrukcji, stanu technicznego oraz wpływów górniczych dla 129 żelbetowych prefabrykowanych budynków wznoszonych w uprzemysłowionym systemie wielkoblokowym zlokalizowanych na terenie górniczym Legnicko-Głódzkiego Okręgu Miedziowego (LGOM). Do analiz zastosowano metodykę sieci przekonania Bayesa (BBN – *Belief Bayesian Networks*). Stosując podejście *score-based Bayesian structure learning* (*Hill-Climbing* oraz *Tabu-Search*) oraz wyselekcjonowane kryteria optymalizacyjne, wyłoniono 16 struktur sieci *Bayesowskich*. Wszystkie modele poddano ocenie ilościowej i jakościowej, weryfikując ich własności w kontekście trafności predykcji, generalizacji nabytej wiedzy oraz zależności przyczynowo-skutkowych. Pozwoliło to na wyselekcjonowanie najlepszej struktury sieci wraz z odpowiadającym kryterium optymalizacyjnym. Analiza wyników wykazała, że metoda *Tabu-Search* przy przyjęciu kryterium optymalizacyjnego w postaci *Locally Averaged Bayesian Dirichlet score* (BDla), prowadzi do uzyskania modelu o najlepszych własnościach spośród wszystkich wyłonionych modeli. Uzyskane rezultaty uzasadniają przyjęcie metodyki BBN, jako efektywnej w kontekście oceny zakresu uszkodzeń budynków na terenach górniczych.

1. Wprowadzenie

Uszkodzenia istniejących budynków na terenach górniczych mogą być spowodowane przez szereg czynników budowlanych i środowiskowych, do których zalicza się również wpływy górnicze. Objawiają się one na powierzchni terenu w postaci ciągłych lub nieciągłych deformacji terenu [6,38] oraz wstrząsów górniczych [23,41]. Uszkodzenia te mogą dotyczyć zarówno elementów konstrukcyjnych, jak i drugorzędnych [8]. Taka sytuacja ma miejsce również w przypadku budynków o prefabrykowanej konstrukcji żelbetowej, wzniesionych w systemach budownictwa uprzemysłowionego [15], w których mieszka około 1/3 mieszkańców Polski (ok. 12 mln ludzi). Dodatkowo są to z reguły wielkogabarytowe budynki wielorodzinne lub użyteczności publicznej, gdzie zakłócenia komfortu użytkownika z tytułu uszkodzeń są bardzo istotne.

Najczęściej zainicjowanie procesu powstawania uszkodzeń zależy nie od jednego lecz od wielu czynników jednocześnie. Powoduje to, że problem dotyczący oceny przyczyn zaistniałego stanu uszkodzeń jest złożony i trudny do opisu z analitycznego punktu widzenia. W kontekście wpływów górniczych, sytuację komplikuje dodatkowo niepewność dotycząca prognoz deformacji na powierzchni terenu oraz wstrząsów [19].

W praktyce, niejednokrotnie konieczne jest przeprowadzenie takiej oceny dla dużej liczby budynków stanowiących zabudowę danego terenu górniczego. Fakt ten dyskwalifikuje w ocenie podejście numeryczne MES, które w takim przypadku jest nieefektywne. Wydaje się, że jedyną możliwością zmierzenia się z problemem dają modele statystyczne.

Do grona popularnych i bardzo efektywnych metod pozwalających na detekcję uszkodzeń w konstrukcjach betonowych można zaliczyć również grupę tzw. metod nieniszczących. Tutaj wymienić należy metody akustyczne (Acoustic Emission - AE) [22], obrazowe (Digital Image Correlation - DIC) [10] lub ultradźwiękowe [31]. Oprócz samej detekcji pęknięć, metody nieniszczące umożliwiają bardziej szczegółową analizę degradacji elementów żelbetowych, która obejmuje również wyznaczenie korozji prętów zbrojeniowych [28]. Ma to szczególne znaczenie w przypadku oceny uszkodzeń w prefabrykowanych budynkach wielkopłytowych, gdzie podstawową kwestią jest rozstrzygnięcie stanu technicznego połączeń oraz ich zbrojenia. Dodatkowo, w ostatnich latach coraz częściej wykorzystywane są również alternatywne podejścia bazujące na wykorzystaniu metod z obszaru uczenia maszynowego np. [28,29].

Biorąc pod uwagę specyfikę analizowanego problemu, szczególnie w kontekście predykcji uszkodzeń dla dużej liczby budynków, wyodrębniono do dalszych badań metody uczenia maszynowego umożliwiające przedstawienie badanego zjawiska w notacji probabilistycznej.

W ramach dotychczasowych badań wykazano efektywność stosowania narzędzi z obszaru *Machine Learning* (ML) [25,27]. Jednak wszystkie z testowanych metod zakładały wzajemną niezależność potencjalnych przyczyn mogących mieć wpływ na proces powstawania uszkodzeń. Z tego powodu zdecydowano o wykorzystaniu metodyki tzw. *sieci Bayesowskich* (*Bayesian Network* - BN) lub *sieci przekonań Bayesa* (*Bayesian Belief Network* - BBN), która zgodnie z [24], dopuszcza możliwość uwzględnienia niezależności warunkowej. To z kolei pozwala na budowę modelu, w którym relacje między poszczególnymi czynnikami, są bliższe rzeczywistości fizycznej związanej z przebiegiem procesu powstawania uszkodzeń. W efekcie ustalona struktura BN może być utożsamiona z modelem ryzyka powstania uszkodzeń.

Dodatkową własnością sieci *Bayesowskich*, która stanowi bardzo istotną zaletę w odniesieniu do zagadnienia powstawania uszkodzeń w budynkach poddanych m.in. wpływom górniczym, jest możliwość wykorzystania utworzonego modelu nie tylko w kontekście predykcji, ale i diagnozy uszkodzeń. To z kolei pozwala na dużo szerszą implementację takiego systemu w praktyce.

Niestety istotnym problemem w przypadku dużej liczby zmiennych opisujących modelowany proces, jest często brak znajomości struktury sieci *Bayesowskiej*. Istnieją jednak metody, które pozwalają na wyodrębnienie struktury sieci z danych. Zgodnie z [18] podzielono je na 3 grupy: *constraint based structure learning*, *score-based structure learning* oraz *podejście hybrydowe*. W pracy zastosowano podejście *score-based*, dla którego uzasadnienie podano w rozdziale 4.

W celu wyłonienia optymalnej struktury sieci *Bayesowskiej* przetestowano dwa algorytmy: *Hill-Climbing* (HC) oraz *Tabu-Search* (TS), które należą do grupy metod *score-based structure learning* [18].

Podstawą do analiz była baza danych o uszkodzeniach grupy 129 żelbetowych, prefabrykowanych budynków wzniesionych w systemie uprzemysłowionym WBL zlokalizowanych na terenie górniczym LGOM (rys. 1). Informacje o stanie technicznym, w tym

o uszkodzeniach były zbierane w trakcie inwentaryzacji dokonywanej „in-situ” oraz na podstawie zgłoszeń. Dane te posłużyły do wyłonienia struktur sieci *Bayesowskich* oraz późniejszego ich testowania. Weryfikowano jakość utworzonych modeli w kontekście poprawnej klasyfikacji oraz własności generalizujących. Dodatkowo, dysponując jawną reprezentacją powiązań między węzłami sieci dokonywano weryfikacji pod kątem zgodności modelu z obserwowaną, rzeczywistą naturą modelowanego procesu. Była to ocena subiektywna, dokonywana na podstawie wiedzy eksperckiej.

Na podstawie uzyskanych wyników wyłoniono strukturę sieci *Bayesowskiej*, która może reprezentować złożony model ryzyka powstania uszkodzeń. Podstawą oceny była tutaj przede wszystkim zgodność klasyfikacji modelu z danymi uczącymi i testowymi.

2. Przegląd literaturowy

Metodyka sieci *Bayesowskich* (BN) lub inaczej *sieci przekonań Bayesa* (BBN) znajduje aktualnie szerokie zastosowanie w analizie ryzyka [3], bezpieczeństwa [12], niezawodności [43] oraz przewidywania zakresu uszkodzeń [16]. W ostatnich latach coraz częściej spotyka się implementację tego typu metodyki w obszarze inżynierii lądowej. Dominuje tutaj jednak podejście ekspertowe, gdzie struktura sieci *Bayesa* nadawana jest w sposób odgórny, a uczeniu podlegają jedynie parametry modelu. Wyszczególniając obszary zbieżne do podejmowanej w pracy tematyki można wymienić zagadnienia związane z analizą ryzyka powstania uszkodzeń w obiektach budowlanych. Przedmiotem tych analiz są przeważnie budowlane obiekty liniowe takie jak: rurociągi, obiekty mostowe [1] lub tunele [40]. Chociaż można spotkać również przykłady dotyczące oceny ryzyka powstania uszkodzeń w budynkach [30]. Zastosowanie sieci *Bayesowskich* występuje również w szerszym ujęciu dotyczącym analiz niezawodnościowych [39], w tym również oceny bezpieczeństwa obiektów budowlanych [5]. Metodyka ta wykorzystywana jest także do budowy systemów diagnostycznych w obszarze zarządzania utrzymaniem obiektów budowlanych [20], jak i do oceny ich stanu technicznego [21]. W węższym zakresie występują również, jako systemy pozwalające na ocenę parametrów wytrzymałościowych istniejących konstrukcji, zarówno statycznych [4], jak i zmęczeniowych [44].

W kwestii różnorodności typów konstrukcji budowlanych, metodyka sieci *Bayesowskich* stosowana jest również w odniesieniu do budynków murowanych [17], jak i stalowych [7]. Natomiast w szerszym kontekście, bardzo często wykorzystywana jest jako narzędzie do prognozowania wpływów środowiskowych o charakterze losowym takich jak: powódzie, trzęsienia ziemi, tsunami [13], zmiany klimatyczne [37] lub osiadania terenu [42]. Wyniesione z takich analiz informacje, są z kolei są wykorzystywane zarówno na etapie projektowania, jaki oceny zagrożenia istniejących konstrukcji budowlanych.

Należy podkreślić, że w ostatnim czasie, metodyka sieci *Bayesowskich* znajduje zastosowanie w obszarze budownictwa również na terenie Polski. Przykładem może być tutaj wykorzystane jej do oceny wpływu drgań komunikacyjnych na zabudowę powierzchni [36] oraz analiza ryzyka w ramach inwestycji budowlanej dotyczącej budowy tunel pod Martwa Wisłą w Gdańsku [14].

Jednak pomimo licznych zastosowań metodyki opartej na sieciach *Bayesowskich* w obszarze inżynierii lądowej, stosowanie i rozwijanie metod wykrywania struktury z danych jest nadal domeną nauk tj. medycyna, biologia, genetyka np.[9]. Z tej przyczyny, prezentowane w pracy badania, stanowią poszerzenie metodyki stosowanej dotychczas w obszarze inżynierii lądowej, które może pozwolić na analizę bardziej złożonych problemów inżynierskich z obszaru analizy ryzyka uszkodzeń lub niezawodności konstrukcji. Podjęte zagadnienie, dotyczące wykrywania struktury sieci *Bayesowskiej* z danych do budowy modelu ryzyka

powstania uszkodzeń w budynkach poddanych wpływow eksploatacji górniczej stanowi zdaniem autorów, interdyscyplinarne i nowatorskie ujęcie tematu.



Rys. 1. Przykłady budynków zrealizowanych w technologii uprzemysłowionej WBL
(own source)

Fig. 1. Examples of buildings constructed using WBL industrialised technology

3. Charakterystyka bazy danych

W bazie danych, która była podstawą badań, zebrano szczegółowe informacje dotyczące grupy 129 żelbetowych prefabrykowanych wielkogabarytowych budynków wielorodzinnych i użyteczności publicznej, wzniesionych uprzemysłowionym systemem wielkoblokowym WBL np. [26]. W każdym przypadku, w miejscu lokalizacji budynku, określone zostały wskaźniki opisujące intensywność wpływów górniczych na czas dokonywanej inwentaryzacji (**MC**, **AH** i **ASG** – por. tab. 1). Zmienna **ASG** została ustalona na podstawie oryginalnego wskaźnika wstrząsów górniczych a_{sg} [41] i wyraża wpływ wielokrotnego oddziaływania wstrząsów górniczych na zużycie techniczne budynków. Bazę uzupełniają informacje dotyczące cech konstrukcyjno-materiałowych, historii i jakości utrzymania, remontów oraz odnotowanych uszkodzeń. W przypadku uszkodzeń wykorzystano autorski wskaźnik uszkodzeń w_u odniesiony zarówno do elementów konstrukcyjnych, jak i wykończeniowych [8].

W trakcie wstępnej analizy bazy danych, dokonano kategoryzacji wszystkich zmiennych pod kątem dalszego ich wykorzystania w trakcie uczenia sieci *Bayesowskich*. Polegało to na przypisaniu etykiet dla poszczególnych kategorii. Wykaz wszystkich zmiennych wraz z przypisanym zakresem etykiet podano w tabeli 1. W późniejszym etapie, każda ze zmiennych będzie odzwierciedlać poszczególne węzły w sieci *Bayesowskiej*.

4. Metodyka badań

Sieci Bayesowskie (BN – *Bayesian Network*), zwane także *Sieciami przekonań Bayesa* (BBN – *Bayesian Belief Networks*) można przedstawić w postaci *acyklicznego grafu skierowanego* (DAG – *Directed Acyclic Graph*) [18]. W strukturze grafu (G) zakodowana jest informacja o wzajemnych zależnościach między poszczególnymi zmiennymi $\mathbf{X} = \{X_1, \dots, X_N\}$, którą reprezentują krawędzie grafu (E) oraz węzły (V). W ogólnym ujęciu, BBN reprezentuje łączny rozkład prawdopodobieństwa nad zbiorem zmiennych losowych \mathbf{X} , który można przedstawić jako [34]:

$$P(\mathbf{X}|G, \boldsymbol{\theta}) = \prod_{i=1}^N P(X_i | \Pi_{X_i}, \theta_{X_i}) \quad (1)$$

gdzie:

$G = G(\mathbf{X}, \mathbf{E}, \mathbf{V})$ – struktura acyklicznego grafu skierowanego

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

$X_i = \{x_i^{(1)}, \dots, x_i^{(k_i)}\}$ – stany j -tej zmiennej

\mathbf{E} – zbiór wszystkich krawędzi

\mathbf{V} – zbiór wszystkich węzłów

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

$\boldsymbol{\theta} = \{\theta_{X_1}, \dots, \theta_{X_N}\}$ – 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 wielonomialnej tablicy prawdopodobieństwa warunkowego (CPT - *Conditional Probability Table*), której elementy wyraża się jako [11]:

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

Zgodnie z zależnością (1) łączny rozkład prawdopodobieństwa $P(\mathbf{X}|G, \boldsymbol{\theta})$ podlega dekompozycji w oparciu o warunkowe rozkłady lokalne $P(X_i | \Pi_{X_i}, \boldsymbol{\theta}_{X_i})$, 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 *Perla* w pracy [24]. Pozwala to dodatkowo na efektywną analizę zmian wartości przyjętego kryterium w trakcie wyszukiwania optymalnej struktury sieci.

W opisywanym problemie, dotyczącym budowy modelu ryzyka powstawania uszkodzeń, niewiadomymi są zarówno struktura BBN, jak również jej parametry. W ramach dotychczasowych badań potwierdzono istotny, lecz subtelny wpływ poszczególnych czynników na proces powstawania uszkodzeń. Dlatego, na etapie selekcji metody uczenia struktury BBN z danych, kierowano się tym, żeby w ostatecznym modelu występowała jak największa liczba zmiennych potencjalnie wpływających na proces inicjowania uszkodzeń. Na podstawie literatury [18] odrzucono metody *constraint-based structure learning* oraz *podejście hybrydowe*. Stwierdzono bowiem, że w ramach tych metod uczenia większa waga przypisywana jest indywidualnym połączeniom między węzłami sieci niż globalnej odpowiedzi modelu. Tym samym ukierunkowano się na metody *score-based structure learning*. Finalnie zastosowano dwie metody: *Hill-Climbing* (HC) i *Tabu-Search* (TS).

Podejście optymalizacyjne HC zaliczane jest do grona metod *greedy-search* [35]. Polega ono na przeszukiwaniu najbliższego otoczenia wokół aktualnego punktu w przestrzeni, któremu odpowiada dana wartość przyjętego kryterium optymalizacyjnego. Następnie, z otoczenia wybierany jest punkt w przestrzeni poszukiwań, którego wartość kryterialna jest wyższa niż w kroku poprzednim. Obszar poszukiwań stanowi przestrzeń struktur acyklicznych grafów skierowanych (DAG), a postęp algorytmu następuje poprzez dodawanie, odejmowanie lub zamianę powiązań między węzłami.

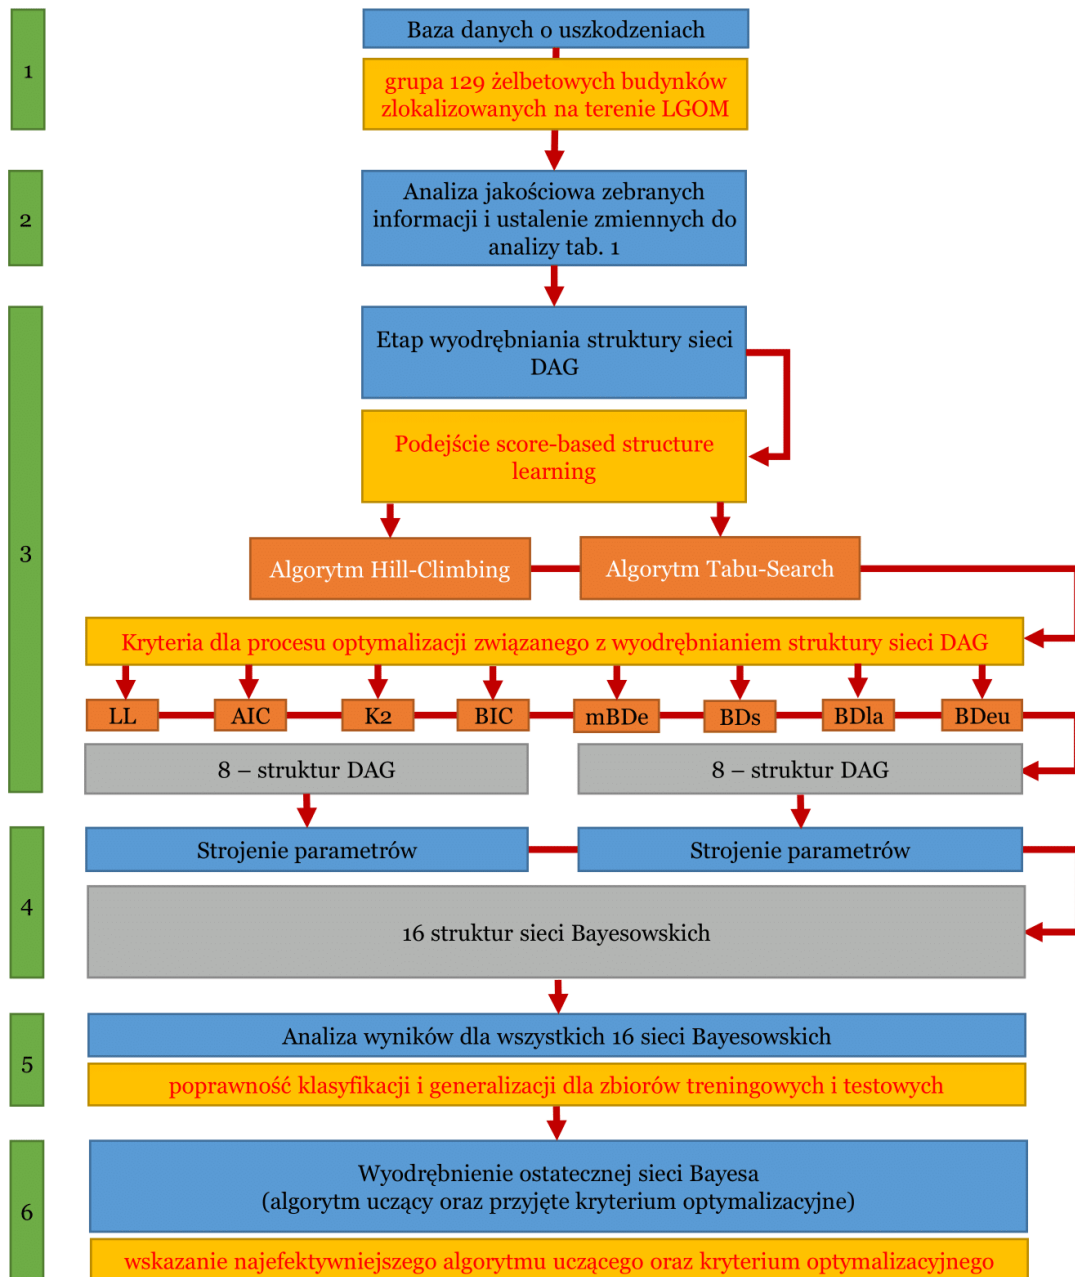
Z kolei podejście TS stanowi modyfikację algorytmu HC. Modyfikacja ta polega na przechowywaniu określonej liczby zakazanych ścieżek w przestrzeni poszukiwań, które zostały już przebyte w ramach poprzednich iteracji, a tym samym ogranicza się ślepe błądzenie oraz utknięcie w optimum lokalnym [33].

Tabela 1. Wykaz zmiennych w bazie danych wraz z przypisanym zakresem etykiet
 Table 1. List of variables in the database with the assigned label range

WYKAZ ZMIENNYCH		
OZN	OPIS	TYP ZMIENNEJ/ ETYKIETY ZMIENNYCH
DANE O ODDZIAŁYWANIACH GÓRNICZYCH W MIEJSCU LOKALIZACJI DANEGO BUDYNKU		
MC	kategoria terenu górniczego	kategor. / 3 kategorie
AH	maksymalna składowa pozioma przyspieszenia drgań gruntu	kategor. / 4 kategorie
ASG	wskaźnik oceny wpływu wstrząsów górniczych [41]	kategor. / 4 kategorie
WSKAŹNIKI USZKODZEŃ ELEMENTÓW KONSTRUKCYJNYCH I WYKOŃCZENIOWYCH		
W _{u2}	wskaźnik uszkodzeń ścian piwnicznych lub fundamentowych	kategor. / 4 kategorie
W _{u3}	wskaźnik uszkodzeń ścian nośnych nadziemna wewn. i zewn. (w tym nadproży i murów podokiennych)	kategor. / 4 kategorie
W _{u7}	wskaźnik uszkodzeń stropów wyżej, stropodachu (przekrycia)	kategor. / 4 kategorie
W _{u11}	wskaźnik uszkodzeń ścian działowych	kategor. / 2 kategorie
W _{u12}	wskaźnik uszkodzeń tynków wewnętrznych i okładzin ściennych	kategor. / 3 kategorie
W _{u13}	wskaźnik uszkodzeń podłogi (warstw podłogowych)	kategor. / 3 kategorie
W _{u17}	wskaźnik uszkodzeń elewacji (warstw elewacyjnych)	kategor. / 4 kategorie
W _{u19}	wskaźnik uszkodzeń pokrycia dachowego	kategor. / 4 kategorie
DANE O UTRZYMANIU I REMONTACH		
CR	remonty bieżące	kategor. / 4 kategorie
FR	remonty elewacji	kategor. / 5 kategorie
RR	remonty dachu	kategor. / 6 kategorie
IR	remonty wnętrza	kategor. / 7 kategorie
DANE O KONSTRUKCJI I GEOMETRII BUDYNKU		
LEN	długość budynku (dłuższy z wymiarów)	kategor. / 6 kategorie
NoST	liczba kondygnacji	kategor. / 6 kategorie
NoSE	liczba segmentów	kategor. / 8 kategorie
LoSE	długość segmentów	kategor. / 6 kategorie
DIL	dylatacja (szerokość)	kategor. / 3 kategorie
SHA	kształt budynku	kategor. / 4 kategorie
ToF	rodzaj fundamentu	kategor. / 5 kategorie
SW	ściany osłonowe	kategor. / 4 kategorie
BC	strop nad piwnicą	kategor. / 4 kategorie
DP	zabezpieczenia projektowe	kategor. / 3 kategorie
EP	zabezpieczenia istniejące	kategor. / 5 kategorie
DANE DOTYCZĄCE TRWAŁOŚCI		
AGE	wiek budynku	kategor. / 4 kategorie
DUR	trwałość	kategor. / 5 kategorie
TS	stan techniczny	kategor. / 4 kategorie

W niniejszej pracy, wykorzystując pakiet *bnlearn*, podjęto analizę porównawczą obydwu podejść. Dodatkowo przetestowano ich działanie w sytuacji przyjęcia różnych kryteriów optymalizacyjnych. W tym celu przyjęto kryteria należące do dwóch grup: *Information-Theoretic scores* (IT) [2] and *Bayesian Dirichlet scores* (BD) [32]. Do pierwszej z nich należą: *Log-Likelihood* (LL), *Akaike Information Criterion* (AIC) and *Bayesian Information Criterion* (BIC). Natomiast z grupy *Bayesian Dirichlet scores* (BD) zastosowano wg. [33]: *Bayesian Dirichlet equivalent uniform* (BDeu), *modified Bayesian Dirichlet equivalent score* (mBDe), *Bayesian Dirichlet sparse score* (BDs), *locally averaged Bayesian*

Dirichlet score (BDla) and the *K2* score. Schemat chronologiczny przeprowadzonych badań przedstawiono na rys. 2.



Rys. 2. Chronologiczny schemat przeprowadzonych analiz
 Fig. 2. Chronological diagram of the carried out analyses

5. Wyniki przeprowadzonych analiz

W badaniach zastosowano metodykę opisaną w rozdziale 3, w której założono dwa podejścia do budowy struktury *sieci przekonań Bayesa* (BBN) z danych. Obydwa podejścia należą do grupy metod *score-based structure learning* [18]. Jako pierwszy zastosowany algorytm *Hill-Climbing* (HC). Natomiast w drugim wykorzystano jego modyfikację, a mianowicie algorytm *Tabu-Search* (TS).

Zestaw danych o budynkach, opisany w rozdziale 2, został podzielony na zbiór treningowy i testowy. Kluczowe było tutaj takie rozdzielanie zbiorów, aby zachować w nich równomierny podział wartości skategoryzowanych zmiennych, ujętych w tab.1 tj.: w_{u2} , w_{u3} , w_{u7} , w_{u11} , w_{u12} , w_{u13} , w_{u17} i w_{u19} . Finalnie dokonano tego za pomocą metody *Stratified Sampling* (SS). Uzyskano tym samym zbiór treningowy o licznosci równej 105 wzorców (81,36% całkowitej liczby wzorców w bazie danych) oraz zbiór testowy, którego liczba wzorców była równa 24 (18,6%).

W przypadku wykorzystanego w analizach pakietu *bnlearn*, istnieje możliwość uwzględnienia wiedzy eksperta. Odbywa się to za pomocą wprowadzania listy reprezentującej powiązania zakazane (*Black List*) i wymuszone (*White List*). Są to ograniczenia typu mocnego (*strong constraint*), które nie podlegają modyfikacji w trakcie procesu uczenia.

W pracy zestawiono wyniki przeprowadzonych analiz, których celem było porównanie obydwu zastosowanych podejść. Ostatecznie wyłoniono 16 struktur BBN, które poddano ocenie. Wynikało to z przyjęcia dwóch algorytmów uczących i ośmiu kryteriów optymalizacyjnych (*Information-Theoretic scores* (IT) and *Bayesian Dirichlet scores* (BD) - wg. rozdziału 3).

Przed rozpoczęciem obliczeń, wprowadzono ograniczenia (*strong constraint*) powodujące wykluczenie z sieci tych powiązań, które są sprzeczne z logiką i nie są obserwowane w rzeczywistości. Łącznie utworzono zestaw 427 par między węzłami, w których zabroniono tworzenia się powiązań. Należy zaznaczyć, iż nie tworzone listy wymuszeń, pozostawiając w tej kwestii swobodę poszczególnym algorytmom uczącym.

W **pierwszym etapie** oceniono poszczególne struktury pod kątem ilościowym. Podstawą była tutaj analiza poprawności klasyfikacji oraz własności generalizacyjne wyłonionych struktur BBN. Zastosowano tutaj miarę względną w postaci procentowego udziału poprawnie sklasyfikowanych wzorców względem licznosci całego zbioru danych (odpowiednio treningowego i testowego). Wyniki te dla poszczególnych kombinacji wynikających z przyjętej metody uczenia i kryterium optymalizacyjnego zestawiono w tab. 2 ÷ 5. Pozwoliło to na ocenę poprawności klasyfikacji oraz własności generalizacyjnych utworzonych modeli. Podstawą było tutaj symulowanie odpowiedzi sieci w węzłach odpowiadających poszczególnym wskaźnikom uszkodzeń: w_{u2} , w_{u3} , w_{u7} , w_{u11} , w_{u12} , w_{u13} , w_{u17} i w_{u19} .

Tabela. 2. Poprawność klasyfikacji dla poszczególnych węzłów odpowiadających wskaźnikom uszkodzeń – zbiór treningowy – algorytm uczący HC

Table 2. Accuracy of classification for individual nodes corresponding to damage indices - training set - algorithm teaching HC

kryterium	Poziom dokładności ac^{HC-TR} [%]							
	w_{u2}	w_{u3}	w_{u7}	w_{u11}	w_{u12}	w_{u13}	w_{u17}	w_{u19}
LL	100,00	99,05	99,05	100,00	100,00	100,00	99,05	99,05
AIC	92,38	90,48	85,71	92,38	94,29	95,24	90,48	90,48
BIC	93,33	90,48	89,52	92,38	94,29	90,48	90,48	90,48
BDeu	89,52	91,43	86,67	92,38	94,29	94,29	91,43	93,33
BDs	92,38	93,33	89,52	97,14	97,14	99,05	94,29	92,38
mBDe	91,43	91,43	85,71	92,38	94,29	94,29	91,43	93,33
BDla	90,48	93,33	85,71	97,14	97,14	95,24	95,24	94,29
K2	93,33	90,48	90,48	93,33	91,43	94,29	95,24	90,48

Tabela. 3. Poprawność klasyfikacji dla poszczególnych węzłów odpowiadających wskaźnikom uszkodzeń – zbiór testowy – algorytm uczący HC

Table 3. Accuracy of classification for individual nodes corresponding to damage indices - test set - algorithm teaching HC

kryterium	Poziom dokładności ac^{HC-TS} [%]							
	wu_2	wu_3	wu_7	wu_{11}	wu_{12}	wu_{13}	wu_{17}	wu_{19}
LL	95,83	95,83	79,17	100,00	100,00	100,00	79,17	95,83
AIC	83,33	87,50	75,00	95,83	95,83	100,00	37,50	95,83
BIC	87,50	87,50	79,17	91,67	91,67	91,67	41,67	95,83
BDeu	83,33	87,50	79,17	95,83	95,83	100,00	62,50	100,00
BDs	91,67	91,67	79,17	100,00	100,00	100,00	75,00	100,00
mBDe	83,33	87,50	83,33	95,83	95,83	100,00	66,67	100,00
BDla	83,33	91,67	83,33	100,00	100,00	100,00	87,50	100,00
K2	95,83	83,33	75,00	95,83	100,00	91,67	87,50	95,83

Tabela. 4. Poprawność klasyfikacji dla poszczególnych węzłów odpowiadających wskaźnikom uszkodzeń – zbiór treningowy – algorytm uczący TS

Table 4. Accuracy of classification for individual nodes corresponding to damage indices - training set - algorithm teaching TS

kryterium	Poziom dokładności $ac^{TABU-TR}$ [%]							
	wu_2	wu_3	wu_7	wu_{11}	wu_{12}	wu_{13}	wu_{17}	wu_{19}
LL	100,00	99,05	100,00	100,00	100,00	100,00	100,00	100,00
AIC	92,38	90,48	85,71	92,38	94,29	96,19	90,48	90,48
BIC	93,33	90,48	89,52	92,38	94,29	90,48	90,48	90,48
BDeu	91,43	90,48	88,57	92,38	94,29	96,19	91,43	93,33
BDs	95,24	96,19	89,52	97,14	97,14	98,10	94,29	93,33
mBDe	91,43	89,52	86,67	93,33	94,29	94,29	90,48	93,33
BDla	91,43	93,33	86,67	97,14	97,14	95,24	95,24	93,33
K2	93,33	90,48	86,67	89,52	94,29	92,38	95,24	90,48

Tabela. 5. Poprawność klasyfikacji dla poszczególnych węzłów odpowiadających wskaźnikom uszkodzeń – zbiór testowy – algorytm uczący TS

Table 5. Accuracy of classification for individual nodes corresponding to damage indices - test set - algorithm teaching TS


kryterium	Poziom dokładności $ac^{TABU-TS}$ [%]							
	wu_2	wu_3	wu_7	wu_{11}	wu_{12}	wu_{13}	wu_{17}	wu_{19}
LL	95,83	95,83	79,17	100,00	100,00	100,00	79,17	95,83
AIC	83,33	87,50	70,83	95,83	95,83	100,00	50,00	95,83
BIC	87,50	87,50	79,17	91,67	91,67	91,67	54,17	95,83
BDeu	87,50	87,50	87,50	95,83	95,83	100,00	66,67	100,00
BDs	91,67	91,67	83,33	100,00	100,00	100,00	66,67	100,00
mBDe	83,33	87,50	83,33	95,83	95,83	100,00	66,67	100,00
BDla	83,33	91,67	87,50	95,83	100,00	100,00	79,17	100,00
K2	95,83	91,67	79,17	91,67	91,67	91,67	87,50	95,83

W **drugim etapie** weryfikowano uzyskane struktury BBN pod kątem jakościowym. Było to podyktowane względami praktycznymi wynikającymi z możliwości późniejszego stosowania utworzonego modelu do oceny ryzyka w budownictwie. Tutaj skupiono się na wykrytych powiązaniach przyczynowo-skutkowych. Ocena była podejmowana w sposób ekspercki, wynikający z doświadczenia autorów w zakresie problematyki uszkodzeń budynków na terenach górniczych.

Na podstawie wyników analizy ilościowej, którą reprezentuje poziom poprawnie sklasyfikowanych wzorców dla zbiorów treningowych i testowych opisanych miarą: ac^{HC-TR} , ac^{HC-TS} , $ac^{TABU-TR}$, $ac^{TABU-TS}$ (tab. 2 ÷ 5), stwierdzono, że:


- kryterium optymalizacyjne LL prowadzi do najlepszego dopasowania wzorców treningowych (tab. 2 i 4), ale generuje największe błędy klasyfikacji dla zbiorów testowych (tab. 3 i 5). Wynika z tego, że zarówno dla metody HC, jak i TS, wyłonione struktury BBN nie posiadają dobrych własności generalizujących i prowadzą do przeuczenia modelu,
- najgorsze rezultaty uzyskano dla predykcji wskaźników uszkodzeń w_{u7} i w_{u17} – por. tab. 3 i 5. Przy czym odpowiadające wyniki w zbiorze treningowym osiągają wartość poprawnej klasyfikacji na poziomie $ac^{HC-TR} \approx ac^{HC-TS} \approx 90\%$. Różnica między wynikami dla zbioru treningowego i testowego świadczy o przeuczenia modelu w zakresie predykcji wskaźników w_{u7} i w_{u17} .
- najlepsze rezultaty w odniesieniu do predykcji wartości wskaźników uszkodzeń w_{u7} i w_{u17} , zarówno w zbiorze treningowym, jak i testowym, uzyskano przyjmując jako kryterium optymalizacyjne miarę BDla i K2 – por. tab. 3 i 5,
- w przypadku predykcji pozostałych wskaźników uszkodzeń: w_{u2} , w_{u3} , w_{u11} , w_{u12} , w_{u13} i w_{u19} , pomijając kryterium LL, obydwie metody uczenia generują modele osiągające w symulacjach bardzo wysoki poziom trafności, zarówno w zbiorze treningowym i testującym. Nie ma tutaj znaczącego wpływu wybór poszczególnych kryteriów optymalizacyjnych.

W ramach **etapu pierwszego**, czyli oceny, ilościowej wyodrębniono łącznie 4 struktury, dla których uzyskano najlepsze wyniki predykcji dla wszystkich wskaźników uszkodzeń (łącznie ze wskaźnikami w_{u7} i w_{u17}) oraz potwierdzono ich własności generalizacyjne. Były to struktury utworzone metodą HC i TS z zastosowaniem kryteriów optymalizacyjnych BDla i K2. Wyniki w postaci graficznej zaprezentowano na rys. 3 do 6.



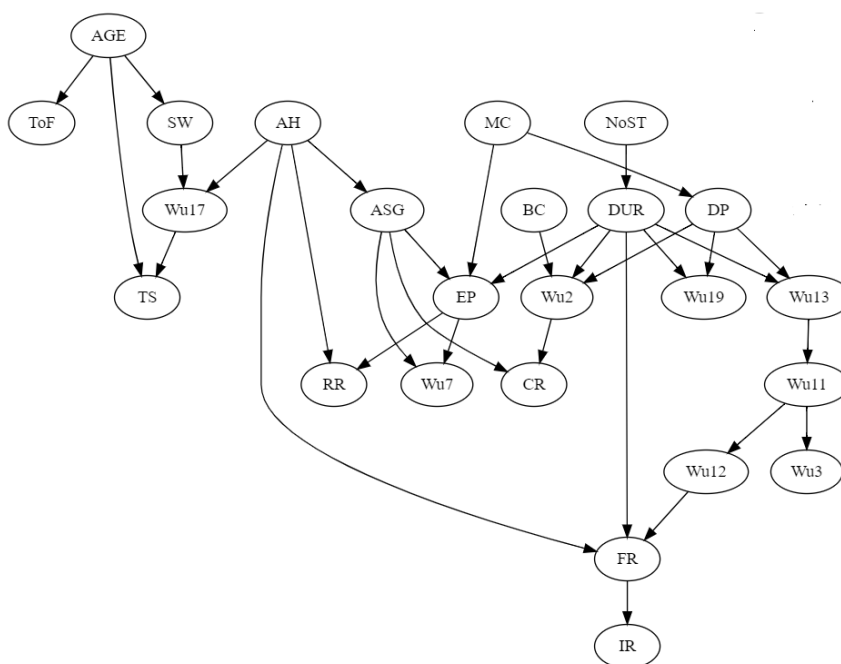
Rys. 3. Struktura BBN wyłoniona metodą HC przy zastosowanym kryterium optymalizacyjnym BDla

Fig. 3. The BBN structure extracted by the HC method using the BDla optimisation criterion




Rys. 4. Struktura BBN wyłonią metodą TS przy zastosowanym kryterium optymalizacyjnym BDla

Fig. 4. The BBN structure extracted by the TS method using the BDla optimisation criterion



Rys. 5. Struktura BBN wyłonią metodą HC przy zastosowanym kryterium optymalizacyjnym K2

Fig. 5. The BBN structure extracted by the HC method using the K2 optimisation criterion



Rys. 6. Struktura BBN wyłoniona metodą TS przy zastosowanym kryterium optymalizacyjnym K2

Fig. 6. The BBN structure extracted by the TS method using the K2 optimisation criterion

W przypadku struktury BBN uzyskanej metodą HC i kryterium BD1a (rys. 3), można zauważyć, że pominięte są dwa węzły reprezentujące zmienne: **NoSE** i **LoSE**. Analogicznie w przypadku struktury wyłonionej metodą TS i kryterium BD1e. Tutaj pominięty jest jedynie jeden węzeł wskazujący zmienną **LoSE**. Zmienna **NoSE** występuje natomiast w łącznej strukturze sieci BBN – rys. 4.

Z kolei w przypadku kryterium K2, bez względu na zastosowany algorytm uczący, poza wyłoniętymi strukturami (rys. 5 i 6) pozostają węzły **LoSE**, **NoSE**, **LEN**, **DIL**, **SHA**.

Cechy geometryczne danego obiektu (por. tab. 1), mają wpływ na jego odporność [27], a co za tym idzie, także na ryzyko powstania uszkodzeń. Dlatego wydaje się, na podstawie wieloletnich doświadczeń autorów, że bliższe rzeczywistości są modele reprezentowane przez struktury sieci BBN wyłonione przy zastosowaniu algorytmu TS oraz kryterium BD1a – por. rys. 4. W tym przypadku uzyskano najpełniejszy opis analizowanego problemu, biorąc pod uwagę zbiór aktywnych zmiennych zawartych w sieci BBN reprezentowanych przez poszczególne węzły.

6. Podsumowanie

W pracy zaprezentowane zostały wyniki analiz dotyczących budowy *sieci Bayesowskiej* (BN) do prognozowania zakresu i oceny uszkodzeń budynków poddanych wpływom eksploatacji górniczej. Z uwagi na fakt, że ustalona *sieć Bayesowska* reprezentuje wynikowe prawdopodobieństwo występowania uszkodzeń oraz wszystkich czynników warunkujących ich powstanie, może stanowić model do oceny ryzyka powstania uszkodzeń. Ostatecznie model taki został opracowany na podstawie informacji dotyczących 129 wielkogabarytowych budynków wielorodzinnych i użyteczności publicznej o konstrukcji żelbetowej prefabrykowanej, wzniesionych w systemie budownictwa uprzemysłowionego WBL. W bazie danych zebrano informacje o cechach konstrukcyjno-materiałowych, jakości utrzymania, a także dane dotyczące oceny uszkodzeń elementów oraz wpływu oddziaływań górniczych. Na tej podstawie, przyjmując dwa algorytmy uczenia struktur *sieci Bayesowskich* z danych (*Hill-Climbing* i *Tabu-Search*) oraz 8 różnych kryteriów optymalizacyjnych utworzono 16 struktur sieci Bayesa do celów predykcji zakresu i prawdopodobieństwa powstania uszkodzeń.

Uzyskane *sieci Bayesowskie* poddano ocenie ilościowej i jakościowej. Ocena ilościowa polegała na weryfikacji zgodności predykcji poszczególnych sieci z danymi ze zbiorów treningowych i testowych. Tym samym sprawdzono również stopień generalizacji nabytej wiedzy. W ramach tych analiz wyodrębniono 4 struktury, które poddano dalszej analizie jakościowej. Z kolei, w trakcie analizy jakościowej oceniano kompletność utworzonych struktur pod względem aktywnie połączonych węzłów reprezentujących poszczególne zmienne potencjalnie mogące wpływać na proces powstawania uszkodzeń. Rezultatem było zawężenie wstępnie wyselekcjonowanych sieci z etapu analizy ilościowej do jednego modelu. Model ten został utworzony z zastosowaniem algorytmu *Tabu-Search* przy zastosowaniu kryterium optymalizacyjnego BDla.

Utworzony model ryzyka w postaci *sieci Bayesowskiej*, powstały w wyniku uczenia struktury DAG na podstawie danych, posiada kilka bardzo istotnych zalet:

- Daje możliwość zarówno przewidywania prawdopodobieństwa zaistnienia uszkodzeń, jak i diagnozy przyczyn ich powstania. Z tego powodu może być wykorzystany jako narzędzie do szacowania ryzyka powstania uszkodzeń dla dużej liczby budynków zlokalizowanych na terenie górniczym.
- Umożliwia interpretację powiązań przyczynowo-skutkowych, których znajomość poszerza wiedzę nt. modelowanego zjawiska. Szczególnie w przypadku oddziaływania zmiennych dotyczących jakości utrzymania obiektu.
- Pozwala na przeprowadzenie wnioskowania względem dowolnej zmiennej zawartej w strukturze DAG reprezentującej sieć *Bayesowską*.
- Może być wykorzystywane w przypadku braku ścisłej informacji nt. stanu zmiennych w poszczególnych węzłach. Umożliwia zatem stosowanie modelu w obszarze niepewności.
- Może być łatwo aktualizowany w przypadku rejestracji nowych danych wynikających z obserwacji rzeczywistego przebiegu danego procesu.

Dodatkowo, tego rodzaju metodyka może być zastosowana w dużo szerszym zakresie niż tylko do oceny wpływów eksploatacji górniczej. Jako przykładowe można wymienić tu: monitoring stanu technicznego konstrukcji (*Structure Health Monitoring*) lub zarządzanie utrzymaniem technicznym i konserwacją obiektów budowlanych (*Maintenance Management*).

Uzyskane wyniki dają asumpt do dalszych badań w tym zakresie, zarówno w kwestii analizy budynków innego typu, jak i testowania innych metod pozwalających na uczenie struktur *sieci Bayesowskich* z danych.

Literatura

1. Abdelkader EM, Zayed T, Marzouk M. A computerized hybrid Bayesian-based approach for modelling the deterioration of concrete bridge decks. *Structure and Infrastructure Engineering* 2019; 15: 1178–99.
2. Carvalho AM. Scoring functions for learning Bayesian networks. *Inesc-id Tec. Rep* 2009; 12.
3. Chung H, Lee I-M, Jung J-H, Park J. Bayesian networks-based shield TBM risk management system: Methodology development and application. *KSCE Journal of Civil Engineering* 2019; 23: 452–65.
4. Dahire S, Tahir F, Jiao Y, Liu Y. Bayesian Network inference for probabilistic strength estimation of aging pipeline systems. *International Journal of Pressure Vessels and Piping* 2018; 162: 30–9.
5. Fang S-E, Tan J, Zhang X-H. Safety evaluation of truss structures using nested discrete Bayesian networks. *Structural Health Monitoring-an International Journal* 2020.

6. Fedorowicz J, Słowik L. Interpretation of the behavior of a system building object-difficult subsoil in modern numerical modeling. *Proceedings of the 11th International Conference on New Trends in Statics and Dynamics of Buildings* October. Vol3. 2013.
7. Fereshtehnejad E, Banazadeh M, Shafieezadeh A. System reliability-based seismic collapse assessment of steel moment frames using incremental dynamic analysis and Bayesian probability network. *Engineering Structures* 2016; 118: 274–86.
8. Firek K. Proposal for classification of prefabricated panel building damage intensity rate in mining areas. *Archives of Mining Sciences* 2009.
9. Gogoshin G, Boerwinkle E, Rodin AS. New algorithm and software (BNOmics) for inferring and visualizing bayesian networks from heterogeneous big biological and genetic data. *Journal of Computational Biology* 2017; 24: 340–56.
10. Golewski GL. Measurement of fracture mechanics parameters of concrete containing fly ash thanks to use of Digital Image Correlation (DIC) method. *Measurement* 2019; 135: 96–105.
11. Heckerman D, Geiger D, Chickering DM. Learning Bayesian networks: The combination of knowledge and statistical data. *Machine learning* 1995; 20: 197–243.
12. Jin Y, Zhang J, Sun L. Safety Risk Assessment of Prefabricated Building Construction Based on Bayesian Network. *IOP Conference Series: Earth and Environmental Science*. Vol371. 2019: 32052.
13. Ravikumar K, Rajiv Kannan A. Survey of Spatial Datamining Methods for Natural Disaster Management. *Middle-East Journal of Scientific Research* 2017; 25: 217–27.
14. Kębłowski MW, Grzyl B, Kristowski A, Siemaszko A. Risk Modelling with Bayesian Networks - Case Study: Construction of Tunnel under the Dead Vistula River in Gdansk. *Procedia Engineering* 2017; 196: 585–91.
15. Knyziak P, Kanoniczak M. Difficulties in Operation of Elevations in Large-Panel Buildings. *IOP Conference Series: Materials Science and Engineering*. Vol661. 2019: 12059.
16. Lee S, Choi M, Lee H-S, Park M. Bayesian Network-based Seismic Damage Estimation for Power and Potable Water Supply Systems. *Reliability Engineering & System Safety* 2020: 106796.
17. Marsili F, Croce P, Klawonn F, Vignoli A, Boschi S, Landi F. A Bayesian network for the definition of probability models for masonry mechanical parameters. *14th International Probabilistic Workshop*. 2017: 253–68.
18. Nagarajan R, Scutari M, Lèbre S. *Bayesian networks in r*. Springer 2013; 122: 125–7.
19. Niedojadło Z, Gruszczynski W. The impact of the estimation of the parameters values on the accuracy of predicting the impacts of mining exploitation. *Archives of Mining Sciences* 2015; doi 10.1515/amsc-2015-0012.
20. Nielsen JS, Sørensen JD. Computational framework for risk-based planning of inspections, maintenance, and condition monitoring using discrete Bayesian networks. *Structure and Infrastructure Engineering* 2018; 14: 1082–94.
21. Nielsen JS, Tcherniak D, Ulriksen MD. A case study on risk-based maintenance of wind turbine blades with structural health monitoring. *Structure and Infrastructure Engineering* 2020: 1–17.
22. Niewiadomski P, Hoła J. Failure process of compressed self-compacting concrete modified with nanoparticles assessed by acoustic emission method. *Automation in Construction* 2020; 112: 103111.

23. Pachla F, Tataro T. Dynamic Resistance of Residential Masonry Building with Structural Irregularities. *Seismic Behaviour and Design of Irregular and Complex Civil Structures III*. Springer, 2020: 335–47.
24. Pearl J. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Elsevier, 2014.
25. Rusek J. Application of Support Vector Machine in the analysis of the technical state of development in the LGOM mining area. *Eksploracja i Niezawodność – Maintenance and Reliability 2017*; 19 (1): 54–61, <http://dx.doi.org/10.17531/ein.2017.1.8>.
26. Rusek J, Firek K. Assessment of technical condition of prefabricated large-block building structures located in mining area using the Naive Bayes classifier. *International Multidisciplinary Scientific GeoConference Surveying Geology and Mining Ecology Management, SGEM. Vol2*. 2016.
27. Rusek J. The Point Nuisance Method as a Decision-Support System Based on Bayesian Inference Approach. *Archives of Mining Sciences 2020*; 65: 117–27.
28. Sadowski L. Non-destructive investigation of corrosion current density in steel reinforced concrete by artificial neural networks. *Archives of Civil and Mechanical Engineering 2013*; 13: 104–11.
29. Sadowski Ł, Hoła J, Czarnecki Sł. Non-destructive neural identification of the bond between concrete layers in existing elements. *Construction and Building Materials 2016*; 127: 49–58.
30. Sari DP, Rosadi D, Effendie AR, others. Application of Bayesian network model in determining the risk of building damage caused by earthquakes. *2018 International Conference on Information and Communications Technology (ICOIACT)*. 2018: 131–5.
31. Schabowicz K, Gorzelańczyk T. A nondestructive methodology for the testing of fibre cement boards by means of a non-contact ultrasound scanner. *Construction and Building Materials 2016*; 102: 200–7.
32. Scutari M. Dirichlet Bayesian network scores and the maximum relative entropy principle. *Behaviormetrika 2018*; 45: 337–62.
33. Scutari M. Learning Bayesian networks with the bnlearn R package. *arXiv preprint arXiv:0908.38172009*; doi 10.18637/jss.v035.i03.
34. Scutari M, Graafland CE, Gutiérrez JM. Who learns better Bayesian network structures: Accuracy and speed of structure learning algorithms. *International Journal of Approximate Reasoning 2019*; 115: 235–53.
35. Scutari M, Vitolo C, Tucker A. Learning Bayesian networks from big data with greedy search: computational complexity and efficient implementation. *Statistics and Computing 2019*: 1–14.
36. Siemaszko A, Jakubczyk-Gałczyńska A, Jankowski R. The Idea of Using Bayesian Networks in Forecasting Impact of Traffic-Induced Vibrations Transmitted through the Ground on Residential Buildings. *Geosciences 2019*; 9: 339.
37. Sperotto A, Molina J-L, Torresan S, Critto A, Marcomini A. Reviewing Bayesian Networks potentials for climate change impacts assessment and management: A multi-risk perspective. *Journal of environmental management 2017*; 202: 320–31.
38. Tajduś K, Misa R, Sroka A. Analysis of the surface horizontal displacement changes due to longwall panel advance. *International Journal of Rock Mechanics and Mining Sciences 2018*; doi 10.1016/j.ijrmms.2018.02.005.

39. Tran T-B, Bastidas-Arteaga E, Aoues Y et al. Reliability assessment and updating of notched timber components subjected to environmental and mechanical loading. *Engineering Structures* 2018; 166: 107–16.
40. Wang F, Li H, Dong C, Ding L. Knowledge representation using non-parametric Bayesian networks for tunneling risk analysis. *Reliability Engineering & System Safety* 2019; 191: 106529.
41. Wodyński A, Lasocki S. Assessment of mining tremor influence on the technical wear of building. *Acta Geodynamica et Geomaterialia. Ser. A and Ser. B* 2004; 50: 187–94.
42. Wu L, Wang J, Zhou J et al. Multi-scale geotechnical features of dredger fills and subsidence risk evaluation in reclaimed land using BN. *Marine Georesources & Geotechnology* 2019: 1–23.
43. Yazdani A, Shahidzadeh M-S, Takada T. Bayesian networks for disaggregation of structural reliability. *Structural Safety* 2020; 82: 101892.
44. Yuan M, Liu Y, Yan D, Liu Y. Probabilistic fatigue life prediction for concrete bridges using Bayesian inference. *Advances in Structural Engineering* 2019; 22: 765–78.