

Identyfikacja zagrożeń jako źródeł ryzyka w działalności górniczej

TADEUSZ CYRUL

Instytut Mechaniki Górotworu PAN, ul. Reymonta 27; 30-059 Kraków

Streszczenie

Niniejsza praca stanowi drugi etap badań związanych z zagadnieniem zarządzania ryzykiem w projektach górniczych. Zarządzanie ryzykiem składa się z szeregu etapów, przy czym etapem początkowym jest identyfikacja zagrożeń. W pracy zwrócono uwagę, że identyfikacja zagrożeń jest najczęściej pojmowana jako ewidencjonowanie zagrożeń w procesie funkcjonowania badanego systemu. Takie podejście do identyfikacji chociaż posiada duże walory praktyczne w zakresie profilaktyki, posiada również wiele wad z których najważniejsze to: 1. duży udział czynnika subiektywnego, 2. Jakościowy charakter metod, 3. Mała przydatność do powtarzalnej prognozy wystąpienia awarii, a tym samym ilościowej oceny ryzyka podejmowanych działań. Te ułomności metod identyfikacji zagrożeń (ewidencjonowania zagrożeń) skłoniły autora do spojrzenia na identyfikację zagrożeń z punktu widzenia ich modelowania. W takim ujęciu identyfikacja jest postrzegana jako klasyfikacja modeli danego zjawiska (zagrożenia) a następnie w oparciu o pewne kryterium, wyboru najlepszego modelu z danej klasy modeli. W pracy zaprezentowano znane metody ewidencjonowania zagrożeń jak: Listy kontrolne, Wstępna Analiza Zagrożeń, Analiza „Co, Jeżeli”, Studium zagrożeń i Zdolności działania oraz Analiza Sposobów Uszkodzeń i Skutków, a ponadto metodę Drzewa Zdarzeń do tworzenia scenariuszy awaryjnych oraz metodą Drzewa Błędów. Oryginalnym elementem pracy jest opracowanie koncepcji prognozowania zdarzeń niebezpiecznych oraz modelu prognostycznego zdarzenia niebezpiecznego.

Słowa kluczowe: identyfikacja, ryzyko, niepewność, zagrożenie, decyzja, prawdopodobieństwo, prognoza, przyczyna, skutek, zdarzenie niebezpieczne

1. Wprowadzenie

Od zarania dziejów działalność ludzka wymaga ciągłego podejmowania decyzji. Decyzje takie podejmowane są zwykle w oparciu o analizę bieżącej sytuacji i dlatego do podejmowania decyzji potrzebna jest wiedza o otaczającej człowieka rzeczywistości. Główna trudność przy podejmowaniu decyzji wiąże się z niepewnością posiadanej wiedzy, która prowadzi do braku wzajemnie jednoznacznej odpowiedniości między zbiorem faktów charakteryzujących stan aktualny a decyzją, którą należy podjąć w danej sytuacji. Zatem, podejmując decyzje w warunkach niepewności, w dłuższym okresie nie ustrzeżemy się błędów. Jeśli nie można uniknąć błędów, to dobrze byłoby wiedzieć jak często będą one popełniane. Informacja ta może być wykorzystana do poszukiwania takiej reguły podejmowania decyzji, która nie zawiedzie nas zbyt często, czyli takiej która minimalizuje stratę w wyniku złych decyzji. Taką regułę nazywa się regułą aproksymacyjną czyli przybliżoną [4] i rozumiemy ją jako pewien mechanizm umożliwiający podejmowanie decyzji na podstawie posiadanej wiedzy. Jednakże wnioskowanie opierające się na regułach przybliżonych nie zawsze doprowadza do prawdziwych wniosków i dlatego nazywane bywa wnioskowaniem przybliżonym.

W życiu codziennym, oprócz wiedzy o otaczającym świecie, wykorzystujemy pewne metody wnioskowania z tej wiedzy, które często nazywamy rozumowaniami zdroworozsądkowymi [27]. Prawie każdy typ inteligentnej aktywności (np. planowanie, uczenie, używanie języka) w pewnym stopniu wymaga rozumowań zdroworozsądkowych. Jednakże formalny opis tego typu rozumowań jest bardzo trudny, gdyż obejmuje on wiele subtelnych sposobów rozumowania, a śledzenie ich wymaga znajomości złożonych zależności występujących w posiadanej wiedzy. W opisie tych rozumowań wykorzystywane są tzw. symboliczne podejścia

na gruncie logicznym [27]. Istnieją też tzw. numeryczne podejścia do problemu formalizacji rozumowań zdroworozsądkowych. Są one oparte na różnego rodzaju wnioskowaniach probabilistycznych. Z punktu widzenia problemu podejmowania decyzji w warunkach niepewności, celem wspomnianych wyżej podejść jest zaproponowanie takiej decyzji, która jest przynajmniej w pewnym stopniu zgodna lub niesprzeczna z aktualnie posiadaną wiedzą.

Oprócz rozumowań zdroworozsądkowych można wykorzystywać do podejmowania decyzji jeszcze inne typy rozumowań. Już w starożytności filozofowie wprowadzili wnioskowanie dedukcyjne [1]. We wnioskowaniu dedukcyjnym mamy dane przesłanki lub aksjomaty, z których każdy przyjmuje się jako prawdziwy sam w sobie. Możemy udowodnić badaną tezę poprzez skonstruowanie jej dowodu formalnego w rozważanym systemie dedukcyjnym.

Innym stosowanym od dawna typem rozumowania jest wnioskowanie indukcyjne [1]. We wnioskowaniu indukcyjnym jako prawdziwe uznajemy zdanie stwierdzające jakąś ogólną prawidłowość, przy czym czynimy to na podstawie uznania zdań stwierdzających poszczególne przypadki tej prawidłowości. Jest to rozumowanie, według którego podejmuje się często decyzje w świecie rzeczywistym. Ma to miejsce w przypadkach odpowiedzi na pytania związane z prognozowaniem, sprawdzaniem hipotez czy też podejmowaniem decyzji w niepowtarzalnej sytuacji. Niestety indukcja nie jest wnioskowaniem niezawodnym, tzn. wnioskując przez indukcję można przejść od przesłanek prawdziwych do fałszywego wniosku. Jeśli bowiem istnieją przypadki spełniające pewną prawidłowość to nie oznacza wcale, że prawidłowość ta będzie zawsze spełniona. Wnioskowanie pojawia się też przy okazji uczenia się w oparciu o przykłady. Problem ten polega na tym, że na podstawie znanych przykładów danego pojęcia np. „zagrożenie” rozumianego jako podzbiór zbioru obiektów należących do rozpatrywanego środowiska (złoża) trzeba utworzyć opis tego pojęcia.

Rozwiązanie problemu uczenia się pojęć w oparciu o przykłady może być wykorzystane do konstrukcji rozumowań pozwalających na podejmowanie decyzji na podstawie posiadanej wiedzy. Zamiast bowiem mówić o uczeniu się na podstawie przykładów można rozważyć bardziej ogólne uczenie się klasyfikacji bądź też identyfikacji obiektów rozumianych jako podjęcie odpowiedniej decyzji o przypisaniu danego obiektu do danej klasy obiektów.

Przedmiotem niniejszej pracy jest dokonanie przeglądu jakościowych i ilościowych metod identyfikacji zagrożeń jako źródeł ryzyka w projektach górniczych. Identyfikacja zagrożeń stanowi jeden z pierwszych etapów procesu zarządzania ryzykiem, w którym wykorzystujemy zarówno posiadaną wiedzę jak i różne sposoby wnioskowania w zależności czy identyfikację rozumiemy jako np. ewidencjonowanie pewnych obiektów z danej klasy czy też jako ocenę dokładności odwzorowania np. ocena czy proponowany model jest ekwiwalentny prototypowi modelowanego obiektu. Podstawowe aspekty zarządzania ryzykiem zostały omówione we wcześniejszych pracach [10, 11]. Z uwagi na złożoność problematyki zagrożeń w działalności zakładu górniczego, preferowany będzie opis systemowy, który zresztą jest dominującym sposobem opisu i analizy środowiska kopalni [18, 19]. Wobec dominującej roli, zarówno w praktyce górniczej jak i w literaturze na tematy górnicze, metod jakościowych identyfikacji zagrożeń, więcej uwagi skoncentrowane zostanie na identyfikacji ilościowej zagrożeń oraz związku zagrożenia z ryzykiem. Ten ostatni aspekt przejawia się w propozycji modelu prognostycznego pozwalającego określić prawdopodobieństwo wystąpienia zdarzenia niebezpiecznego, czyli zdarzenia równoznacznego z wystąpieniem szkody jako jednego z komponentów miary ryzyka.

2. Zagrożenie a ryzyko

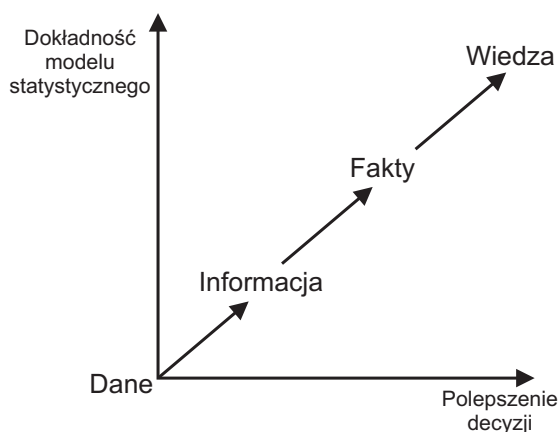
Termin zagrożenie jest niewątpliwie najczęściej używanym terminem w tekstach na tematy górnicze. Zagrożenie wybuchem, tąpnięciami czy ocena stanu zagrożeń skojarzonych to tylko nieliczne przykłady fragmentów tytułów artykułów ukazujących się w literaturze naukowej na tematy górnicze. Systematycznej klasyfikacji zagrożeń podejmował się m.in. Ryncarz [26] zaś próbę sformalizowanego opisu zagrożeń z perspektywy teorii decyzji w warunkach niepewności i ryzyka przedstawił Kortas [16].

Ryzyko i zagrożenie w ogólności odnoszą się do tego samego zjawiska naturalnego lub sztucznego wytworu jednakże treść tych pojęć jest zasadniczo odmienna, chociaż w literaturze często jest ze sobą utożsamiana [19, 28]. Zagrożenie jest stanem natury o takiej własności, która w wyobraźalnych okolicznościach może wygenerować szkodę materialną. Np. wysoka metanonośność pokładu węgla stanowi zagrożenie wyrzutem gazu i skał, pożarem, wybuchem mieszaniny gazu i powietrza czyli ogólnie stanowi potencjał do wygenerowania zdarzenia niebezpiecznego (ZN) tj. wyrzutu, wybuchu czy pożaru. Zdarzenia te (wybuch,

pożar, wyrzut) określamy terminem zdarzenia niebezpieczne (ZN), gdyż ich wystąpienie następuje zwykle w sposób niekontrolowany, nieprzewidywany i wbrew intencjom osób ingerujących w stan natury określany mianem „zagrożenie metanowe” oraz powoduje szkody materialne (uszkodzenie obudowy, zniszczenie maszyn, śmierć lub okaleczenie ludzi). Zagrożenie jako stan natury sam w sobie nie powoduje szkody tj. nie generuje ZN. Jest niejako wewnętrzną własnością rozważanego systemu, rozumianego jako świadomie i celowo wyodrębniony fragment otaczającej rzeczywistości. Pojawienie się ZN jest reakcją natury na ingerencję człowieka lub innego obiektu zewnętrznego względem obiektu określanego mianem zagrożenie.

Z kolei treść pojęcia ryzyko wyraża oczekiwany bilans świadomej ingerencji człowieka w naturę będącą w stanie zagrożenia. Tak więc bilans ten zależy nie tylko od zagrożenia samego w sobie ale również, a nawet przede wszystkim od sposobu ingerencji w stan zagrożenia. Uzasadnione jest w tym momencie założenie, że ingerencja człowieka w stan zagrożenia jest racjonalna, a miarą racjonalności jest minimalizowanie strat wywołanych tą ingerencją. Podstawą racjonalnego działania jest wiedza o środowisku, w którym działanie ma być przeprowadzone, w naszym przypadku chodzi o górotwór, a właściwie fragment górotworu wydzielony fizycznie lub myślowo do realizacji planowanych zadań (eksploatacji kopaliny). Wiedza jest tym co dobrze wiemy. Jedną z podstawowych form utylizacji posiadanej wiedzy jest jej przekazywanie innym podmiotom. Przekazywanie wiedzy jest informacją. Informację można klasyfikować, przetwarzać czy modyfikować. Surową formą informacji są dane, które same w sobie nie są wiedzą. Na drodze od surowych danych do wiedzy o analizowanym systemie pojawia się najpierw informacja, w którą przekształcają się dane jeśli okazują się one odpowiednie do rozważanego problemu decyzyjnego. Informacja z kolei staje się faktem jeśli posiadane dane ją potwierdzają. W związku z tym, że dane o badanym obiekcie/procesie mają zwykle charakter prób, dlatego też wiedza stosowana jaką uzyskujemy o badanym obiekcie tą drogą nie może być uznana za wiedzę pełną, a raczej za wiedzę o określonym statystycznym poziomie ufności.

Fakty stają się wiedzą, kiedy pozwalają skonstruować kompletny proces decyzyjny zakończony sukcesem. Rysunek 1.1 obrazuje proces wnioskowania statystycznego bazujący na danych wykorzystywanych do konstrukcji modelu dla potrzeb decyzji w warunkach niepewności. Należy sobie uświadomić, że o ile opis matematyczny zagrożenia może być nawet bardzo skomplikowany to i tak nie ma możliwości wyrażenia go w kategoriach ilościowych. Taki opis jest jedynie modelem pewnego obiektu, który konstruujemy w naszej wyobraźni na podstawie posiadanej wiedzy.



Rys. 1.1. Schemat transformacji danych w wiedzę

Model ten wygeneruje dane liczbowe, jeśli poddamy go warunkom wynikającym z planowanego i przemysłanego działania na obiekt będący w stanie zagrożenia, który ten model opisuje. Np. rozpoczęcie wykonywania wyrobiska górniczego w modelowanej partii złoża wywoła zmianę naprężeń, przepływ gazu ze złoża do przestrzeni wyrobiska i wiele innych zmian w pierwotnym stanie natury, który został zakwalifikowany do klasy obiektów określanych mianem zagrożenie.

Innymi słowy zagrożenie opisuje warunki podczas gdy dla wystąpienia ryzyka wymagana jest decyzja o podjęciu działania. Aby z kolei kwantyfikować ryzyko określonych konsekwencji podjętego działania, musimy oprócz modelu „obektu – zagrożenia” dobrze określić czasowo przestrzenny scenariusz tego działania. Tak więc z definicji ryzyko jest zawsze wyrażone liczbowo. Pytanie czy ryzyko wyrażone jest

ilościowo czy jakościowo to pytanie o wielkość błędu oszacowania ryzyka. Jeżeli błąd oszacowania ryzyka jest duży możemy ryzyko wrazić jakościowo np. „wysokie”, „średnie”, „niskie” lub „bardzo niskie”. Jako skutek niepewności taka reprezentacja ryzyka może być uznana za jakościową ocenę ryzyka, chociaż taka przybliżona klasyfikacja ma zwykle zgrubną liczbową ocenę np. 10% to „ryzyko bardzo niskie”, a 50% to średnie itp.

Jak wynika z przeglądu literatury górniczej w języku polskim, utożsamianie ryzyka z zagrożeniem zintensyfikowało się w ostatnich latach, kiedy to zaczęto częściej posługiwać się terminem ryzyko. W przeszłości, zamienne stosowanie tych terminów można było znaleźć jedynie w mniej rygorystycznych fragmentach tekstów i było spowodowane raczej pewnymi ograniczeniami języka niesformalizowanego w wyrażeniu złożonych i nieostrych sytuacji.

Utożsamianie tych pojęć w języku naukowym jest niedopuszczalne. Fakt, że są jednak często utożsamiane dowodzi, że zarówno pojęcie ryzyka jak i pojęcie zagrożenia są niewystarczająco ostro zdefiniowane. Zachodzi więc pilna potrzeba opracowania precyzyjnych definicji zagrożeń górniczych. Z uwagi na specyfikę poszczególnych zagrożeń górniczych, podejmowane są w praktyce ruchowe różne działania dostosowane do specyficznego zagrożenia, np. inne działania podejmowane są w przypadku zagrożenia pożarowego, a inne w przypadku zagrożenia wodnego. Definicja zagrożenia winna być ostra, aby spełnić rolę operacyjną tj. móc być wykorzystana w procesie tworzenia scenariuszy działań i szacowania ryzyka.

Jeśli spojrzeć na zagrożenie Z jako na obiekt w przestrzeni U zagrożeń, to można przypisać mu skończony niepusty zbiór atrybutów (cech) $C = \{c_1, \dots, c_{n_C}\}$ tj. przyporządkowań (funkcji) dla $c : U \rightarrow V_C^c$ dla $c \in C$, gdzie V_C^c jest zbiorem wartości cechy c zwanym dziedziną cechy c .

W przypadku gdy wszystkie cechy ze zbioru C przyjmują wartości rzeczywiste, tj. $c_i : U \rightarrow \mathfrak{R}$ dla $i = \{1, \dots, n_C\}$, na zagrożenia (obiekty) ze zbioru U możemy patrzeć jak na punkty $P_u = (c_1(u), c_2(u), \dots, c_{n_C}(u))$ w n_C wymiarowej przestrzeni afinicznej \mathfrak{R}^{n_C} .

Wobec tego opracowując scenariusze S_i np. prowadzenia wyrobiska górniczego w złożu z punktu A do punktu B, w którym występują liczne zagrożenia, aby dokonać analizy ryzyka musimy odwołać się do przestrzeni zagrożeń U . Jeśli nasza wiedza o przestrzeni U jest pełna to mamy do czynienia z przypadkiem pewności i brakiem ryzyka w podejmowaniu decyzji. Z kolei gdy nic nie wiemy o przestrzeni U mamy do czynienia z pełną niewiedzą, a więc z przypadkiem niepewności, w którym nie możemy określić prawdopodobieństwa jakiegokolwiek zdarzenia, a tym samym określić ryzyka związanego z dokonanym wyborem działania. Niektórzy autorzy [3] twierdzą, iż w takim przypadku, tj. pełnej niepewności uzasadnione jest przyjęcie równomiernego rozkładu prawdopodobieństwa zdarzeń. Taka postawa wydaje się być niewłaściwa, gdyż posiadanie wiedzy o rozkładzie prawdopodobieństwa zdarzeń pozwala na wyznaczenia ryzyka z tym zdarzeniem związanego, a tym samym przeczy postulowanej sytuacji pełnej niepewności. Niezależnie od różnych niuansów terminologicznych pewnym jest to, że jeśli zagrożenie nie zostanie zidentyfikowane, nie można ocenić ryzyka, a tym samym nim zarządzać.

3. Przegląd podstawowych metod jakościowej identyfikacji zagrożeń

Istnieje obecnie wiele metod identyfikacji zagrożeń (IZ), stosujących sformalizowane techniki o różnym stopniu zaawansowania. Nie można ustalić tylko jednego kryterium dla optymalnego wyboru jednej z tych metod. Wybór może zależeć od wielu czynników obiektywnych związanych z przeprowadzoną analizą (celem, zakresem), wyróżniających określone cechy metod IZ jak również od preferencji zespołu przeprowadzającego analizę, jego doświadczenia i dostępności analiz analogicznych obiektów (zwanymi czasami obiektami odniesienia). Najczęściej dla zapewnienia kompletności listy źródeł zagrożenia, a w konsekwencji listy Zdarzeń Początkujących (ZP), przeprowadza się IZ za pomocą kilku wybranych metod. Należy dobrze zrozumieć typ i naturę groźnych sytuacji związanych z eksploatacją obiektu oraz znać warunki/zdarzenia, które mogą prowadzić do takiej sytuacji. Bez takiego zrozumienia przeprowadzenia ocen ilościowych zagrożenia i wykorzystanie ich w praktycznych działaniach służących podniesieniu poziomu bezpieczeństwa obiektu nie jest możliwe. IZ jest kluczowym elementem dla osiągnięcia tego celu.

Znane metody IZ różnią się znacznie między sobą co do poziomu zaawansowania i przyjętego stopnia szczegółowości analiz – od technik opartych na prostej liście kontrolnej do szczegółowych diagramów logicznych. Metody te znajdują zastosowanie w fazach projektowania, budowy i eksploatacji obiektu. Dla różnych faz istnienia obiektu istnieją różne optymalne metody analiz. Podstawowe sformalizowane techniki identyfikacji źródeł zagrożeń wiążą się z metodykami ocen zagrożeń [20].

Identyfikacja zagrożeń poprzedza wszelkie inne prace związane z zarządzaniem bezpieczeństwem systemu. Używa się w tym celu wielu technik. Na rynku znajdują się liczne produkty ułatwiające przeprowadzanie identyfikacji, w tym także programy komputerowe, pozwalające na lepsze usystematyzowanie prac związanych z identyfikacją. Podstawowe techniki można podzielić na kilka klas.

Są to:

- metody porównawcze wykorzystujące wiedzę z analiz bezpieczeństwa podobnych obiektów. Należą do nich metody indeksowe, listy kontrolne,
- metody przeglądowe ułatwiające systematyczne przestudiowanie wszystkich potencjalnych, źródeł zagrożeń. Wśród tych metod najbardziej znana to HAZOP. Należą do nich także metody PHA, FMEA, What-If,
- metody analityczne, takie jak FTA, ETA, CCA pozwalają zarówno na wykrycie źródeł zagrożeń, jak i na ocenę scenariuszy awaryjnych. Ze względu na wykorzystywanie precyzyjnych zależności logicznych zachodzących w analizowanych sytuacjach, pozwalają na numeryczne wyznaczanie wielkości ryzyka.

Wybór jednego z dostępnych sposobu identyfikacji zagrożeń zależy od wielu czynników. Są nimi; cel analizy, dostępne informacje, doświadczenie ekspertów, wymagany czas przeprowadzenia analizy, czy w końcu tradycja i preferencje wykonawców analizy. Jak już wspomniano analizy zawsze wykonywane są przez interdyscyplinarny zespół. Na jego czele stoi lider, odpowiedzialny za przygotowanie materiałów do analizy, za przebieg analizy oraz za opracowanie wyników analizy. Lider przede wszystkim powinien znać stosowane techniki analizy, pozwala to na znaczne przyśpieszenie jej wykonywania, a co za tym idzie redukcję kosztów.

3.1. Metoda List Kontrolnych (ang. *Checklist Analysis*)

Metoda List Kontrolnych polega na użyciu przez analityka odpowiednio przygotowanego kwestionariusza (bądź kilku kwestionariuszy) dzięki któremu jest w stanie odpowiedzieć na pytania identyfikujące znane rodzaje zagrożeń i potencjalnie niebezpieczne sytuacje związane ze stosowanymi procesami i operacjami. Najczęściej opiera się na doświadczeniu wynikającym z dotychczas przeprowadzonych analiz identycznych lub zbliżonych systemów. Pozwala na wczesne wykrycie i przeprowadzenie akcji zapobiegających wystąpieniu ZN (awarii) mających miejsce w podobnych systemach. Warunki analizy zależą w dużym stopniu od osobistego doświadczenia i wiedzy autorów listy oraz zrozumienia specyfiki badanego obiektu. Czynniki te determinują wybór odpowiedzi „tak” lub „nie” na pytania listy sprawdzającej. Prawidłowo wykonany przegląd metodą list kontrolnych dostarcza pewności, że analizowany system odpowiada akceptowanym standardom lub pozwala na określenie fragmentów wymagających dalszych badań.

Metoda list kontrolnych składa się z trzech głównych etapów: 1 – wyboru i przygotowania odpowiedniej listy kontrolnej, 2 – przeglądu, 3 – przygotowania raportu.

Tab. 3.1. Fragment przykładowej listy kontrolnej identyfikującej zagrożenia w zakładzie górniczym

Systematyka zagrożeń		Pytania pozwalające na zidentyfikowanie zagrożenia	Odpowiedzi	
			Tak	Nie
1	2	3	4	5
Zagrożenia geologiczno-górnice	Lokalne zagrożenia geotechniczne	Czy występuje zakleszczanie wiertła?		
		Czy występuje utrata stateczności ociosów wyrobiska?		
		Czy występuje trwała deformacja obudowy wyrobiska?		
	Lokalne zagrożenia wodne	Czy występuje wypiętrzanie spągu wyrobiska?		
		Czy występuje zawodniony spąg?		
		Czy występują wycieki wody z ociosu wyrobiska?		
Zagrożenia ergonomiczne	Warunki klimatyczne	Czy występuje zbyt duża prędkość powietrza		
		Czy wentylacja jest niesprawna?		
		Czy występuje zbyt wysoka temperatura?		
Inne....		Czy występuje zbyt niska temperatura?		

Więcej szczegółów na ten temat można znaleźć w pracy [17].

3.2. Wstępna Analiza Zagrożeń (ang. *Preliminary Hazard Analysis*)

Wstępna Analiza Zagrożenia (PHA) jest metodą jakościową koncentrującą się na identyfikacji materiałów niebezpiecznych i głównych elementów systemu. Jest stosowana najczęściej we wstępnej fazie opracowywania projektu systemu. Metoda polega na stworzeniu listy zagrożeń adekwatnej do poziomu szczegółowości dostępnych informacji. Proces analizy zagrożenia jest przeprowadzany poprzez systematyczny przegląd dostępnej dokumentacji projektowej. Analizy dokonuje zespół, w skład którego, oprócz kierownika mającego doświadczenie w analizach PHA, mogą wchodzić: projektanci, technolodzy, mechanicy, automatycy, operatorzy. Dla każdego wybranego elementu systemu czy materiału niebezpiecznego ustala się wszystkie potencjalne zagrożenia. Dla każdego z nich określa się możliwe przyczyny i skutki oraz konstruuje tabelę ryzyka, w której podaje się oszacowane prawdopodobieństwo wystąpienia skutków i ich skalę oraz ryzyko. Przykładową tabelę ryzyka pokazano na rysunku 3.1.

		Skutki				
Prawdopodobieństwo		1	2	3	4	5
			2	4	5	6
		3	5	6	7	8
		4	6	7	8	9
		5	7	8	9	10

	Ryzyko nieakceptowalne			Ryzyko tolerowane			Ryzyko akceptowalne
--	------------------------	--	--	-------------------	--	--	---------------------

Skala prawdopodobieństwa	Skala skutków
1 – bardzo duże prawdopodobieństwo	1 – katastroficzne
2 – duże prawdopodobieństwo	2 – duże
3 – średnie prawdopodobieństwo	3 – średnie
4 – małe prawdopodobieństwo	4 – małe
5 – bardzo małe prawdopodobieństwo	5 – bardzo małe

Rys. 3.1. Tabela ryzyka dla analiz PHA

Na podstawie wyników analizy są formułowane wytyczne do następnych faz projektowania, dotyczące redukcji poziomu zagrożenia lub eliminacji wykrytych źródeł tego zagrożenia.

3.3. Analiza „Co, Jeżeli” (ang. *What if Analysis*)

Analiza „Co Jeżeli” jest kreatywnym sposobem testowania procesu lub operacji opartym na metodzie „burzy mózgów”. Głównym zadaniem Analizy „Co Jeżeli” jest szczegółowa ocena wpływu możliwych odstępstw, sformułowanych jako pytanie: co się stanie jeżeli..., od założeń projektowych, konstrukcyjnych i procedur obsługi na podstawie zdarzeń o groźnych skutkach. Metoda ta identyfikuje zagrożenia, skutki i potencjalne metody redukcji zagrożenia. Użycie metody „Co Jeżeli” jest korzystne ze względu na jej proste wykonanie, dużą efektywność w stosunku do poniesionych kosztów, a także możliwość identyfikowania scenariuszy zagrożeń. Analiza „Co Jeżeli” wykonuje się w następujących etapach:

- Zdefiniowanie celu i zakresu analizy
- Zebranie informacji o badanym systemie
- Wytypowanie zespołu roboczego
- Przeprowadzenie analizy
- Opracowanie i przedstawienie wyników analizy

Pierwsze trzy etapy mają charakter analogiczny do analizy PHA.

Przygotowanie. Etap ten obejmuje zapoznanie z opisem procesu, schematami i procedurami operacyjnymi. Jeśli analiza dotyczy działającego systemu przydatne mogą się okazać rozmowy z personelem operacyjnym, ekipami technicznymi i służbami awaryjnymi. Ostatnim krokiem jest zaproponowanie wstępnych pytań „Co-Jeżeli”, za pomocą których kierownik analizy inicjuje spotkanie zespołu.

Przegląd. Proces analiz z zastosowaniem tej metody rozpoczyna się od przedstawienia systemu przez personel posiadający wiedzę na jej temat. Następnym krokiem jest stawianie pytań dotyczących wpływu możliwych odstępstw od założeń technologicznych, przewidywanie odpowiedzi obiektu i proponowanie działań zaradczych.

Dokumentacja. Analiza „Co, Jeżeli” jest często dokumentowana w postaci arkuszy jak niżej:

Nazwa.....		Data.....	
Nr dokumentacji.....		Członkowie zespołu.....	
Co-Jeżeli	Skutek/zagrożenie	Środki zaradcze	Zalecenia

Rys. 3.2. Fragment kwestionariusza w metodzie „Co jeżeli”

3.4. Studium Zagrożeń i Zdolności Działania (ang. *Hazard and Operability Study*)

Technika Hazard and Operability Study (HAZOP) – Studium Zagrożenia i Zdolności Działania opisana jest szczegółowo w szeregu publikacji [7, 20]. Metoda ta polega na systematycznym przeglądzie założeń projektowych i procesu technologicznego pod kątem możliwych odchyłeń od przyjętych parametrów. Służy ona głównie do określenia prawdopodobnych zdarzeń niebezpiecznych (zagrożających zdrowiu i życiu ludzkiemu, środowisku naturalnemu, powodujących uszkodzenia urządzeń technicznych) i problemów technologicznych (powodujących obniżenie efektywności procesu czy spadek produkcji).

Studium HAZOP prowadzone jest w formie sesji z udziałem zespołu inżynierów, technologów, projektantów, specjalistów urządzeń kontrolno-pomiarowych oraz innych osób znających analizowany proces. Sesja ma charakter „burzy mózgów” kierowanej przez przewodniczącego zespołu mającego doświadczenie w zakresie metod określania zagrożeń. Za pomocą zestawu tzw. słów przewodnich zespół systematycznie analizuje poszczególne elementy systemu korzystając ze schematu technologicznego. Słowa przewodnie – brak, nadmiar, więcej, mniej, odwrotnie niż, itp. – charakteryzują odchylenia od założonych parametrów np. przepływu, koncentracji, naprężeń, ciśnienia, temperatury w istotnych punktach systemu. Zespół dokonuje oceny prawdopodobieństwa wystąpienia odchylenia i w przypadku znalezienia realistycznych przyczyn (tak zwanych zdarzeń początkujących) określa zagrożenia przez nie spowodowane. Następnie ocenia się, czy stosowane zabezpieczenia (sprzętowe i proceduralne) są wystarczające w stosunku do efektów wywołanych niepożądanymi zdarzeniami i w razie potrzeby wprowadza się własne zalecenia. Mogą nimi być na przykład sugestie dotyczące właściwych rozwiązań czy opinie o konieczności przeprowadzenia dodatkowych badań nad skutecznością proponowanych środków.

HAZOP (*Hazard and Operability Study*) jest jedną z bardziej uniwersalnych metod analitycznych stosowanych do określania możliwości wystąpienia zagrożeń w zakładach przemysłowych. Jej uniwersalność polega na tym, że można ją stosować na każdym etapie konstruowania czy eksploatacji technologii. Zasadniczymi etapami są:

- projektowanie,
- konstruowanie,
- przegląd komisyjny,
- rozruch,
- normalna eksploatacja,
- modyfikowanie,
- przegląd,
- testowanie,
- wyłączenie z ruchu (nagły wypadek, planowe),
- postój.

Metoda HAZOP zalecana jest szczególnie przy projektowaniu nowo powstających zakładów, kiedy projekt jest już dobrze udokumentowany oraz przy zmianie planów istniejących zakładów lub gdy nie

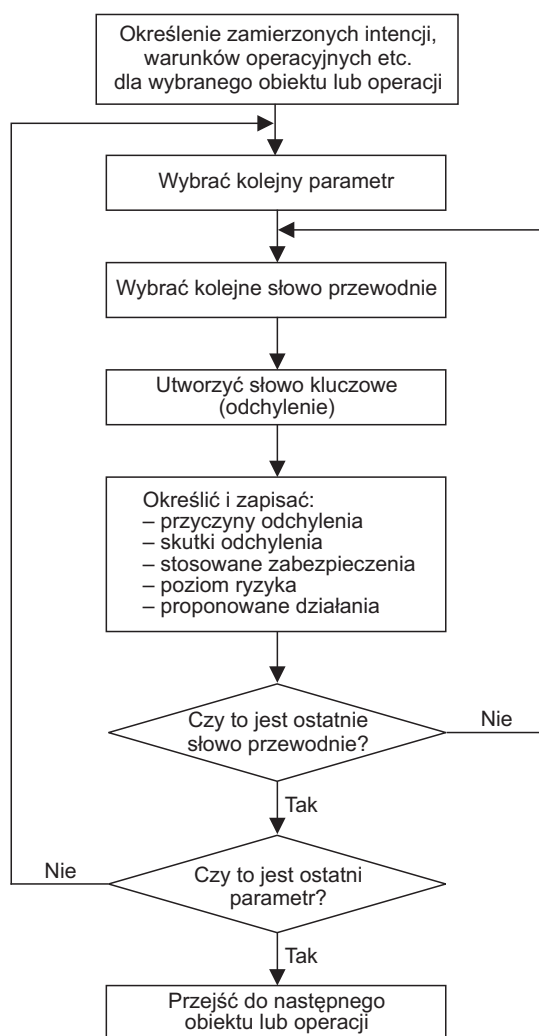
zostały jeszcze przeprowadzone poprzednio analizy HAZOP. Jej celem jest przeprowadzenie badań nad możliwościami odchylenia systemu od założeń projektowych i identyfikacja zagrożeń lub zakłóceń zdolności produkcyjnych. Definicja metody HAZOP szczególny nacisk kładzie na jej charakter zespołowy. O ile w pozostałych technikach służących do analizy stanu bezpieczeństwa procesowego całość prac może wykonać praktycznie jedna osoba, o tyle sesja HAZOP wymaga uczestnictwa kilku specjalistów z różnych dziedzin związanych z analizowanym procesem. Zespół ponadto musi być kierowany przez przewodniczącego znającego zasady prowadzenia analizy i potrafiącego zastosować je w praktyce. Systematyczny przegląd systemu przy korzystaniu z maksymalnej liczby wariantów parametr-słowo przewodnie-odchylenie stanowi podstawę do stwierdzenia o właściwym i kompletnym przeprowadzeniu analiza HAZOP, została przeprowadzona właściwie w sposób całościowy.

Charakterystyczny dla HAZOP sposób działania polega na prowadzonych przez multidyscyplinary zespół poszukiwaniach odchylenia od zamierzeń projektowych w szeregu spotkań prowadzonych metodą „burzy mózgów”. Metoda ta stymuluje aktywność członków zespołu i pomaga w tworzeniu pomysłów, opiera się ona na założeniu, że wysiłek grupowy jest efektywniejszy niż wysiłek poszczególnych członków. Doświadczony kierownik systematycznie prowadzi zespół poprzez wszystkie elementy projektu zgodnie ze strukturą analizy uwarunkowaną przez słowa przewodnie, których stosowanie gwarantuje przegląd projektu w możliwie pełnym zakresie. Odchylenia od zamierzeń projektowych są generowane przez zastosowanie słów przewodnich w opisie parametrów procesu we wszystkich węzłach systemu. Dla każdego odchylenia, zespół identyfikuje wszystkie wiarygodne przyczyny i znaczące skutki zdarzeń będących ich efektem. Wyniki analizy zawierają opis zagrożeń i problemów związanych z ciągłością pracy oraz zalecenia dotyczące możliwych do przeprowadzenia zmian w projekcie, procedurach itp. służących poprawie stanu bezpieczeństwa jak również zalecenie przeprowadzenia studiów uzupełniających.

Proces analizy HAZOP można podzielić na następujące etapy:

Proces analizy HAZOP można podzielić na następujące etapy:

- 1) zdefiniowanie studium
 - cele i zakres działań;
- 2) dobór zespołu
 - przewodniczący, sekretarz, członkowie;
- 3) przygotowanie do studium
 - zdobywanie i przetwarzanie informacji,
 - zaplanowanie harmonogramu studium,
 - zorganizowanie spotkań;
- 4) przeprowadzenie studium
 - przegląd projektu procesowego i prowadzonych operacji,
 - przedyskutowanie planu i celów studium,
 - przegląd danych o instalacjach i wyposażeniu,
 - przeprowadzenie analizy HAZOP;
- 5) sporządzenie raportów



Rys. 3.3. Schemat postępowania w metodzie HAZOP

3.5. Analiza Sposobów Uszkodzenia i Skutków (ang. *Failure Modes and Effects Analysis*)

Analiza Sposobów Uszkodzenia i Skutków (FMEA) jest usystematyzowanym tablicowaniem elementów systemów, sprzętu, ich możliwych sposobów uszkodzenia i skutków dla innych elementów, systemów lub stanu całego obiektu. FMEA wymaga dobrej znajomości powiązań funkcjonalnych elementów i systemów. Bezpośrednio nie uzyskuje się informacji o kombinacjach uszkodzeń sprzętu prowadzących do wypadku.

Procedura analiz FMEA składa się z trzech etapów: 1 – przygotowania, 2 – analiz, 3 – opracowania dokumentacji.

Przygotowanie. Na tym etapie identyfikuje się zakres analiz i warunki, jakie należy spełnić, aby je pomyślnie wykonać. Definicja problemu wymaga podania poziomu szczegółowości analiz i określenia granic analiz. Szczegółowość analiz zależy od rodzaju analizowanego obiektu. Jeśli jest analizowany cały zakład FMEA, koncentruje się na sposobach uszkodzeń poszczególnych systemów a nie na pojedynczych elementach. Jeśli jest analizowany pojedynczy system FMEA, koncentruje się na uszkodzeniach poszczególnych elementów. Definicja granic analiz obejmuje:

- identyfikację systemów które są przedmiotem analiz;
- określenie fizycznych granic systemu i powiązań z innymi systemami i procesami;
- określenie analitycznych granic systemu, tzn. rodzajów uszkodzeń, skutków działań operacyjnych, systemów bezpieczeństwa itd., które nie są brane pod uwagę;
- zebranie materiałów dotyczących wyposażenia i sposobu jego współdziałania z systemem.

Przegląd. Analiza FMEA odbywa się w formie narady w sposób systematyczny, eliminujący możliwe przeoczenia i zapewniający kompletność analiz. W procesie analiz powstaje arkusz zawierający listę urządzeń wraz z odpowiednim oznaczeniem projektowym, opisy urządzeń, rodzaje możliwych uszkodzeń, skutki, środki bezpieczeństwa i działania zaradcze.

Dokumentacja. Dokumentacją analiz FMEA jest stabilizowany raport opisujący skutki uszkodzeń sprzętu na działanie innych urządzeń i systemu.

Tab. 3.2. Wzór formularza do analiz FMEA

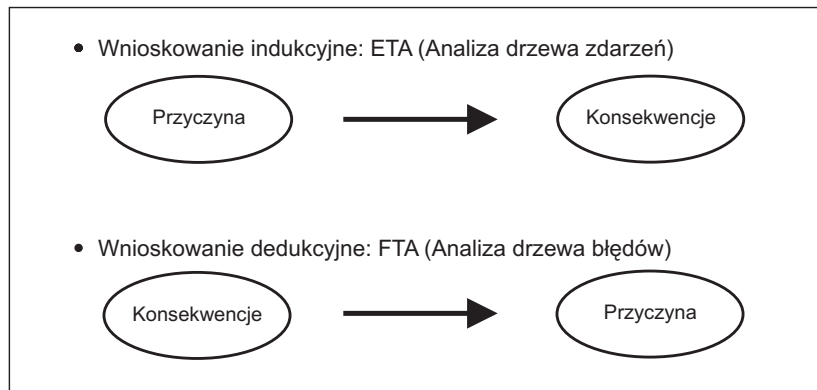
Nr	Identyfikacja	Opis	Rodzaj uszkodzenia	Skutek	Środki bezpieczeństwa	Działania

4. Ilościowa identyfikacja zagrożeń

Prawdopodobieństwo wystąpienia określonego rodzaju zdarzenia w wyniku zajścia określonego scenariusza awaryjnego można wyznaczyć na dwa sposoby: wykorzystać dane historyczne dotyczące analogicznych obiektu, jego podsystemów i elementów lub zastosować odpowiednie modele obliczeniowe i sformalizowane techniki analiz takie jak drzewa zdarzeń i drzewa błędów (rys. 4.1).

Tutaj zatrzymamy się przez chwilę na drugim z wymienionych wyżej podejść, które wiąże się bezpośrednio z zagadnieniem teorii niezawodności systemów człowiek-obiekt techniczny.

Analiza Drzew Zdarzeń (*Event Tree Analysis* – ETA) rozpatruje drogę od zdarzenia początkującego do końcowego ze szczególnym uwzględnieniem momentów mających decydujące znaczenie dla stanu obiektu. Technika ta ma charakter dedukcyjny. Z kolei drzewo błędów (*Fault Tree* – FT) jest modelem określającym logiczne związki pomiędzy uszkodzeniami elementarnych składowych systemu, błędami obsługi a zajściem określonego zdarzenia jednoznacznego z niewypełnieniem odpowiedniej funkcji przez system. Analiza Drzew Błędów (*Fault Tree Analysis* – FTA) ma naturę indukcyjną.



Rys. 4.1. Natura logiczna analizy drzewa zdarzeń (ETA) i drzewa błędów (FTA)

4.1. Analiza Drzew Zdarzeń (ang. *Event Tree Analysis*)

Analiza Drzew Zdarzeń (ETA) rozpatruje drogę od zdarzenia początkującego do końcowego ze szczególnym uwzględnieniem momentów mających decydujące znaczenie na stan obiektu. W odróżnieniu od analiz FTA, które mają naturę dedukcyjną, analiza ETA ma charakter indukcyjny.

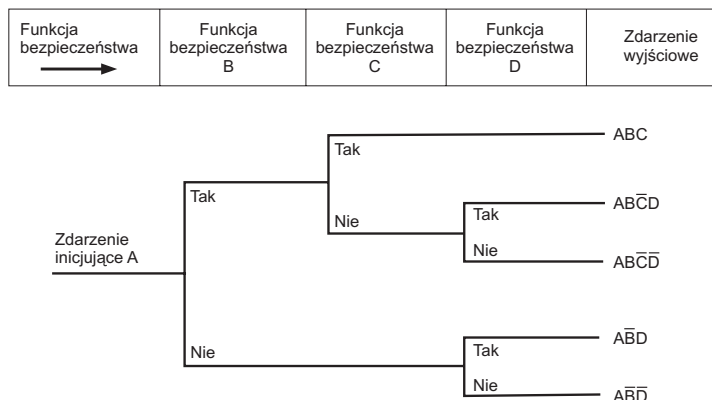
W wielu sytuacjach pojedyncze zdarzenie może prowadzić do wielu różnorodnych następstw w zależności od sprawności lub niesprawności elementów/systemów/działań operatorskich przewidzianych do opanowania tego zdarzenia. Kombinacja zdarzenia początkującego i tych sprawności/niesprawności definiuje poszczególne ciągi zdarzeń awaryjnych. ETA jest podstawową metodą tworzenia probabilistycznego modelu obiektu do analiz zagrożenia. Wyróżnia się dwie formy ETA: przedwypadkowa i powypadkowa. Przedwypadkowa może służyć do ustalenia zbiorów zdarzeń początkujących i oceny prawdopodobieństwa ich zajścia. Powypadkowa – do analizy zaistniałej awarii i identyfikacji niedoskonałości funkcjonalnej systemów bezpieczeństwa.

Procedura analiz ETA składa się z sześciu głównych etapów:

- identyfikacji zdarzenia inicjującego, które może doprowadzić do założonej awarii;
- identyfikacji funkcji bezpieczeństwa, przewidzianych do łagodzenia skutków zdarzenia inicjującego;
- konstrukcji drzewa zdarzeń;
- opisu wynikających z konstrukcji drzewa sekwencji awaryjnych;
- wyznaczenia minimalnych przekrojów drzewa
- opracowania dokumentacji.

Drzewo zdarzeń przedstawia graficznie chronologiczny rozwój awarii. Przykładowe drzewo zdarzeń ze zdarzeniem inicjującym \bar{A} i funkcjami bezpieczeństwa B, C i D pokazano na rysunku 4.2.

Każda funkcja bezpieczeństwa ma dwa stany – sukces lub porażkę. Taka kwantyfikacja prowadzi do wyznaczenia sekwencji awaryjnych, które dla omawianego przykładu są następujące: \bar{A}



Rys. 4.2. Drzewo zdarzeń

gdzie: \bar{A} oznacza wystąpienie zdarzenia inicjującego, a następnie wypełnienie (B, C, D), bądź nie, funkcji bezpieczeństwa.



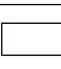

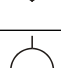
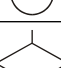
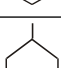
Oszacowanie wystąpienia każdej sekwencji awaryjnej opiera się na wyznaczeniu prawdopodobieństwa warunkowego dla każdej funkcji bezpieczeństwa przy warunku że zaistniało zdarzenie bezpośrednio poprzedzające. Prawdopodobieństwa dla każdej gałęzi muszą sumować się do jedności. Źródłem prawdopodobieństw warunkowych mogą być dane historyczne, dane z podobnych instalacji lub oceny ekspertów. Najpewniejszym oszacowaniem jest jednak konstruowanie i analiza ilościowa drzew uszkodzeń dla każdej gałęzi drzewa zdarzeń w przypadku systemów bezpieczeństwa o dużym stopniu komplikacji. Zdarzeniem szczytowym dla takiego drzewa uszkodzeń jest niewypełnienie funkcji bezpieczeństwa przez system.

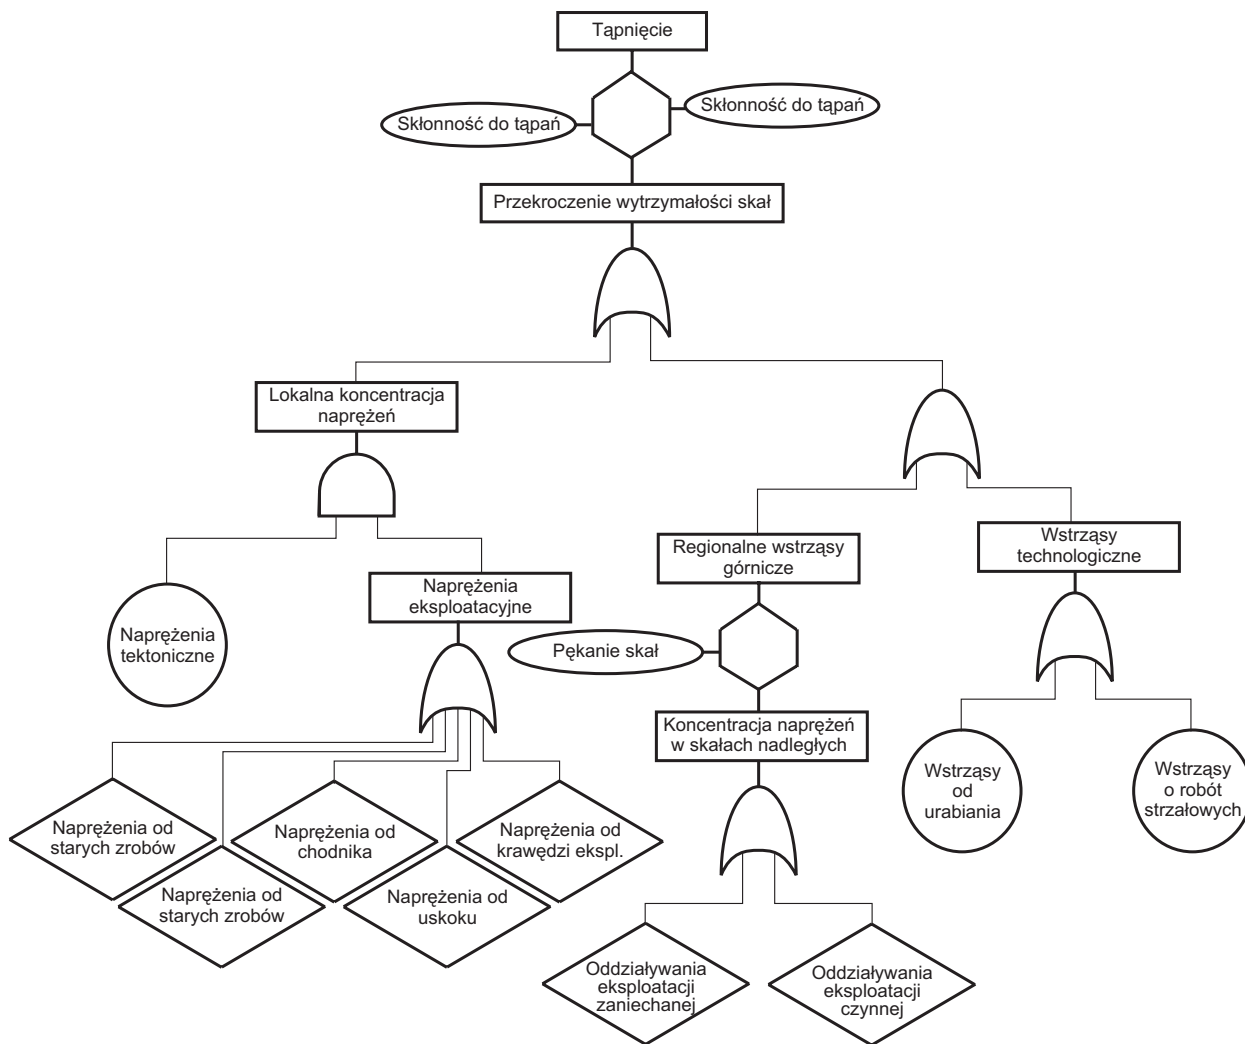
4.2. Analiza Drzewa Błędów (ang. *Fault Tree Analysis*)

Analiza Drzewa Błędów (FTA) jest jedną z częściej stosowanych metod analiz niezawodności systemów. Czasami służy ona również do identyfikacji i oceny prawdopodobieństwa zdarzeń początkujących. Polega ona na określeniu powiązań logicznych pomiędzy przyczynami – tzw. zdarzeniami elementarnymi (awarią pompy, wadliwym zadziałaniem przełącznika, nieprawidłowym działaniem operatora) a ich skutkami – zdefiniowanymi przez analityka stanami odbiegającymi od założonej normy (niesprawnością systemu, wyciekiem substancji, eksplozją, brakiem odprowadzania ciepła). O ile w poszukiwaniu zdarzeń elementarnych FTA zbliżona jest do metody HAZOP, o tyle w ich ocenie jest metodą ilościową. Korzysta z danych niezawodnościowych dotyczących urządzeń mechanicznych, elektrycznych, aparatury kontrolno-pomiarowej, danych o wytrzymałości skał, zbiorników i rur oraz innych informacji opisujących prawdopodobieństwo uszkodzenia dowolnego elementu wchodzącego w skład systemu i wpływającego na jej funkcjonowanie. Nazwa metody związana jest z jej postacią graficzną: stan awaryjny – zdarzenie szczytowe połączone jest „gałęziami” wraz z odpowiednimi logicznymi bramkami wyboru ze zdarzeniami pośrednimi i elementarnymi nie mającymi dalszego rozwinięcia. FTA służy do ilościowej oceny prawdopodobnej częstotliwości występowania zdarzeń niepożądanych w systemach składających się z szeregu elementów o dającej się określić niezawodności. Polega na:

- zdefiniowaniu zdarzenia szczytowego (niesprawności systemu, zdarzenia początkującego),
- ustaleniu hierarchicznej struktury drzewa uszkodzeń (zdarzenia pośrednie),
- skonstruowaniu drzewa uszkodzeń, polegającego na powiązaniu zdarzeń logicznymi bramkami wyboru,
- określeniu zdarzeń podstawowych wiodących do zdarzenia szczytowego,
- określeniu prawdopodobieństwa zajścia zdarzeń początkujących,
- wyznaczeniu „minimalnych przekrojów drzewa” tj. minimalnych zbiorów zdarzeń elementarnych prowadzących do zdarzenia szczytowego,
- obliczeniu prawdopodobieństwa zajścia zdarzenia szczytowego,
- analizie wyników pod kątem wyznaczenia dominujących zdarzeń elementarnych,
- analizie czułości polegającej na sprawdzeniu jak zmiana prawdopodobieństwa uszkodzenia jednego elementu ze zbioru przekrojów minimalnych wpływa na prawdopodobieństwo wystąpienia zdarzenia szczytowego.

Tab. 4.1. Zestawienie wybranych symboli graficznych

	Bramka „I”	– Zdarzenie na wyjściu bramki zachodzi tylko wtedy, gdy wszystkie zdarzenia stanowiące wejścia do bramki zachodzą jednocześnie.
	Bramka „LUB”	– Zdarzenie na wyjściu bramki zachodzi, jeżeli zachodzi jedno lub więcej zdarzeń stanowiących wejścia do bramki.
	Bramka „SPECJALNA”	– Zdarzenie wyjściowe zachodzi w sytuacji określonej przez funkcję logiczną podaną przez użytkownika / z prawej strony bramki/
	Bramka „ZAKAZ”	– Zdarzenie wyjściowe zachodzi w wyniku pojedynczego zdarzenia wejściowego i spełnienia dodatkowego warunku /podanego na zewnątrz bramki, jako tzw. zdarzenie warunkujące/
	Zdarzenie Pierwotne	– Zdarzenie nie wymagające dalszego rozwijania
	Zdarzenie Nierozwinięte	– Zdarzenie, które nie jest dalej rozwijane ze względu na małe znaczenie tego zdarzenia lub brak dostatecznych informacji
	Zdarzenie zewnętrzne	– Zdarzenie, które zwykle w normalnych warunkach zachodzi




Rys. 4.3. Przykładowe drzewo błędów dla zdarzenia „Tapnięcie” [19]

5. Koncepcja przyczynowo-skutkowego modelu predykcji wystąpienia zdarzenia niebezpiecznego (ZN)

5.1. Kilka uwag na temat modelowania zdarzeń niebezpiecznych

Istnieje wiele naturalnych zagrożeń w górotworze, które mogą generować wystąpienie zdarzenia niebezpiecznego [26]. Przez zdarzenie niebezpieczne rozumiemy, zdarzenie którego zajście powoduje szkody materialne, przyjmując niejednokrotnie rozmiary katastroficzne (liczne ofiary w ludziach i/lub poważne straty w mieniu). Istnieje zgodność co do tego, że naturalne zdarzenia niebezpieczne w górnictwie takie jak np. wyrzut skalno-gazowy, tąpnięcie, wybuch pyłu czy pożar są złożonymi zjawiskami, którym zwykle stowarzyszą skomplikowane procesy fizyczno-chemiczne. W dalszym ciągu dla uproszczenia używamy skrótowo ZN na określenie rozważanego dalej zdarzenia niebezpiecznego jako zdarzenia uwarunkowanego wieloma zmiennymi. Złożoność ZN utrudnia wyjaśnienie ich mechanizmu i uzasadnia różne podejścia badawcze zmierzające do przewidywania ich wystąpienia. Np. w terminologii teorii systemów [13], ZN jest złożonym systemem, który schematycznie można przedstawić jak na rysunku 5.1.



Rys. 5.1. Schemat relacji przyczyna (P)-skutek (S)

W zależności od dziedziny zastosowań teorii systemów, wektor P nazywany bywa wzbudzeniem, wejściem lub przyczyną, wektor S przyjmuje określenia reakcja, wyjście lub skutek. Wektor Z oznacza schematycznie zakłócenia. W przypadku dużej złożoności systemu i niewiedzy o jego mechanizmie, stosuje się koncepcję tzw. „czarnej skrzynki” [2]. Znajomość wektorów P , S i Z oraz pewne założenia o wnętrzu skrzynki, tj. operatorze przejścia, prowadzi do jego identyfikacji [29], tj. wybrania „najlepszego” modelu z pewnej klasy. Głównym elementem procesu identyfikacji jest tzw. eksperyment identyfikacyjny, w wyniku którego generuje się P i S i identyfikuje się system.

W teorii identyfikacji, np. [8], i teorii eksperymentu m.in. [24], rozróżnia się tzw. eksperyment aktywny, tj. taki, na którego przebieg ma wpływ eksperymentator oraz tzw. eksperyment pasywny, w którym rola eksperymentatora ogranicza się jedynie do obserwacji systemu. Obserwacje odnoszą się do większości zjawisk naturalnych (systemów naturalnych) w astronomii, ekologii czy geologii. Do nich należy zaliczyć również ZN.

Przeprowadzenie serii eksperymentów ZN w warunkach naturalnych, jak wykazano w pracy [9], wydaje się mało realne ze względu na trudności techniczne i koszty. Staje więc pod znakiem zapytania możliwość wiarygodnej weryfikacji opisów teoretycznych mechanizmu ZN w sensie ich przydatności do celów praktycznych. W praktyce kopalnianej natomiast głównym problemem jest prognoza ZN.

Przewidywanie wystąpienia ZN jest związane z ryzykiem, które maleje wraz ze wzrostem ilości informacji, jaką dysponujemy o środowisku, w którym ZN prognozujemy. Jedynym źródłem tej informacji są pomiary kopalniane takich wielkości, które na danym etapie wiedzy o ZN mają bezpośredni związek z ich występowaniem. Efektywność wykorzystania tej informacji wzrasta wraz z posiadaniem ogólnego modelu zjawiska. Wobec braku takiego modelu dla wielu ZN ich prognoza opiera się zwykle na doświadczeniu kadry inżynierskiej oraz różnych jakościowych kryteriów [30].

Charakteryzacja

Zadaniem modelowania jest zbudowanie systemu definiowanego jako dowolny zbiór elementów dowolnej natury, z których każdy pozostaje w pewnej relacji do pozostałych. Jakikolwiek element, który nie należy do systemu należy do jego otoczenia i jest rolą badacza określenie, które elementy określają system. W zależności od granicy pomiędzy systemem a jego otoczeniem system może być opisany za pomocą różnych relacji typu wejście-wyjście. Również złożę z jego fizycznymi i chemicznymi zjawiskami jakie mogą towarzyszyć ZN jako jego elementy są zgodne z powyższą definicją.

W modelowaniu matematycznym ZN takich jak np. wyrzut, tąpnięcie czy wybuch ta faza wydaje się być główną przyczyną niepowodzeń. Istotą tej przyczyny jest brak dobrych definicji górniczych niebezpiecznych zdarzeń naturalnych. Charakterystyka przestrzeni przyczyn P i skutków S zawierać powinna nie tylko listę składników, ale również ich naturę, strukturę przestrzenną i wzajemne relacje pomiędzy nimi. Jak wynika z literatury w wielu przypadkach zagrożeń naturalnych występuje brak zgody co do czynników odgrywających decydującą rolę w kształtowaniu się poszczególnych zagrożeń naturalnych i w konsekwencji towarzyszących im ZN. Np. Cyrul [9] przeprowadził ankietę wśród 25 ekspertów w zakresie wyrzutów skalno-gazowych, którzy wskazywali różne dominujące czynniki w wyrzucie. W efekcie wskazano 41 mierzalnych wielkości jako przyczyn lub skutków wyrzutu.

Identyfikacja

Identyfikacja jest obszerną dziedziną nauki i w tym miejscu odwołamy się do niej jedynie w tym celu aby uzupełnić naszą dyskusję na temat modelowania ZN. Za Zadechem [31] „Identyfikacja jest określeniem, w oparciu o wejścia i wyjścia, systemu wśród specjalnej klasy systemów, dla której badany system jest ekwiwalentny”. Aby skorzystać z tej definicji Zadecha, musimy najpierw określić klasę $\{M\}$ obiektów, klasę $\{P\}$ wejść (przyczyn), klasę $\{S\}$ wyjść (skutków) i nadać znaczenia pojęciu ‘ekwiwalentny’. Elementy klasy $\{M\}$ są po prostu modelami, a pojęcie ‘ekwiwalentny’ jest zwykle określane z wykorzystaniem kryterium jakościowego, które może być wyrażone jako

$$Q = Q(s_0, s_m)$$

gdzie:

- s_0 – reakcja badanego obiektu;
- s_m – reakcja modelu.

Identyfikacja zatem zawsze polega na określeniu najlepszego modelu z danej klasy modeli w oparciu o pewne kryterium oraz informację a priori o obiekcie i dane pomiarowe z eksperymentu lub monitoringu. Z punktu widzenia ‘klasy modeli’ modele można identyfikować stosując reprezentację parametryczną lub nieparametryczną [23]. W przypadku nieparametrycznej identyfikacji systemu nie dokonuje się żadnych założeń o strukturze modelu. Taki model systemu nazywany bywa modelem „wejście-wyjście” lub „czarnej skrzynki”. Często pewna informacja a priori o systemie upoważnia do formułowania jego modelu, w którym jedynie pewne parametry są niewiadome. W takiej sytuacji mamy do czynienia z identyfikacją parametryczną.

Identyfikacja jest blisko skojarzona z eksperymentem, gdyż eksperymenty stanowią główne źródło informacji o modelowanym obiekcie. W teorii informacji [12] i w teorii eksperymentu [25] dokonuje się podziału na tzw. ‘eksperyment aktywny’, na który ma wpływ eksperymentator i tzw. eksperyment pasywny, w którym rola eksperymentatora ograniczona jest do monitorowania badanego systemu. Eksperymenty pasywne (monitoring) odnoszą się do większości zjawisk naturalnych (systemów naturalnych) w astronomii, ekologii czy geologii. ZN można również zaliczyć do takich systemów. Łatwo zauważyć, że prowadzenie eksperymentów in situ wielu ZN jest przedsięwzięciem nierealistycznym. To eliminuje możliwość identyfikacji modelu wielu z nich i tym samym czyni niemożliwą ich racjonalną predykcję. Aby ominąć te trudności należy opracowywać plany obserwacji ZN w obszarach złoza wskazujących na możliwość ich wystąpienia. Wybrane wielkości, których wpływ na dane ZN jest bezdyskusyjny powinny być monitorowane. Zbiór dostatecznej ilości danych z takich obserwacji może przy pewnych założeniach o złożu [9] być traktowany jak dane pochodzące z eksperymentu aktywnego. To może pozwolić na identyfikację modelu ZN i zastosowanie metod dobrze rozwiniętej teorii eksperymentu aktywnego.

Weryfikacja

Identyfikacja jest takim optymalnym dopasowaniem, że zachowanie obiektu i modelu powinno być tak bliskie jak to tylko możliwe. Ta bliskość zachowań, aby być określona matematycznie wymaga wprowadzenia pojęcia dystansu $D(O,M)$ między obiektem i modelem. Pojęcie ‘dystans’ przywołuje notację bliskości, która odgrywa tutaj znaczącą rolę. Można użyć różnych rodzajów dystansu; jednym z nich może być np. funkcyjne kryterium w postaci całki z kwadratu odległości pomiędzy wyjściami z obiektu i modelu

$$D(O, M) = \int_v (s_0 - s_m)^2 dx$$

W ogólności, dystans spełnia warunki:

$$D(O, M) > 0, \quad D(O, M) = 0 \quad \text{wtt} \quad O \equiv M$$

Pojęcie dystansu można utożsamić z miarą jakości predykcji. Im dystans mniejszy tym lepsza predykcja wyjścia modelu przy danym wejściu. Rozważanego dystansu nigdy nie można zredukować do zera. Nawet w przypadku teoretycznym, gdy charakteryzacja jest idealna, błędy pomiarowe powodują, że minimalny dystans jest różny od zera.

5.2. Koncepcja ZN jako zdarzenia

W praktyce mamy do czynienia z następującą sytuacją. W złożu prowadzone jest wyrobisko i nagle niespodziewanie występuje ZN. Poza pewnymi wyjątkami często nie można ustalić żadnej reguły wystąpienia ZN. ZN jako zjawisko dyskretne, można przedstawić w przestrzeni jako punkt i nazywać zdarzeniem. Jest ono obserwowanym wynikiem działania systemu naturalnego, który można wyizolować z górotworu. Każdy system można scharakteryzować za pomocą wielkości zwanych cechami systemu.

Niech F oznacza zbiór cech ZN. Zbiór ten można podzielić na dwa podzbiory:

$$F = P + S$$

gdzie:

- P – zbiór cech mierzalnych charakteryzujących system przed wystąpieniem ZN (zbiór przyczyn ZN);
- S – zbiór cech charakteryzujących system po wystąpieniu ZN (zbiór konsekwencji wystąpienia ZN).

Niektóre elementy zbioru S i P mogą mieć identyczną naturę fizykalną np. temperatura $T_p \in P$ przed wystąpieniem ZN i $T_s \in S$. Jednakże inne cechy charakteryzujące zbiory S i P mogą mieć całkiem odmienną naturę fizykalną jak np. zawartość gazu, wartość naprężeń, czy energia wstrząsów będące elementami zbioru P są zasadniczo odmienne od takich wielkości jak np. objętość gazu wyrzuconego w czasie wyrzutu, masa skał lub objętość górotworu zniszczonego w czasie tąpnięcia, które są elementami zbioru S . Wszystkie mierzalne cechy ZN są funkcjami przestrzeni i podobnie do wielu cech charakteryzujących złożę ich wartości cechuje duża losowa zmienność co powoduje, że często nadawana jest im interpretacja probabilistyczna [21]. Zgodnie z taką interpretacją środowisko ZN można scharakteryzować przez pole losowe

$$Z(x, \omega) = (S_0(x, \omega), S_1(x, \omega), \dots, S_k(x, \omega), P_1(x, \omega), \dots, P_m(x, \omega)) \quad (5.1)$$

gdzie:

- $T_s \in R^p$ – punkt w przestrzeni,
- $\omega \in \Omega$ – zdarzeniem elementarnym.

Składowa S_0 może przyjmować tylko dwie wartości: 1 – ZN wystąpiło, 0 – nie wystąpiło.

Składowe S_1, \dots, S_k wektora $S = (S_1, \dots, S_k)$ opisują obserwowalne skutki ZN. Przyjmują one niezerowe wartości wówczas, gdy $S_0 = 1$.

Składowe P_1, \dots, P_k wektora $P = (P_1, \dots, P_k)$ reprezentują obserwowalne przyczyny ZN.

Poniżej przedstawiono propozycję koncepcji prognozy ZN, opartej na danych pomiarowych. Składają się na nią dwa modele przyczynowo-skutkowe, które łącznie opisują wystąpienie ZN. Zaistnienie, bądź nie, ZN jest więc wewnętrzną własnością złoża. Zakłada się, że nie następują istotne zmiany w technice wykonywania wyrobiska. Za punkt wyjścia przyjmujemy zależność (5.1). Duża nieregularność i lokalna „przypadkowa” zmienność cech złożowych i uzasadnia podejście probabilistyczne do tych zagadnień. Wybór sposobu opisu rzeczywistości jest wyborem typu decyzyjnego [22], a nie wynikiem umotywowanej przewagi jednego sposobu nad drugim. Podobnie jest z wyborem modelu lub założeń upraszczających w modelu. Zwykle nie mamy możliwości testowania a priori tych założeń i dopiero zgodność wyników modelu z rzeczywistością jest kryterium jakości modelu i poprawności założeń.

Niech $B \subset R^p$ będzie pewnym zbiorem punktów. Wiadomo, że najlepszą (w sensie średniokwadratowym) aproksymacją składowej S_i w klasie pól losowych mierzalnych względem σ -ciała [14] $\mathfrak{S} = \sigma(P(x, \omega))$, $x \in B$, jest średnia a posteriori $E(S_i | \mathfrak{S})$. Znalezienie warunkowej wartości oczekiwanej względem σ -ciała wymaga pełnej informacji probabilistycznej. Do dyspozycji mamy tymczasem macierz Z , postaci:

$$Z = \begin{bmatrix} S_{01} & \dots & S_{0n} \\ S_{11} & \dots & S_{1n} \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ S_{k1} & \cdot & S_{kn} \\ P_{11} & \dots & P_{1n} \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ P_{m1} & \dots & P_{m1n} \end{bmatrix} = \begin{bmatrix} S_{01} & \dots & S_{0n} \\ S_1 & \dots & S_n \\ P_1 & \dots & P_n \end{bmatrix} \quad (5.2)$$

tzn. dyskretny zbiór n obserwacji $B = \{x_1, \dots, x_n\}$. Potrzebne są więc pewne założenia zawężające obszar poszukiwań (tzn. klasę \mathfrak{S}). Aby uzyskać rozsądny kompromis pomiędzy optymalnym, lecz niedostępnym, modelem a możliwym do uzyskania modelem uproszczonym musimy przyjmować pewne założenia upraszczające, których weryfikacja, o ile to będzie możliwe, będzie dokonywana w oparciu o dane eksperymentalne.

Będziemy się zajmować dwoma modelami:

Model 1 (przyczynowo-skutkowy) o postaci

$$\hat{S} = (\hat{S}_1, \dots, \hat{S}_k) = \Phi(P_1, \dots, P_n) \quad (5.3)$$

będący aproksymacją warunkowej wartości oczekiwanej $E = (S|\sigma(P_1, \dots, P_n) \wedge S_0 = 1)$ podaje zależności skutków ZN od przyczyn P_1, \dots, P_n pod warunkiem, że ZN wystąpiło.

Model 2 (przyczynowo-skutkowy) o postaci

$$\hat{S}_0 = f(P_1, \dots, P_n) \quad (5.4)$$

będący aproksymacją warunkowej wartości oczekiwanej $E = (S_0|\sigma(P_1, \dots, P_n))$ podaje prawdopodobieństwo wystąpienia ZN, gdy zaobserwowano P_1, \dots, P_n . Równania (5.3) i (5.4) umożliwiają sekwencyjne wprowadzanie danych.

Konstrukcja operacyjnych form tych modeli jest poza zasięgiem tego opracowania. Modele te w ich ogólnej formie stanowią obszar przyszłych badań dot. predykcji ZN w górotworze. Badania powinny uwzględniać dobrze przygotowany program monitoringu złoża oraz różnorodne parametryczne i nieparametryczne estymacje modelu.

5.3. Heurystyczna koncepcja prognozy ZN

Jak wiadomo w kopalniach realizowane są permanentne pomiary cech złoża zarówno jako wymóg przepisów górniczych jak również w ramach realizacji różnych projektów badawczych. Również zaistniałe w przeszłości liczne ZN były szczegółowo charakteryzowane również za pomocą cech mierzalnych. Tak więc istnieją duże zbiory danych charakteryzujące zarówno złoża jak i ZN jakie w nich wystąpiły. Większość udokumentowanych danych posiada również wartości współrzędnych przestrzennych.

Charakteryzacja P i S oraz identyfikacja Φ

Rozważmy dwa zbiory $P \subset R^m$ i $S \subset R^k$. Elementy zbiorów P i S reprezentują odpowiednio przyczyny i skutki pewnego zdarzenia (ZN). Naturalna relacja \prec częściowego porządku określona w przestrzeni R^q w następujący sposób:

$$(x_1, \dots, x_q) \prec (y_1, \dots, y_q) \Leftrightarrow \forall 1 \leq i \leq q, \quad x_i \leq y_i \quad (5.5)$$

indukuje w zbiorach P i S częściowy porządek.

Jest to relacja:

1. zwrotna:

$$\forall (x_1, \dots, x_q) \in R^q \wedge (x_1, \dots, x_q) \prec (x_1, \dots, x_q)$$

2. antysymetryczna:

$$\begin{aligned} &\forall (x_1, \dots, x_q) \in R^q \wedge (y_1, \dots, y_q) \in R^q \\ &(x_1, \dots, x_q) \prec (y_1, \dots, y_q) \wedge (y_1, \dots, y_q) \prec (x_1, \dots, x_q) \Rightarrow \\ &\Rightarrow (x_1, \dots, x_q) = (y_1, \dots, y_q) \end{aligned}$$

3. przechodnia:

$$\begin{aligned} &\forall (x_1, \dots, x_q), (y_1, \dots, y_q), (z_1, \dots, z_q) \in R^q \\ &(x_1, \dots, x_q) \prec (y_1, \dots, y_q) \wedge (y_1, \dots, y_q) \prec (z_1, \dots, z_q) \Rightarrow \\ &\Rightarrow (x_1, \dots, x_q) \prec (z_1, \dots, z_q) \end{aligned}$$

lecz nie jest to relacja spójna, gdyż

$$\begin{aligned} & \exists (x_1, \dots, x_q), (y_1, \dots, y_q) \in R^q \\ & \neg(x_1, \dots, x_q) \prec (y_1, \dots, y_q) \wedge \neg(y_1, \dots, y_q) \prec (x_1, \dots, x_q) \end{aligned}$$

gdzie:

– oznacza negację, czyli istnieją elementy „nieporównywalne” w sensie relacji \prec .

Zakładamy, że w zbiorze S jest zadana metryka $d(\cdot)$ tzn. $d_s : S \times S \rightarrow R_+$ i zachodzą warunki:

1. $\forall \bar{x}, \bar{y} \in S \quad d_s(\bar{x}, \bar{y}) = 0 \Leftrightarrow \bar{x} = \bar{y}$
2. $\forall \bar{x}, \bar{y} \in S \quad d_s(\bar{x}, \bar{y}) = d_s(\bar{y}, \bar{x})$
3. $\forall \bar{x}, \bar{y} \in S \quad d_s(\bar{x}, \bar{z}) \leq d_s(\bar{x}, \bar{y}) + d_s(\bar{y}, \bar{z})$

Jako d_s można przyjąć np. „ważoną” metrykę euklidesową

$$d_s(x_1, \dots, x_k), (y_1, \dots, y_k) = \left[\sum_{i=1}^k u_i (x_i - y_i)^2 \right]^{\frac{1}{2}} \quad (5.6)$$

przy czym zakładamy, że wagi u_i są znane, czyli że potrafimy wycenić poszczególne składowe (współrzędne $\bar{x} \in R^k$) skutków.

Zbiór P (przyczyn) traktujemy jako podzbiór przestrzeni wektorowej $(R^m, R, +, \cdot)$ z działaniami dodawania wektorów i mnożenia wektorów przez liczby. Jest to zbiór częściowo uporządkowany przez relację \prec . Ponadto zakładamy, że zbiór P jest przestrzenią metryczną z metryką d_p mającą następującą faktoryzację:

$$d_p((x_1, \dots, x_k), (y_1, \dots, y_k)) = \delta(d_1(x_1, y_1), \dots, (d_m(x_m, y_m))) \quad (5.7)$$

gdzie:

d_i – metryka na i -tej osi w R^m (i -tej przyczynie),

δ – metryka w produkcie kartezjańskim $\times_{i=1}^m [0, \infty)$. Warunki konieczne i wystarczające jakie muszą spełnić d_i i δ aby d_p była metryką nie są znane. Pewne konieczne i wystarczające warunki można znaleźć np. w pracy [5]. Teraz zajmiemy się specyfikacją operatora $\Phi : P \rightarrow S$.

Przypuśćmy, że operator $\Phi : P \rightarrow S$ (rys. 5.1) spełnia warunki:

$$\forall \bar{x}, \bar{y} \in P \quad \bar{x} \prec \bar{y} \Rightarrow \Phi(\bar{x}) \prec \Phi(\bar{y}) \quad (5.8)$$

$$\forall \bar{x}, \bar{y}, \bar{z} \in P \quad \bar{x} \prec \bar{y} \prec \bar{z} \wedge d_p(\bar{x}, \bar{y}) \leq d_p(\bar{x}, \bar{z}) \Rightarrow d_s(\Phi(\bar{x}), \Phi(\bar{y})) \leq d_s(\Phi(\bar{x}), \Phi(\bar{z})) \quad (5.9)$$

Uwaga: z (5.8) wynika, że

$$\bar{x} \prec \bar{y} \prec \bar{z} \Rightarrow \Phi(\bar{x}) \prec \Phi(\bar{y}) \prec \Phi(\bar{z}) \quad (5.10)$$

Warunek (5.8) zachowania porządku interpretujemy w ten sposób, że większym (w sensie \prec) przyczynom odpowiadają większe (w sensie \prec) skutki, a warunek (5.9) interpretujemy w ten sposób, że większym różnicom porównywalnych (w sensie \prec) przyczyn odpowiadają większe różnice porównywalnych skutków.

W pewnych sytuacjach zamiast (5.8) i (5.9) można rozważać inny warunek:

$$\forall \bar{x}, \bar{y}, \bar{z} \in P \quad d_p(\bar{x}, \bar{y}) \leq d_p(\bar{x}, \bar{z}) \Rightarrow d_s(\Phi(\bar{x}), \Phi(\bar{y})) \leq d_s(\Phi(\bar{x}), \Phi(\bar{y}), \Phi(\bar{z})) \quad (5.11)$$

Warunek (5.11) ma podobną interpretację jak (5.9) z tym, że nie ograniczamy go do łańcuchów punktów, lecz stosujemy globalnie do wszystkich punktów. Na podstawie danych empirycznych należy zweryfikować własności (5.8) i (5.9) operatora Φ . Aby uwolnić rozważania od układu jednostek, w których dokonujemy pomiaru przyczyn i skutków, należy przeprowadzić skalowanie zmiennych.

Identyfikacja metryki d_p

Postaramy się zidentyfikować metrykę d_p . W tym celu założymy że znamy funkcyjną postać d_p z dokładnością do wektorowego parametru α . W oparciu o wyspecyfikowaną metrykę d_p i znaną metrykę d_s określamy macierze: \bar{D} – odległości pomiędzy kolumnami macierzy przyczyn \tilde{P} oraz $\bar{\bar{D}}$ – odległości pomiędzy kolumnami macierzy skutków \tilde{S} . Macierze \bar{D} i $\bar{\bar{D}}$ o wymiarach (n,n) , symetryczne z zerami na przekątnej są elementami przestrzeni macierzy i są macierzami typu $(M_{(n,n)}, \gamma)$. Kryterium na wektorowy parametr α ma postać:

$$\hat{\alpha} = \arg \min \gamma(\bar{D}(\alpha), \bar{\bar{D}}) \quad (5.12)$$

Rozważmy przypadek szczególny powyższego zadania: δ jest ważoną metryką euclidesa, czyli

$$d_p((x_1, \dots, x_m), (y_1, \dots, y_m)) = k \left[\sum_{i=1}^m w_i d_i(x_i, y_i)^2 \right]^{1/2} \quad (5.13)$$

gdzie: $\forall i \quad 0 \leq w_i \leq 1, \quad \sum_{i=1}^m w_i = 1, \quad k \geq 0, \quad d_i$ jest znana

$$\gamma(\bar{D}, \bar{\bar{D}}) = \left[\sum_{\substack{i,j=1 \\ j \geq i}}^n (\bar{d}_{ij}^2 - \bar{\bar{d}}_{ij}^2)^2 \right]^{1/2}$$

Rozwiązanie:

Rozważając szczególną postać metryk d_p i γ otrzymujemy

$$\gamma(\bar{D}, \bar{\bar{D}})_{(w_1, \dots, w_m, k)} = \left[\sum_{i=1}^{n-1} \sum_{j=i+1}^n \left[k^2 \sum_{l=1}^m w_l d_l^2 (\tilde{p}_{li}, \tilde{p}_{lj}) - \bar{\bar{d}}_{i,j}^2 \right]^2 \right]^{1/2}$$

$$0 \leq w_i \leq 1, \quad \sum_{i=1}^m w_i = 1, \quad k \geq 0$$

Wprowadzając nową parametryzację mamy:

$$v_i = k^2 w_i \quad i = 1, \dots, m-1$$

$$v_m = k^2 \left(1 - \sum_{i=1}^{m-1} w_i \right)$$

Stąd

$$\gamma(\bar{D}, \bar{\bar{D}})_{(v_1, \dots, v_m)} = \left[\sum_{i=1}^{n-1} \sum_{j=i+1}^n \left[\sum_{l=1}^m v_l d_l^2 (\tilde{p}_{li}, \tilde{p}_{lj}) - \bar{\bar{d}}_{i,j}^2 \right]^2 \right]^{1/2}$$

Należy znaleźć

$$(\hat{v}_1, \dots, \hat{v}_m) = \arg \min_{\{v_i \geq 0, i=1, \dots, m\}} \gamma(\bar{D}, \bar{\bar{D}})_{(v_1, \dots, v_m)} = \arg \min_{\{v_i \geq 0, i=1, \dots, m\}} \gamma^2(\bar{D}, \bar{\bar{D}})_{(v_1, \dots, v_m)}$$

Problem ten można przedstawić w następującej postaci

$$(\hat{v}_1, \dots, \hat{v}_m) = \arg \min f(v_1, \dots, v_m) = \sum_{q=1}^m \alpha_{pq} v_p v_q - 2 \sum_{r=1}^m \beta_r v_r + \gamma$$

$\forall i \ v_i \geq 0$ gdzie

$$\alpha_{pq} = \sum_{i=1}^{n-1} \sum_{j=i+1}^n d_p^2(\tilde{P}_{pi}, \tilde{P}_{pj}) d_q^2(\tilde{P}_{qi}, \tilde{P}_{qj})$$

$$\beta_r = \sum_{i=1}^{n-1} \sum_{j=i+1}^n d_r^2(\tilde{P}_{ri}, \tilde{P}_{rj}) \bar{d}_{ij}^2$$

$$\gamma = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \bar{d}_{ij}^4$$

Zagadnienie to łatwo sprowadza się więc do zadania programowania kwadratowego

minimalizować $\frac{1}{2} x^T A x - b^T x$ przy warunkach $u \geq x \geq l$, $c^T x \geq d$.

Po rozwiązaniu zagadnienia programowania kwadratowego otrzymujemy optymalne $(\hat{v}_1, \dots, \hat{v}_m)$ i po powrocie do wcześniejszej parametryzacji

$$\hat{w}_i = (\hat{v}_i / \sum_{i=1}^m \hat{v}_i), \quad \hat{k} = \sum_{i=1}^m \hat{v}_i$$

Weryfikacja zależności (5.8) i (5.9) dotyczącą modelu (5.3)

Zakładamy, że składowe P i S pola losowego $(P(x, \omega), S(x, \omega))$ są ‘białymi szumami’ o niezależnych składowych. Pomiędzy P i S istnieje zależność stochastyczna. Zakładamy także, że metryka d_p została zidentyfikowana.

Sposób weryfikacji składa się z dwóch części.

W części pierwszej:

- 1) wybieramy parametr lokalności r (promień kuli) jako pewną część średnicy zbioru obserwacji $\tilde{P}_1, \dots, \tilde{P}_n$
- 2) dla elementów $\tilde{P}_1, \dots, \tilde{P}_n$ wybieramy wszystkie dwuelementowe łańcuchy \tilde{P}_i, \tilde{P}_j , $\tilde{P}_i < \tilde{P}_j$, spełniające warunek lokalności $d_p(\tilde{P}_i, \tilde{P}_j) < r$. Liczbę takich łańcuchów oznaczamy przez $N_2(r)$. Dla każdego takiego łańcucha sprawdzamy, czy prawdziwa jest relacja

$$\tilde{P}_i < \tilde{P}_j \wedge d_p(\tilde{P}_i, \tilde{P}_j) < r \Rightarrow \tilde{S}_i < \tilde{S}_j \quad (5.14)$$

oraz podajemy następujące wielkości:

n – liczność próbki,

r – promień kuli,

$N_2(r)$ – liczba dwuelementowych łańcuchów spełniających warunek lokalności opisany powyżej,

$n_2(r)$ – liczba przypadków, które spełniają relację (5.14),

$n_2(r)/N_2(r)$ – stosunek ten informuje nas jak liczna część rozważanych zdarzeń ZN weryfikuje nasz model

W części drugiej:

- a) wyznaczamy wszystkie 3 elementowe łańcuchy

$$(\tilde{P}_i, \tilde{P}_j, \tilde{P}_k), \tilde{P}_i < \tilde{P}_j < \tilde{P}_k$$

spełniające warunek lokalności

$$d_p(\tilde{P}_i, \tilde{P}_j) < r \wedge d_p(\tilde{P}_j, \tilde{P}_k) < r \text{ i warunek}$$

$$\tilde{P}_i < \tilde{P}_j < \tilde{P}_k$$

liczbę tych łańcuchów oznaczamy przez $N_3(r)$,

b) wśród wszystkich takich łańcuchów sprawdzamy, w ilu przypadkach prawdziwa jest relacja

$$\begin{aligned} [d_p(\tilde{P}_i, \tilde{P}_j) \leq d_p(\tilde{P}_j, \tilde{P}_k) \Rightarrow d_s(\tilde{S}_i, \tilde{S}_j) \leq d_s(\tilde{S}_j, \tilde{S}_k)] \vee \\ [d_p(\tilde{P}_k, \tilde{P}_j) \leq d_p(\tilde{P}_j, \tilde{P}_i) \Rightarrow d_s(\tilde{S}_k, \tilde{S}_j) \leq d_s(\tilde{S}_j, \tilde{S}_i)] \end{aligned} \quad (5.15)$$

Podajemy następująco:

$N_3(r)$ – ilość łańcuchów 3-elementowych spełniających warunki podane w a)

$n_3(r)$ – ilość powyższych łańcuchów, które spełniają (5.15)

$n_3(r)/N_3(r)$

6. Prognozowanie wystąpienia ZN

6.1. Model prognostyczny ZN

Rozważmy pole losowe

$$Z(x, \omega) = (S_0(x, \omega), P_1(x, \omega), \dots, P_m(x, \omega)) \quad (6.1)$$

gdzie:

$x \in R^p$ – punktem przestrzeni górotworu,

$\omega \in \Omega$ – zdarzeniem elementarnym.

Składowe P_1, \dots, P_k traktujemy jako przyczyny występowania ZN. Zakładamy, że składowa S_0 nie zależy od zmiennej przestrzennej x bezpośrednio (w sposób jawny), lecz jedynie poprzez przyczyny $P_1(x, \omega), \dots, P_m(x, \omega)$, które jawnie zależą od x .

Zbiór P wartości przyczyn P_1, \dots, P_k , będący podzbiorem właściwym lub niewłaściwym przestrzeni R^m przedstawimy w postaci skończonej sumy rozłącznych zbiorów $B_i, i = 1, \dots, k$, tzn.

$$P = \bigcup_{i=1}^k B_i \wedge i \neq j \Rightarrow B_i \cup B_j = \emptyset \quad (6.2)$$

Składową dychotomiczną $S_0(x, \omega)$ będziemy aproksymować za pomocą funkcji prostych względem podziału $\{B_i\}$ tak, aby minimalizować błąd średniokwadratowy tej aproksymacji. Oznaczając przez $\chi_B(x)$ indykator zbioru B , tzn. funkcję

$$\chi_B(x) = \begin{cases} 1, & x \in B \\ 0, & x \notin B \end{cases}$$

możemy składową S_0 przybliżać w postaci

$$\hat{S}_0(x, \omega) = \sum_{i=1}^k \alpha_i \chi_{B_i}(P_1(x, \omega), \dots, P_m(x, \omega)) \quad (6.3)$$

przy czym

$$(\alpha_1, \dots, \alpha_k) = \arg \min E_p \left[S_0(x, \omega) - \sum_{i=1}^k \alpha_i \chi_{B_i}(P_1(x, \omega), \dots, P_m(x, \omega)) \right]^2$$

gdzie E_p oznacza wartość oczekiwaną względem (nieznanego) rozkładu P na przestrzeni Ω zdarzeń elementarnych. Łatwo zauważyć, że

$$\begin{aligned}
\varepsilon^2 &= E_p \left[S_0(x, \omega) - \sum_{i=1}^k \alpha_i \chi_{B_i}(P_1(x, \omega), \dots, P_m(x, \omega)) \right]^2 = \\
&\sum_{i=1}^k \sum_{j=1}^k \alpha_i \alpha_j E_p \{ \chi_{B_i}[P_1(x, \omega), \dots, P_m(x, \omega)] \chi_{B_j}[P_1(x, \omega), \dots, P_m(x, \omega)] \} \\
&- 2 \sum_{i=1}^k \alpha_i E_p \{ S_0(x, \omega) \chi_{B_i}[P_1(x, \omega), \dots, P_m(x, \omega)] \} + E_p \{ S_0(x, \omega) \} = \\
&\sum_{i=1}^k \alpha_i^2 P(\{ [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \}) \\
&- \sum_{i=1}^k \alpha_i P(\{ [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \} \wedge S_0(x, \omega) = 1 \}) + P(\{ S_0(x, \omega) = 1 \})
\end{aligned}$$

Wyznaczając minimum powyższej funkcji kwadratowej dostajemy

$$\begin{aligned}
\alpha_i &= \frac{P(\{ [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \} \wedge S_0(x, \omega) = 1 \})}{P(\{ [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \})} = \\
&= P(S_0(x, \omega) = 1 | \{ [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \})
\end{aligned}$$

Wobec tego

$$\hat{S}_0(x, \omega) = \sum_{i=1}^k P(S_0(x, \omega) = 1 | \{ [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \}) \chi_{B_i}(P_1(x, \omega), \dots, P_m(x, \omega)) \quad (6.4)$$

Powyższe wyrażenie jest wersją warunkowej wartości oczekiwanej składowej $S_0(x, \omega)$ względem podciała generowanego przez podział $\{B_i\}$ przestrzeni wartości przyczyn P_1, \dots, P_m , gdyż $\hat{S}_0(x, \omega)$ jest funkcją mierzalną względem tego podciała i spełnia stosowne równanie funkcyjne [6]. Ponadto błąd średniokwadratowy ε^2 powyższej aproksymacji jest określony wzorem

$$\begin{aligned}
\varepsilon^2 &= P(\{ S_0(x, \omega) = 1 \}) - \sum_{i=1}^k P^2 \{ (S_0(x, \omega) = 1 | \\
&| [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \}) P(\{ [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \})
\end{aligned} \quad (6.5)$$

Na podstawie obserwacji możemy wyestymować wielkości $\hat{\alpha}_i$ będące oceną prawdopodobieństw warunkowych

$$P(\{ S_0(x, \omega) = 1 | [P_1(x, \omega), \dots, P_m(x, \omega)] \in B_i \})$$

W tym celu można wykorzystać dane z pomiarów in situ, które mogą być potraktowane jako próba ucząca dla modelu prognostycznego we fragmencie złoża, z którego pochodzą dane pomiarowe. Próba ta może być sekwencyjnie uzupełniana w miarę napływu nowych danych pomiarowych, a parametry modelu bieżąco aktualizowane. Mamy więc model

$$\hat{S}_0(x, \omega) = \sum_{i=1}^k \hat{\alpha}_i \chi_{B_i}(P_1(x, \omega), \dots, P_m(x, \omega)) \quad (6.6)$$

pozwalający w dowolnym punkcie x przestrzeni górotworu na podstawie pomiaru lub w wyniku predykcji przyczyn P_1, \dots, P_m określić prawdopodobieństwo wystąpienia pewnego ZN i szacować błąd średniokwadratowy oceny tego prawdopodobieństwa. Jeżeli dysponujemy techniką pozwalającą na precyzyjną predykcję wartości przyczyn w zadanym punkcie x , to ta technika w połączeniu z zaproponowanym modelem (6.6) pozwala na prognozowanie prawdopodobieństwa występowania rozważanego ZN w dowolnym punkcie przestrzeni górotworu.

6.2. Przykład prognozowania wystąpienia ZN

Za pomocą wyestymowanego modelu (6.6) możemy prognozować występowanie ZN w dowolnym punkcie przestrzeni górotworu. Prognoza odbywa się w dwóch etapach.

Etap I. Dla dowolnego ustalonego $x_0 \in R^p$ punktu przestrzeni geograficznej estymujemy wartości przyczyn $P_1(x_0, \omega), \dots, P_m(x_0, \omega)$ wykorzystując metody geostatystyczne [15], np. kriging poszczególnych przyczyn lub lepiej cokriging wektora przyczyn. Etap ten jest oprogramowany na PC. Wybór konkretnej metody geostatystycznej zależy od jakości i ilości dostępnych danych. W wyniku etapu pierwszego otrzymujemy oceny:

$$\hat{P}_1(x_0, \omega), \dots, \hat{P}_m(x_0, \omega)$$

Etap II. Wyznaczamy wielkość:

$$\hat{S}_0(x_0, \omega) = \sum_{i=1}^k \alpha_i \chi_{B_i}(\hat{P}_1(x_0, \omega), \dots, \hat{P}_m(x_0, \omega)) \quad (6.7)$$

którą interpretujemy jako prawdopodobieństwo wystąpienia ZN w punkcie x_0 (lub jako stopień zagrożenia ZN).

Zaproponowany sposób prognozowania ZN można uważać za zrandomizowaną regułę decyzyjną. Konkretną decyzję można podjąć po wykonaniu eksperymentu losowego, który ZN przypisuje prawdopodobieństwo $S_0(x_0, \omega)$, a brakowi ZN prawdopodobieństwo $1 - S_0(x_0, \omega)$. Powyższe rozumowanie można przedstawić graficznie jak na rysunku 6.1.

W zaproponowanym procesie prognozy etap II jest szczególnie prosty, gdyż ogranicza się do zaklasyfikowania punktu $(\hat{P}_1(x_0, \omega), \dots, \hat{P}_m(x_0, \omega))$ do jednego ze zbiorów B_i i przyjęciu

$$S_0(x_0, \omega) = \hat{\alpha}_i = \hat{P}[S_0(x_0, \omega) = 1 | [P_1(x_0, \omega), \dots, P_m(x_0, \omega)] \in B_i] \quad (6.8)$$

Zaproponowany sposób postępowania jest otwarty. Każdy z etapów może być ulepszony. W następnym podrozdziale zostanie przedstawiona alternatywna wersja tego modelu.

6.3. Model prognostyczny, wersja II

Jak wcześniej zaznaczono praktyczna estymacja modelu

$$\hat{S}_0(x, \omega) = \sum_{i=1}^k \alpha_i \chi_{B_i}(\hat{P}_1(x, \omega), \dots, \hat{P}_m(x, \omega))$$

napotyka na pewne trudności związane z wymaganą licznością obserwacji. Zastrzeżenie może budzić arbitralność w wyborze zbiorów B . Łącząc zalety powyższego modelu i pewne idee zaczerpnięte z teorii wygładzania danych, proponujemy pewien heurystyczny sposób budowy modelu, który zastąpi model zaproponowany powyżej i będzie wolny od wspomnianych wad.

W pierwszej fazie budowy modelu przypiszemy poszczególnym przyczynom P_1, \dots, P_m wagi $\alpha_1, \dots, \alpha_m$, których wielkość będzie wyrażała siłę wpływu rozważanej przyczyny na zaistnienie ZN. Wagę α_i dla i -tej przyczyny wyznaczamy następująco: Mając do dyspozycji zbiór obserwacji i -tej przyczyny, dzielimy go na dwa podzbiory. Pierwszy podzbiór tworzą te obserwacje, którym odpowiada $S_0 = 1$. Drugi podzbiór tworzą pozostałe obserwacje. Dysponując powyższymi zbiorami tworzymy dystrybuanty empiryczne $F_i^1(x)$ oraz $F_i^0(x)$.

Jeśli x_1, \dots, x_n są kolejnymi obserwacjami a $x_{(1)} \leq x_{(2)}, \dots, \leq x_{(n)}$ statystykami porządkowymi utworzonymi z x_1, \dots, x_n , to dystrybuantę empiryczną można zdefiniować następująco:

$$F_e(x) = \begin{cases} 0 & ; x \leq x_{(1)} \\ \frac{m-1}{n} & ; x_{(m-1)} < x < x_{(m)} \\ 1 & ; x > x_{(n)} \end{cases}$$

Waga α_i jest równa odległości między dystrybuantami $F_i^1(x)$, $F_i^0(x)$, tzn:

$$\alpha_i = \sup_x |F_i^1(x) - F_i^0(x)| \quad (6.9)$$

Z powyższej definicji widać, że $0 \leq \alpha_i \leq 1$. Ponadto, jeśli obserwacje są niezależne to znany jest rozkład asymptotyczny statystyki α_i (tzw. rozkład Smirnowa). Wagi α_i są metrykami Czebyszewa w zbiorze funkcji schodkowych i mierząc odległość między dystrybuantami, w oczywisty sposób mierzą siłę wpływu danej przyczyny na składową S_0 , wartość tej składowej była kryterium podziału obserwacji na 2 rozłączne podzbiory, dla których budowano dystrybuanty empiryczne.

Wagi α_i służą do określenia metryki $d(\cdot, \cdot)$ w zbiorze wartości przyczyn (czyli w pewnym podzbiore zbioru R^m). Jeżeli $P_i = P_{1i}, \dots, P_{mi}$ i $P_j = P_{1j}, \dots, P_{mj}$ są dwoma wyskalowanymi wektorami obserwacji, to ich odległość wyznaczamy ze wzoru

$$d(P_i, P_j) = \left[\sum_{k=1}^m \alpha_k^2 (P_{ki} - P_{kj})^2 \right]^{1/2} \quad (6.10)$$

Wykorzystując zdefiniowaną odległość d dla dowolnego ustalonego $P \in R^m$ i i -tej obserwacji wektora przyczyn P_i , $i = 1, \dots, N$ definiujemy wielkość $w_i(P)$ w następujący sposób:

$$w_i(P, \delta) = \frac{f(\delta^{-1}d(P_i, P))}{\sum_j f(\delta^{-1}d(P_j, P))} \quad (6.11)$$

gdzie f jest funkcją nieujemną nierosnącą i ograniczoną w zerze. Parametr δ , zwany parametrem lokalności, jest odpowiedzialny za szybkość opadania funkcji f . Przykłady funkcji f zawarto w tabeli 6.1.

Tab. 6.1. Wybrane funkcje wygładzające

a)	$f(u) = \begin{cases} 1 & u \in \langle 0, 1 \rangle \\ 0 & u \notin \langle 0, 1 \rangle \end{cases}$	
b)	$f(u) = \begin{cases} 1-u, & u \in \langle 0, 1 \rangle \\ 0 & u \notin \langle 0, 1 \rangle \end{cases}$	
c)	$f(u) = e^{-u}$	
d)	$f(u) = e^{-u^2}$	

Łatwo zauważyć, że $w_i \geq 0$ i $\sum_i w_i = 1$. Dysponując wagami w_i budujemy rodzinę modeli, parametryzowaną parametrem lokalności $\delta > 0$. Wyboru konkretnego modelu (tzn. konkretnego δ) należy dokonać na drodze eksperymentalnej. Model jest opisany równaniem

$$\hat{S}_0(x, \omega)_\delta = \sum_{i=1}^N w_i (P(x, \omega), \delta) S_0(x, \omega) \quad (6.12)$$

gdzie $S_0(x_i, \omega)$ oznacza składową dychotomiczną odpowiadającą obserwacji

$$P = (P_1(x_i, \omega), \dots, P_m(x_i, \omega)).$$

Z przeprowadzonych rozważań w tym rozdziale wynikają następujące wnioski:

1. Cechą opracowanych modeli jest to, że utożsamiają zagrożenie bezpośrednio z punktem przestrzeni przyczyn, a tylko pośrednio z punktem przestrzeni górotworu.
2. Uwzględnia się siłę wpływu pewnych wielkości, traktowanych jako przyczyny ZN, na fakt jego zajścia oraz hierarchizuje się te przyczyny na podstawie odległości pomiędzy ich dystrybucjami empirycznymi dyskryminowanymi wartością składowej dychotomicznej S_0 .
3. Hierarchizacja przyczyn umożliwia odrzucenie z rozważań, przyczyn ZN statystycznie nieistotnych, a przez to redukcję wymiaru zadania, uproszczenie obliczeń i obniżenie poziomu szumu powodowanego przez te przyczyny.
4. W zredukowanym zagadnieniu uwzględnia się siłę wpływu poszczególnych przyczyn ZN przyjętych jako statystycznie istotne, poprzez odpowiednią konstrukcję metryki strukturalnej w przestrzeni przyczyn.
5. Wyrażenie (6.12) określa właściwie jednoparametrową rodzinę (z parametrem lokalności δ) modeli. W zależności od rozmiaru i jakości próby uczącej (dane jednorodne lub skupione), dobierając δ możemy sterować wielkością obszaru uśredniania.
6. Model (6.12) pozwala na szacowanie prawdopodobieństwa zaistnienia ZN w dowolnym punkcie złoża, a przez to tworzenie map pokładowych tej miary zagrożenia.
7. Model (6.12) można łatwo rozbudowywać i adaptować do prognozowania różnych zagrożeń naturalnych w górotworze.

7. Literatura

- [1] Ajdukiewicz K., 1974: *Logika pragmatyczna*, PWN, Warszawa.
- [2] Ashby W.R., 1962: *Wstęp do cybernetyki*. PWN, Warszawa.
- [3] Ashram H., 2003: *Tools for Decision Analysis*. <http://home.ubalt.edu/ntsbarsh/Business-stat/opre/partIX.htm>
- [4] Bazan J. G., 1998: *Metody wnioskowań aproksymacyjnych la syntezy algorytmów decyzyjnych*, Praca doktorska, UW, Instytut Matematyki, Warszawa.
- [5] Beals R., Kranz D.H., Tverski, A., 1968: *Foundation of multidimensional scaling*, Psychol. Rev., 75, 7-12.
- [6] Billingsley P., 1987: *Prawdopodobieństwo i miara*, (s. 428-442), PWN, Warszawa.
- [7] Borysiewicz, M., Furtek A., Potemski S., 2000: *Poradnik metod ocen ryzyka związanego z niebezpiecznymi instalacjami procesowymi*, Instytut Energii Atomowej, Otwock-Świerk.
- [8] Bubnicki Z., 1974: *Identyfikacja obiektów sterowania*, PWN, Warszawa.
- [9] Cyrul T., 1987: *Opracowanie założeń do eksperymentu wyrzutu w skali naturalnej*, Sprawozdanie z prac badawczych. IMG PAN. Kraków.
- [10] Cyrul T., 2003: *Podstawowe zagadnienia zarządzania ryzykiem projektu górniczego.*, Prace IMG PAN, t. 5, nr 3-4, s. 315-336.
- [11] Cyrul T., 2003: *Wybrane aspekty ryzyka i niepewności w projektach inżynierskich*, Prace IMG PAN, t. 5, nr 1, s. 3-20.
- [12] Eykhoff P., 1974: *System identification parameter and state estimation*, John Willey and Sons, London.
- [13] Hall A.D., 1968: *Podstawy techniki systemów*. WNT, Warszawa.

- [14] Halmos P.R., 1950: *Measure Theory*, D. Van Nostrand Co., Inc. Princeton, N.Y.
- [15] Journel A.G., Huijbregts Ch.J., 1978: *Mining Geostatistics*, Academic Press.
- [16] Kortas G., 1982: *Model stanu zagrożenia wodnego kopalń soli*, Archiwum Górnictwa, t. 27, z. 1-2.
- [17] Kozioł W., Hebda A., Lewicki J., Kawalec P., 2004: *Ryzyko zawodowe w odkrywkowych zakładach górniczych*, Biblioteka Szkoły Eksploatacji Podziemnej, Kraków.
- [18] Krzemień S., 1985: *Metoda systemowo-jakościowej oceny stanu zagrożeniowego zakładu górniczego*, Zeszyty Naukowe Pol. Śl., Seria Górnictwo, z. 139, Gliwice.
- [19] Krzemień S., 1992: *Teoretyczne podstawy określania miar stanu zagrożenia bezpieczeństwa w wyrobiskach górniczych*, Zeszyty Naukowe Pol. Śl., Seria Górnictwo, z. 204, Gliwice.
- [20] Markowski A.S., (red.) 2000: *Zapobieganie stratom w przemyśle*, Wyd. Politechniki Łódzkiej.
- [21] Matheron G., 1971: *The Theory of Regionalized Variables and its Applications*. Les Cahiers du Centre de Morphologie Mathematique, Fasc.5, CG Fontainebleau.
- [22] Matheron G., 1989: *Estimating and Choosing. An Essay on Probability in Practice*, Springer-Verlag.
- [23] Podolak K., 1982: *System identification in structural mechanics: a survey*, IFTR Reports, No 37, Warszawa.
- [24] Polański Z., 1978: *Współczesne metody badań doświadczalnych*, Wiedza Powszechna, Warszawa.
- [25] Polański Z., 1984: *Planowanie eksperymentów*, PWN, Warszawa.
- [26] Ryncarz T., 1983: *O systematycznej klasyfikacji zagrożeń występujących w górnictwie podziemnym*, Górnictwo, Kwartalnik AGH, z. 3, Kraków.
- [27] Shapiro S.C., 1992: *Encyclopedia of Artificial Intelligence*, New York, John Wiley and Sons.
- [28] Sobala J., Rosmus P., 1997: *System zarządzania bezpieczeństwem pracy w zakładach górniczych*, GIG, Katowice.
- [29] Sobczyk K., 1986: *O identyfikacji układów*, Prace IPPT PAN, nr 26.
- [30] Szewczyk K., 1985: *Opis fragmentów dyskusji nt. prognozowania i zwalczania zagrożenia wyrzutowego*, Mat. Konferencji, Sobotka Górka, 31 Maj-2 czerwiec, nr 2, s. 296-326.
- [31] Zadeh L.A., 1962: *From circuit theory to system theory*, Proc. IRE 50, 856-65.

Identification of hazards as the sources of risks in mining activity

Abstract

The paper is the second stage of the research on risk management in mining projects. Risk management procedure contains a number of steps, identification of hazards being the first one. In the paper it was pointed out that identification is mainly understood as recording of hazards in a given system. This kind of approach to hazard identification, despite its practical advantages in the area of prevention, displays also some disadvantages, among which the most important are: 1. Significance of subjective components, 2. Qualitative character of methods, 3. Low usefulness for repetitive prognosis of a fault occurrence and at the same time risk assessment of actions being undertaken. These imperfections of hazard identification methods pushed the author to look at hazard identification from the point of view of its modelling. In such a context an identification is a classification of models of a given phenomenon and then, on the ground of a certain criteria, a choice of the best model from a class of models. In the paper known methods of hazard identification such as Checklist Analysis, What If Analysis, PHA, HAZOP, FMEA, were presented and more over FTA for scenario creation as well as ETA. The original result of the paper is the evaluation of a conception of prognosis of dangerous events as well as of a prognostic model of dangerous event.

Keywords: hazard, risk, model, prognosis, identification, decision, cause effect, probability, dangerous event

Recenzent: Dr hab. inż. Grzegorz Kortas, Instytut Mechaniki Górniczej PAN