

## Rozdział 10

# Przykłady zastosowania systemu DISESOR w diagnostyce maszyn i urządzeń

Mateusz Kalisch, Wojciech Moczulski, Piotr Przyszałka, Anna Timofiejczuk, Dominik Wachla

---


### 10.1 Wstęp

Szkieletowy system DISESOR może być stosowany w wielu dziedzinach, w których zachodzi potrzeba gromadzenia danych, ich analizy, oceny, a także wnioskowania z wykorzystaniem informacji niesionej przez te dane. Klasycznym polem zastosowań systemu DISESOR jest diagnostyka maszyn i urządzeń.

Diagnoza jest rozwiązaniem zagadnienia odwrotnego (rys. 10.1), w którym przesłankami są m. in. wartości cech sygnałów diagnostycznych  $Y$  i parametrów procesowych (a więc dane), faktami pomocniczymi są wartości cech warunków działania obiektu diagnozowanego oraz sterowań  $U$ , a konkluzje dotyczą klas wartości cech stanu technicznego  $X$ . Sam proces wnioskowania diagnostycznego przebiega z wykorzystaniem wiedzy diagnostycznej, która reprezentowana jest w bazie wiedzy systemu diagnostycznego. Przedstawiony na tym rysunku schemat jest bardzo ogólny, przy czym strzałki w kolorze czerwonym reprezentują proces wnioskowania.

DISESOR jest systemem szkieletowym. Aby mógł być wykorzystany do diagnozowania maszyn i urządzeń, wymaga odpowiedniej reprezentacji wiedzy, która powinna być pozyskana z dostępnych źródeł. System jest wyposażony w odpowiednie narzędzia umożliwiające działania w zakresie inżynierii wiedzy, takie jak [10.10]:

- pozyskiwanie wiedzy od specjalistów dziedzinowych:
  - bezpośrednio – np. w formie wywiadów z ekspertami, a następnie reprezentacji wiedzy ekspertów przez inżyniera wiedzy,



Rys. 10.1. Zadanie diagnozowania [10.10]

- pośrednio – poprzez analizę ankiet wypełnionych przez ekspertów, analizę publikacji, tekstów i patentów;
- budowa bazy wiedzy metodami uczenia na podstawie przykładów, uprzednio sklasyfikowanych przez specjalistów;
- budowa bazy wiedzy metodami odkrywania wiedzy w bazach danych, zawierających przykłady niesklasyfikowane przez eksperta.

Wymienione narzędzia zostały zastosowane do procesu pozyskania wiedzy diagnostycznej o wybranych maszynach górniczych. Wiedza ta została zapisana w bazie wiedzy systemu DISESOR, umożliwiając zastosowanie tego systemu szkieletowego do rozwiązywania przykładowych zadań z zakresu diagnostyki maszyn górniczych. W niniejszym rozdziale przedstawiono wybrane wyniki w zakresie monitorowania i diagnostyki głowicy kombajnu ścianowego oraz przenośnika zgrzeblowego. Badania weryfikacyjne opracowanej implementacji systemu przeprowadzono na danych uzyskanych w ramach eksperymentu numerycznego, a także zgromadzonych w ramach biernego eksperymentu diagnostycznego. Kompletny opis przeprowadzonych badań znajduje się w [10.13].

## 10.2 Przykład zastosowania systemu w diagnostyce przenośnika zgrzeblowego z wykorzystaniem symulatora

Obiektem niniejszych badań w zakresie diagnostycznego eksperymentu numerycznego jest przenośnik zgrzeblowy lekki typu JOY BLS charakteryzujący się długością równą 250 m oraz wydajnością 2160 t/h. Model matematyczny i

symulacyjny przenośnika (zrealizowany w oprogramowaniu MATLAB/Simulink) oraz jego wszystkie parametry techniczne opisano szczegółowo w podrozdziale 8.3.

### 10.2.1 Eksperyment symulacyjny

Podczas eksperymentu diagnostycznego założono, że rozpatrywane będą wyłącznie elementarne stany techniczne, w związku z czym rozważano następujące przypadki:

- stan pełnej zdadności,
- spadek napięcia zasilania,
- zanieczyszczenie miałem dolnej przestrzeni rynien,
- przeładowanie urobkiem,
- uszkodzenie przetwornika pomiarowego Mpg powodujące zmniejszenie dokładności pomiaru,
- uszkodzenie przetwornika pomiarowego Mgn powodujące zmniejszenie dokładności pomiaru,
- uszkodzenie przetwornika pomiarowego vn powodujące zmniejszenie dokładności pomiaru,
- uszkodzenie przetwornika pomiarowego vn polegające na utrzymywaniu się wartości stałej na wyjściu czujnika,
- uszkodzenie przetwornika pomiarowego vn powodujące zmianę czułości czujnika ,
- uszkodzenie przetwornika pomiarowego natężenia prądu fazy A silnika nr 1 polegające na utrzymywaniu się wartości stałej na wyjściu czujnika,
- uszkodzenie przetwornika pomiarowego prądu fazy A silnika nr 1 powodujące zmianę czułości czujnika.

Dodatkowo przyjęto założenie, że rejestrowane będą wyłącznie wybrane zmienne procesowe, biorąc pod uwagę obecny stan techniki w zakresie systemów monitorowania tego typu obiektów. Zbiór zmiennych procesowych uzyskiwany w wyniku symulacji przedstawiono w Tab. 10.1 Dla celów diagnostycznych dostępne są jedynie zmienne procesowe tj. VN, INZ1A, INZ1B, INZ1C, INZ2A, INZ2B, INZ2C oraz STER, UR. Zakłada się, że zmienne procesowe STER i UR wykorzystywane są w celu utworzenia cechy kontekstowej (KON) oraz, że będą one dostępne w systemie monitorowania w wyniku odpowiedniego przetwarzania sygnałów sterowania przenośnikiem i kombajnem. Pozostałe zmienne (IT, USZK, GENDAT) zawierają informację dotyczącą parametrów danej symulacji.

W celu odwzorowania adekwatnych warunków pracy rozważanego przenośnika zgrzeblowego zdecydowano, że eksperyment symulacyjny będzie uwzględniał następujące tryby pracy przenośnika:

- STER=0 – tryb wybiegu,
- STER=1 – tryb rozruchu,
- STER=2 – tryb pracy podczas procesu urabiania.

Tab. 10.1. Zmienne procesowe uzyskiwane w wyniku numerycznego eksperymentu diagnostycznego

Nazwa zmiennej	Jednostka	Opis zmiennej
VN	m/s	Prędkość liniowa zgrzebeł przenośnika
INZ1A	A	Natężenie prądu fazy A silnika nr 1
INZ1B	A	Natężenie prądu fazy B silnika nr 1
INZ1C	A	Natężenie prądu fazy C silnika nr 1
INZ2A	A	Natężenie prądu fazy A silnika nr 2
INZ1B	A	Natężenie prądu fazy B silnika nr 2
INZ2C	A	Natężenie prądu fazy C silnika nr 2
Mpg	Nm	Moment obciążenia silników
Mpn	Nm	Moment generowany przez silniki
STER		Identyfikator trybu pracy przenośnika
UR		Identyfikator trybu pracy kombajnu
IT		Identyfikator określający numer symulacji dla określonego wariantu scenariusza z zadaniem stanem
KON		Identyfikator wariantu kontekstu
USZK		Identyfikator klasy stanu
GENDAT		Numer porządkowy eksperymentu określonego wariantu scenariusza z zadaniem stanem

oraz podstawowe tryby pracy kombajnu:

- UR=0 – kombajn nie urabia,
- UR=1 – kombajn urabia.

Biorąc pod uwagę rzeczywiste warunki pracy przenośnika oraz obecny stan techniki w zakresie systemów monitorowania tego typu obiektów zdecydowano, że rozważane będą wyłącznie scenariusze S3-S8 z pominięciem uszkodzeń F4 i F5. Szczegółowy opis scenariuszy oraz uszkodzeń został zawarty w podrozdziale 8.3. Takie ograniczenie wynika z faktu, że podczas rozruchu i wybiegu jałowego nie jest możliwa sytuacja, w której następuje przeładowanie przenośnika urobkiem. Z drugiej strony systemy pomiarowe przenośników zgrzeblowych aktualnie funkcjonujące w przemyśle górniczym nie są wyposażane w czujniki momentów. Plan eksperymentu zakłada również badania mające na celu sprawdzenie przydatności metodyki wnioskowania diagnostycznego z zastosowaniem kontekstu. Mając to na uwadze podczas niniejszych badań uwzględniono zaproponowane warianty kontekstu (trybu pracy przenośnika i kombajnu), które zestawiono w Tab. 10.2.

Dane symulacyjne generowane są dla wybranych kombinacji wartości zmiennych USZK, KON oraz GENDAT. Ponadto założono, że dla każdego wariantu wartości GENDAT wykonanych zostanie 20 powtórzeń eksperymentu dla różnych obciążeń roboczych przenośnika (w zakresie 80%-110%). W trakcie ekspery-

Tab. 10.2. Zdefiniowane warianty kontekstu

Id wariantu kontekstu	Tryb pracy przenośnika	Tryb pracy kombajnu
W1	1	0
W2	1	1
W3	2	0
W4	2	1
W5	0	0
W6	0	1

mentów symulacyjnych zastosowano metodę ode45 (Dormand–Prince) o zmiennym kroku całkowania.

### 10.2.2 Dane uczące

Wartości chwilowe zmiennych procesowych VN, INZ1A, INZ1B, INZ1C, INZ2A, INZ2B, INZ2C oraz KON stanowią źródło danych bazowych do wyznaczenia dodatkowych cech liczbowych. Cecha kontekstowa reprezentowana za pomocą zmiennej procesowej KON wykorzystywana jest do wyliczenia cech liczbowych z rozważanych szeregów czasowych (wartości KON determinowała szerokość okna czasowego, dla którego wyznaczano cechy liczbowe). Podczas badań wyliczono cechy tj. wartość średnią – Avg, wartość minimalną – Min, wartość maksymalną – Max, odchylenie standardowe – Std, wartość skuteczną – Rms, współczynnik kształtu – Shf, kurtoza – Krt, energię – En, skośność – Skw, entropię – Ent, średnią bezwzględną – AbsAvg, wartość średnia kwadratowa – Ms, wariancję – Var, bezwzględną wartość maksymalną – AbsMax, bezwymiarowy współczynnik szczytu – Crs, bezwymiarowy współczynnik impulsowości – Imp, wartość międzyszczytową – P2P. Rozpatrywane cechy stanowiły podstawę określenia zbioru atrybutów opisowych (potencjalnych wejść klasyfikatorów) branych pod uwagę w procesie uczenia klasyfikatorów. W wyniku tych działań wyznaczono 120 atrybutów opisowych. Zmienna USZK pełniła rolę atrybutu decyzyjnego. Na etapie przygotowania danych wyznaczono znormalizowane wagi poszczególnych atrybutów z zastosowaniem metody szacowania niepewności symetrycznej (ang. symmetrical uncertainty). W wyniku przeprowadzenia eksperymentu symulacyjnego uzyskano szeregi czasowe wartości chwilowych sygnałów zmiennych procesowych (49200 próbek szeregu czasowego dla stanu pełnej zdatności oraz tą samą liczbę próbek dla stanu z uszkodzeniami).

### 10.2.3 Akwizycja wiedzy

Pozyskanie wiedzy z zastosowaniem technik uczenia maszynowego i danych wygenerowanych za pomocą symulatora przenośnika zgrzeblowego przeprowadzono zgodnie ze schematem widocznym na Rys. 10.2. Jak można zauważyć dane źródłowe (szeregi czasowe pozyskane w wyniku symulacji) posłużyły do wyznaczenia liczbowych cech sygnałów oraz istotnych atrybutów opisowych (wejść

klasyfikatora). Atrybut decyzyjny stanowił identyfikator klasy stanu (USZK). W oparciu o ten schemat opracowano dziesięć koncepcji wykorzystania różnych algorytmów klasyfikacji oraz cechy kontekstowej w procesie detekcji i izolacji uszkodzeń. Element diagramu opisany jako KLASYFIKATOR dotyczy zarówno koncepcji, w których wykorzystano pojedynczy elementarny klasyfikator jak również wybraną metodę meta-uczenia, w wyniku której generowany był komitet klasyfikatorów. Przyjęto następujące oznaczenia: Z – zbiór pierwotnych zmiennych procesowych, C – zbiór cech sygnałów, N – zbiór znormalizowanych cech sygnałów, A – zbiór atrybutów rozpatrywanych w zadaniu klasyfikacji, F – wypadkowa diagnoza. Zaprezentowany sposób pozyskiwania wiedzy został wykorzystany w zadaniu detekcji i izolacji uszkodzeń. Detekcja uszkodzenia polegała na rozróżnianiu dwóch klas stanu: OK – stan pełnej zdatności, FAULT – stan z uszkodzeniem. W przypadku izolacji uszkodzenia rozróżniano osiem klas stanu F1-F3 i F6-F10. W eksperymencie wykorzystano tylko i wyłącznie sygnały, które są powszechnie mierzone w praktyce przemysłowej.

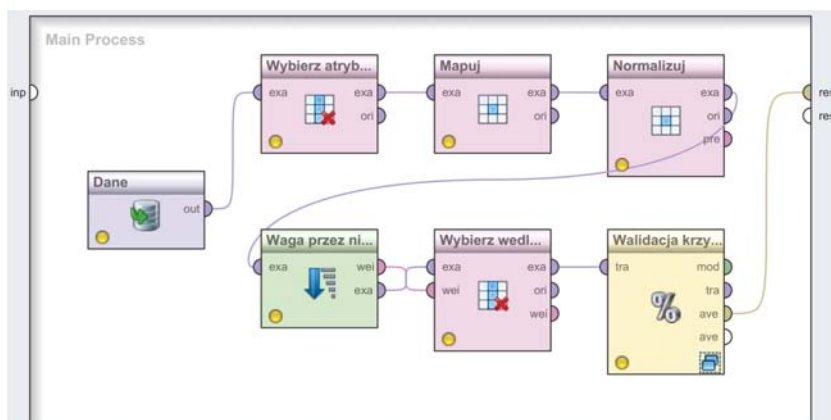


Rys. 10.2. Schemat ideowy sposobu pozyskiwania wiedzy z wykorzystaniem pojedynczego klasyfikatora działającego wg metody elementarnej

Ogólny schemat widoczny na Rys. 10.2 został przystosowany do realizacji 10 różnych podejść, w których stosowano zarówno pojedyncze klasyfikatory jak i komitety zbudowane w oparciu o różne metody. Każda z koncepcji wnioskowania została zweryfikowana biorąc pod uwagę trzy bazowe metody klasyfikacji: drzewo decyzyjne, sieć Bayesa oraz k-najbliższych sąsiadów. Różnice pomiędzy koncepcjami dotyczyły kombinacji dwóch elementów, tzn. zastosowanej metody meta-uczenia i sposobu wykorzystania cechy kontekstowej. Każde z podejść można opisać w następujący sposób:

- Koncepcja nr 1 - zastosowanie pojedynczego klasyfikatora bez udziału cechy kontekstowej,
- Koncepcja nr 2 - zastosowanie metody Bagging bez udziału cechy kontekstowej,
- Koncepcja nr 3 - zastosowanie metody AdaBoost bez udziału cechy kontekstowej,
- Koncepcja nr 4 - zastosowanie metody AdaBoost z udziałem jednowartościowej cechy kontekstowej (kontekst globalny) uwzględnianej przez metodę jako kolejny atrybut wejściowy,
- Koncepcja nr 5 - zastosowanie metody AdaBoost z udziałem wielowartościowej cechy kontekstowej uwzględnianej przez metodę jako kolejny atrybut wejściowy,

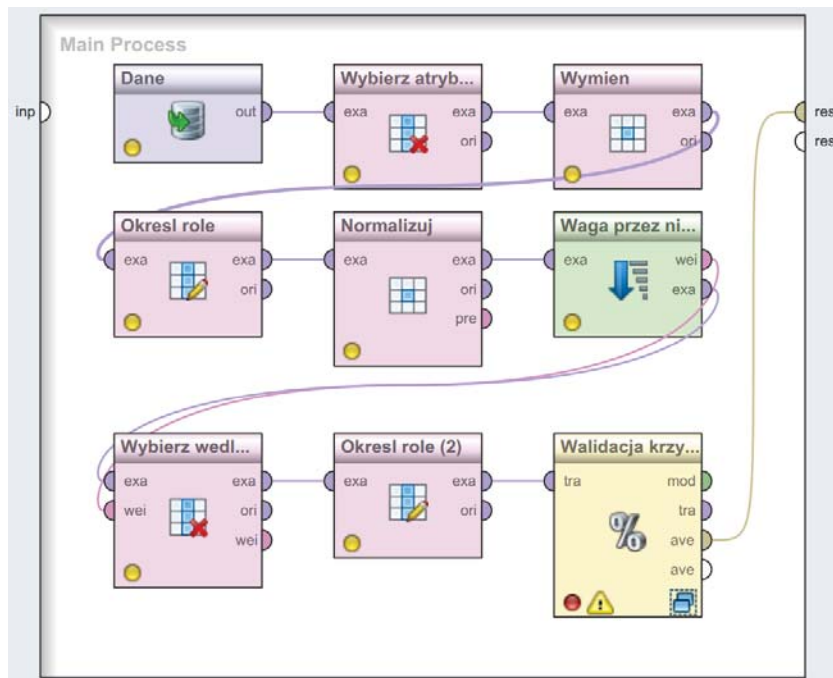
- Koncepcja nr 6 - zastosowanie metody Bagging z udziałem jednowartościowej cechy kontekstowej (kontekst globalny) uwzględnionej przez metodę jako kolejny atrybut wejściowy,
- Koncepcja nr 7 - zastosowanie metody Bagging z udziałem wielowartościowej cechy kontekstowej uwzględnianej przez metodę jako kolejny atrybut wejściowy,
- Koncepcja nr 8 - zastosowanie pojedynczego klasyfikatora z udziałem jednowartościowej cechy kontekstowej (kontekst globalny) uwzględnianej przez klasyfikator jako kolejny atrybut wejściowy,
- Koncepcja nr 9 - zastosowanie pojedynczego klasyfikatora z udziałem wielowartościowej cechy kontekstowej uwzględnianej przez klasyfikator jako kolejny atrybut wejściowy,
- Koncepcja nr 10 - zastosowanie metody kontekstowego wyboru klasyfikatora.



Rys. 10.3. Główny widok schematu wnioskowania, w którym nie zastosowano cechy kontekstowej

Na rysunkach 10.3, 10.4, 10.5 przedstawiono główne schematy wnioskowania zaimplementowane w aplikacji RapidMiner. Różnica pomiędzy tymi schematami dotyczy sposobu wykorzystania cechy kontekstowej. W procesie widocznym na Rys. 10.3 realizowane były następujące kroki:

- wczytanie danych trenujących,
- usuwanie cech, które nie mogą brać udziału w procesie klasyfikacji,
- normalizacja wartości atrybutów,
- przypisanie do cech wag, które określają ich istotność w procesie klasyfikacji,
- usuwanie cech, które nie spełniają określonego kryterium,
- zastosowanie algorytmu walidacji krzyżowej na wybranym klasyfikatorze, w celu oszacowania jego dokładności.

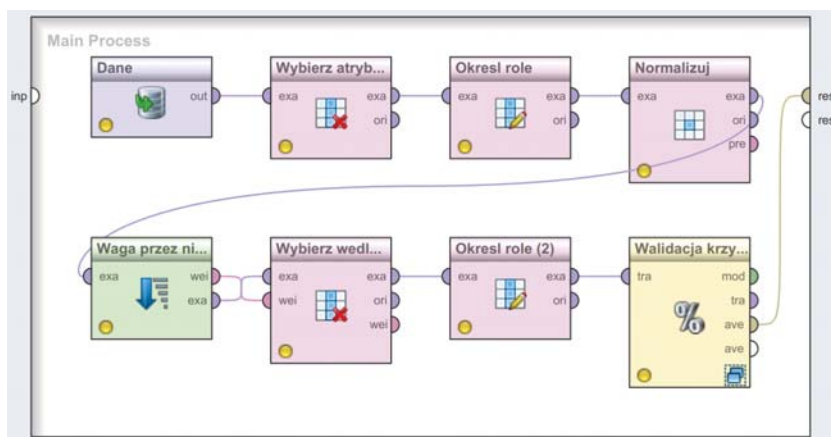


Rys. 10.4. Główny widok schematu wnioskowania, w którym zastosowano kontekst globalny

Proces ten nie uwzględnia cechy kontekstowej, która jest usuwana na etapie stosowania algorytmu selekcji cech. Kolejny proces przedstawiony na Rys. 10.4 uwzględnia cechę kontekstową, jednak reprezentuje on tzw. kontekst globalny, czyli zmienna kontekstowa przyjmuje tylko jedną stałą wartość. W samym procesie uwzględniono dodatkowe operatory (w porównaniu do poprzedniego procesu), których zadaniem było przystosowanie cechy kontekstowej do koncepcji kontekstu globalnego oraz dodanie cechy kontekstowej do listy cech wynikowych. W ostatnim ogólnym schemacie wnioskowania, który został pokazany na Rys. 10.5 zastosowano dyskretną cechę kontekstową.

Każdy z procesów widoczny na rysunkach 10.3, 10.4, 10.5 został zweryfikowany w oparciu o różne metody klasyfikacji i meta-uczenia. W trakcie badań do oszacowania poprawności zgromadzonej wiedzy stosowano miarę dokładności klasyfikacji (ang. accuracy rate), którą wyznaczano z zastosowaniem walidacji krzyżowej z tzw. losowaniem warstwowym (ang. stratified sampling). Na etapie walidacji krzyżowej zastosowano zarówno elementarne klasyfikatory (drzewo decyzyjne, k-najbliższych sąsiadów oraz sieć Bayesa) jak i wybrane metody meta-uczenia (Bagging, AdaBoost oraz algorytm kontekstowej selekcji klasyfikatorów).





Rys. 10.5. Główny widok schematu wnioskowania, w którym zastosowano dyskretną cechę kontekstową

Dla każdej zastosowanej metody meta-uczenia zastosowano wybrane elementarne algorytmy klasyfikacji. Wybierany jest jedynie typ klasyfikatora (np. drzewo decyzyjne) a na etapie trenowania tworzony jest komitet klasyfikatorów, gdzie każdy z nich trenowany jest w oparciu o inny zbiór danych.

Dla wszystkich koncepcji i klasyfikatorów zastosowano tę samą koncepcję selekcji atrybutów, polegającą na przypisaniu za pomocą odpowiedniego algorytmu wag do poszczególnych cech, gdzie wartość wagi określa istotność danej cechy. Możliwe jest zastosowanie różnych kryteriów wyboru listy końcowych cech. Na potrzeby opisanych tu badań postanowiono określić stałą liczbę cech, które znajdują się na początku posortowanej listy (o najwyższych wartościach wag). Liczbę cech wyznaczono na podstawie wzoru:

$$C_z = \frac{n}{\log(n)} \quad (10.1)$$

gdzie  $C_z$  określa liczbę wybranych cech a  $n$  jest liczbą wszystkich cech, spośród których wybierana jest lista najistotniejszych. Całkowita liczba cech obliczona dla wszystkich zmiennych procesowych jest równa 119. Stosując wyżej przedstawiony wzór otrzymujemy informację, że należy wykorzystać 57 atrybutów charakteryzujących się największą istotnością według zastosowanej metody.

W tabelach 10.3 i 10.4 przedstawiono wyniki detekcji i izolacji uszkodzeń z zastosowaniem miary dokładności oraz odchylenia standardowego (wartość podana w nawiasach). Zweryfikowano dziesięć koncepcji schematów wnioskowania wykorzystując każdą z trzech metod klasyfikacji: drzewo decyzyjne, sieć Bayesa oraz k-najbliższych sąsiadów. Koncepcje w tabelach zostały oznaczone identyfikatorami liczbowymi widocznymi w pierwszym wierszu tabeli, które zostały opisane na początku tego rozdziału. Zaprezentowane wyniki zebrane na etapie detekcji uszkodzeń nie są jednoznaczne i nie pozwalają na sformułowanie ogólnego

Tab. 10.3. Dokładność klasyfikatora do detekcji uszkodzeń uzyskana dla wszystkich rozpatrywanych koncepcji

Metoda klasyfikacji	1	2	3	4	5	6	7	8	9	10
Drzewo decyzyjne	77,69 (1, 27)	78,32 (1, 19)	77,69 (1, 27)	77,69 (1, 27)	89,97 (0, 86)	78,10 (1, 28)	89,95 (0, 86)	77,69 (1, 27)	89,97 (0, 86)	91,03 (1, 33)
Sieć Bayesa	90,22 (1, 26)	82,55 (23, 37)	90,23 (1, 25)	90,03 (1, 40)	89,92 (1, 32)	83,21 (13, 56)	89,54 (1, 08)	90,03 (1, 40)	89,92 (1, 32)	90,45 (1, 05)
k-najbliższych sąsiadów	91,52 (0, 86)	91,43 (0, 83)	91,52 (0, 86)	91,52 (0, 86)	91,52 (0, 86)	91,35 (0, 82)	91,28 (0, 82)	91,52 (0, 86)	91,52 (0, 86)	91,52 (0, 86)

Tab. 10.4. Dokładność klasyfikatora do izolacji uszkodzeń uzyskana dla wszystkich rozpatrywanych koncepcji

Metoda klasyfikacji	1	2	3	4	5	6	7	8	9	10
Drzewo decyzyjne	78,40 (2, 63)	77,26 (21, 65)	83,21 (3, 69)	83,21 (3, 69)	92,01 (1, 34)	84,92 (1, 43)	86,17 (2, 66)	78,40 (2, 63)	78,40 (2, 63)	88,94 (1, 74)
Sieć Bayesa	93,83 (1, 55)	59,73 (32, 52)	93,83 (1, 55)	93,45 (1, 49)	93,42 (1, 52)	68,34 (32, 80)	61,09 (32, 29)	93,45 (1, 49)	83,42 (1, 52)	93,40 (0, 78)
k-najbliższych sąsiadów	92,55 (1, 16)	92,39 (0, 88)	92,55 (1, 16)	92,55 (1, 16)	92,55 (1, 16)	92,45 (1, 05)	92,01 (1, 06)	92,55 (1, 16)	92,55 (1, 16)	92,55 (1, 16)

nych wniosków na ich temat. W przypadku algorytmu k-najbliższych sąsiadów nie zaobserwowano żadnego wpływu zastosowanej metody na dokładność klasyfikacji, różnice pomiędzy wynikami są pomijalnie małe i mogą wynikać głównie z działania algorytmu losującego próbki do zbioru danych trenujących i testowych. Dla algorytmu sieci Bayesa zaobserwowano istotny spadek dokładności klasyfikacji w koncepcjach, w których stosowano algorytm meta-uczenia Bagging bez udziału cechy kontekstowej i z udziałem globalnego kontekstu. Dla pozostałych koncepcji wyniki klasyfikacji były do siebie zbliżone i uzyskiwały wartość dokładności bliskie 90%. Natomiast algorytm drzewa decyzyjnego wykazał wysoką wrażliwość na występowanie cechy kontekstowej, w takich przypadkach dokładność detekcji znacząco wzrastała. Dla wszystkich wyników wartość odchylenia standardowego jest skorelowana z wartością dokładności.

W przypadku izolacji uszkodzeń zaobserwowano podobne zależności jakie wystąpiły na etapie detekcji uszkodzeń. Tym razem zastosowanie klasyfikatora sieci Bayesa wraz z wszystkimi algorytmami meta-uczenia Bagging wyraźnie pogorszyło dokładność izolacji uszkodzeń. Algorytm k-najbliższych sąsiadów podobnie jak w przypadku detekcji uszkodzeń dla każdej zastosowanej koncepcji uzyskał niemal identyczny wynik. Rezultaty uzyskane przy użyciu algorytmu drzewa decyzyjnego w przypadku izolacji uszkodzeń nie są odzwierciedleniem wyników uzyskanych dla detekcji uszkodzeń. W tym przypadku cecha kontekstowa nie pełni już tak wyraźnie istotnej roli. Najwyższą dokładność uzyskano dla koncepcji bazującej na metodzie meta-uczenia AdaBoost, gdzie dyskretna cecha kontekstowa jest rozpatrywana jako dodatkowy atrybut wejściowy klasyfikatora. Podobne wyniki uzyskano dla metody kontekstowej selekcji klasyfikatorów.

W opisanych badaniach porównano różne podejścia, w których zastosowano odmienne metody klasyfikacji bazujące zarówno na elementarnych klasyfikatorach jak i algorytmach meta-uczenia. W celu estymacji sprawności schematów wnioskowania opartych na zastosowanych klasyfikatorach wykorzystano metodę walidacji krzyżowej oraz klasyczne miary poprawności klasyfikacji wyznaczone na podstawie macierzy pomyłek. Pozyskana w ten sposób wiedza została zaimplementowana w szkieletowym systemie ekspertowym.

### **10.3 Przykład zastosowania systemu w diagnostyce układu urabiania kombajnu ścianowego z wykorzystaniem symulatora**

W ramach niniejszego podrozdziału przedstawiono przykład akwizycji wiedzy diagnostycznej dotyczącej układu urabiania górniczego kombajnu ścianowego. Do tego celu wykorzystano symulator układu urabiania kombajnu JOY 4LS20 (rozd. 8.4) oraz narzędzia akwizycji wiedzy dostępne w szkieletowym systemie ekspertowym DISESOR (rozd. 6). Za pomocą symulatora wygenerowano dane (szeregi czasowe zmiennych procesowych) reprezentujące określone stany techniczne diagnozowanej maszyny. Dla pozyskanych szeregów czasowych wyznaczano wybrane cechy liczbowe, które posłużyły do utworzenia bazy przykładów uczących wykorzystywanych w procesie trenowania i testowania klasyfikatora.

rów stanu technicznego. W wyniku końcowym, za pomocą narzędzi dostępnych w szkieletowym systemie ekspertowym DISESOR, opracowano dwa klasyfikatory stanu, jeden w postaci drzewa decyzyjnego i drugi w postaci sieci Bayesa.

### 10.3.1 Eksperyment symulacyjny

Stosowany symulator układu urabiania kombajnu ścianowego umożliwia m.in. symulowanie pracy obiektu z trzema typami uszkodzeń:

- wyłamania noża styczno-obrotowego na głowicy urabiającej (uszkodzenie F1),
- wyłamania zęba na wybranym kole lub kołach zębatych zespołu przeniesienia napędu (uszkodzenie F2),
- pęknięcia wałka przeciążeniowego (uszkodzenie F3).

Wyłamanie noża na głowicy urabiającej (uszkodzenie F1) jest związane z modelem procesu urabiania, w ramach którego obliczana jest siła skrawania przypadająca na pojedynczy nóż. Siła ta zależy od własności mechanicznych urabianej skały, parametrów skrawania (posuw kombajnu, prędkość obrotowa głowicy urabiającej) oraz parametrów definiujących rozkład noży styczno-obrotowych na głowicy urabiającej wraz z orientacją przestrzenną ich osi. Symulacja wyłamania pojedynczego noża polega wówczas na obliczaniu sumarycznej siły skrawania z pominięciem cech opisujących ten nóż. W prowadzonych symulacjach założono, że wyłamany został nóż znajdujący się w środkowej części organu skrawającego. Wpływ wyłamania tego noża na proces skrawania został pokazany na rysunku 8.13.

Uszkodzenie w postaci wyłamania zęba (uszkodzenie F2) jest modelowane poprzez istotne zmniejszenie wartości funkcji sztywności na odcinku łuku koła podziałowego odpowiadającego odcinkowi przyporu wybranego zęba na kole zębatym czynnym (rys. (b)). W prowadzonych symulacjach założono, że wyłamany został jeden z zębów koła zębatego czynnego przekładni zębatej pierwszego stopnia redukcji zespołu przeniesienia napędu. Wartość współczynnika względnej zmiany sztywności  $g_z$  na odcinku przyporu odpowiadającemu położeniu wybranego zęba ustalono na poziomie 0,9.

Pęknięcie wałka przeciążeniowego (uszkodzenie F3) jest modelowane poprzez zmniejszenie jego nominalnej sztywności skrętnej (20827 Nm/rad). W prowadzonych symulacjach wartość tej sztywności została określona na podstawie obliczeń przeprowadzonych w oparciu o model tzw. *pęknięcia oddychającego* [10.6]. Podstawowym parametrem takiego modelu pęknięcia jest głębokość nacięcia wykonanego prostopadle do osi obrotu wałka. Przy nominalnej średnicy wałka przeciążeniowego wynoszącej 40 mm założono, że głębokość symulowanego pęknięcia będzie wynosić 15 mm. Dla takiej wartości głębokości pęknięcia, obliczona sztywność skrętna wałka wyniosła 20516 Nm/rad.

Przedstawione powyżej stany symulowanego obiektu zostały uzupełnione o stan pełnej zdadności F0, który jest tożsamy z domyślnymi nastawami parametrów symulatora.

W celu pozyskania odpowiednich danych (trenujących oraz testowych) umożliwiających identyfikację relacji diagnostycznych dotyczących ww. uszkodzeń, zostały opracowane dwa schematy eksperymentu symulacyjnego. Pierwszy schemat dotyczył pozyskania danych do trenowania klasyfikatorów stanu. W ramach tego schematu dla każdego z rozpatrywanych stanów (F0÷F3) zdefiniowano 15 wariantów symulacji. We wszystkich wariantach założono stały posuw kombajnu  $v_p = 3,45$  m/min., stałą wartość kąta bocznego rozkruszenia węgla  $\psi = 45^\circ$  oraz wytrzymałość węgla na ściskanie  $R_c \in \{10; 15; 20; 25; 30\}$  MPa [10.11]. Wytrzymałość węgla na rozciąganie  $R_r$  wyznaczono w oparciu o zależność  $R_r = pR_c$  przyjmując wartości parametru  $p \in \{0,10; 0,15; 0,20\}$  [10.11]. Z kolei, drugi schemat eksperymentu symulacyjnego dotyczył pozyskania danych do testowania klasyfikatorów. W ramach tego schematu zdefiniowano po 4 warianty symulacji dla każdego z rozpatrywanych stanów ze stałą wartością posuwu kombajnu  $v_p = 3,45$  m/min. oraz stałą wartością kąta bocznego rozkruszenia węgla  $\psi = 45^\circ$ . Wytrzymałość węgla na ściskanie  $R_c$  została dobrana w sposób losowy z przedziału  $\langle 10; 30 \rangle$  MPa.

Ze względu na cel prowadzonych eksperymentów symulacyjnych założono, że rejestrowane będą tylko takie zmienne procesowe które aktualnie są rejestrowane w systemach monitorowania pracy kombajnów ścianowych oraz takie których pomiar może być łatwo zrealizowany, ale nie są monitorowane. Zbiór rozpatrywanych zmiennych procesowych przedstawiono w tabeli 10.5. Dla celów diagnostycznych dostępne są jedynie zmienne procesowe  $IP1$ ,  $IP2$ ,  $IP3$ ,  $V$  i  $A$ . Zmienna  $D$  jest zmienną o marginalnym znaczeniu diagnostycznym. Z kolei zmienna  $MOB$  jest w praktyce niemierzalna a jej rejestracja ma na celu monitorowanie przebiegu obciążenia podczas symulacji.

Tab. 10.5. Zmienne procesowe rejestrowane w trakcie eksperymentów symulacyjnych


Nazwa zmiennej	Jednostka	Opis zmiennej
IP1	A	Natężenie prądu fazy A silnika
IP2	A	Natężenie prądu fazy B silnika
IP3	A	Natężenie prądu fazy B silnika
D	rad	Przemieszczenie kątowe wału silnika
V	rad/s	Prędkość kątowna wału silnika
A	rad/s <sup>2</sup>	Przyspieszenie kątowne wału silnika
MOB	Nm	Moment obciążający głowicę urabiającą

Na podstawie wyników testowania symulatora przyjęto następujące parametry symulacji [10.9]:

- rodzaj solwera: ode5 (Dormand-Prince) ze stałym krokiem całkowania,

- krok symulacji:  $1e-5$  s,
- czas symulacji: 10,597 s (11 obrotów głowicy urabiającej).


W efekcie przeprowadzenia eksperymentów symulacyjnych uzyskano 76 zestawów szeregów czasowych wartości chwilowych sygnałów zmiennych procesowych, 60 zestawów dla trenowania modeli klasyfikacyjnych oraz 16 dla testowania. Każdy z zarejestrowanych szeregów składa się z 1059683 próbek obejmujących 11 obrotów głowicy urabiającej i wyznaczających (przy częstotliwości próbkowania  $F_s = 1e5$  Hz) czas symulacji pracy układu urabiającego na poziomie 10,597 s. Na kolejnych rysunkach (rys. 10.6÷rys. 10.9) przedstawiono przykładowe realizacje szeregów czasowych uzyskanych podczas eksperymentu.




Rys. 10.6. Wykres zmienności obciążenia w przypadku symulacji pracy obiektu: (a) bez uszkodzeń, (b) z uszkodzeniem w postaci wyłamania noża stycznobrotowego

### 10.3.2 Dane uczące

Do przygotowania danych uczących wybrano cztery rejestrowane w trakcie symulacji zmienne procesowe tj. natężenie prądu IPA, IPB i IPC pobieranego z sieci przez silnik napędowy oraz przyspieszenie kątowne A. Zestaw danych trenujących oraz testowych przygotowano zgodnie z przyjętym planem eksperymentów symulacyjnych wyznaczając dla każdego z pozyskanych sygnałów następujące cechy punktowe [10.3]: wartość średnią  $x_{MEAN}$ , wartość średnią bezwzględną  $x_{AVE}$ , wartość międzyszczytową  $x_{P-P}$ , odchylenie standardowe  $x_{STD}$ , wartość skuteczną  $x_{RMS}$ , kurtoza  $x_{KURT}$ , współczynnik kształtu  $x_{FORM}$ , współczynnik szczytu  $x_{CREST}$ , współczynnik impulsowości  $x_{IMP}$ . Dodatkowo, w przypadku sygnału przyspieszenia kątownego, wyznaczono cechy stanowiące wynik analizy oktawowej (względna szerokość pasma  $b=7,07\%$ ) prowadzonej w przedziale częstotliwości 1 Hz ÷ 16 kHz [10.5].



Rys. 10.7. Wykres przebiegu natężenia prądu fazy A w przypadku symulacji pracy obiektu: (a) bez uszkodzeń, (b) z uszkodzeniem w postaci wyłamania noża stycznno-obrotowego




Rys. 10.8. Wykres zmian prędkości kątowej w przypadku symulacji pracy obiektu: (a) bez uszkodzeń, (b) z uszkodzeniem w postaci pęknięcia wałka przeciążeniowego

Z kolei w przypadku sygnałów prądowych prowadzono dodatkową analizę częstotliwościową FFT [10.8] w celu wyznaczenia 4. cech związanych z wartością amplitudy i fazy ww. sygnałów dla częstotliwości 1 Hz i 33 Hz:

$$X_{1Hz} = 20 \log_{10} \left( \sqrt{\operatorname{Re}(\operatorname{FFT}(x)|_{1Hz})^2 + \operatorname{Im}(\operatorname{FFT}(x)|_{1Hz})^2} \right), \quad (10.2)$$

$$\theta_{1Hz} = \arctan \left( \frac{\operatorname{Im}(\operatorname{FFT}(x)|_{1Hz})}{\operatorname{Re}(\operatorname{FFT}(x)|_{1Hz})} \right), \quad (10.3)$$



Rys. 10.9. Wykres zmian przyspieszenia kąowego w przypadku symulacji pracy obiektu: (a) bez uszkodzeń, (b) z uszkodzeniem w postaci wylamania zęba

$$X_{33Hz} = 20 \log_{10} \left( \sqrt{\operatorname{Re}(\operatorname{FFT}(x)|_{33Hz})^2 + \operatorname{Im}(\operatorname{FFT}(x)|_{33Hz})^2} \right), \quad (10.4)$$

$$\theta_{33Hz} = \arctan \left( \frac{\operatorname{Im}(\operatorname{FFT}(x)|_{33Hz})}{\operatorname{Re}(\operatorname{FFT}(x)|_{33Hz})} \right). \quad (10.5)$$

Wymienione powyżej cechy wyznaczano w oparciu o pozyskane sygnały w przedziale czasu od 5 s do 10 s symulacji, czyli w przedziale czasowym obejmującym ustabilizowane warunki pracy badanego układu. Dla każdego z wyznaczonych zestawów cech (zgodnie z przyjętym planem eksperymentu) przypisano adekwatną etykietę określającą klasę symulowanego stanu obiektu badań. Przyjęto, że dla stanów F0, F1, F2 i F3 etykiety te będą odpowiednio znakami: **B** – stan F0, **N** – stan F1, **Z** – stan F2 oraz **W** – stan F3.

### 10.3.3 Akwizycja wiedzy

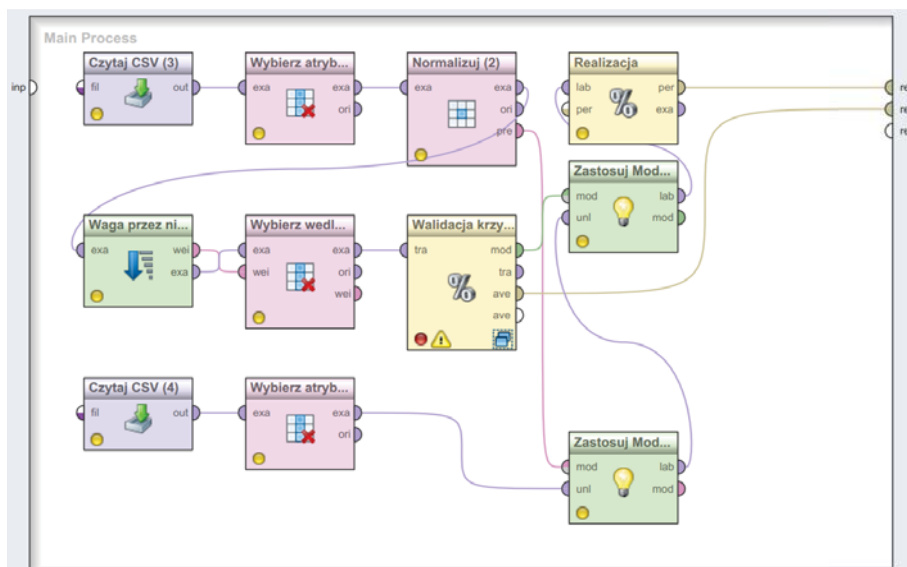
Pozyskanie wiedzy z zastosowaniem technik uczenia maszynowego i danych wygenerowanych za pomocą symulatora kombajnu ścianowego przeprowadzono zgodnie ze schematem widocznym na rys. 10.10. Schemat ten obejmuje wyznaczenie cech liczbowych (rozd. 10.3.2) sygnałów pozyskanych podczas eksperymentu symulacyjnego, normalizację i selekcję cech relewantnych oraz indukcję klasyfikatora. W oparciu o powyższy schemat prowadzono indukcję dwóch typów klasyfikatorów dostępnych w szkieletowym systemie ekspertowym DISESOR, tj. drzewa decyzyjnego i sieci Bayesa. Przyjęto następujące oznaczenia: **Z** – zbiór pierwotnych zmiennych procesowych, **C** – zbiór cech sygnałów, **N** – zbiór znormalizowanych cech sygnałów, **A** – zbiór atrybutów rozpatrywanych w zadaniu klasyfikacji, **F** – wypadkowa diagnoza. Zaprezentowany sposób pozyskiwania wiedzy został wykorzystany w zadaniu detekcji i izolacji uszkodzeń.

Na rysunku 10.11 przedstawiono główny schemat wnioskowania zaimplementowany w aplikacji RapidMiner. Proces ten jednocześnie realizuje detekcję oraz






Rys. 10.10. Proces indukcji klasyfikatorów do detekcji i izolacji uszkodzeń układu urabiania kombajnu ścianowego



Rys. 10.11. Widok głównego procesu detekcji i izolacji uszkodzeń w środowisku systemu DISESOR

izolację uszkodzeń. Jest to możliwe dzięki odpowiedniemu przygotowaniu danych w których występuje równa liczba rekordów danych, dla każdej z klas. Schemat pozwala na przeprowadzenie zarówno procesu trenowania i testowania przy pomocy metody *leave one out* jak i weryfikacji wytrenowanego końcowego modelu przy pomocy danych weryfikacyjnych. Wynikiem działania procesu są macierze pomyłek oraz miara dokładności klasyfikacji. Miary obliczane są osobno dla procesu uczenia i weryfikacji. W przypadku procesu uczenia dokładność jest podawana jako wartość średnia razem z odchyleniem standardowym obliczanym z wszystkich prób.



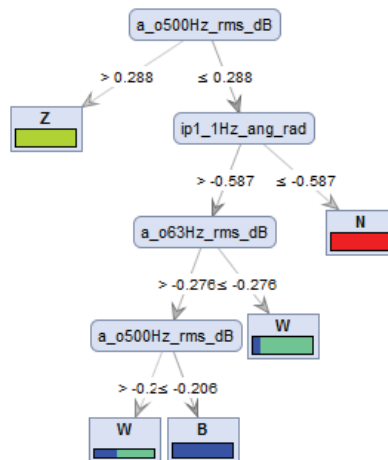
Rys. 10.12. Zastosowanie algorytmu sieci Bayesa wewnątrz operatora walidacji *Leave one out*

W trakcie badań, do oszacowania poprawności zgromadzonej wiedzy stosowano miarę dokładności klasyfikacji (ang. *accuracy rate*), którą wyznaczano z zastosowaniem metody walidacji *Leave one out*. Zadaniem procesu widocznego z lewej strony na rysunku 10.12 jest wytrenowanie modelu klasyfikacji. Z prawej strony realizowany jest proces wyliczania dokładności klasyfikacji w oparciu o dane testowe, które w tym przypadku oznaczają pojedynczy wektor danych, który nie brał udziału w trenowaniu klasyfikatora. Dla wszystkich algorytmów klasyfikacji zastosowano tę samą koncepcję selekcji atrybutów, polegającą na przypisaniu za pomocą odpowiedniego algorytmu, wag do poszczególnych cech, gdzie wartość wagi określa istotność danej cechy. Możliwe jest zastosowanie różnych kryteriów wyboru listy końcowych cech. Na potrzeby opisanych tu badań zastosowano operator ważenia cech o nazwie *Waga przez nieokreśloność (uncertainty)* oraz postanowiono określić stałą liczbę cech, które znajdują się na początku posortowanej listy (o najwyższych wartościach wag). Liczbę cech określono indywidualnie dla każdego z klasyfikatorów stosując metodę systematycznego przeszukiwania. Dla drzewa decyzyjnego ograniczono liczbę cech do 5, a dla sieci Bayesa do 30 najbardziej istotnych.

W tabeli 10.6 pokazano rezultaty działania dwóch testowanych algorytmów klasyfikacji. Wynik został podzielony na dwie sekcje. W pierwszej przedstawiono średnią dokładność oraz jej odchylenie standardowe uzyskane na etapie trenowania i testowania za pomocą metody *Leave one out*. Ostatnia kolumna zawiera informację o dokładności klasyfikacji wytrenowanego klasyfikatora na odrębnym zbiorze weryfikacyjnym. W tabeli można zaobserwować wysoką skuteczność działania wybranych algorytmów klasyfikacji zarówno dla zbioru danych uczących

Tab. 10.6. Dokładność rozpatrywanych klasyfikatorów do detekcji i izolacji uszkodzeń układu urabiania kombajnu

Nazwa algorytmu	<i>Leave one out</i>		Weryfikacja
	Dokładność	Odchylenie standardowe	
Drzewo decyzyjne	86,67 %	33,99 %	100,00 %
Sieć Bayesa	88,33 %	32,10 %	87,50 %



Rys. 10.13. Struktura drzewa decyzyjnego zbudowanego w oparciu o dane trenujące

jak i weryfikacyjnych. Wysokie odchylenie standardowe wynika w głównej mierze z zastosowanej metody estymacji dokładności klasyfikacji algorytmu na etapie uczenia, którą była metoda *Leave one out*.

Na rysunku 10.13 pokazano schemat drzewa decyzyjnego, które zostało zbudowane w oparciu o dane uczące. Można zaobserwować, że już niewielka liczba atrybutów pozwala na zbudowanie klasyfikatora, który charakteryzuje się wysoką dokładnością.

## 10.4 Przykład zastosowania systemu w diagnostyce kombajnu ścianowego z wykorzystaniem danych pomiarowych

Rosnąca złożoność obiektów przemysłowych powoduje, że detekcja uszkodzeń jest jednym z najważniejszych kierunków badań w dziedzinie robotyki i nowoczesnych systemów automatycznej kontroli [10.2, 10.7, 10.12]. Istnieje wiele obszarów, w których wymagane jest aby systemy oraz procesy techniczne były użytkowane w sposób niezawodny i bezpieczny. Większość stosowanych rozwiązań detekcji i izolacji uszkodzeń jest opartych na prostych metodach, ponieważ są łatwe i szybkie do wdrożenia, ale efekt końcowy może być niezadowalający ze względu na ograniczenia jak np. zbyt powolne działanie systemu. W celu osiągnięcia lepszych wyników w trudniejszych przypadkach można zastosować bardziej złożone rozwiązania. Jednym z rozwiązań jest stworzenie systemu detekcji i izolacji uszkodzeń w oparciu o klasyfikatory, które są używane do klasyfikowania zbiorów danych. Innym rozwiązaniem jest podejście bazujące na kontekście.

### 10.4.1 Obiekt rzeczywisty

Przedmiotem niniejszego rozdziału jest kombajn ścianowy pracujący w kopalni węgla kamiennego w Polsce. Kombajn górniczy jest maszyną pracującą pod ziemią, która bierze bezpośredni udział w procesie wydobywania węgla. Waga kombajnu wynosi około 100 ton a jego długość około 15 metrów. Kombajn wyposażony jest w dwa organy urabiające, które obracają się najczęściej z prędkością od 30 do 40 obr/min [10.1, 10.4].

Dostępne zestawy danych rzeczywistych składają się z 36 sygnałów takich jak: prądy, ciśnienia oleju i wody, temperatury i prędkości obrotowe lewego i prawego organu urabiającego. Między innymi, po analizie korelacyjnej ze zbioru danych zostały usunięte sygnały nadmiarowe. Ostateczna liczba sygnałów wynosiła 21. Jedną ze zmiennych był stan operacyjny, który zawierał informacje na temat bieżącego stanu kombajnu ścianowego. Informacje dotyczące tej zmiennej są reprezentowane przez zmienną binarną, a każdy bit jest związany z określonym stanem. Dostępny zestaw danych, obejmujący swoim zakresem kilka dni, został podzielony na mniejsze zestawy danych dotyczące pojedynczych dni. W każdym zbiorze określono liczbę pustych wierszy oraz wierszy zawierających dane. Wyniki tych analiz przedstawiono w tabeli 10.7.

Tab. 10.7. Relacja pomiędzy liczbą wektorów zawierających dane a całkowitą liczbą danych dla każdego z dni

Data	Liczba wektorów z danymi	Liczba wszystkich wektorów	Zawartość użytecznych danych w całym zbiorze
18 Grudnia	64783	106385	61%
19 Grudnia	72337	102470	71%
20 Grudnia	79719	105248	76%
21 Grudnia	77200	103746	74%
22 Grudnia	44746	67080	66%

W tabeli 10.7 można zauważyć, że zawartość pustych wektorów (nie zawierających danych) w całym zbiorze danych (z podziałem na dni) waha się w przedziale od 24% do 39%.

#### 10.4.2 Dane uczące

Dla zbioru danych z 19 października możliwe było rozróżnienie 28 fragmentów zawierających spójne dane nie zawierające żadnej przerwy. W tabeli 10.8 pokazano jaka liczba fragmentów danych mieściła się w określonym przedziale czasu. Na potrzeby dalszych badań wykorzystano jedynie 7 podzbiorów danych zawierających najdłuższe przebiegi czasowe niezawierające przerw. Liczba próbek zawarta w kolejnych podzbiórach wynosi kolejno 5031, 5362, 6461, 7351, 7680, 9937 i 10998. Czas trwania najkrótszego zbioru to 1 godzina i 7 minut, czas trwania najdłuższego zbioru wynosi 2 godziny i 30 minut. Zbiór danych zawierający więcej próbek może dostarczyć więcej wektorów danych związanych z każdym ze stanów operacyjnych kombajnu, co daje możliwość utworzenia lepiej wytrenowanego klasyfikatora charakteryzującego się brakiem zbyt dużego dopasowania do danych i wysoką dokładnością klasyfikacji nowych danych.

Tab. 10.8. Związek pomiędzy liczbą użytecznych fragmentów danych (ciągłych) a czasem ich trwania

Czas trwania	Liczba fragmentów
0 - 1 min	2
1 - 10 min	12
10 - 60 min	7
1 - 3 h	7

Stany operacyjne kombajnu ścianowego były rozpatrywane jako cecha kontekstowa. Rozpatrywano sześć stanów eksploatacyjnych:

1. awaria,

2. ostrzeżenie,
3. układ napędowy działa,
4. układ napędowy nie działa,
5. jazda kombajnu w lewo,
6. jazda kombajnu w prawo.

W badaniu przedstawionym w niniejszym rozdziale, stany pracy kombajnu ścianowego zostały zapisane razem z pozostałymi danymi (zmiennymi procesowymi) monitorowanymi przez system SCADA. W przypadku, gdy dane na temat stanu pracy kombajnu nie są zapisywane w bazie danych, konieczne może być określenie stanów pracy urządzenia przez eksperta. Stany pracy kombajnu są dostępne w zestawie danych jako wartości dziesiętne i istotne jest, aby przekształcić je do postaci binarnej, aby wydobyć informacje o każdym stanie roboczym. Tabela 10.9 prezentuje listę rozpatrywanych stanów i możliwych ich kombinacji. W pierwszym wierszu wymieniono rozpatrywane stany, przy czym każdy stan może występować (1) lub nie występować (0). Pierwsza kolumna zawiera listę wszystkich możliwych kombinacji stanów reprezentowanych przez wartości dziesiętne (4, 5, 8, 20, 36, 38), a ich reprezentacje binarne są przedstawione w środkowej części tabeli. Numery kolumn tabeli dla obszaru dot. reprezentacji binarnej odpowiadają ww. numerom/etykiatom stanów pracy kombajnu.


Tab. 10.9. Reprezentacja dziesiętna i binarna rozpatrywanych stanów operacyjnych kombajnu górniczego

	1	2	3	4	5	6
4	0	0	1	0	0	0
5	1	0	1	0	0	0
8	0	0	0	1	0	0
20	0	0	1	0	1	0
36	0	0	1	0	0	1
38	0	1	1	0	0	1

Niektóre kombinacje stanów nie są poprawne i nie mogą być traktowane jako możliwe do osiągnięcia. Na przykład nie jest możliwe, aby ustawić bity 5 i 6 na wartość 1 w tym samym czasie, ponieważ bit 5 jest połączony z zadaniem *Jazda kombajnu w lewo* a bit 6 jest połączony z zadaniem *Jazda kombajnu w prawo*. Nie jest możliwe, aby kombajn poruszał się w obu kierunkach równocześnie, ale możliwe jest zatrzymanie maszyny, wówczas bit 5 i 6 są równe 0.

Na rysunku 10.14 pokazano występowanie grup cech kontekstowych we fragmencie zbioru danych, gdzie każdy identyfikator grupy (od 1 do 6) jest związany z następującą kombinacją stanów eksploatacyjnych:


1. układ napędowy działa,
2. awaria i układ napędowy działa,



Rys. 10.14. Występowanie możliwych grup stanów eksploatacyjnych w pojedynczym zbiorze danych

3. układ napędowy nie działa,
4. układ napędowy działa i kombajn jedzie w lewo,
5. układ napędowy działa i kombajn jedzie w prawo,
6. ostrzeżenie, układ napędowy działa i kombajn jedzie w prawo.


Rysunek 10.15 przedstawia w jednym ze zbiorów danych miejsca, w których występują określone bazowe stany eksploatacyjne kombajnu. Można zaobserwować, że liczba wektorów danych powiązanych z każdym ze stanów jest bardzo różna. Wartości ID cech kontekstowych są związane z ID cech kontekstowych wymienionych na początku tego rozdziału.



Rys. 10.15. Występowanie stanów eksploatacyjnych w pojedynczym zbiorze danych

### 10.4.3 Akwizycja wiedzy

Przeprowadzono weryfikację dwóch metod klasyfikacji grup kontekstów. Założono, że każda cecha kontekstowa jest cechą binarną i może przyjmować wartość 1 albo 0. Wartości wszystkich cech kontekstowych mogą zostać połączone w wektor i przedstawione w postaci wartości dziesiętnej (np. wartości sześciu wariantów kontekstów zapisanych w postaci binarnej 010010 są równe wartości 18 w systemie dziesiętnym). Istnieje możliwość określenia wszystkich możliwych kombinacji wartości wariantów kontekstu w grupie i utworzyć listę tych kombinacji reprezentowanych za pomocą wartości dziesiętnych. Takie podejście (rys. 10.16) pozwala na wykorzystanie tylko jednego wieloklasowego klasyfikatora a końcowy rezultat klasyfikacji może być zdekodowany do reprezentacji binarnej. Dzięki temu można ocenić każdą binarną cechę kontekstową osobno.




Rys. 10.16. Schemat klasyfikacji cech kontekstowych za pomocą pojedynczego klasyfikatora

Zaletą pierwszego sposobu jest to, że wynik klasyfikacji może być połączony tylko z jednym ze znanych kombinacji wartości cech kontekstowych w grupie, ponieważ wszystkie możliwe kombinacje są zdefiniowane w danych treningowych. Drugi sposób (rys. 10.17) opiera się na komitecie klasyfikatorów binarnych, przy czym każdy z nich jest wytrenowany do wykrywania pojedynczej binarnej cechy kontekstowej. Jeżeli w procesie wnioskowania rozpatrywanych jest sześć cech kontekstowych, konieczne jest utworzenie komitetu składającego się z sześciu klasyfikatorów. W obu koncepcjach każda z cech kontekstowych w grupie może być wykorzystana samodzielnie w zadaniu detekcji i izolacji uszkodzeń. Jednak w drugiej koncepcji istnieje możliwość osiągnięcia wyniku, który nie jest prawidłowy. Bardziej szczegółowy opis tego problemu przedstawiono w następnej części rozdziału.

Porównano cztery różne klasyfikatory: sieć Bayesa, naiwny klasyfikator bayesowski, drzewo decyzyjne oraz sztuczną sieć neuronową. Każdy z tych klasyfikatorów pozwala zaklasyfikować niesklasyfikowany przypadek do jednej z klas. W szczególności, zwraca etykietę klasy, do której powinien należeć niesklasyfikowany przypadek oraz stopień przekonania o przynależności tego przypadku do wybranej klasy jak również wartość stopnia przynależności do wszystkich pozostałych klas. Najlepszym oczekiwanym rezultatem jest sytuacja, gdy jedna z klas charakteryzuje się poziomem przekonania równym 1, a reszta z nich jest równa 0. To daje 100% pewność, że nowy element powinien być sklasyfikowany jako należący do tej konkretnej klasy.





Rys. 10.17. Schemat klasyfikacji cech kontekstowych za pomocą komitetu klasyfikatorów, gdzie jeden klasyfikator jest przypisany do jednej cechy

Aby wyniki obu metod były ze sobą zgodne, rezultaty drugiej metody (rysunek 10.17) zostały uznane za prawidłowe tylko i wyłącznie wtedy, gdy wszystkie klasyfikatory binarne zwróciły poprawny wynik. Nawet jeśli tylko jeden klasyfikator popełnił błąd, ostateczny wynik był traktowany jako nieprawidłowy. Takie rozwiązanie jest w pełni porównywalne z pierwszą metodą, gdzie ostateczny wynik bazuje na grupie kontekstów.

Tabela 10.10 pokazuje dokładność wszystkich klasyfikatorów stosowanych w obu rozważanych metodach. Klasyfikatory zostały przedstawione w tabeli za pomocą skrótów (DD – drzewo decyzyjne; NB – naiwny klasyfikator bayesowski; SN – sieć neuronowa; SB – sieć Bayesa). Każda kolumna jest połączona z innym zbiorem treningowym, a wartości w komórkach tabeli pokazują średnią wartość dokładności obliczoną na zbiorach testowych. Można wyraźnie zaobserwować, że komitet klasyfikatorów binarnych osiągnął znacznie lepsze rezultaty niż pojedynczy wieloklasowy klasyfikator.

Tab. 10.10. Dokładność obliczona dla wszystkich klasyfikatorów i metod

Pojedynczy klasyfikator							
Dataset id	1	2	3	4	5	6	7
DD	78,1	42,8	68,9	57,7	63,6	76,6	65,4
NB	30,4	45,3	55,2	48,2	72,0	56,7	37,6
SN	51,4	53,6	70,2	65,2	75,6	75,5	51,3
SB	51,9	27,6	33,1	37,3	46,0	48,5	51,5
Komitet binarnych klasyfikatorów							
Dataset id	1	2	3	4	5	6	7
DD	89,4	86,8	89,9	90,8	91,0	88,5	89,4
NB	76,9	80,1	87,2	79,8	88,3	85,9	83,3
SN	83,3	86,7	92,6	82,9	92,4	92,1	88,8
SB	77,9	60,0	58,2	75,7	80,0	70,4	78,0

Dokładność jest obliczana w oparciu o stosunek pomiędzy wszystkimi prawidłowo sklasyfikowanymi wektorami danych a liczbą wszystkich wierszy danych. Wynik określony w oparciu o dokładność nie może być rozpatrywany jako jedyna miara skuteczności klasyfikacji z powodu niezbalansowania danych testowych. Drugi pomiar stosowany w tym teście to czułość. Czułość obliczono dla każdej klasy oddzielnie jako stosunek liczby wszystkich wierszy danych poprawnie przypisane do danej klasy do wszystkich wierszy danych związanych z daną klasą. Wynik końcowy jest średnią arytmetyczną wyznaczoną z wszystkich wartości czułości obliczonych dla każdej z klas.

Tab. 10.11. Czułość obliczona dla wszystkich klasyfikatorów i metod

Pojedynczy klasyfikator							
Dataset id	1	2	3	4	5	6	7
DD	68,3	46,6	57,7	51,3	55,3	64,9	61,1
NB	27,0	29,7	35,8	29,2	46,8	35,3	32,1
SN	36,1	31,6	55,1	36,6	47,2	37,9	44,5
SB	35,8	27,4	27,9	35,8	37,9	38,9	43,0
Komitet binarnych klasyfikatorów							
Dataset id	1	2	3	4	5	6	7
DD	82,4	73,2	79,8	84,3	79,4	81,8	82,5
NB	58,1	61,1	63,9	59,0	65,9	64,1	58,2
SN	64,6	65,9	64,2	60,1	73,4	57,2	55,3
SB	65,2	53,1	60,1	66,9	66,8	67,8	66,1

Metoda opierające się na komitecie klasyfikatorów binarnych osiągnęła znacznie lepsze wyniki niż pojedynczy klasyfikator. Można zauważyć, że wartości średnie czułości są gorsze niż wyniki dla dokładności. Świadczy to o tym, że klasyfikatory wytrenowane na niezbalansowanym zbiorze danych nie zostały prawidłowo ocenione przez miarę dokładności. Wyniki dla dokładności pokazują, że jedynie dwa klasyfikatory w każdej kolumnie osiągnęły najlepsze wyniki: drzewo decyzyjne (DD) i sieć neuronowa (SN). Reszta klasyfikatorów prawie zawsze osiągała gorsze wyniki, niż dwa wymienione wcześniej. Średnia wartość czułości pokazuje, że algorytm oparty na drzewie decyzyjnym jest w stanie pracować poprawnie z danymi niezbalansowanymi i we wszystkich kolumnach osiągnął najlepszy wynik. Klasyfikator oparty na sieci neuronowej (SN) miał tendencję do ignorowania klas z mniejszą liczbą przykładów.

## 10.5 Podsumowanie

W ramach rozdziału przedstawiono badania jakie prowadzono w zakresie pozyskiwania wiedzy diagnostycznej dotyczącej wybranych maszyn i urządzeń górniczych. Wiedzę tą pozyskiwano z wykorzystaniem narzędzi dostępnych w szkie-

letowym systemie ekspertowym DISESOR (rozdz. 10) poprzez analizę i eksploatację danych będących wynikiem eksperymentów numerycznych prowadzonych z użyciem opracowanych symulatorów (rozdz. 8) oraz danych pomiarowych gromadzonych przez system monitorowania i nadzoru kombajnu ścinowego. W oparciu o funkcjonalność opracowanych symulatorów przygotowano plany eksperymentów symulacyjnych, w wyniku których zostały pozyskane dane reprezentujące relacje zachodzące pomiędzy określonymi stanami diagnozowanych obiektów a obserwowanymi sygnałami wyjściowymi takimi jak: prądy na poszczególnych fazach silnika napędowego, prędkość obrotowa wału silnika, prędkość liniowa zgrzebel przenośnika i inne. Dla pozyskanych sygnałów wyznaczano wybrane cechy liczbowe: wartość średnią, wartość skuteczną, współczynnik szczytu, współczynnik kształtu i inne. Cechy te posłużyły do utworzenia przykładów uczących, za pomocą których zbudowano klasyfikatory stanu rozpatrywanych obiektów.

Klasyfikatory stanu rozpatrywanych obiektów opracowano w formie prostych i złożonych modeli wnioskowania z wykorzystaniem klasyfikatorów bazowych takich jak: drzewo decyzyjne, sieć Bayesa, naiwny klasyfikator Bayesa oraz metod meta-uczenia jak np. metoda głosowania większościowego lub meta-klasyfikator bazujący na sieci neuronowej. W celu estymacji sprawności wyznaczonych modeli wnioskowania zastosowano metodę walidacji krzyżowej oraz klasyczne miary poprawności klasyfikacji oparte na macierzy konfuzji. Pozyskana w ten sposób wiedza została zaimplementowana w szkieletowym systemie ekspertowym DISESOR.

## Literatura

- [10.1] A. O. Altun, I. Yilmaz, M. Yildirim. A short review on the surficial impacts of underground mining. *Scientific Research and Essays*, 21(5):3206–3212, 2010.
- [10.2] F. Caccavale, L. Villani. *Fault Diagnosis and Fault Tolerance for Mechatronic Systems: Recent Advances*. Springer Tracts in Advanced Robotics. Springer Berlin/Heidelberg, 2003.
- [10.3] W. Cholewa, W. Moczulski. *Diagnostyka techniczna maszyn. Pomiary i analiza sygnałów*, vol. 1758 serii *Skrypty uczelniane*. Politechnika Śląska, Gliwice, 1993.
- [10.4] G. A. Einicke, J. C. Ralston, C. O. Hargrave, D. C. Reid, D. W. Hainsworth. Longwall mining automation an application of minimum-variance smoothing. *IEEE Control Systems*, 28(6):28–37, 2008.
- [10.5] IEC 61260-1. *Electroacoustics – Octave-band and fractional-octave-band filters – Part 1: Specifications*, 2014.
- [10.6] J. Kiciński, i in. *Rotor Dynamics*. Institute of Fluid-Flow Machinery, Gdańsk, 2005.
- [10.7] J. Kościelny. *Diagnostyka zautomatyzowanych procesów przemysłowych*. Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2001.
- [10.8] R. G. Lyons. *Wprowadzenie do cyfrowego przetwarzania sygnałów*. WKiŁ, Warszawa, wyd. 2, 2010.

- [10.9] MATLAB. *version 7.7.0 (R2008b)*. The MathWorks Inc., Natick, Massachusetts, 2008.
- [10.10] W. Moczulski. *Diagnostyka techniczna. Metody pozyskiwania wiedzy*. Wydawnictwo Politechniki Śląskiej, 2002.
- [10.11] T. Opolski. *Urabianie mechaniczne i fizykalne skal*. Wydawnictwo Śląsk, Katowice, 1982.
- [10.12] R. J. Patton, P. M. Frank, R. N. Clark. *Issues of Fault Diagnosis for Dynamic Systems*. Springer-Verlag Berlin and Heidelberg, 2000.
- [10.13] M. Sikora, et al. Zintegrowany, szkieletowy system wspomagania decyzji dla systemów monitorowania procesów, urządzeń i zagrożeń. Raport, Instytut Technik Innowacyjnych EMAG, 2016.