

Andrzej SOKOŁOWSKI

P. 3361/03

**WYBRANE ZAGADNIENIA PROJEKTOWANIA  
UKŁADÓW DIAGNOSTYCZNYCH  
OBRABIARKI I PROCESU SKRAWANIA**



**GLIWICE 2003**

**Andrzej SOKOŁOWSKI**



**WYBRANE ZAGADNIENIA PROJEKTOWANIA  
UKŁADÓW DIAGNOSTYCZNYCH  
OBRABIARKI I PROCESU SKRAWANIA**

WYDAWNICTWO POLITECHNIKI ŚLĄSKIEJ  
GLIWICE 2003

**OPINIODAWCY**

Prof. dr hab. inż. Adam HAMROL  
Prof. dr hab. inż. Wojciech KACALAK

**KOLEGIUM REDAKCYJNE**

REDAKTOR NACZELNY — Prof. dr hab. Zygmunt KLESZCZEWSKI  
REDAKTOR DZIAŁU — Prof. dr hab. inż. Andrzej BUCHACZ  
SEKRETARZ REDAKCJI — Mgr Elżbieta LEŚKO

**REDAKCJA**  
Mgr Kazimiera SZAFIR

**REDAKCJA TECHNICZNA**  
Alicja NOWACKA

**MECHANIKA z. 142**  
Nr kol. 1575

ISSN 0434-0817

© Copyright by Andrzej Sokolowski  
Gliwice 2003

**SPIS TREŚCI**

Wstęp	11
1. WPROWADZENIE	11
2. PRZEDMIOTY PRACY W ZAKRESIE FIZYKI	12
2.1. Ciężkość i siła ciężkości w układach odniesienia	12
2.1.1. Ciężkość w układach odniesienia przemieszczających się ruchem jednostajnym	12
2.1.2. Ciężkość w układach odniesienia przemieszczających się ruchem jednostajnie przyspieszonym	12
2.2. Ciężkość w układach odniesienia przemieszczających się ruchem jednostajnie przyspieszonym	12
2.3. Ciężkość w układach odniesienia przemieszczających się ruchem jednostajnie przyspieszonym	12
2.4. Ciężkość w układach odniesienia przemieszczających się ruchem jednostajnie przyspieszonym	12
3. CIEPŁOTA I PRACA	13
3.1. Ciepłota	13
3.2. Praca	13
3.3. Praca	13
4. CHARAKTERYSTYKA I ZASTOSOWANIE METOD	14
4.1. Metody	14
4.2. Metody	14
4.3. Metody	14
4.4. Metody	14
4.5. Metody	14
4.6. Metody	14
4.7. Metody	14
4.8. Metody	14
4.9. Metody	14
4.10. Metody	14
4.11. Metody	14
4.12. Metody	14
4.13. Metody	14
4.14. Metody	14
4.15. Metody	14
4.16. Metody	14
4.17. Metody	14
4.18. Metody	14
4.19. Metody	14
4.20. Metody	14

*Pracę tę dedykuję Glorii,  
mojej trzyletniej córce.*

**/ Andrzej Sokolowski /**

## SPIS TREŚCI

Wykaz podstawowych oznaczeń .....	11
<b>1. WPROWADZENIE .....</b>	<b>13</b>
<b>2. PRZEDMIOT PRACY W UJĘCIU LITERATUROWYM .....</b>	<b>15</b>
2.1. Charakterystyka badań prowadzonych w dziedzinie diagnostyki obrabiarki i procesu skrawania .....	15
2.1.1. Potrzeba wspomaganie projektowania układów diagnostycznych .....	22
2.2. Inteligentny Projektant Układów Diagnostycznych .....	23
2.2.1. Koncepcja Inteligentnego Układu Diagnostycznego (IUD) .....	23
2.2.2. Zastosowanie koncepcji IUD w Inteligentnym Projektancie Układów Diagnostycznych (IPUD) .....	26
2.3. Wstępny wybór oraz ogólna charakterystyka metod i algorytmów .....	29
2.3.1. Sieci neuronowe .....	30
2.3.2. Logika rozmyta – wnioskowanie rozmyte .....	31
2.3.3. Algorytmy genetyczne i ewolucyjne .....	33
2.3.4. Dyskusja uzupełniająca .....	34
<b>3. CEL, TEZA I ZAKRES PRACY .....</b>	<b>36</b>
3.1. Cel pracy .....	36
3.2. Teza pracy .....	37
3.3. Zakres pracy .....	39
<b>4. CHARAKTERYSTYKA ZASTOSOWANYCH METOD I ALGORYTMÓW .....</b>	<b>40</b>
4.1. Sieć neuronowa FFBP .....	41
4.1.1. Struktura i podstawy treningu sieci neuronowej FFBP .....	41
4.1.2. Metody szacowania liczby komórek w warstwie ukrytej .....	44
4.1.3. Metody oceny istotności danych bazujące na sieci neuronowej FFBP .....	47
4.2. Algorytmy genetyczne .....	50
4.3. System logiki rozmytej .....	51
4.3.1. Struktura systemu logiki rozmytej .....	52
4.3.2. Konstruowanie systemu logiki rozmytej .....	54
4.4. Hybrydowa metoda oceny istotności danych SR+AG .....	60
4.5. Metody oceny istotności danych bazujące na macierzy rozproszenia SM+SFS i SM+AG .....	61
4.6. Zestawienie zastosowanych metod i algorytmów .....	62
4.6.1. Ocena istotności danych i selekcja istotnych danych .....	62

Część badań charakteryzowanych w niniejszej pracy finansowana była ze środków Komitetu Badań Naukowych w formie Projektu Badawczego nr 707319101 „Badania nad wykorzystaniem sygnałów wibroakustycznych do nadzorowania zużycia ostrza skrawającego”, Projektu Badawczego nr 7T07 D 010 08 „Inteligentny system wspomaganie projektowania układów nadzorujących stan procesu skrawania” oraz Projektu Badawczego nr 7 TO7 D 005 17 „Inteligentne narzędzia w diagnostyce procesu skrawania”.

4.6.2. Zasady realizacji testów .....	64
4.7. Kryteria i sposoby oceny zastosowanych metod selekcji i integracji danych ....	66
4.7.1. Uzupełniające kryteria i sposoby oceny metod selekcji danych .....	68
4.7.2. Uzupełniające kryteria i sposoby oceny metod integracji danych .....	72
<b>5. TESTY WSTĘPNE .....</b>	<b>73</b>
5.1. Zadanie parzystości .....	75
5.2. Zadanie graficzne .....	82
5.2.1. Zastosowanie metod selekcji danych bazujących na sieci neuronowej FFBP .....	82
5.2.2. Przykład zastosowania systemu logiki rozmytej .....	89
5.3. Podsumowanie testów wstępnych .....	93
<b>6. DIAGNOSTYKA STANU WIERTEŁ PODCZAS WIERCENIA WIELOWRZECIONOWEGO .....</b>	<b>97</b>
6.1. Opis stanowiska pomiarowego i ekstrakcji cech sygnałów pomiarowych .....	97
6.2. Wstępne analizy danych .....	100
6.2.1. Próba wyboru istotnych cech sygnałów pomiarowych .....	101
6.2.2. Próba selekcji danych z zastosowaniem analizy korelacji rangowej .....	103
6.3. Integracja danych z zastosowaniem sieci neuronowej FFBP .....	105
6.3.1. Integracja danych wyselekcjonowanych z zastosowaniem metod bazujących na sieci neuronowej FFBP .....	105
6.3.2. Integracja danych wyselekcjonowanych z zastosowaniem metod bazujących na macierzy rozproszenia i metody SR+AG .....	113
6.3.3. Podsumowanie .....	116
6.4. Zastosowanie systemu logiki rozmytej do integracji danych .....	118
6.5. Ocena końcowa zastosowanych metod selekcji i integracji danych .....	123
<b>7. DIAGNOSTYKA PRZEDMIOTU OBRABIANEGO – PROBLEM ZADZIORÓW POOBRÓBKOWYCH .....</b>	<b>128</b>
7.1. Wprowadzenie .....	128
7.2. Opis badań eksperymentalnych i wstępna analiza wyników .....	130
7.2.1. Analiza wpływu parametrów obróbki na wysokość zadziorów i próba wyznaczenia modelu wysokości zadziorów w funkcji parametrów obróbki .....	132
7.3. Przetwarzanie sygnału pomiarowego dla celów wyznaczenia modeli wysokości zadziorów poobróbkowych .....	134
7.4. Zastosowanie metod statystycznych w zadaniu wyznaczenia modelu wysokości zadziorów .....	136
7.4.1. Zastosowanie analizy korelacji .....	138
7.4.2. Zastosowanie miar jakości modeli jako wielkości kryterialnych .....	139

7.4.3. Podsumowanie .....	142
7.5. Zastosowanie metod selekcji danych bazujących na sieci neuronowej FFBP ....	144
7.5.1. Problem wyboru wartości drogi narzędzia .....	145
7.5.2. Problem wyboru cechy sygnału pomiarowego i wartości drogi narzędzia .....	148
7.5.3. Problem wyboru wartości parametrów metod wstępnego przetwarzania sygnału pomiarowego i drogi narzędzia .....	150
7.5.4. Podsumowanie .....	154
7.6. Zastosowanie metody SR+AG w zadaniu wyznaczenia modelu wysokości zadziorów poobróbkowych .....	154
7.7. Modele wysokości zadziorów poobróbkowych o postaci sieci neuronowej FFBP i systemu logiki rozmytej .....	156
7.8. Wnioski podsumowujące rozdział .....	162
<b>8. DIAGNOSTYKA ZUŻYCIA NARZĘDZIA PODCZAS TOCZENIA .....</b>	<b>165</b>
8.1. Charakterystyka badań eksperymentalnych i wstępna analiza sygnałów pomiarowych .....	165
8.1.1. Stanowisko pomiarowe i opis przeprowadzonych pomiarów .....	165
8.1.2. Konwencjonalne próby wyznaczenia symptomów zużycia ostrza .....	168
8.2. Wybrane zagadnienia realizacji selekcji i integracji danych w zadaniu diagnozowania zużycia ostrza podczas toczenia .....	170
8.2.1. Przyjęcie koncepcji układu diagnostycznego i określenie postaci zbiorów danych .....	170
8.2.2. Struktura podstawowa oraz wybrane parametry symulacji sieci neuronowej FFBP .....	172
8.2.3. Próba selekcji danych z zastosowaniem metody leave-one-out .....	175
8.2.4. Selekcja danych z zastosowaniem analizy korelacji rangowej .....	176
8.3. Integracja danych z zastosowaniem sieci neuronowej FFBP .....	179
8.3.1. Integracja danych wyselekcjonowanych z zastosowaniem metod bazujących na sieci neuronowej FFBP .....	179
8.3.2. Integracja danych wyselekcjonowanych z zastosowaniem metod bazujących na macierzy rozproszenia i metody SR+AG .....	184
8.3.3. Podsumowanie zastosowań sieci neuronowej FFBP .....	186
8.4. Zastosowanie systemu logiki rozmytej do integracji danych .....	187
8.5. Podsumowanie badań .....	188
<b>9. DIAGNOSTYKA ODKSZTAŁCEŃ TERMICZNYCH SZLIFIERKI ....</b>	<b>192</b>
9.1. Stanowisko pomiarowe i charakterystyka sygnałów pomiarowych .....	193
9.2. Testy zdolności interpolacji sieci neuronowej FFBP .....	199
9.3. Próba selekcji danych .....	202

9.4. Podsumowanie badań .....	205
<b>10. PODSUMOWANIE PRACY .....</b>	<b>208</b>
<b>Literatura .....</b>	<b>213</b>
<b>Streszczenia .....</b>	<b>230</b>

## CONTENTS

<b>Basic notations .....</b>	<b>11</b>
<b>1. INTRODUCTION .....</b>	<b>13</b>
<b>2. SUBJECT OF THE DISSERTATION IN THE LIGHT OF LITERATURE REVIEW .....</b>	<b>15</b>
2.1. Characteristics of the research conducted in the field of machine tool and cutting process diagnostics .....	15
2.1.1. A need for aiding design of diagnostic systems .....	22
2.2. Intelligent Diagnostic System Designer .....	23
2.2.1. A concept of Intelligent Diagnostic System (IUD) .....	23
2.2.2. Application of the IUD concept in Intelligent Diagnostic System Designer (IPUD) .....	26
2.3. Preliminary selection and general characteristics of methods and algorithms ....	29
2.3.1. Neural networks .....	30
2.3.2. Fuzzy logic – fuzzy reasoning .....	31
2.3.3. Genetic algorithms and evolutionary algorithms .....	33
2.3.4. Complementary discussion .....	34
<b>3. AIM, THESIS AND SCOPE OF THE DISSERTATION .....</b>	<b>36</b>
3.1. Aim of the dissertation .....	36
3.2. Thesis of the dissertation .....	37
3.3. Scope of the dissertation .....	39
<b>4. CHARACTERISTICS OF THE METHODS AND ALGORITHMS APPLIED .....</b>	<b>40</b>
4.1. FFBP neural network .....	41
4.1.1. Structure and training basis of the FFBP neural network .....	41
4.1.2. Methods of hidden cell number estimation .....	44
4.1.3. Methods of data importance assessment based on the FFBP neural network .....	47
4.2. Genetic algorithms .....	50
4.3. Fuzzy logic system .....	51
4.3.1. Structure of the fuzzy logic system .....	52
4.3.2. Designing of the fuzzy logic system .....	54
4.4. Hybrid method of data importance assessment SR+AG .....	60
4.5. Methods of data importance assessment based on the scatter matrix SM+SFS and SM+AG .....	61
4.6. The methods and algorithms applied .....	62
4.6.1. Data importance assessment and important data selection .....	62

4.6.2. Rules for running the tests .....	64
4.7. Criteria and means of assessment of the applied data selection and integration methods .....	66
4.7.1. Supplementary criteria and means of the data selection method assessment .....	68
4.7.2. Supplementary criteria and means of the data integration method assessment.....	72
<b>5. PRELIMINARY TESTS .....</b>	<b>73</b>
5.1. Parity task .....	75
5.2. Graphical task .....	82
5.2.1. Application of the data selection methods based on FFBP neural network .....	82
5.2.2. An example of fuzzy logic system application .....	89
5.3. Summary of the preliminary tests .....	93
<b>6. DRILL STATE DIAGNOSTICS DURING MULTISPINDLE DRILLING .....</b>	<b>97</b>
6.1. Description of measuring set-up and measured signal feature extraction .....	97
6.2. Preliminary data analysis .....	100
6.2.1. An attempt of important measured signal feature selection .....	101
6.2.2. An attempt of data selection based on the rang correlation analysis .....	103
6.3. Data integration with the FFBP neural network .....	105
6.3.1. Integration of the data selected with the FFBP neural network based methods .....	105
6.3.2. Integration of the data selected with the scatter matrix based methods and the SR+AG method .....	113
6.3.3. Summary .....	116
6.4. Application of the fuzzy logic system for data integration .....	118
6.5. Final assessment of the data selection and integration methods applied .....	123
<b>7. WORKPIECE DIAGNOSTICS – CUTTING BURR PROBLEM .....</b>	<b>128</b>
7.1. Introduction .....	128
7.2. Description of experimental research and preliminary data analysis .....	130
7.2.1. Analysis of influence of machining parameters on the burr height and attempt of burr height model determination as a function of machining parameters .....	132
7.3. Measured signal processing for the burr height model determination .....	134
7.4. Application of statistic methods in the burr height model determination task .....	136
7.4.1. Application of statistic analysis .....	138

7.4.2. Application of the model quality measure as a criterion quantity .....	139
7.4.3. Summary .....	142
7.5. Application of the FFBP neural network based data selection methods .....	144
7.5.1. Problem of drill path value selection .....	145
7.5.2. Problem of measured signal feature selection and drill path value selection .....	148
7.5.3. Problem of parameter value selection of preliminary signal processing methods and drill path value selection .....	150
7.5.4. Summary .....	154
7.6. Application of the SR+AG method in the burr height model determination task .....	154
7.7. Burr height models developed with the FFBP neural network and the fuzzy logic system .....	156
7.8. Conclusions summarising the chapter .....	162
<b>8. CUTTING TOOL DIAGNOSTICS DURING TURNING .....</b>	<b>165</b>
8.1. Characteristics of experimental research and preliminary measured signal analysis .....	165
8.1.1. Measuring set-up and description of the measurements conducted .....	165
8.1.2. Conventional attempts of tool wear symptom determination .....	168
8.2. Selected problems of data selection and integration while diagnosing tool wear during turning .....	170
8.2.1. Assumptions on a diagnostic system concept and data set determination .....	170
8.2.2. Basic structure and selected parameters of the FFBP neural network simulations .....	172
8.2.3. An attempt of data selection with leave-one-out method .....	175
8.2.4. Data selection with the rang correlation analysis .....	176
8.3. Data integration with the FFBP neural network .....	179
8.3.1. Integration of the data selected with the FFBP neural network based methods .....	179
8.3.2. Integration of the data selected with the scatter matrix based methods and the SR+AG method .....	184
8.3.3. Summary of the FFBP neural network application .....	186
8.4. Application of the fuzzy logic system for data integration .....	187
8.5. Summary of the research .....	188
<b>9. DIAGNOSTICS OF GRINDING MACHINE THERMAL DEFORMATION .....</b>	<b>192</b>
9.1. Measuring set-up and characteristics of the measured signals .....	193

9.2	The tests of interpolation ability of the FFBP neural network .....	199
9.3.	An attempt of data selection .....	202
9.4.	Summary of the research .....	205
<b>10.</b>	<b>THE SUMMARY OF THE DISSERTATION .....</b>	<b>208</b>
	<b>REFERENCES .....</b>	<b>213</b>
	<b>Abstracts .....</b>	<b>230</b>

## WYKAZ PODSTAWOWYCH OZNACZEŃ

(a, b)	- para, np. liczb;
[a, b]	- przedział zmian wartości, stosowany jest również zapis $\pm a$ , odpowiadający oznaczeniu [-a, a];
{a, b, ...}	- zbiór, np. liczb;
$\alpha_M$	- współczynnik momentum;
$\eta_c$	- współczynnik treningu o stałej wartości;
$\eta_F$	- współczynnik treningu o wartości zależnej od struktury sieci neuronowej FFBP, wartość współczynnika wyznaczana jest metodą fan-in;
ABS(...)	- wartość bezwzględna;
AG	- algorytm genetyczny, oznaczenie stosowane również w odniesieniu do metody konstruowania bazy reguł systemu logiki rozmytej z zastosowaniem algorytmu genetycznego;
AG-H*	- ogólne oznaczenie hybrydowej metody konstruowania bazy reguł systemu logiki rozmytej z zastosowaniem algorytmu genetycznego; w zależności od przyjętego podejścia, oznaczenia szczegółowe przyjmują postać AG-H1 i AG-H2;
ATS-cum	- kumulacyjny algorytm treningu sieci neuronowej FFBP;
ATS-des	- algorytm (metoda) szacowania liczby komórek ukrytych sieci neuronowej FFBP;
ATS-inc	- inkrementalny algorytm treningu sieci neuronowej FFBP;
BP	- algorytm wstecznej propagacji błędów;
BPI <sub>AV</sub>	- średni błąd powtarzalności wyznaczania istotności danych;
BPI <sub>MAX</sub>	- maksymalny błąd powtarzalności wyznaczania istotności danych;
E <sub>MAX</sub>	- błąd maksymalny treningu, weryfikacji lub testów sieci neuronowej;
E <sub>RMS</sub>	- błąd skuteczny treningu, weryfikacji lub testów sieci neuronowej;
FFBP	- wielowarstwowa sieć neuronowa trenowana algorytmem wstecznej propagacji błędów BP;
FL	- logika rozmyta (system logiki rozmytej – system FL);
FL(A, B)	- ogólne oznaczenie systemu logiki rozmytej skonstruowanego z zastosowaniem metody A do inicjalizacji funkcji przynależności oraz metody B do konstruowania bazy reguł, oznaczenia metod A i B mogą być pomijane w zależności od kontekstu;
H <sub>Z</sub>	- wysokość zadzioru;
ID	- istotność danych;
ID <sub>P</sub>	- próg istotności danych;
J <sub>SM</sub>	- ślad macierzy rozproszenia (SM);



KFM	- sieć neuronowa Kohonen's Feature Map, również oznaczenie metody inicjalizacji funkcji przynależności systemu logiki rozmytej bazującej na sieci neuronowej Kohonen's Feature Map;
MF	- funkcja przynależności systemu logiki rozmytej;
MF <sub>WE</sub> , MF <sub>WY</sub>	- wejściowe i wyjściowe funkcje przynależności systemu logiki rozmytej;
MKBR	- metoda konstruowania bazy reguł systemu logiki rozmytej;
MOI	- metoda oceny istotności danych;
MS( MOI )	- metoda selekcji danych bazująca na metodzie oceny istotności MOI;
OPN-PS	- Obrabiarka; Przedmiot; Narzędzie – Proces Skrawania;
pr <sub>K</sub>	- parametr metody pruningu komórek;
pr <sub>w</sub>	- parametr metody pruningu wag;
R, R <sub>M</sub>	- współczynnik korelacji;
RN	- metoda równomiernej inicjalizacji funkcji przynależności systemu logiki rozmytej;
S	- sprawność klasyfikacji;
S <sub>FFBP</sub>	- sprawność sieci neuronowej FFBP stosowanej jako klasyfikator;
S <sub>FL</sub>	- sprawność systemu logiki rozmytej stosowanego jako klasyfikator;
SFS	- algorytm sekwencyjnego przeszukiwania w przód;
SM+AG	- metoda oceny istotności danych bazująca na macierzy rozproszenia i algorytmie genetycznym;
SM+SFS	- metoda oceny istotności danych bazująca na macierzy rozproszenia i algorytmie sekwencyjnego przeszukiwania w przód (SFS);
S <sub>P</sub>	- próg sprawności klasyfikacji;
SR+AG	- hybrydowa metoda oceny istotności danych bazująca na sieciach neuronowych i algorytmie genetycznym;
SW+GS	- metoda szacowania liczby komórek ukrytych, bazująca na symulowanym wyżarzaniu i algorytmie gradientów sprzężonych;
S <sub>Z</sub>	- zastępcza sprawność klasyfikacji;
UP <sub>K</sub>	- współczynnik kary, parametr metody SW+GS;
UP <sub>w</sub>	- współczynnik kary, parametr metody SR+AG;
VB	- ogólne oznaczenie zużycia powierzchni przyłożenia ostrza skrawającego;
WS <sub>R</sub>	- wartość skuteczna wartości reszt;
WTA	- algorytm treningu sieci neuronowych, również oznaczenie sieci neuronowych trenowanych algorytmem Winer-Take-All;
WTA(*)	- ogólne oznaczenie metody konstruowania bazy reguł systemu logiki rozmytej bazującej na algorytmie WTA, oznaczenia szczegółowe przyjmują postać w zależności od przyjętej minimalnej siły reguł WTA(0.0) i WTA(0.1)

## 1. WPROWADZENIE

Stale rosnące wymagania stawiane przedmiotom obrabianym stanowią jeden z zasadniczych czynników motywujących dynamiczny rozwój przemysłu obrabiarkowego. Ogólnie rozumiane wymagania odnoszą się nie tylko do zwiększenia dokładności wymiarowo - kształtowej i zmniejszenia chropowatości powierzchni obrabianej, ale dotyczą także obniżenia kosztów i skrócenia czasu wytwarzania. Spełnienie wymagań związane jest, między innymi, z koniecznością uzyskania wysokiego stopnia automatyzacji obrabiarek, co w połączeniu z rozwojem układów sterowania prowadzi do budowy gniazd obróbczych, zautomatyzowanych linii produkcyjnych i ostatecznie elastycznych systemów produkcyjnych (ESP).

Rozpatrując ekonomiczne aspekty wdrażania elastycznych systemów produkcyjnych za truizm, w świetle dużej liczby publikacji, uznać można stwierdzenie, iż jeden z najistotniejszych składników kosztów wytwarzania związany jest z możliwością zapewnienia ciągłej i bezobsługowej pracy ESP poprzez stosowanie odpowiednich układów diagnostycznych i nadzorujących. Przytaczając za dyskusją przeprowadzoną w [Jemielniak, 2001] stwierdza się, że brak stosowania układów diagnostycznych prowadzić może do związanych z usuwaniem awarii postojów, powodujących radykalne zmniejszenie efektywnego czasu pracy ESP. W konsekwencji, aby zabezpieczyć się przed awariami, stosowane są zaniżone parametry skrawania, co wtórnie powoduje wzrost kosztów wytwarzania. Należy także zwrócić uwagę na zdecydowane ograniczenie roli operatorów obrabiarek, których działania oparte na doświadczeniu i wiedzy mogłyby w pewnym stopniu zastępować funkcje realizowane przez układy diagnostyczne. Ograniczenie to związane jest nie tylko z dążeniem do autonomiczności ESP, ale wynika również ze zdecydowanie utrudnionego dostępu do osłoniętej przestrzeni obróbkowej, w której prowadzona jest obróbka z wysokimi parametrami skrawania i dużą ilością cieczy chłodząco - smarującej.

Uznając potrzebę diagnostyki nowoczesnych obrabiarek i procesów obróbczych, konieczne jest odniesienie się do stanu rozwoju układów diagnostycznych. Zaznaczyć należy, że rozważając zagadnienie diagnostyki obrabiarki i procesu skrawania rozważa się nie tylko maszynę (obrabiarkę) i realizowany proces (proces skrawania), ale również przedmiot obrabiany i narzędzie. Zatem zagadnienie to odzwierciedla uogólniony problem diagnostyki OPN-PS (Obrabiarki; Przedmiotu; Narzędzia – Procesu Skrawania) [Kosmol, 1995]. Kontynuując, stan rozwoju układów diagnostycznych scharakteryzować można na przykładzie wybranych, reprezentatywnych w uznaniu autora, pozycji literaturowych [TCM Workshop, 1993], [Sokołowski, 1995], [Byrne et al., 1995], [Jemielniak i Kosmol, 1995], [Ketteler, 1999] oraz [Jemielniak, 2001].

Podjmując charakterystykę stwierdzić należy, iż już w połowie lat 80. większość liczących się producentów oferowała obrabiarki ze zintegrowanymi układami diagnostycznymi OPN-PS. Dostępne również były układy niezależne, dedykowane diagnostyce wybranych procesów lub elementów obrabiarek. Niemniej jednak, jak wykazała praktyka produkcyjna, większość układów diagnostycznych eksploatowana była w okresie nie dłuższym niż jeden rok. Użytkownicy zauważali, że ówczesne układy diagnostyczne były zbyt zawodne i równocześnie zbyt drogie oraz trudne w obsłudze. Zmusiło to zarówno producentów, jak i ośrodki badawcze do gruntownej analizy przyczyn tego niepowodzenia oraz podjęcia intensywnych badań.

Pomimo podjętych prac i poszerzenia oferty układów diagnostycznych zasygnalizowane problemy nie zostały rozwiązane w kolejnej dekadzie. Za typowe w połowie lat 90. uznać można opinie wyrażane podczas spotkań w ramach International Institution for Production Engineering Research (CIRP), w których udział brali zarówno przedstawiciele czołowych producentów układów diagnostycznych, użytkownicy takich układów jak i przedstawiciele ośrodków akademickich. Większość opinii (np. [TCM Workshop, 1993], [Byrne et al., 1995]) dotyczących stanu rozwoju układów diagnostycznych sprowadzić można do stwierdzeń o małej uniwersalności i wiarygodności układów, nieprzydatności stosowanych strategii w przypadku małych serii przedmiotów obrabianych, zawężonym zakresie parametrów skrawania oraz ewidentnym braku układów diagnostyki naturalnego zużycia ostrzy skrawających. Wnioski wynikające ze spotkań nie odnosiły się jedynie do krytyki stanu bieżącego. Dyskutowano także kierunki przyszłych prac i badań wskazując jednoznacznie na konieczność rozwoju wieloczujnikowych układów diagnostycznych i konieczność zdecydowanego rozszerzenia procedur przetwarzania sygnałów pomiarowych.

Odnosząc się ostatecznie do stanu obecnego, w dalszym ciągu kłopotliwe byłoby uznanie problemu diagnostyki OPN-PS za rozwiązany. Świadczyć o tym może, iż jedynie 29% producentów obrabiarek i 38% ich użytkowników pozytywnie ocenia proponowane rozwiązania. Za niemniej znaczącą uznać należy kontynuację szeroko zakrojonych badań, których przykładem jest sygnalizowany w [Jemielniak, 2001] światowy program badawczy „Sensor Fused Intelligent Monitoring System for Machining”.

Stwierdzając nie w pełni zadowalający stan rozwoju układów diagnostycznych OPN-PS zasadne jest podjęcie prób wskazania kierunków badań potencjalnie prowadzących do uzyskania efektywniejszych rozwiązań. Autor sugeruje skoncentrowanie badań na stanowiącym przedmiot niniejszej pracy zagadnieniu wspomaganie projektowania układów diagnostycznych OPN-PS. Potrzeba wspomaganie prac inżynierskich wydaje się być oczywista i nie wymaga uzasadnienia. W przypadku układów diagnostycznych OPN-PS, potrzeba ta staje się w uznaniu autora koniecznością, co rozważane i uzasadniane jest w kolejnym rozdziale pracy.

## 2. PRZEDMIOT PRACY W UJĘCIU LITERATUROWYM

Dyskusję stanowiącego przedmiot pracy zagadnienia wspomaganie projektowania układów diagnostycznych rozpoczęto od próby dokonania wybiórczej, syntetycznej charakterystyki badań prowadzonych w dziedzinie diagnostyki OPN-PS. Następnie rozważany jest problem praktycznej realizacji wspomaganie projektowania układów diagnostycznych. Charakteryzowana jest koncepcja Inteligentnego Układu Diagnostycznego (IUD) oraz jej implementacja w tzw. Inteligentnym Projektancie Układów Diagnostycznych (IPUD).

Jak to zostanie przedstawione, dyskusja zagadnienia wspomaganie projektowania układów diagnostycznych prowadzi do uwypuklenia istotności ogólnie rozumianych metod przetwarzania danych. Stąd też w drugiej części rozdziału przedstawiono charakterystykę wybranych metod oraz dokonano wstępnego wyboru metod analizowanych w dalszej części pracy. Należy podkreślić, że dokonany wybór ma na celu jedynie zasygnalizowanie przyjętych podejść oraz umożliwienie określenia celu, tezy i zakresu pracy. Zasadnicza dyskusja zastosowanych metod podejmowana jest natomiast w rozdziale 4.

### 2.1. Charakterystyka badań prowadzonych w dziedzinie diagnostyki obrabiarki i procesu skrawania

Przedstawiany poniżej przegląd literaturowy ukierunkowano na zobrazowanie ewolucji badań w dziedzinie diagnostyki OPN-PS. Ze względu na obszerność i złożoność zagadnienia diagnostyki OPN-PS w opisach poruszany jest głównie reprezentatywny, uznawany powszechnie za jeden z najistotniejszych, problem diagnostyki narzędzia skrawającego. Dodać należy, iż przytaczane są jedynie wybrane, sygnalizujące różne orientacje badań pozycje literaturowe oraz pomijana jest charakterystyka komercyjnie dostępnych układów diagnostycznych, którą znaleźć można w [Jemielniak, 1998].

Charakteryzując badania prowadzone w latach 80. i na początku lat 90., zauważa się zróżnicowanie kierunków badań, wyrażające się głównie próbami analiz zróżnicowanych sygnałów pomiarowych. Jedną z najczęściej i najchętniej analizowanych wielkości była siła skrawania (składowe siły skrawania), której współzmiennność ze zużyciem ostrza związana jest ze zmianą charakteru kontaktu oraz zmianą charakterystyki tarcia pomiędzy powierzchnią przyłożenia i powierzchnią natarcia a przedmiotem obrabianym [Shiraishi, 1988]. Przykładem kompleksowych prób zastosowań pomiarów siły skrawania podczas toczenia w diagnostyce zużycia zarówno naturalnego (VB), jak i katastroficznego są prace prowadzone w Politechnice Warszawskiej, np. [Bajtyngier i Jemielniak, 1988] i [Jemielniak, 1995], podsumowane w [Jemielniak, 2001]. Podjmując próby zastosowania pomiarów siły skrawania zwracano uwagę na konieczność stosowania odpowiednich metod przetwarzania sygnału pomiarowego. Uwypuklano niekorzystną, dużą czułość siły skrawania na zmiany parametrów skrawania,

a także zmienność wynikającą z charakteru prowadzonej obróbki. Typowym przykładem jest w tym przypadku frezowanie. W [Virck i Tlusty, 1992] podejmowano próby analizy wpływu nierównomiernego rozkładu posuwu na ostrze powodowanego złamaniem ostrzy głowicy frezarskiej. Natomiast w [Richter i Spiewak, 1990] dążono do zmniejszenia zmienności analizowanego sygnału poprzez zastosowanie metody ruchomej średniej. Stosowano także bardziej rozbudowane metody przetwarzania sygnału pomiarowego, np. [Szabo et al., 1989]. W pracy tej prowadzono analizy składowej obwodowej siły frezowania metodą Data Dependant System. Natomiast w [Basil, 1994] analizowano składową posuwową siły wiercenia w dziedzinie częstotliwości. W wielu pracach zwracano uwagę na kłopotliwy, wymagający zazwyczaj zmian konstrukcyjnych obrabiarki, montaż czujników siły skrawania. Próba rozwiązania tego problemu było stosowanie pomiarów wielkości wtórnych w stosunku do sił skrawania, np. prądu lub mocy silników posuwowych [Constantinides i Bennett, 1987], [Kosmol i Sokołowski, 1991].

Analizując zastosowania drgań jako kolejnej wielkości stanowiącej potencjalne źródło informacji o zużyciu ostrza zauważa się stosunkowo dużą liczbę prac mających charakter badań podstawowych, np. [Mehta et al., 1983], [Rao, 1986]. W pracach tych koncentrowano się na wskazaniu pasma częstotliwości, w którym ujawniały się zjawiska związane z naturalnym zużyciem ostrza skrawającego. Następnie, podobnie jak w przypadku prób zastosowań pomiarów siły skrawania, wykazywano znaczną zależność poziomu drgań od parametrów skrawania, np. [Bahre et al., 1992]. Ciekawym przykładem prób opracowania strategii identyfikacji zużycia naturalnego ostrza podczas toczenia jest zastosowanie analizy cepstralnej [Mechanik, 1989] i [Lierath et al., 1988]. Porównując uzyskiwane wyniki zauważa się jednakże zasadnicze rozbieżności. W [Mechanik, 1989] wykazano bardzo małą przydatność cepstrum do wyznaczenia symptomu naturalnego zużycia ostrza, czemu zaprzeczają wnioski przytaczane w [Lierath et al., 1988]. Badania nad zastosowaniem pomiarów drgań w układach diagnostycznych narzędzia prowadzono również w odniesieniu do zużycia katastroficznego. Przykładowo, w [Kim i Klamecki, 1990] zastosowano metodę wzorca poprawnego przebiegu obróbki w celu identyfikacji wykruszeń ostrza, bazującej na pomiarze przyspieszeń drgań skrętnych wrzeciona frezarki.

Intensywne badania prowadzono nad zastosowaniem pomiarów emisji akustycznej (EA). Za klasyczne uznać można próby określenia współzmienności wskaźników zużycia ostrza z wartością skuteczną sygnału EA, współczynnikami dewiacji i spłaszczenia, czy też częstotliwością przejść przez poziom zerowy, np. [Teti i Dornfeld, 1989], [Diniz et al., 1992]. Analizowano również spowodowane zużyciem VB zmiany poziomu emisji akustycznej występujące podczas wcinania ostrza skrawającego [Takeshita i Inasaki, 1991] lub zmiany energii EA [Emel i Kannatey-Asibu, 1991]. Przykładem stosowania bardziej wyrafinowanych metod przetwarzania sygnału pomiarowego jest [Liang i Dornfeld, 1989]. Celem badań było wykazanie współzmienności zużycia naturalnego z parametrami modelu autoregresji bieżącej

wartości skutecznej emisji akustycznej. W [Diei i Dornfeld, 1987] zastosowano natomiast filtrację grzebieniową sygnału EA w celu wskazania cech sygnału niezależnych od parametrów skrawania. Prowadzono także badania nad wykorzystaniem pomiarów emisji akustycznej do diagnostyki katastroficznego zużycia narzędzi. W tym przypadku koncentrowano się zazwyczaj na pomiarach energii EA, wyzwalanej w chwili złamania lub wykruszenia ostrza skrawającego [König et al., 1992].

Przytoczone pozycje literaturowe oczywiście nie wyczerpują charakterystyki stosowanych podejść. W formie uzupełnienia wskazuje się na uznane za interesujące próby zastosowania metod wizyjnych i optoelektronicznych [Giusti et al., 1987]. W [Takata et al., 1987] zaproponowano pomiar prędkości obrotowej wrzeciona frezarki jako wielkości, której analiza dostarczała informacji o zużyciu ostrzy narzędzia. Odmienne podejście do diagnostyki narzędzi obrotowych przedstawiono w [Takata et al., 1986]. W pracy tej analizowano dźwięk emitowany podczas skrawania na centrum obróbczym, bazując na krótkoczasowych widmach mocy stosowanych w analizie mowy. Zwraca się również uwagę na próby prognozowania zużycia narzędzia z zastosowaniem modeli analitycznych [Gawlik i Zębała, 1995].

W tym miejscu dogodne a zarazem konieczne w uznaniu autora jest uwzględnienie zapoczątkowanej na przełomie lat 80. i 90. nowej orientacji badań w dziedzinie diagnostyki OPN-PS. Prekursorem tej orientacji był Rangwala, którego prace z lat 1986-1990 podsumowano między innymi w [Rangwala i Dornfeld, 1990]. Rangwala traktowany jest jako prekursor zastosowań sieci neuronowych w diagnostyce zużycia narzędzi skrawających. W swych badaniach Rangwala zastosował wielowarstwową sieć neuronową trenowaną algorytmem wstecznej propagacji błędów (sieć neuronowa Feed Forward Back Propagation – FFBP). Gwoli ścisłości zaznacza się, iż zastosowanie sieci możliwe było po opublikowaniu prac Rumelhardta ([Rumelhardt et al., 1986]), który zaproponował efektywny algorytm treningu sieci wielowarstwowych. W pracach Rangwali podejmowano także próby wyboru istotnych danych stosując metodę macierzy rozproszenia (SM) skojarzoną z algorytmem sekwencyjnego przeszukiwania w przód (SFS). Kontynuację prac Rangwali stanowiły badania przedstawione w [Choi et al., 1990] i [Wang i Dornfeld, 1992]. Podobnie jak Rangwala, autorzy tych prac skupili się na klasyfikacji naturalnego zużycia ostrza podczas toczenia oraz zastosowali analogiczną metodę wyboru istotnych danych.

Opublikowanie prac Rangwali oraz rosnące zainteresowanie sieciami neuronowymi spowodowały lawinowy wzrost liczby badań. W [Barton i Thangaraj, 1991] zastosowano sieć neuronową FFBP do diagnostyki stanu wiertel, bazując na pomiarach drgań wrzeciennika centrum obróbczego. Następnie wskazać można na próby zastosowania sieci FFBP do modelowania zależności pomiędzy parametrami obciążania ściernicy i chropowatością powierzchni przedmiotu obrobionego [Sakakura i Inasaki, 1992]. Istotne są także badania wpływu zużycia na dokładność wymiarową przedmiotu obrabianego podczas toczenia [Hamrol i Twardowski, 1995]. Specyficzne podejście opisano w [Monostori, 1992], [Monostori, 1993].

W badaniach tych „uczono” sieć FFBP rozpoznawania głębokości skrawania w przypadku skrawania ostrym narzędziem. Natomiast wyznaczone w trybie testowania sieci różnice pomiędzy obliczoną i znaną, rzeczywistą głębokością skrawania interpretowano jako wpływ postępującego zużycia VB ostrza. Dodać można, że liczbę danych wejściowych ustalono stosując wspomnianą wcześniej metodę bazującą na macierzy rozproszenia (SM) i algorytmie SFS.

Prace przedstawione w [Sunil et al., 1990] charakteryzują się znacznie szerszym ujęciem problemu zużycia ostrza skrawającego. Fizykalna zależność pomiędzy zużyciem i chropowatością powierzchni obrobionej stanowiła w tym przypadku podstawę zastosowania hierarchicznie połączonych sieci FFBP, wyznaczających w pierwszym kroku wartości wskaźników zużycia ostrza, a następnie wartości parametrów chropowatości. Podobnie szerszym ujęciem charakteryzują się badania przedstawione w [Teshima et al., 1993], w których analiz zużycia ostrza dokonywano na podstawie przetworzonych obrazów (zdjęć) powierzchni przyłożenia i natarcia. Także w [Bhar et al., 1994] zastosowano system wizyjny i sieć neuronową FFBP w diagnostyce zużycia naturalnego. Natomiast w [Yao i Fang, 1993] rozważano wpływ naturalnego zużycia ostrza nie tylko na chropowatość powierzchni obrobionej ale również na postać wiórów.

Analizując kolejne przykłady zastosowań sieci neuronowej FFBP zauważa się, że sieć ta przestała być jedynym i zasadniczym narzędziem przetwarzania danych. Przykładowo, w [Westkamper et al., 1995] analizowano możliwość zastosowania sieci FFBP w układzie sterowania adaptacyjnego geometrycznego. Następnie wskazać można na próby zastosowania systemu ekspertowego do podejmowania decyzji o sposobie eliminacji lub redukcji identyfikowanych z zastosowaniem sieci FFBP drgań szlifierki [Mori et al., 1992]. Sieć neuronową FFBP stosowano również w układach optymalizacji, np. [Marsumura et al., 1993], [Ko i Cho, 1994]. W [Ko i Cho, 1994] zastosowano kaskadowo połączone sieci neuronowe do optymalizacji parametrów frezowania w celu minimalizacji zużycia ostrza.

Sieć neuronowa FFBP nie stanowiła również jedynego typu sieci neuronowych i jedynej metody sztucznej inteligencji analizowanych w świetle diagnostyki OPN-PS. Pierwszym przykładem może być [Elanayar i Shin, 1992], gdzie zastosowano Radial Basis Neural Network do oceny naturalnego zużycia powierzchni przyłożenia i powierzchni natarcia. Relatywnie często stosowaną w próbach diagnostyki zarówno naturalnego zużycia ostrza (np. [Burke, 1989]), jak i zużycia katastroficznego (np. [Tansel i Mc Laughlin, 1991]) była sieć ART 2 [Carpenter i Grossberg, 1987]. Przykładem zastosowania kolejnej odmiany sieci ART, tj. sieci ART 2A [Carpenter et al., 1991], jest [Tarnig et al., 1994], gdzie skoncentrowano się na problemie diagnostyki drgań samowzбудnych występujących podczas wiercenia. Stosunkowo rzadko stosowane, aczkolwiek bardzo interesujące z punktu widzenia analogii do funkcjonowania mózgu ludzkiego, były sieci neuronowe opracowane przez Kohonena, *Kohonen's Feature Map* (KFM) lub sieć trenowana z zastosowaniem algorytmu

*Winer-Take-All* (WTA) [Kohonen, 1988]. Próby zastosowań sieci KFM w diagnostyce stanu ostrza skrawającego podczas toczenia i wiercenia przedstawiono w [Leem i Dreyfus, 1992]. W [Kacalak, 1995a] zastosowano natomiast zmodyfikowany algorytm treningu konkurencyjnego sieci Kohonena w zadaniu optymalizacji cykli współrzędnościowego szlifowania otworów. Wspomnieć również należy o interesujących badaniach porównawczych, np. porównaniu wyników zastosowań sieci neuronowej FFBP i sieci ART 2 [Choi et al., 1990] lub sieci ART 2 i sieci KFM [Jammu et al., 1993].

Podjęmowano także, jakkolwiek znacznie mniej intensywne w świetle liczby publikacji, próby stosowania logiki rozmytej (wnioskowania rozmytego) [Zadeh, 1983]. Wskazać w tym przypadku można na próby zastosowania logiki rozmytej (FL) w diagnostyce stanu narzędzia [Du et al., 1992] lub diagnostyce procesu formowania wiórów [Jawahir i Fei, 1993], a także do kompensacji zakłóceń procesów technologicznych [Kacalak i Wawryn, 1995]. Publikowane są również istotne dla dalszego rozwoju badań metod sztucznej inteligencji uogólnienia wybranych podejść, np. [Kacalak, 1995], oraz zestawienia i porównania wyników zastosowań sieci neuronowych i logiki rozmytej [Monostori, 1995], [Inasaki, 1995].

Dążąc do podsumowania badań przeprowadzonych do połowy lat 90., wskazuje się na chronologię badań zrealizowanych przez autora niniejszej pracy. Pierwszy etap badań, podsumowany między innymi w [Sokołowski i Kosmol, 1991] i [Sokołowski et al., 1992], sprowadzał się do klasycznych prób wyznaczenia symptomów zużycia ostrza skrawającego niezależnych od parametrów obróbki. Bazując na wnioskach z przeprowadzonych badań, na początku lat 90. podjęto próby zastosowań wybranych metod sztucznej inteligencji, tj. sieci neuronowych i hybrydowych systemów logiki rozmytej, tzw. neuro-fuzzy logic systems (np. [Sokołowski, 1993]), a także algorytmów genetycznych (np. [Sokołowski i Rehse, 1994]). Prowadzone prace pozwoliły na wstępne, a zarazem bardziej szczegółowe analizy wybranych zagadnień. Analizowano zagadnienie prognozowania wysokości zadziorów poobróbkowych z zastosowaniem sieci neuronowej FFBP i logiki rozmytej [Sokołowski et al., 1994a] oraz problem kompensacji odkształceń termicznych szlifierki [Campos et al., 1994]. Następnie porównywano wyniki uzyskiwane w przypadku zastosowań klasycznych metod przetwarzania danych [Sokołowski i Kosmol, 1995c] i sieci neuronowej FFBP [Sokołowski, 1995], [Sokołowski et al., 1995] i [König et al., 1995]. Porównywano także wybrane typy sieci neuronowych w zastosowaniach do diagnostyki OPN-PS [Sokołowski i Dornfeld, 1994a] i [Sokołowski i Kosmol, 1995e]. Przeprowadzone prace badawcze umożliwiły podjęcie prób uogólnień i zestawień uzyskanych wyników [Sokołowski i Dornfeld, 1994], [Sokołowski i Kosmol, 1994], a także [Sokołowski i Kosmol, 1995] i [Kosmol (red), 1996].

Dokonując ogólnej oceny badań przeprowadzonych do połowy lat 90. wydawać się może, że problem diagnostyki stanu ostrza skrawającego, a w domyśle diagnostyki OPN-PS, był bliski rozwiązania. Jednakże pogląd taki, rozważany również w świetle uwag i komentarzy z rozdziału 1, należy uznać za zbyt pochopny. Dokładna analiza scharakteryzowanych prac

wskazuje na wielokrotne pojawianie się sprzeczności we wnioskach z przeprowadzonych badań. Podkreślić należy także przypadki prowadzenia badań dla stosunkowo wąskiego zakresu parametrów obróbki, a następnie dokonywanie daleko posuniętych uogólnień. Korzystne w rozpatrywanym okresie czasu było natomiast ugruntowanie się opinii o celowości stosowania wieloczuJNIKOWYCH układów diagnostycznych, w których przetwarzanie danych realizowane jest z zastosowaniem metod sztucznej inteligencji. Uznano zatem, iż metody klasyczne w znacznym stopniu ograniczają możliwość uwzględnienia złożoności i zróżnicowania procesów obróbki skrawaniem, co stanowiło uzasadnienie celowości, a raczej konieczności, prowadzenia dalszych prac.

Charakteryzując współcześnie realizowane prace badawcze kontynuuje się w pierwszym kroku opis badań prowadzonych przez autora niniejszej pracy. W tym przypadku odwołać się należy do wspomnianych powyżej zestawień wyników badań. Istotne jest, iż zestawienia te oraz podjęte próby uogólnień krystalizowały podejście autora do sposobu zastosowania metod sztucznej inteligencji w diagnostyce OPN-PS. Początkowo rozważano tzw. Inteligentny Czujnik [Sokołowski i Kosmol, 1995d], a następnie ukierunkowano badania na zagadnienia związane ze wspomaganiami projektowania układów diagnostycznych [Sokołowski i Kosmol, 1996], [Sokołowski i Kosmol, 1996a], [Sokołowski i Kosmol, 1996b]. Kolejne prace autora podporządkowane były przyjętej orientacji badań. Przykładowo, prowadzono (lub kontynuowano) badania odnoszące się do diagnostyki narzędzia (np. [Sokołowski et al., 1997a]) lub diagnostyki przedmiotu obrabianego (np. [Sokołowski i Kosmol, 1998]). Wskazać również można na prace nie związane bezpośrednio z OPN-PS, jakkolwiek ukierunkowane na testy wybranych metod sztucznej inteligencji, np. algorytmów genetycznych [Sokołowski i Gude, 1999]. Równoległe prowadzono prace nad oprogramowaniem komputerowym, umożliwiającym hybrydyzację lub implementację oryginalnych rozwiązań w sieciach neuronowych, logice rozmytej i algorytmach genetycznych [Sokołowski et al., 1996a], [Sokołowski i Kosmol, 1997] i [Sokołowski et al., 1997b]. Ostatnie prace autora sprowadzały się do ponownych prób podsumowań przeprowadzonych badań, czego wynikiem są niniejsza praca oraz publikacje przeglądowe ([Sokołowski, 2000], [Sokołowski i Kosmol, 2001a], [Sokołowski i Kosmol, 2001b]), publikacje poświęcone wybranym problemom diagnostyki OPN-PS ([Sokołowski i Kosmol, 2001], [Sokołowski, 2001]) i publikacje poświęcone praktycznym aspektom wdrożeń inteligentnych układów diagnostycznych [Projekt Badawczy KBN, 1999] (np. [Sokołowski i Kosmol, 2000]). Uwypuklić należy także próby uogólnienia zagadnienia diagnostyki OPN-PS w świetle jakości i efektywności obróbki skrawaniem [Sokołowski i Kosmol, 1999] czy też rozważania, w których obrabiarka i proces skrawania rozpatrywane są jako złożony układ mechatroniczny [Kosmol i Sokołowski, 2000a], [Kosmol et al., 2002].

Powracając do charakterystyki pozostałych prac badawczych zauważa się znaczne zróżnicowanie podejść. Podejmowane są próby typowych zastosowań sieci neuronowej FFBP w diagnostyce OPN-PS (np. [Dimla et al., 1997], [Gindy i Al-Habaibeh, 1997], [Urbaniak, 2001]) oraz ponawiane są dyskusje zastosowań układów wieloczuJNIKOWYCH (np. [Kang et al., 2001], [Antic, et al., 2001]). Niemniej jednak wskazać również można na bardziej oryginalne podejścia. Ciekawe są próby prognozowania zużycia ostrza skrawającego z zastosowaniem sieci neuronowych [Gawlik i Karbowski, 1997]. Kontynuowane (np. [Hamrol i Twardowski, 1998]) i równocześnie rozszerzane (np. [Hamrol, 1998]) są badania wpływu zużycia narzędzia na błędy kształtu przedmiotu obrabianego. Zastosowanie sieci neuronowych poprzedzane jest rozbudowanym przetwarzaniem wstępnym sygnałów pomiarowych poprzez, przykładowo, zastosowanie analizy falkowej [Such et al., 1999], [Tang et al., 2001]. Kontynuowane są próby zastosowania innych metod sztucznej inteligencji, a szczególnie logiki rozmytej w ujęciu zarówno standardowym [Balazinski i Jemielniak, 1998], jak i hybrydowym [Leżański, 1998], [Ali i Zhang, 1999], [Gibiec, 2000]. Próby hybrydyzacji ujawniają się także w odniesieniu do sieci neuronowych, np. sieci FFBP i sieci Kohonena [Azouzi i Guillot, 1996]. Ponownie dokonuje się wartościowych podsumowań prowadzonych badań oraz wskazuje się kierunki przyszłych prac w odniesieniu do wybranych metod sztucznej inteligencji (np. [Jędrzejewski, 1997]) czy też danego sposobu obróbki (np. [Inasaki, 1998]). W ostatnich latach zauważa się powrót do uznawanych za klasyczne badań nad zastosowaniem modeli analitycznych, w tym modeli procesu skrawania [DeVor et al., 1996] czy też modeli formowania wiórów [Kishawy i Elbestawi, 1997]. Stosuje się podejścia bazujące na teorii chaosu [Govekar i Grabec, 1998], macierzy Toeplitza [Berger et al., 2001] lub zdecydowanie klasyczne próby diagnozowania narzędzi poprzez pomiar i analizy hałasu [Kopac i Sali, 2001].

Podejmując próbę podsumowania przeprowadzonego przeglądu literatury zasadne jest uwypuklenie zastanawiającej sprzeczności pomiędzy bez wątpienia bardzo szerokim zakresem zrealizowanych prac badawczych a nie w pełni zadowalającym stanem rozwoju układów diagnostycznych. Wskazać można w tym przypadku na kilka przyczyn, uznanych przez autora za najistotniejsze. W pierwszym kroku wskazuje się na dążenie producentów i placówek badawczych do zapewnienia wymaganej przez użytkowników dużej uniwersalności układów. Jak łatwo zauważyć, nie jest możliwe przeprowadzenie testów danego układu we wszystkich warunkach, co powoduje, że układ taki może okazać się zawodny w danym, konkretnym zastosowaniu. Następnie, pomimo powszechnej opinii o konieczności stosowania wieloczuJNIKOWYCH układów diagnostycznych, na komercyjnym rynku brak jest takich układów. Ostatecznie zwraca się uwagę na znaczne zróżnicowanie podejść ujawniające się we współcześnie prowadzonych badaniach. Szczególnie znaczące jest prowadzenie badań o charakterze badań podstawowych. Wydaje się, że przyczyną jest w tym przypadku duży postęp w dziedzinach bezpośrednio lub pośrednio związanych z obróbką skrawaniem. Autor wskazuje przede wszystkim na rozwój materiałów narzędziowych

(np. [Krimmel et al., 2000]), umożliwiających znaczne zwiększenie wydajności obróbki. Ponadto obróbce poddaje się nowe materiały konstrukcyjne (np. [Oishi i Yasuda, 1997]) czy też materiały o mało znanej skrawalności (np. [Mahdi i Zhang, 2001]). Stosowane są także nowe technologie, czego przykładem jest wymuszanie drgań narzędzi w przypadku skrawania twardych materiałów [Jin i Murakawa, 2001], [Pettersson et al., 2001]. Reasumując, znaczący rozwój w zasygnalizowanych dziedzinach powodować może nienadążanie producentów układów diagnostycznych z uaktualnianiem oferowanych rozwiązań, a tym samym stanowić może kolejną przyczynę jedynie częściowo zadowalającego stanu rozwoju układów diagnostycznych OPN-PS.

### 2.1.1. Potrzeba wspomaganie projektowania układów diagnostycznych

Określenie najistotniejszych przyczyn nie w pełni zadowalającego stanu rozwoju układów diagnostycznych OPN-PS umożliwia podjęcie prób wskazania potencjalnych sposobów rozwiązania tego problemu. Przyjmując za trywialne sugerowanie zwiększenia intensywności badań i przyspieszenia prac wdrożeniowych, Autor odwołuje się do przedmiotu niniejszej pracy, tj. wspomaganie projektowania układów diagnostycznych, i rozwija dalszą dyskusję w świetle tego zagadnienia.

W pierwszym kroku zwraca się uwagę na uniwersalność układów diagnostycznych. Przyjmując, że kłopotliwe jest stosowanie układów uniwersalnych, konieczne staje się dostosowanie tych układów do specyfiki diagnozowanego zjawiska. Otwarte pozostaje w takim przypadku pytanie, jakie podejście wybrać. Wykazane w niniejszym rozdziale zróżnicowanie badań związanych z zagadnieniem diagnostyki OPN-PS wydaje się być bardzo korzystne. Wydaje się, że na podstawie przeglądu literatury relatywnie łatwo jest dokonać wyboru odpowiedniego i dogodnego rozwiązania. Jednakże wystąpić może przypadek nadmiaru informacji, przejawiający się koniecznością przeprowadzenia wielu testów pozwalających ostatecznie wybrać rozwiązanie zbliżone do optymalnego. Zdecydowanie korzystne byłoby ułatwienie dokonania takiego wyboru.

Analogiczny problem wystąpić może przy podjęciu próby skonfigurowania wieloczułnikowego układu diagnostycznego. W dalszym ciągu otwarte pozostaje pytanie, jakie czujniki i jakie metody przetwarzania sygnałów pomiarowych należy zastosować. Pewnym rozwiązaniem może być sugerowane, w świetle przeprowadzonego przeglądu literatury, zastosowanie metod sztucznej inteligencji. Metody te potencjalnie zapewniają zwiększenie elastyczności układów diagnostycznych, bardzo pożądaną w przypadkach wprowadzania, jakkolwiek jedynie w pewnym zakresie, zmian parametrów obróbki. Niemniej jednak, zastosowanie metod sztucznej inteligencji narzuca konieczność ogólnie rozumianej inicjalizacji działania układu diagnostycznego poprzez, przykładowo, wprowadzenie do układu wiedzy podstawowej. Pojawia się pytanie, czy projektant (konstruktor) układu posiada wystarczającą wiedzę, aby przeprowadzić tak rozumianą inicjalizację.

Ostatecznie, nie wymagający szerszego komentarza, jest przypadek zastosowania nowych, nieznanych parametrów obróbki lub technologii. Konieczność przeprowadzenia badań podstawowych wydaje się być w tym przypadku nieunikniona. Ponownie otwarte pozostaje pytanie, jak efektywnie przeprowadzić badania, aby zminimalizować ponoszone nakłady.

Podsumowując powyższą dyskusję odwołać się należy do założonej przez autora konieczności wspomaganie projektowania układów diagnostycznych. Autor uznaje, iż przytoczone uwagi i komentarze stanowią uzasadnienie założonej konieczności, a zarazem stanowią uzasadnienie celowości podjęcia badań w ramach przyjętego przedmiotu pracy. Potwierdzając celowość badań należy w kolejnym kroku rozważyć sposób praktycznej realizacji wspomaganie projektowania układów diagnostycznych. Proponowane przez autora podejście dyskutowane jest w następnym podrozdziale.

## 2.2. Inteligentny Projektant Układów Diagnostycznych

### 2.2.1. Koncepcja Inteligentnego Układu Diagnostycznego (IUD)

W formie wprowadzenia do opisu proponowanego sposobu realizacji wspomaganie projektowania układów diagnostycznych charakteryzowana jest koncepcja Inteligentnego Układu Diagnostycznego (IUD) [Sokołowski i Kosmol, 1996], [Sokołowski i Kosmol, 1996a], [Sokołowski i Kosmol, 1996b]. Koncepcja IUD stanowi, co należy podkreślić, odzwierciedlenie przewodniej idei podjętych przez autora badań. Zaznacza się także, iż rozważania prowadzone są w odniesieniu do obrabiarki i procesu skrawania, traktując tę maszynę i ten proces jako wybrane przykłady maszyn i procesów technologicznych.

Koncepcja IUD opiera się na związanych z oceną przebiegu obróbki oraz stanu obrabiarki działaniach doświadczonego operatora obrabiarki i jednocześnie odzwierciedla strukturę klasycznego układu diagnostycznego. Dodać można, że rozważane są działania operatora wyidealizowanego, charakteryzującego się umiejętnością adaptacji do odbioru informacji niepewnej i nieścislej, czy też umiejętnością odkrywania nowych zależności, pomijając jednocześnie ograniczenie percepcji operatora pod względem zróżnicowania i ilości zapamiętywanych jednorazowo informacji [Kacalak, 1995], [Kacalak, 1996]. Doświadczony operator obrabiarki obserwując proces obróbki stara się analizować informacje pozwalające wnioskować o przebiegu obróbki lub stanie obrabiarki. Wykorzystuje w tym przypadku swoją wiedzę i wybiera te informacje, które posłużyć mogą do oceny istotnych (zazwyczaj niekorzystnych) zjawisk. Jednocześnie operator wzbogaca swoją wiedzę wiążąc wybrane informacje, przykładowo, z jakością gotowego wyrobu lub skutecznością działań podejmowanych w przypadku wystąpienia nieprawidłowości.

Jak można zauważyć, klasyczne układy diagnostyczne realizują zbliżone funkcje. W pierwszym kroku następuje pomiar wybranego sygnału(ów) i dokonywane jest przetwarzanie wstępne. Następnie realizowane jest wyznaczanie (ekstrakcja) cech sygnału

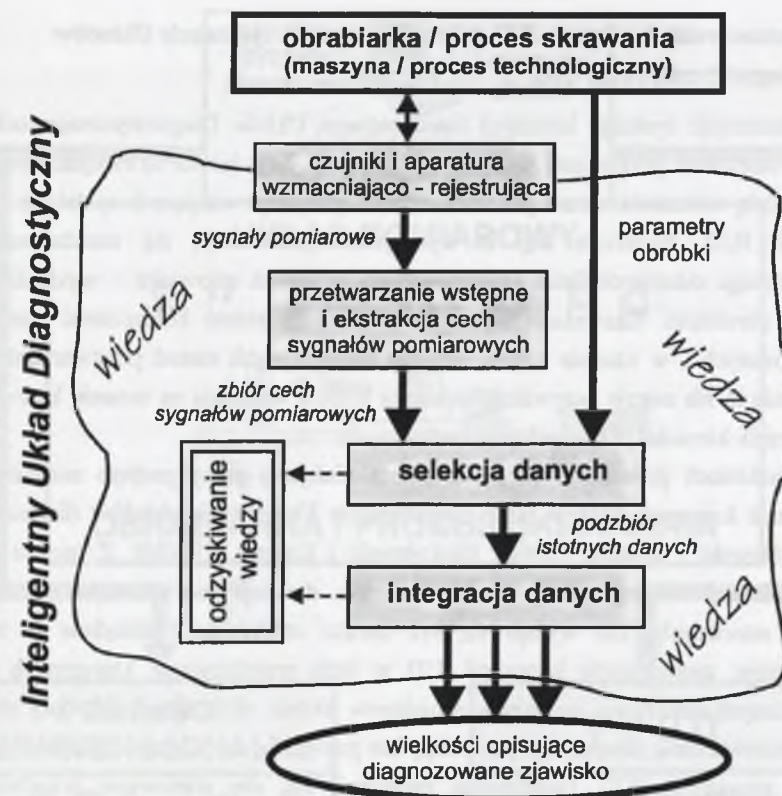
pomiarowego. Cechy sygnału pomiarowego oraz wybrane parametry obróbki reprezentują dane<sup>(1)</sup> poddawane integracji<sup>(2)</sup>, której celem jest wyznaczenie wartości wielkości opisujących diagnozowane zjawisko. Do wyznaczenia tych wartości stosowany jest model współzależności (współzależności) rozpatrywanych danych i wielkości opisujących diagnozowane zjawisko.

Porównując działania doświadczonego operatora i funkcje realizowane przez klasyczny układ diagnostyczny wskazać jednakże należy na zasadnicze różnice. Przede wszystkim, funkcje układu oraz wielkości przetwarzane w układzie są jednoznacznie definiowane w fazie projektowania. W pracy przyjmuje się, iż w fazie projektowania układu diagnostycznego określana jest konfiguracja czujników pomiarowych, dokonywany jest wybór i wyznaczenie parametrów metod przetwarzania wstępnego i ekstrakcji cech sygnałów pomiarowych oraz identyfikowany jest wspomniany model współzależności. Pozostałe, ogólnie rozumiane czynności, np. wybór typu i sposobu mocowania czujników pomiarowych, wybór aparatury wzmacniającej, wybór sposobów połączenia czujników z aparaturą wzmacniającą, wybór przetwarzania cyfrowego lub analogowego itd., realizowane są w fazie konstruowania układu. Kontynuując, w klasycznym układzie diagnostycznym możliwa jest zatem ekstrakcja jedynie ściśle określonych, wybranych przez projektanta układu, cech sygnałów pomiarowych. Również, do układu wprowadzane są jedynie te wielkości reprezentujące parametry obróbki, które uznano za istotne w fazie projektowania układu. Uogólniając, w klasycznym układzie diagnostycznym brak jest możliwości adaptacji do nowych, nieznanymi parametrów obróbki. Oznacza to, że brak jest możliwości dokonania selekcji (wyboru) i integracji nowych, istotnych (relewantnych) danych umożliwiającą uwzględnienie zaistniałych zmian. W klasycznym układzie diagnostycznym zdecydowanie ograniczona jest także zdolność zapamiętywania i interpretacji informacji o skutkach zmian parametrów obróbki, co w ogólnym ujęciu prowadzi do braku możliwości pozyskiwania, a tym samym generalizacji wiedzy.

Wskazane różnice stanowią podstawę zdefiniowania wymagań stawianych Inteligentnym Układem Diagnostycznym (rys. 2.1). Przede wszystkim wymaga się, aby inteligentny układ, bez względu na stosowane parametry obróbki, samoczynnie, tj. bez udziału człowieka, dokonywał selekcji istotnych danych. Następnie, układ powinien samoczynnie dokonać integracji wybranych danych do postaci modelu współzależności wielkości opisujących diagnozowane zjawisko i tych danych. Ostatecznie żąda się, aby wyniki selekcji i integracji dostępne były w postaci zrozumiałej dla człowieka, tj. powinna istnieć możliwość odzyskania wiedzy o zależnościach pomiędzy danymi i wielkościami opisującymi diagnozowane zjawisko.

(1) Pojęcie „dane” stosowane jest głównie w odniesieniu do zbioru cech sygnałów pomiarowych i parametrów obróbki. Pojęcie to stosowane jest również w znaczeniu ogólnym, np. „metody przetwarzania danych” lub jest uszczegółowiane, np. „dane wejściowe”, „dane wyjściowe”.

(2) Pojęcie przyjęte przez autora, stanowiące odpowiednik powszechnie stosowanego w języku angielskim pojęcia „data integration”.



Rys. 2.1. Schematyczne zobrazowanie koncepcji Inteligentnego Układu Diagnostycznego  
Fig. 2.1. Schematic presentation of the Intelligent Diagnostic System concept

W tym miejscu należy podkreślić, że w niniejszej pracy rozpatrywana jest jedynie koncepcja Inteligentnego Układu Diagnostycznego. Dlatego też nie podaje się formalnej definicji IUD oraz pomija się zagadnienia związane z uwidocznioną na rys. 2.1 wiedzą układu. Nie wskazuje się sposobu reprezentacji wiedzy ani mechanizmów pozyskiwania wiedzy. Nie wykazuje się także zróżnicowania pomiędzy wiedzą podstawową a wiedzą pozyskaną przez układ. Następnie przyjmuje się, iż w układzie możliwe jest zastosowanie dowolnej metody przetwarzania wstępnego oraz możliwe jest wyznaczenie dowolnych cech sygnałów pomiarowych. Znaczące jest natomiast, że wyznaczenie dowolnego zbioru cech decyduje o możliwości realizacji efektywnej selekcji najistotniejszych danych. Zaznacza się, iż selekcji podlegają nie tylko, obarczone zwykle szumem, cechy sygnałów pomiarowych ale również zdeterminowane wielkości reprezentujące parametry obróbki. Wskazuje się także na specyficzne umiejscowienie na rys. 2.1 bloku reprezentującego czujniki pomiarowe i aparaturę wzmacniająco - rejestrującą. Uznaje się, że urządzenia te mogą wchodzić w skład IUD jak i stanowić integralną część obrabiarki.

## 2.2.2. Zastosowanie koncepcji IUD w Inteligentnym Projektancie Układów Diagnostycznych (IPUD)

Rozszerzając dyskusję koncepcji Inteligentnego Układu Diagnostycznego celowe jest rozważyć możliwość praktycznej realizacji tej koncepcji. Zagadnienie to związane jest głównie z możliwością wskazania metod przetwarzania danych, zapewniających spełnienie wymagań stawianych IUD. Podkreśla się, iż wymagania sprowadzają się zasadniczo do jak najwierniejszego odzwierciedlenia (naśladowania) zachowań człowieka – wyidealizowanego operatora obrabiarki. Rozważane wymagania narzucają zatem konieczność zastosowania bardzo złożonych i, w uznaniu autora, obecnie niedostępnych metod przetwarzania danych. Stwierdzenie to nie neguje oczywiście koncepcji IUD, a wskazuje na uznanie koncepcji IUD za wyznacznik kierunku przyszłych prac badawczych.

W badaniach prowadzonych przez autora niniejszej pracy podjęto natomiast próby zastosowania koncepcji IUD w fazie projektowania klasycznych układów diagnostycznych (np. [Sokołowski i Kosmol, 1996a], [Sokołowski i Kosmol, 1996b]). Z punktu widzenia przeprowadzonej w poprzedniej części rozdziału dyskusji nawet częściowe spełnienie wymagań stawianych IUD wydaje się być bardzo atrakcyjne i pożądane w tej fazie. Równocześnie, zastosowanie koncepcji IUD w fazie projektowania klasycznych układów diagnostycznych umożliwia ingerencję projektanta układu w przypadkach, gdy stosowane metody przetwarzania danych nie pozwalają lub pozwalają na jedynie częściowe spełnienie wymagań stawianych IUD. Uogólniając, proponuje się, aby stanowiące przedmiot pracy wspomaganie projektowania układów diagnostycznych realizować z zastosowaniem bazującego na koncepcji IUD narzędzia, które umożliwiłoby minimalizację nakładów ponoszonych na ogólnie rozumianą analizę diagnozowanego zjawiska. Narzędzie to, tzw. Inteligentny Projektant Układów Diagnostycznych (IPUD), umożliwiłoby samoczynną (tj. bez udziału człowieka) lub zbliżoną do samoczynnej realizację kroków, jakie podejmuje projektant rozwiązując zadanie projektowania układu diagnostycznego (rys. 2.2).

W celu uszczegółowienia opisu IPUD odwołuje się do badań autora przeprowadzonych w ramach [Projekt Badawczy KBN, 1997]. W ujęciu zaproponowanym w wyżej wspomnianych badaniach Inteligentny Projektant Układów Diagnostycznych składa się z zestawu czujników pomiarowych i aparatury wzmacniająco - rejestrującej oraz pakietu oprogramowania realizującego przetwarzanie wstępne, ekstrakcję, selekcję oraz integrację danych. Przyjmuje się, że w skład zestawu czujników wchodzić mogą standardowe, komercyjnie dostępne czujniki pomiarowe, czujniki zintegrowane z obrabiarką oraz tzw. Czujniki Inteligentne, np. [Yamasaki, 1996], [Bolikowski, 1997]. Zastosowanie IPUD polega na wykorzystaniu zestawu dostępnych czujników i dokonaniu rejestracji sygnałów pomiarowych i parametrów obróbki z jednoczesną obserwacją rozważanych stanów diagnozowanego zjawiska i/lub rejestracją wielkości opisujących to zjawisko. Sugerując



Rys. 2.2. Dwa podejścia do projektowania układów diagnostycznych OPN-PS

Fig. 2.2. Two approaches to the designing of the OPN-PS diagnostic systems



zastosowanie zestawu dostępnych czujników pomiarowych zwraca się uwagę na występujący w wielu przypadkach brak możliwości jednoznacznego określenia *a priori* optymalnej konfiguracji czujników. Podejście takie nie wyklucza oczywiście zastosowania arbitralnie określonej konfiguracji. Zarejestrowane sygnały pomiarowe poddawane są w pierwszym kroku, mającemu charakter opcjonalny przetwarzaniu wstępnemu oraz ekstrakcji cech. Podobnie jak w przypadku wyboru konfiguracji czujników pomiarowych, wybór metod wstępnego przetwarzania sygnałów pomiarowych i wybór metod ekstrakcji cech zależy od doświadczenia (wiedzy) potencjalnego Użytkownika IPUD. W sytuacjach skrajnych sugeruje się zastosowanie jak najbardziej zróżnicowanych metod przetwarzania wstępnego sygnałów pomiarowych i wyznaczanie wszystkich, tj. możliwych do wyznaczenia z zastosowaniem IPUD, cech. Zbiór wyznaczonych cech sygnałów pomiarowych i wielkości reprezentujących parametry obróbki stanowi podstawę przeprowadzenia selekcji danych. Zaznacza się, iż w zależności od stosowanych metod selekcji wymagane może być uzupełnienie powyższego zbioru o wielkości opisujące diagnozowane zjawisko.

Etap selekcji danych jest jednym z najistotniejszych etapów, ponieważ decyduje o liczbie czujników (koszcie i złożoności układu diagnostycznego), które będą stosowane w diagnostyce rozpatrywanego zjawiska. W zdecydowanej większości przypadków istotna jest nie tylko liczba czujników ale również liczność zbioru wyselekcjonowanych danych. Nadmiar danych prowadzi zazwyczaj do zbędnej rozbudowy wyznaczanego w kolejnym kroku modelu współzależności, utrudniać może identyfikację parametrów modelu oraz może wpływać na jakość modelu (np. sprawność klasyfikatora lub zdolność generalizacji) [Piramuthu, 1996], [Diagnostyka techniczna, 2001]. Podzbiór wybranych, istotnych danych poddawany jest ostatecznie integracji stanowiącej ostatni etap projektowania układu diagnostycznego. Znaczenie etapu integracji danych jest niepodważalne, ponieważ to wyniki uzyskane na tym etapie stanowią o możliwości ogólnie rozumianej oceny rozpatrywanego zjawiska.

Łatwo jest zauważyć, iż uzupełnieniem powyższej charakterystyki powinno być wskazanie metod stosowanych na etapie selekcji i integracji danych. W tym przypadku można by odwołać się do wcześniejszych badań prowadzonych przez autora pracy. Jednakże, badania te miały charakter badań wstępnych, których wyniki nie pozwalają na tak daleko idące uogólnienia. Dlatego też w tym miejscu nie przytacza się stosowanych dotychczas rozwiązań, a wyniki wcześniejszych badań traktuje się jako przesłanki dokonywanego w dalszych częściach pracy wyboru i następnie analiz metod selekcji i integracji danych.

W efekcie zastosowania IPUD projektant układu diagnostycznego uzyskuje informacje o konfiguracji czujników pomiarowych oraz metodach (również parametrach metod) przetwarzania wstępnego i ekstrakcji cech sygnałów pomiarowych, a także uzyskuje model współzależności wybranych danych i wielkości opisujących diagnozowane zjawisko. Jednocześnie przyjmuje się, iż projektant odzyskuje i przyswaja wiedzę ujawnioną na etapie selekcji i integracji danych.

### 2.3. Wstępny wybór oraz ogólna charakterystyka metod i algorytmów

W formie wprowadzenia do podejmowanych w niniejszym podrozdziale rozważań przypomnieć można, że zastosowanie koncepcji IUD w Inteligentnym Projektancie Układów Diagnostycznych spowodowane było niedostępnością, jak uznano, metod pozwalających na spełnienie wymagań stawianych IUD. Podkreśla się, że zaproponowane podejście, tj. IPUD, jedynie w nieznacznym stopniu zmniejsza znaczenie wspomnianych wymagań. Stąd też dokonując wstępnego wyboru metod i algorytmów potencjalnie mogących mieć zastosowanie w IPUD, zasadne jest skojarzenie wymagań stawianych IUD z wnioskami wynikającymi z dokonanego przeglądu literatury, ze szczególnym uwzględnieniem badań autora pracy oraz dyskusji przeprowadzonej w podrozdziale 2.2.2. W tym świetle, za w pełni uzasadnione i wymagające jedynie ograniczonego komentarza uznaje się wskazanie na celowość podjęcia prób zastosowania wybranych metod sztucznej inteligencji, tj. sieci neuronowych, logiki rozmytej i algorytmów genetycznych lub ewolucyjnych.

Dodać należy, że dokonując wyboru odwołano się także do charakteryzowanych dalej cech wybranych metod sztucznej inteligencji oraz ostatnich publikacji, w których zwraca się uwagę na jedynie częściowe wykorzystanie sieci neuronowych w diagnostyce maszyn ([Tadeusiewicz, 2000]), możliwości układów (systemów) logiki rozmytej (np. [Rutkowska et al., 1997]) czy też atrakcyjność algorytmów ewolucyjnych stosowanych w rozwiązaniach hybrydowych ([Korbicz, 2000]). Istotne jest, iż dokonując wyboru skupiono się na metodach, które potencjalnie stosowane mogą być na etapie selekcji i integracji danych. Natomiast zagadnienie odzyskiwania wiedzy jest uwzględniane, aczkolwiek nie jest szczegółowo analizowane. Oznacza to, że możliwość odzyskiwania wiedzy nie stanowiła zasadniczego kryterium wyboru. Niemniej jednak kryterium to jest uwzględniane w ogólnej ocenie zastosowanych metod poprzez rozpatrywanie możliwości (lub braku możliwości) odzyskiwania wiedzy (np. rozdział 4). Zwraca się także uwagę na hierarchię podejmowanych badań, tj. konieczność dokonania analiz metod selekcji i integracji, aby móc w kolejnym kroku podjąć dyskusję zagadnienia odzyskiwania wiedzy. Również, mając na uwadze doniesienia literaturowe (np. [Moczulski, 1997]), autor uważa, że zagadnienie odzyskiwania wiedzy, zbliżone do zagadnienia pozyskiwania wiedzy, stanowi niezależną dziedzinę badań, których zakres byłby zdecydowanie trudny do uwzględnienia w ramach niniejszej pracy.

Komentując wstępny wybór metod wskazuje się na pominięcie systemów ekspertowych w zastosowaniu w IPUD. Podejście takie związane jest głównie z uznaniem zasadności stosowania systemów ekspertowych na poziomie nadzorowania, a nie analizowanym w pracy poziomie diagnostyki OPN-PS. Odwołać się także można do wybranych pozycji literaturowych, w których dyskutowano istotne w świetle prowadzonych w pracy rozważań, ograniczenia systemów ekspertowych. Jednym z najistotniejszych ograniczeń jest konieczność wprowadzenia do systemów wiedzy mającej postać ściśle określonych

reguł [Tadeusiewicz, 2000]. Problematyczną w niektórych przypadkach jest możliwość dokonywania jedynie jakościowej oceny danego zjawiska [Barschdorff i Monostori, 1991], [Monostori, 1992]. Uważa się również, że systemy ekspertowe są zwykle zbyt powolne do zastosowań *on-line* [Kosko, 1992], [Bavarian, 1992]. Dodać jednakże należy, iż prowadzone obecnie prace badawcze wskazują na możliwość znacznego zmniejszenia wpływu niektórych z tych ograniczeń. Przykładem jest stosowanie dynamicznych systemów ekspertowych ([Cholewa, 2000]) w układach działających *on-line*, stosowanie efektywniejszych metod pozyskiwania wiedzy ([Moczulski, 1997], [Ciupke, 2001]) lub też stosowanie rozwiązań hybrydowych, w których funkcje generatora i selektora reguł realizują sieci neuronowe ([Tadeusiewicz, 2000]).

### 2.3.1. Sieci neuronowe

Charakteryzując sieci neuronowe zasadne jest wypuklenie ich ogólnych cech, szczególnie interesujących w świetle wymagań stawianych IUD. Sieci neuronowe cechuje zdolność uczenia (się), zdolność adaptacji (adaptacyjny charakter uczenia), zdolność selekcji istotnych informacji, umiejętność samoorganizacji oraz zdolność generalizacji. Przedstawione cechy sieci neuronowych zestawiono opierając się na [Rumelhardt et al., 1986], [Pao, 1989], [Hertz et al., 1991], [Żurada, 1992], [Tadeusiewicz, 1993], [Korbicz et al., 1994] oraz [Osowski, 1996] i [Praca zbiorowa, 2000]. Zaznaczyć należy, iż powyższe cechy odnoszą się do „poprawnie” skonstruowanych sieci neuronowych i nie uwzględniają zagadnień problematycznych, np. tzw. przewymiarowania struktury mogącego powodować utratę zdolności generalizacji [Diagnostyka techniczna, 1997], [Zacksenhouse, 2001].

Spośród bardzo dużej liczby sieci neuronowych do testów i analiz prowadzonych w niniejszej pracy wybrano wspomnianą wielokrotnie sieć neuronową FFBP. W pracy przyjęto, że sieć FFBP stosowana będzie zarówno do selekcji, jak i integracji danych. Uwzględniono także inne typy sieci neuronowych, np. sieci Kohonena KFM i WTA [Kohonen, 1988]. Sieci te stosowane są głównie jako podejścia uzupełniające w rozwiązaniach hybrydowych i dlatego nie są w tym miejscu szerzej opisywane. Wyboru sieci neuronowej FFBP dokonano głównie na podstawie przeglądu literatury i wniosków z badań przeprowadzonych przez autora pracy (np. [Sokołowski i Dornfeld, 1994a], [Sokołowski i Kosmol, 1995e]) oraz korzystnych dla sieci FFBP wyników porównań z innymi metodami przetwarzania danych. Przykładami mogą być porównania sieci neuronowej FFBP i metody drzewa decyzyjnego (decision tree) [Li et al., 1992], macierzy wpływów (influence matrix) [Colgan et al., 1992] oraz metod regresji [Yerramareddy et al., 1993], [Heyden, 1996] i [Westkamper et al., 1996].

Przyjmując, że zastosowanie sieci neuronowej FFBP do integracji danych jest zrozumiałe, dyskusyjne może być zastosowanie tej sieci na etapie selekcji danych.

W dostępnej autorowi literaturze nie podaje się zbyt wielu rozwiązań. W [Peterson i Ladage, 1992] zaproponowano selekcję istotnych danych z zastosowaniem analizy wrażliwości. Wrażliwość wyjść sieci na poszczególne wejścia oceniano na podstawie różniczki cząstkowej wyjść względem danego wejścia lub względną zmianę wartości wyjść w przypadku zmian  $\pm 10\%$  wartości danego wejścia. W podsumowaniu stwierdzono jednak, że metoda nie pozwalała na uzyskanie wyników korzystniejszych niż w przypadku arbitralnie dokonanej selekcji danych. Ciekawszym i bardziej efektywnym rozwiązaniem bazującym na analizie wrażliwości jest rozwiązanie zaproponowane w [Żurada et al., 1994], scharakteryzowane także w [Osowski, 1996]. Inne podejście zastosowano w [Kumuluca et al., 1997] i [Jemielniak, 2001]. Charakter zastosowanej metody selekcji odzwierciedla metodę *leave-one-out*. Ocena istotności danych sprowadza się do prób eliminacji (zerowania) kolejnych wejść skonstruowanej sieci FFBP i wnioskowania o istotności wejść na podstawie wartości błędów wyznaczanych z zastosowaniem zbioru trenującego i testującego. W formie komentarza dodaje się, że w pracy stosowane będzie zbliżone podejście pozwalające na uzyskiwanie korzystniejszych wyników, jakkolwiek wymagające większych nakładów obliczeniowych (rozdział 8). Problem selekcji danych poruszano również w [Clabian et al., 1997]. W pracy tej zastosowano jednocześnie wspomniane podejścia bazujące na metodzie *leave-one-out* [Kumuluca et al., 1997] i metodzie zbliżonej do metody zaproponowanej w [Peterson i Ladage, 1992].

Rozszerzając dyskusję o podejścia hybrydowe i próby zastosowania innych typów sieci neuronowych wskazać można na [Jacob i Ball, 1997] i [STATISTICA-NN]. Selekcja danych prowadzona jest w tych przypadkach z zastosowaniem algorytmu genetycznego poszukującego minimum błędu treningu sieci neuronowych Radial Basic Function (RBF) ([Jacob i Ball, 1997]) i sieci probabilistycznych lub sieci regresyjnych [STATISTICA-NN].

### 2.3.2. Logika rozmyta – wnioskowanie rozmyte

Alternatywną metodą integracji danych rozważaną w niniejszej pracy jest metoda bazująca na wnioskowaniu rozmytym realizowanym w systemach (układach, sterownikach) rozmytych. Uzasadniając ponownie zastosowanie logiki rozmytej (wnioskowania rozmytego) odwołać się można do ogólnych cech procesu skrawania, których dyskusję odnoszącą się do procesu szlifowania przeprowadzono w [Kacalak, 1995]. Uogólniając wspomnianą dyskusję na inne sposoby obróbki skrawaniem stwierdzić można, że dla wielu cech charakteryzujących obróbkę skrawaniem nie można określić wyraźnych granic klasyfikacji tych cech. Przykładowymi wielkościami, których zbiory wartości nie mają ostro określonych granic, są dopuszczalne lub optymalne parametry obróbki czy też okres trwałości ostrza. Typowym przykładem jest także głębokość skrawania, której zbiór wartości nie ma ostro określonych granic ze względu na zmiany głębokości nominalnej, nierówności powierzchni

przedmiotu w strefie obróbki czy też podatność materiału obrabianego. Zbiory te są zbiorami rozmytymi i dlatego naturalne jest dążenie do wykorzystania teorii takich zbiorów w diagnostyce OPN-PS.

Rozważając bardziej szczegółowo zastosowanie systemu logiki rozmytej należy zwrócić uwagę na konieczność konstruowania odpowiedniej bazy reguł systemu oraz konieczność określenia liczby i parametrów funkcji przynależności. Zazwyczaj zadanie to rozwiązywane jest przez eksperta. Dysponując jedynie danymi numerycznymi (np. zbiorami wartości cech sygnałów pomiarowych) wymagane jest natomiast podejście przybliżające system logiki rozmytej do spełnienia wymagań stawianych IUD / IPUD. W tym przypadku podjąć można próby zastosowania tzw. systemów rozmyto-neuronowych, np. [Kosko, 1992], [Khan, 1993], [Gupta i Rao, 1994], [Yager, 1994]. Ukierunkowując dyskusję na systemy rozmyto - neuronowe wskazuje się na kilka rozwiązań, zestawionych między innymi w [Rutkowska et al., 1997]. W [Wang i Mendel, 1992] zaproponowano metodę konstruowania bazy reguł (MKBR) z zastosowaniem tzw. *table look up scheme* i wskazano sposób oceny stopnia prawdziwości wyznaczonych reguł. Przytoczyć można także próby zastosowania sieci neuronowych do realizacji rozmywania [Sung i Kuo, 1992] lub wyostrzania [Żurada, 1992]. Bardzo ciekawe podejście zaproponowano w [Takagi i Hayashi, 1991], gdzie rozważano algorytmy i metody wyznaczania zarówno funkcji przynależności, jak i konstruowania bazy reguł systemu logiki rozmytej zaproponowanego w [Takagi i Sugeno, 1985]. Problematyczne jednakże jest w tym przypadku kodowanie przesłanek i konkluzji reguł w postaci sieci neuronowych, co powoduje brak możliwości wyodrębnienia zrozumiałych dla człowieka reguł systemu i postaci funkcji przynależności [Rutkowska et al., 1997].

Najbardziej rozbudowany i jednocześnie najbardziej zbliżony do spełnienia wymagań stawianych IUD / IPUD jest system logiki rozmytej zaproponowany w [Lin i Lee, 1991]. System reprezentuje rozwiązanie potencjalnie umożliwiające zastosowanie jedynie danych numerycznych w fazie konstruowania. Zaznaczyć należy, że w przeciwieństwie do [Takagi i Hayashi, 1991] system ten zachowuje klasyczną strukturę po fazie konstruowania, a tym samym umożliwia łatwe wyodrębnienie bazy reguł oraz zbiorów rozmytych (np. [Sokołowski, 1993]). Możliwa jest zatem modyfikacja bazy reguł lub przeniesienie bazy reguł do innego systemu (układu, sterownika), wykorzystującego wnioskowanie rozmyte [Rutkowska et al., 1997].

Podsumowując niniejszą charakterystykę zwraca się uwagę na stosowane w pracy nazewnictwo, tj. stosowanie nazwy *systemy logiki rozmytej (systemy FL)* zamiast przytaczanego powyżej określenia *systemy (układy, sterowniki) rozmyto - neuronowe*. Autor uważa, że określenie *rozmyto - neuronowe* stosowane powinno być w przypadku, gdy sieć neuronowa stanowi integralną część skonstruowanego systemu logiki rozmytej. W pozostałych przypadkach możliwe jest pominięcie tego określenia, co równoznaczne jest z pominięciem wskazań na metody i algorytmy stosowane podczas konstruowania systemu FL.

### 2.3.3. Algorytmy genetyczne i ewolucyjne

Algorytmy genetyczne (AG) to jedna z metod inspirowanych genetyką i ewolucją, stosowanych do przeszukiwania (poszukiwania ekstremów) przestrzeni rozwiązań [Arabas, 2000]. Przytaczając za [Holland, 1975] oraz [Goldberg, 1989] i [Davis, 1991], algorytmy genetyczne „radzą sobie” bardzo dobrze w przestrzeni charakteryzującej się występowaniem wielu lokalnych ekstremów. Wiadomo, że klasyczne algorytmy optymalizujące łatwo mogą „utknąć” w lokalnym ekstremum i nie znaleźć ekstremum globalnego. Algorytmy genetyczne prowadzą poszukiwania wychodząc nie z pojedynczego punktu, lecz z pewnej ich populacji, a następnie realizują wielokierunkowe przeszukiwanie przestrzeni rozwiązań, testując w ten sposób wiele różnych, jeżeli występują, ekstremów lokalnych. Istotną cechą algorytmów genetycznych jest możliwość dosyć dowolnego określenia funkcji kryterialnej, której ekstremum jest poszukiwane. W zdecydowanej większości algorytmów klasycznych wymagane jest, aby funkcja kryterialna była funkcją ciągłą i różniczkowalną. W przypadku algorytmów genetycznych warunki te nie muszą być spełnione. Wymagana jest jedynie możliwość wyznaczenia wartości funkcji kryterialnej w każdym punkcie przestrzeni rozwiązań.

Algorytmy genetyczne oprócz strategii ewolucyjnych, programowania genetycznego i programowania ewolucyjnego stanowią jedno z podejść określanych mianem algorytmów ewolucyjnych [Michalewicz, 1992], [Arabas, 2000]. Zasadniczą różnicą pomiędzy, przykładowo, strategiami ewolucyjnymi i algorytmami genetycznymi jest sposób reprezentacji osobników [Michalewicz, 1992]. W strategiach ewolucyjnych osobnik reprezentowany może być liczbami zmiennoprzecinkowymi, podczas gdy w algorytmach genetycznych osobnik kodowany jest w postaci wektora (chromosomu) liczb binarnych. Następnie wskazuje się na zróżnicowanie operatorów genetycznych oraz zróżnicowanie kolejności procedur selekcji i rekombinacji (zmian wartości genów z zastosowaniem operatorów genetycznych). Również parametry algorytmów genetycznych, takie jak prawdopodobieństwo krzyżowania czy prawdopodobieństwo mutacji, pozostają stałe w czasie procesu ewolucji, podczas gdy w strategiach ewolucyjnych parametry te ulegają zmianie (samoadaptacja parametrów). Analizując proponowane w [Davis, 1991] modyfikacje algorytmu genetycznego stwierdzić można jednakże, iż różnice te zanikają, na co wskazuje się również w [Rutkowska et al., 1997].

W badaniach prowadzonych w pracy algorytmy genetyczne stosuje się w rozwiązaniach (układach) hybrydowych w odniesieniu zarówno do metod selekcji, jak i integracji danych. Algorytmy genetyczne nie stanowią zatem niezależnego podejścia. Zaznacza się także, że w dalszej części pracy nie używa się pojęcia *algorytmy ewolucyjne* pomimo zróżnicowania sposobów zastosowania AG narzucającego konieczność wprowadzania modyfikacji zbliżających algorytmy genetyczne do innych algorytmów ewolucyjnych.

### 2.3.4. Dyskusja uzupełniająca

Dyskusja uzupełniająca prowadzona w podsumowaniu niniejszego rozdziału ponownie nawiązuje do problemu metod przetwarzania danych, a szczególnie metod stosowanych na etapie selekcji danych. Podkreślić należy, że dokonując w podrozdziale 2.3.1 skrótego przeglądu literatury przytoczono jedynie wybrane podejścia. Ponieważ skoncentrowano się na zastosowaniach sieci neuronowych, odnieść można wrażenie, że problem wyboru istotnych danych jest problemem nowym, analizowanym jedynie w przytoczonych pracach badawczych. Pogląd taki oczywiście nie może być uznany za prawdziwy ze względu na relatywnie dużą liczbę publikacji poświęconych selekcji danych. Jednakże większość tych publikacji ma charakter ogólny, nie uwzględniający specyfiki zagadnienia diagnostyki OPN-PS, np. [Sobczak i Malina, 1985], [John et al., 1994], [Susmaga et al., 1999]. Bliższe zagadnieniom rozpatrywanym w niniejszej pracy, ponieważ odnoszące się do dziedziny diagnostyki technicznej, są [Cempel, 1980], [Cholewa i Solipiwo, 1985], [Kostka, 1998], [Ciupke, 2001], [Diagnostyka techniczna, 2001], a także [Cholewa i Kiciński, 1995] i [Moczulski, 1997]. Koncentrując się na pracach o najbardziej spójnym z badaniami autora charakterze, wskazać można na [Diagnostyka techniczna, 2001] i [Ciupke, 2001]. Idea podejścia rozważanego w [Diagnostyka techniczna, 2001] sprowadza się do uznania istotności tych cech sygnałów diagnostycznych, które charakteryzują się dużą wrażliwością na zmiany stanu technicznego badanego obiektu. Stwierdza się, że zaobserwowane zmiany cech stwarzają szansę na odpowiednie wykrycie i rozpoznanie zmian stanu obiektu. Następnie, w [Diagnostyka techniczna, 2001] zwraca się uwagę na typ wartości, jakie przyjmują cechy stanu obiektu i dokonuje się szczególnie interesującego przeglądu podejść do wyznaczania wrażliwości w przypadku, gdy cechy stanu obiektu nie przyjmują dowolnych wartości rzeczywistych. Rozważa się wartości określone z dokładnością do przedziału (wartości przedziałowe), uporządkowane i mianowane.

W [Ciupke, 2001] skupiono się natomiast na zagadnieniu redukcji ilości informacji i selekcji informacji w celu pozyskiwania wiedzy dla systemów ekspertowych. W pracy przyjęto założenie, iż bezpośrednie zastosowanie zgromadzonych danych ilościowych nie jest rozwiązaniem najlepszym. Zaakcentowano zatem etap redukcji ilości informacji, w którym dokonywana jest konwersja ilościowych wartości cech sygnałów diagnostycznych na wartości jakościowe. Przytaczając za [Ciupke, 2001] i [Moczulski, 1997], redukcja ilości informacji pozwala na uogólnienie i uniezależnienie pozyskanej wiedzy od indywidualnych cech poszczególnych obiektów, uzyskanie mniejszej złożoności pozyskanej wiedzy oraz poprawę skuteczności klasyfikacji. Dodaje się jednakże [Ciupke, 2001], iż konwersja wartości może mieć negatywny wpływ na sprawność klasyfikatora. Wskazuje się także na praktyczny aspekt dostępności metod i algorytmów, spośród których wiele wymaga stosowania wartości jakościowych lub stosowanie wartości ilościowych znacznie utrudnia ich wykorzystanie.

Komentując scharakteryzowane badania uwypuklić należy dotychczas nie ujawnianą, milcząco zakładaną cechę metod selekcji i integracji danych rozważanych w niniejszej pracy. Autor zakłada, że wielkości opisujące diagnozowane zjawiska mogą przyjmować wartości zarówno jakościowe (klasyfikacja), jak i ilościowe (aproxymacja). Analogicznie, cechy sygnałów pomiarowych i parametry obróbki przyjmować mogą wartości ilościowe lub jakościowe. Nie wskazuje się jednoznacznie przypadku, który występuje częściej. Odpowiada to uznaniu wyznaczanych modeli współzależności za modele ilościowe lub modele jakościowe z klasyfikatorem [Diagnostyka techniczna, 1997]. Konsekwencją takiego podejścia jest dodatkowy wymóg stawiany rozpatrywanym w pracy metodom, sprowadzający się do zapewnienia możliwości dokonania selekcji i integracji zarówno danych o wartościach ilościowych, jak i jakościowych. Kolejną konsekwencją jest mniejsza przydatność analizowanych w [Ciupke, 2001] metod selekcji, w większości wymagających stosowania danych o wartościach ilościowych, np. metod opartych na teorii zbiorów przybliżonych, minimalizacji entropii zbioru przykładów czy metod bazujących na algorytmie indukcyjnym.

Podobnie komentuje się często stosowane podejście polegające na redukcji wymiaru przestrzeni danych przed dokonaniem selekcji danych. Zazwyczaj stosowana jest w tym przypadku analiza czynnikowa (np. metoda składowych głównych [Morrison, 1990]), której celem jest uzyskanie oszczędniejszego opisu danych przy założeniu możliwie jak najmniejszej utraty informacji (zakodowanie informacji w mniejszej liczbie zmiennych). Możliwość taka wydaje się być bardzo pożądana. Niemniej jednak, zastosowanie rozważanego podejścia w zagadnieniach poruszanych w pracy może nie być efektywne. Zasadniczym problemem jest problem zmniejszenia liczby czujników w projektowanym układzie diagnostycznym. Jak łatwo zauważyć, zastosowanie analizy czynnikowej nie pozwala bezpośrednio na zmniejszenie liczby danych, a tym samym nie prowadzi do uzyskania optymalnej konfiguracji czujników.

Uogólniając, należy jednoznacznie stwierdzić, że autor nie zaprzecza zasadności stosowania zasygnalizowanych podejść (metod i algorytmów). Mając na uwadze przeprowadzoną dyskusję, podejścia te nie są jednakże szczegółowo analizowane w dalszych częściach pracy. Natomiast zastosowanie w prowadzonych badaniach niektórych z rozwiązań umożliwia porównanie uzyskiwanych wyników i dokonanie bardziej obiektywnej oceny metod selekcji zasadniczo testowanych w niniejszej pracy. Odwołując się do ogólnej idei IPUD przypomnieć można, że to potencjalny użytkownik decyduje w wielu przypadkach o zastosowaniu danej metody. Stąd też, jeżeli użytkownik uzna za wskazane, to dokonać może, przykładowo, redukcji informacji na etapie przetwarzania wstępnego. W tym świetle należy również rozważyć przyjęcie do dalszych testów i analiz wspomnianej w podrozdziale 2.1 metody macierzy rozproszenia. Uwypuklenie tej metody uzasadnia się głównie dosyć szerokim zastosowaniem w zagadnieniach związanych z diagnostyką OPN-PS (zob. podrozdział 2.1). Autor uważa, że porównanie wyników uzyskiwanych z zastosowaniem testowanych w pracy metod z wynikami podejść przytaczanych w literaturze jest jak najbardziej wskazane.

### 3. CEL, TEZA I ZAKRES PRACY

Podstawą podejmowanych w niniejszym rozdziale rozważań są ogólne wnioski uwypuklone w przeprowadzonym przeglądzie literatury (rozdział 2). Przegląd literatury skoncentrowano na dyskusji ewolucji badań w dziedzinie diagnostyki OPN-PS, a następnie ukierunkowano na uzasadnienie konieczności, stanowiącego przedmiot pracy, wspomagania projektowania układów diagnostycznych. W kolejnym kroku rozpatrywano problem praktycznej realizacji wspomagania projektowania układów diagnostycznych. Scharakteryzowano koncepcję Inteligentnego Układu Diagnostycznego (IUD) oraz zaproponowano zastosowanie tej koncepcji w Inteligentnym Projektancie Układów Diagnostycznych (IPUD). Wnioski wynikające z przeprowadzonych dyskusji podkreślały znaczenie metod przetwarzania danych, co było przesłanką podjęcia wstępnego wyboru możliwych podejść. Wskazano w tym przypadku na wybrane metody sztucznej inteligencji.

Wykazana istotność ogólnie rozumianego przetwarzania danych jak i uznanie możliwości zastosowania wybranych metod sztucznej inteligencji stanowią o celu, tezie oraz zakresie niniejszej pracy.

#### 3.1. Cel pracy

*Celem pracy jest wybór i usystematyzowanie, a także opracowanie lub zmodyfikowanie metod selekcji i integracji danych oraz przeprowadzenie testów i porównań zorientowanych na weryfikację przydatności rozpatrywanych metod i wskazanie wytycznych oraz zasad ich jak najbardziej skutecznego zastosowania w projektowaniu układów diagnostycznych obrabiarki i procesu skrawania.*

Rozwijając postawiony cel pracy zwraca się uwagę na zasadnicze zróżnicowanie pomiędzy dokonanym, wstępnym wyborem metod i algorytmów (rozdział 2) i *wyborem* zasadniczym, ujętym w celu pracy. Podkreślić należy, że wskazanie na wybrane metody sztucznej inteligencji ma charakter ogólny, nie ujawniający sposobu ich zastosowania, a jedynie sygnalizujący dziedzinę, w której dokonany zostanie wybór zasadniczy. Również, mając na uwadze sygnalizowaną w rozdziale 2 relatywnie niewielką liczbę sugerowanych rozwiązań, szczególnie istotne jest podjęcie prób *opracowania* metod selekcji i integracji danych lub prób wprowadzenia *modyfikacji* metod proponowanych w literaturze.


W kolejnym kroku podkreśla się, że celem pracy jest także *usystematyzowanie* metod selekcji i integracji oraz *weryfikacja* ich przydatności. Wskazuje się w ten sposób na podjęcie prób dokonania porównań wyników zastosowań rozważanych metod uzyskiwanych w przypadku rozwiązywania zróżnicowanych zadań. Istotne jest, iż w wielu pracach badawczych uwypukla się jedynie wyniki korzystne, nie wskazując na ograniczony zakres

zastosowań danego podejścia. Innymi słowy, metoda sprawdzona dla jednego zadania, może w pozostałych przypadkach dawać niezadowalające rezultaty. Wskazując na próby *usystematyzowania* i *zweryfikowania* przydatności metod odnieść się należy do wcześniejszych badań autora niniejszej pracy. Badania prowadzono wielokierunkowo, rozpatrując zarówno zagadnienia ogólne, jak i skupiając się na wybranych szczegółowych problemach. Podjęcie prób *usystematyzowania* jak i *weryfikacji* stanowi o nie ujawnianym jednoznacznie, uogólnionym celu pracy, którym jest podsumowanie dorobku autora w dziedzinie diagnostyki OPN-PS. Zwraca się jednakże uwagę na uwzględnione w celu pracy dążenia do *wskazania zasad* i *wytycznych skutecznego* zastosowania rozważanych metod. W tym świetle za konieczne uznaje się ponowne przeprowadzenie większości testów i analiz dokonanych dotychczas w ramach prac autora oraz innych prac bezpośrednio uwzględnianych w prowadzonych badaniach. Ostatecznie, odwołać się można do często przytaczanych i dyskutowanych wymagań stawianych IUD / IPUD. W takim ujęciu, innym, również nie ujawnianym jednoznacznie, uogólnionym celem pracy jest wykazanie stopnia zbliżenia się wybranych lub opracowanych metod do spełnienia wspomnianych wymagań.

#### 3.2. Teza pracy

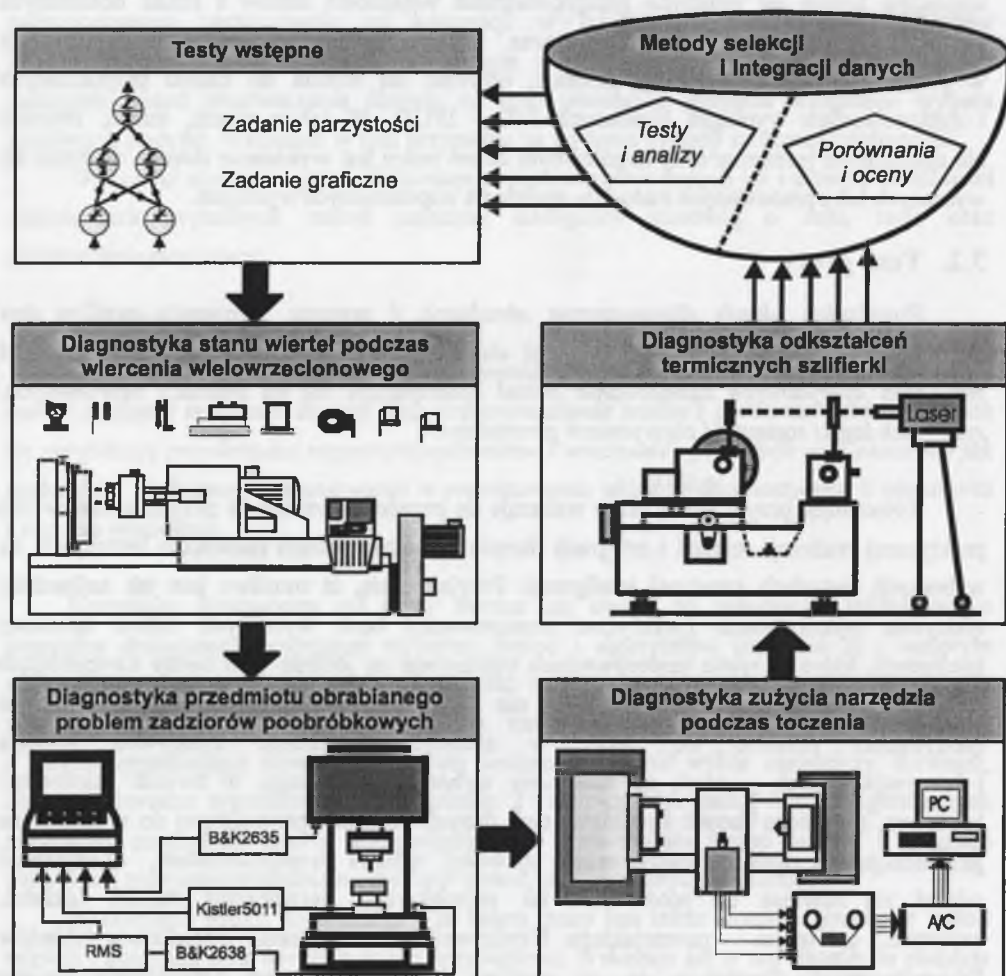
*Projektując układy diagnostyczne obrabiarki i procesu skrawania możliwa jest efektywna realizacja selekcji i integracji danych poprzez bezpośrednie lub w postaci rozwiązań hybrydowych zastosowanie metod opierających się na sieciach neuronowych, systemach logiki rozmytej i algorytmach genetycznych.*

Komentując przyjętą tezę pracy wskazuje się przede wszystkim na przyjęcie możliwości praktycznej realizacji selekcji i integracji danych z zastosowaniem rozwiązań bazujących na wybranych metodach sztucznej inteligencji. Przyjmuje się, iż możliwe jest jak najbardziej *efektywne* wykorzystanie (praktyczne zastosowanie) cech wybranych metod sztucznej inteligencji, które w wielu zastosowaniach traktowane są jedynie jako cechy uwypuklające potencjalną atrakcyjność tych metod, a nie ich rzeczywiste możliwości. Użyte pojęcie *efektywności* rozumie się także w szerszym znaczeniu. *Efektywna* selekcja i integracja danych pozwala na dokonanie wyboru optymalnego, w świetle założonego kryterium, podzbioru danych i poddanie tych danych integracji prowadzącej do wyznaczenia generalizującego opis rozpatrywanego zjawiska modelu współzależności. *Efektywność* odnosi się również do możliwości jak największego ograniczenia funkcji (działań, czynności) człowieka – potencjalnego Użytkownika Inteligentnego Projektanta Układów Diagnostycznych. Przyjmuje się, że możliwe jest zdecydowane ograniczenie ogólnie rozumianych nakładów ponoszonych na dokonanie zarówno selekcji, jak i integracji danych poprzez *zastosowanie metod opierających się na sieciach neuronowych, systemach logiki rozmytej i algorytmach genetycznych.*



Rys. 3.1. Podział diagnostyki obrabiarki i procesu skrawania

Fig. 3.1. Classification of machine tool and cutting process diagnostics



Rys. 3.2. Schematyczne przedstawienie zakresu badań prowadzonych w ramach pracy

Fig. 3.2. Schematic presentation of the scope of the research conducted within the dissertation

### 3.3. Zakres pracy

Charakteryzując zakres niniejszej pracy pomija się rozdziały 1 i 2, w których przeprowadzono dyskusje prowadzące do postawienia celu i przyjęcia tezy pracy. Zasadniczy zakres pracy wyznaczają rozdziały 4-9. W rozdziale 4 dokonywany jest wybór i przedstawiana jest charakterystyka analizowanych metod selekcji i integracji danych. Ponieważ zastosowano kilka zróżnicowanych podejść, na początku odpowiednich podrozdziałów podano krótkie wprowadzenia uogólniające, a następnie skoncentrowano się na szczegółowych opisach wybranych rozwiązań. Charakterystyki i opisy podsumowano zestawieniem rozpatrywanych metod selekcji i integracji. Przedstawiono także zasady realizacji testów oraz zaproponowano kryteria i sposoby oceny tych metod.

W rozdziale 5 przedstawiono wstępne testy metod selekcji bazujących na sieci neuronowej FFBP (rys. 3.2). W testach zastosowano dwa zadania o znanych rozwiązaniach, tj. zadanie parzystości oraz tzw. zadanie graficzne. Oprócz prób oceny rozważanych w tym rozdziale metod, dyskutowano także problem korelacji danych wejściowych ze szczególnym uwzględnieniem wpływu skorelowania na wyznaczone istotności danych.

Zasadnicze testy i analizy metod selekcji i integracji zestawiono w rozdziałach 6-9, gdzie podjęto próby rozwiązania wybranych problemów diagnostycznych. Podkreśla się, iż dążono do przeprowadzenia testów rozważanych metod w świetle podziału diagnostyki OPN-PS dokonanego w [Kosmol, 1995] (rys. 3.1). Analizowano problem klasyfikacji zużycia narzędzia podczas wiercenia wielowrzecionowego (rozdział 6) i podczas toczenia (rozdział 8) (rys. 3.2). Zróżnicowany w tym przypadku był nie tylko sposób obróbki ale również stosowany układ pomiarowy. W rozdziale 6 rozważany jest typowy układ wieloczujnikowy, a w rozdziale 8 układ jednoczujnikowy. Analizowano także zastosowania metod selekcji i integracji danych w zadaniach aproksymacji, tj. rozważano problem diagnostyki przedmiotu obrabianego ze względu na tworzenie się zadziorów poobróbkowych (rozdział 7) oraz problem diagnostyki odkształceń termicznych szlifierki (rozdział 9) (rys. 3.2). W każdym z rozdziałów 6-9 dokonywano opisu stanowiska pomiarowego oraz charakteryzowano przeprowadzone pomiary. Dokonywano również wybiórczej analizy technologicznych aspektów rozpatrywanych problemów w celu uwypuklenia specyfiki lub stopnia złożoności rozwiązywanego zadania. Starano się, aby testy zasadnicze poprzedzić przybliżoną oceną istotności danych, co pozwalało na uogólnienia, przeprowadzanej w podsumowaniu każdego z rozdziałów, oceny zastosowanych metod. Dokonując oceny odwoływano się często do potencjalnego (hipotetycznego) Użytkownika IPUD, co ułatwiało uwypuklenie użytecznego charakteru wniosków.

Badania podsumowano w rozdziale 10, gdzie podjęto ostateczną, ogólną dyskusję uzyskanych wyników. Dyskusję prowadzono w świetle postawionego celu i przyjętej tezy niniejszej pracy. Rozważano także kierunki przyszłych badań.

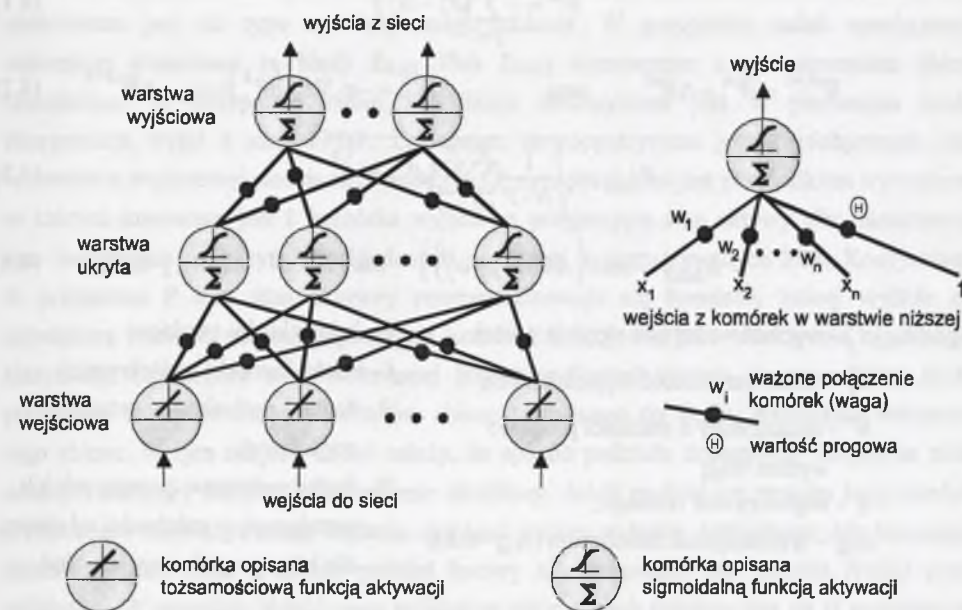
## 4. CHARAKTERYSTYKA ZASTOSOWANYCH METOD I ALGORYTMÓW

Charakterystykę zastosowanych metod i algorytmów starano się uporządkować tak, aby ułatwić opisy rozwiązań hybrydowych. Przykładowo, jednym z pierwszych jest opis algorytmów genetycznych, które stosowane są zarówno do konstruowania, rozważanych w kolejnym kroku, systemów logiki rozmytej, jak i w niektórych metodach selekcji danych. Prowadzona w rozdziale dyskusja zorientowana jest głównie na wskazanie rozwiązań stosowanych w pracy. Stąd też opisy ogólne zredukowano do uznanych za konieczne minimum. Zastosowanie większości z rozważanych metod i algorytmów wymaga określenia (wyboru) specyficznych parametrów. Oprócz proponowanych przez autora rozwiązań skoncentrowano się w tym przypadku na najbardziej uznanych i dostępnych podejściach. Wybór taki potencjalnie zapewnia możliwość uniknięcia rozwiązań o wąskim zakresie zastosowań.

We wprowadzeniu do niniejszego rozdziału należy odnieść się do zagadnienia selekcji danych. Selekcja realizowana jest w dwóch krokach, tj. dokonywana jest ocena istotności danych i następnie dokonywany jest wybór istotnych danych. W niniejszym rozdziale początkowo charakteryzuje się jedynie metody oceny istotności danych (MOI). Rozważania nad dokonaniem wyboru podzbioru istotnych danych prowadzone są w końcowej części rozdziału. Uściślenia wymaga także stosowane pojęcie *istotności* danych. Pojęcie to używane jest w pracy w znaczeniu potocznym, wyrażającym ważność, ważkość, relewantność danych dla rozwiązania rozpatrywanego zadania. Równocześnie, przez *istotność* rozumie się wielkość o wartości wyznaczanej w efekcie zastosowania metod oceny istotności (MOI) i stanowiącej podstawę wyboru istotnych (ważnych, ważkich, relewantnych) danych.

Przed rozpoczęciem opisów konieczne jest także dokonanie zasadniczego wyboru dyskusowanych w dalszej części rozdziału metod selekcji (oceny istotności) i integracji danych. Pierwszą grupę metod stanowią metody zasygnalizowane w rozdziale 2. W przypadku oceny istotności danych do testów wybrano metodę bazującą na analizie wrażliwości [Żurada et al., 1994], nazywaną dalej metodą analizy wrażliwości, oraz hybrydową metodę określaną skrótem SR+AG, dostępną w [STATISTICA-NN] (podrozdział 2.3.1). Zgodnie z uwagami z podrozdziału 2.3.4, uwzględniono również metody bazujące na macierzy rozproszenia, tj. SM+SFS i oryginalną metodę SM+AG. Natomiast w przypadku systemów logiki rozmytej zastosowano zmodyfikowany system proponowany w [Lin i Lee, 1991]. W badaniach stosowane są także oryginalne, opracowane przez autora metody oceny istotności bazujące na sieci neuronowej FFBP, tj. metoda pruningu<sup>(1)</sup> wag i metoda sumy wag, oraz adaptowana przez autora metoda optymalizacji struktury sieci FFBP [Karin, 1991] (metoda A-Karina).

<sup>(1)</sup> Pruning (ang.) – przycinanie, otrząsanie, usuwanie, w tym przypadku wag sieci neuronowej FFBP.



Rys. 4.1. Sieć neuronowa Feed Forward Back Propagation (FFBP); ogólna struktura i wyizolowana komórka sieci

Fig. 4.1. Feed Forward Back Propagation neural network (FFBP); the general structure and an isolated neural network cell

### 4.1. Sieć neuronowa FFBP

#### 4.1.1. Struktura i podstawy treningu sieci neuronowej FFBP

Nazwa angielska sieci Feed Forward Back Propagation (FFBP) zawiera dwie charakterystyczne cechy tej sieci. "Feed Forward" określa kierunek przesyłania danych, tzn. dane przesyłane są w kierunku od wejść do wyjść (rys. 4.1). "Back Propagation" (Error Back Propagation, [Rumelhardt et al., 1986]) odnosi się natomiast do algorytmu treningu sieci. Dodać można, że często opisuje się sieć FFBP jako sieć składającą się z wielu perceptronów odpowiednio ze sobą połączonych, tzw. wielowarstwowy perceptron, MLP.

W pracy stosuje się sieci trójwarstwowe, tzn. sieci z jedną warstwą ukrytą (rys. 4.1). Zgodnie z [Hornik, 1991] trójwarstwowa sieć neuronowa stosowana może być do modelowania dowolnej funkcji matematycznej z dokładnością zależną od liczby komórek w warstwie ukrytej. Komórki w warstwie wejściowej opisane są tożsamościową funkcją aktywacji, a komórki w pozostałych warstwach funkcją sigmoidalną.

$$E^k = \frac{1}{2} \sum_{j=1}^P (d_j^k - o_j^k)^2 \quad (4.1)$$

$$\bar{W}^{k+1} = \bar{W}^k + \Delta \bar{W}^k \quad \text{oraz} \quad \Delta \bar{W}^k = -\eta \cdot \nabla E^k(\bar{W}^k) + \alpha_M \cdot \Delta \bar{W}^{k-1} \quad (4.2)$$

$$E_{RMS} = \sqrt{\frac{1}{N \cdot P} \sum_{i=1}^N \sum_{j=1}^P (d_j^i - o_j^i)^2} \quad (4.3)$$

$$E_{MAX} = \max \{ ABS(d_j^i - o_j^i) \} \quad \text{dla } i=1..N \quad \text{oraz } j=1..P, \quad (4.4)$$

gdzie:  $d_j^k$  - wartość wzorcowa wyjścia z sieci;  $k$  - indeks kroku treningu;  
 $o_j^k$  - obliczona wartość wyjścia z sieci;  $j$  - indeks komórki wyjściowej;  
 $\bar{W}$  - rozszerzony o wartości progowe wektor wag;  $P$  - liczba komórek w warstwie wyjściowej;  
 $\eta$  - współczynnik treningu;  $N$  - liczba wektorów trenujących lub testujących w zależności od zbioru, dla którego obliczany jest błąd.  
 $\alpha_M$  - współczynnik momentum ( $\alpha_M=0.8$ );

Trening sieci FFBP polega na minimalizacji błędu  $E$  (4.1) bazując na metodzie największego spadku na powierzchni błędu w przestrzeni wag. Zmiana (uaktualnienie, dopasowanie) wag i wartości progowych realizowana jest poprzez przesunięcie wzdłuż kierunku ujemnego gradientu w wielowymiarowej przestrzeni wag (4.2).

Trening sieci FFBP jest treningiem z nauczycielem (trening nadzorowany) i polega na cyklicznej prezentacji sieci zbioru uczącego. Przez krok treningu rozumiana jest prezentacja sieci danego wektora uczącego, obliczenie wartości bieżącej wyjść sieci i wyznaczenie wartości zmian (poprawek) wag i wartości progowych. Zrealizowanie kroków treningu z zastosowaniem wszystkich wektorów uczących nazywane jest iteracją.

Zbiór uczący utożsamiany może być ze zbiorem trenującym w przypadku, gdy nie jest stosowany zbiór weryfikujący. Zbiór weryfikujący to zbiór wydzielany ze zbioru uczącego w celu weryfikacji treningu sieci. Zbiór uczący zawiera pary wektorów, tj. wektor trenujący (wektor reprezentujący dane wejściowe, wejścia do sieci) i odpowiadający wektor wartości wzorcowych na wyjściu (wektor wyjść). Wartości wejść skalowane są w przedziale [0, 1], a wartości wzorcowe wyjść w przedziale [0.1, 0.9]. Trening sieci uznaje się zwykle za zakończony, gdy sieć osiągnie założony błąd treningu  $E_{RMS}$  (4.3) lub  $E_{MAX}$  (4.4). Stosowane są także kryteria bazujące na postępie treningu, tj. zmianach wartości błędu treningu, lub bazujące na wartościach błędów  $E_{RMS}$  i/lub  $E_{MAX}$  wyznaczanych z zastosowaniem zbioru weryfikującego.

Ocena jakości, interpretowanej jako model pewnego zjawiska, skonstruowanej sieci uzależniona jest od typu rozwiązywanego zadania. W przypadku zadań aproksymacji najczęściej stosowane są błędy  $E_{RMS}$  i/lub  $E_{MAX}$  wyznaczone z zastosowaniem zbioru testującego. W przypadku zadań klasyfikacji dokonywana jest w pierwszym kroku interpretacja wyjść z sieci FFBP. Zakładając, że rozpatrywane jest  $P$  rozłącznych klas, w warstwie wyjściowej stosuje się  $P$  komórek. Przypadek 2 klas jest przypadkiem trywialnym, w którym stosowana jest 1 komórka wyjściowa przyjmująca stan aktywnej albo nieaktywnej, tzn. wskazująca na przynależność danych do jednej z rozpatrywanych klas. Kontynuując, w przypadku  $P$  klas stan aktywnej przyporządkowuje się komórce, której wyjście ma największą wartość, natomiast pozostałe komórki traktuje się jako nieaktywne. Sprawność klasyfikacji (sprawność sieci stosowanej jako klasyfikator) wyraża się stosunkiem liczby poprawnie sklasyfikowanych wektorów zbioru testującego do liczby wszystkich wektorów tego zbioru. W tym miejscu dodać należy, że sposób podziału dostępnych danych na zbiór uczący i testujący nie jest jednoznacznie określony. Jeżeli podział nie wynika bezpośrednio z charakteru rozwiązywanego zadania, dokonać można podziału arbitralnego lub losowego. Stosowany jest także  $N$ -krotny podział losowy lub stosowana jest metoda *N-fold cross validation*. W metodzie *N-fold cross validation* zbiór danych dzielony jest na  $N$  podzbiorów, z których każdy interpretowany jest w kolejnych symulacjach<sup>(1)</sup> sieci jako zbiór testujący.

$$\eta \rightarrow \eta_C \quad (4.5)$$

$$\eta \rightarrow \eta_{F,m} = \frac{S_A}{P_m} \quad \eta_F = \max \left( \frac{S_A}{P_1}, \frac{S_A}{P_2} \right), \quad (4.6)$$

gdzie:  $S_A$  - stała o arbitralnie przyjmowanej wartości;  
 $P_m$  - liczba komórek w warstwie m-tej.

Odwołując się ponownie do zależności (4.2), zauważyć można zastosowanie powszechnie uznanej metody momentu pierwszego rzędu ze współczynnikiem  $\alpha_M=0.8$ . Następnie, wartość współczynnika treningu  $\eta$  ustalano arbitralnie ( $\eta_C$ , (4.5)) lub, należy dodać w większości symulacji, wartość współczynnika treningu ustalano metodą *fan-in* (4.6). W metodzie tej stosowane są zróżnicowane wartości współczynnika treningu w poszczególnych warstwach sieci. W celu ułatwienia dalszych opisów przyjęto, aby współczynnik treningu wyrażać wartością maksymalną  $\eta_F$  (4.6). W uzupełnieniu zaznacza się, że wyboru sposobu ustalania wartości  $\eta$  dokonano na podstawie wyników testów (np. [Sokołowski, 1995]), w których oprócz  $\eta_F$  i  $\eta_C$  analizowano także metody sprawdzające się do zmian wartości  $\eta$  w funkcji błędu  $E$  (4.1) oraz testowano kompromisowe podejście Vogla.

<sup>(1)</sup> Pojęcie „symulacja sieci FFBP” używane jest w pracy jako pojęcie ogólne, wyrażające realizację wszystkich lub jedynie części koniecznych działań (czynności, operacji) mających na celu skonstruowanie sieci, w tym także zastosowanie sieci do oceny istotności danych. W analogicznym znaczeniu pojęcie to stosowane jest w odniesieniu do systemów logiki rozmytej oraz algorytmów genetycznych.



Trening sieci realizowano z zastosowaniem algorytmu kumulacyjnego ATS-cum (Cumulative Weight Adjustment) lub algorytmu inkrementalnego ATS-inc (Incremental Weight Adjustment). W algorytmie ATS-inc zmiany wag sieci dokonywane są w każdym kroku treningu. Stosując algorytm ATS-cum zmiany wag wprowadzane są natomiast jednorazowo, po każdej iteracji. W tym przypadku wagi uaktualniane są na podstawie średnich wartości zmian wag wyznaczonych po prezentacji wszystkich wektorów trenujących. Zaletą algorytmu ATS-inc jest dokonywanie zmian wag w rzeczywistym kierunku minimalizacji błędu, a nie, jak w przypadku ATS-cum, w kierunku wypadkowym. Niebezpieczeństwo polega jednak na fakcie, iż wagi sieci mogą być zmieniane (chwilowo odchylane) w kierunku wyznaczonym przez ostatnio prezentowane wektory trenujące, co prowadzić może do znacznych wahań wartości błędu treningu (destabilizacji treningu). Dlatego też zaleca się, aby stosując algorytm ATS-inc losowo ustalać kolejność prezentacji wektorów zbioru trenującego.

Zastosowanie jedynie algorytmów ATS-inc i ATS-cum wskazywać może na znaczne uproszczenie zagadnienia wyboru algorytmu treningu sieci FFBP. W świetle celu prowadzonych badań jak najbardziej zasadne wydawałoby się zastosowanie tzw. szybkich algorytmów treningu. Przeprowadzone testy z zastosowaniem, co należy podkreślić, danych analizowanych w niniejszej pracy oraz wcześniejsze badania autora ([Sokołowski, 1995], [Sokołowski, 2000]) wzbudziły jednakże szereg wątpliwości. W ramach testów porównywano algorytm normalizujący [Parlos et al., 1992], zmodyfikowany w [Sokołowski, 1995] algorytm adaptacyjny [Fan i Wu, 1992] oraz algorytm gradientów sprzężonych (np. [Sarwal i Srinath, 1992]) w wariantach Polaka-Ribiere'a [STATISTICA-NN] i algorytm Levenberga-Marquardta (np. [Osowski, 1996], [STATISTICA-NN]). Wykazano, iż algorytm normalizujący i algorytm adaptacyjny nie pozwalały na wyraźne przyspieszenie treningu, a także negatywnie wpływały na zdolność generalizacji sieci FFBP. Wykazano także podatność na „utknięcia” w lokalnych minimach funkcji błędu (tzw. blokowanie treningu) lub duże tendencje do destabilizacji treningu. Podobnymi cechami charakteryzował się także algorytm Quick-Prop (np. [Osowski, 1996]). Znaczne skrócenie czasu treningu uzyskiwano natomiast stosując algorytm gradientów sprzężonych i algorytm Levenberga-Marquardta. Niemniej jednak, w przeprowadzonych symulacjach wyraźnie ujawniła się podatność na utknięcia w minimach lokalnych. Praktycznie, w przeciwieństwie do algorytmów ATS-inc i ATS-cum, jedynie w 40%+60% symulacji osiągnęto założone wartości błędów treningu. Podkreślić należy, że blokowanie treningu prowadzić może do wniosku o konieczności zwiększenia liczby komórek ukrytych, czyli zbędnego rozbudowania sieci i potencjalnej utraty zdolności generalizacji lub krytycznego uznania małej reprezentatywności analizowanych danych.

#### 4.1.2. Metody szacowania liczby komórek w warstwie ukrytej

Podjmując zagadnienie oszacowania liczby komórek w warstwie ukrytej przypomnieć można zdecydowanie negatywne konsekwencje potencjalnego błędu popełnionego na tym

etapie konstruowania sieci FFBP. Pomija się w tym przypadku przyjęcie zbyt małej liczby komórek ukrytych i koncentruje się na problemie tzw. przewymiarowania warstwy ukrytej (przewymiarowania struktury sieci). Problem sprowadza się do przyjęcia zbyt dużej liczby komórek w stosunku do liczby wektorów trenujących. W efekcie, wyznaczony model może nie stanowić uogólnienia danych i być jedynie zapisem tych danych w innej postaci [Diagnostyka techniczna, 1997], tzn. sieć neuronowa FFBP zatracać może zdolność generalizacji.

Zdaniem autora, zbyt rozbudowana struktura sieci nie jest warunkiem wystarczającym utraty zdolności generalizacji. Równie istotny jest warunek zakończenia treningu sieci. Oznacza to, że nawet w przypadku przewymiarowania struktury sieci, odpowiednio dobrany warunek zakończenia treningu może stanowić skuteczne zabezpieczenie przed utratą zdolności generalizacji. Jak to zostanie przedstawione w dalszej części pracy (rozdział 7), nie mniej istotny jest charakter danych. Ogólnie, pomimo prowadzonych prac (np. [Mehrotra et al., 1991], [Takahashi et al., 1993], [Zacksenhouse, 2001]), brak jest niezawodnych reguł pozwalających na określenie optymalnej struktury sieci FFBP. Zazwyczaj stosuje się zbiór weryfikujący lub też metody szacowania liczby komórek ukrytych. Wybrane, stosowane w dalszej części pracy metody, charakteryzowane są w poniższej części podrozdziału.

#### *Algorytm ATS-des ([Li i Kim, 1992])*

Algorytm ATS-des może być stosowany do konstruowania trójwarstwowej sieci z komórkami w warstwie wyjściowej i wejściowej opisanymi tożsamościową funkcją aktywacji oraz komórkami w warstwie ukrytej opisanymi funkcją sigmoidalną. Konstruowanie sieci FFBP rozpoczyna się od treningu sieci z tylko jedną komórką w warstwie ukrytej. Po stwierdzeniu, iż kolejne iteracje nie powodują zmian wartości błędu treningu (następuje stabilizacja wartości błędu treningu), do warstwy ukrytej wprowadzana jest druga komórka i rozpoczyna się następna faza treningu. Należy zaznaczyć, że w fazie tej zmieniane są jedynie wagi nowo wprowadzonej komórki. Po ponownym stwierdzeniu stabilizacji błędu treningu wprowadzana jest kolejna komórka i rozpoczyna się trening wag tej komórki. Wprowadzanie komórek kontynuowane jest do uzyskania założonej wartości błędu treningu lub do osiągnięcia fazy, w której wprowadzanie kolejnych komórek nie powoduje zasadniczych zmian wartości błędu treningu. Dodaje się, że obserwowanym błędem treningu może być błąd  $E_{RMS}$  lub  $E_{MAX}$ .

#### *Metoda pruningu komórek ([Sietsma i Dow, 1991], [Sokołowski, 1995])*

Metoda pruningu komórek opiera się na przeprowadzonym po treningu sieci wyborze komórek w warstwie ukrytej, których wyjścia przyjmują w przybliżeniu wartości stałe lub komórek, których wyjścia przyjmują wartości analogiczne do wartości wyjść innych komórek ukrytych, tzn. "naśladują" inne komórki ukryte. Zakłada się, że wybrane komórki mogą być odrzucone, co odpowiada określeniu koniecznej, z punktu widzenia rozwiązywanego zadania, liczby komórek w warstwie ukrytej.

$$\theta_{m+1,j}^* = \theta_{m+1,j} + w_{m+1,j,i} \cdot a_{m,i} \quad (4.7)$$

$$w_{m+1,j,q}^* = w_{m+1,j,q} + w_{m+1,j,p} \quad (4.8)$$

$$o_{m,q} \cong 1 - o_{m,p} \quad (4.9)$$

$$w_{m+1,j,q}^* = w_{m+1,j,q} - w_{m+1,j,p} \quad \text{oraz} \quad \theta_{m+1,j}^* = \theta_{m+1,j} + w_{m+1,j,p}, \quad (4.10)$$

gdzie:  $m$  - indeks warstwy ukrytej;

$w_{m,j,i}$  - waga łącząca  $i$ -tą komórkę (warstwa  $m-1$ ) z komórką  $j$ -tą w  $m$ -tej warstwie;

$\theta_{m,j}$  - wartość progowa  $j$ -tej komórki w warstwie  $m$ -tej;

$o_{m,i}$  - wyjście  $i$ -tej komórki w warstwie  $m$ -tej;

$a_{m,i}$  - wartość średnia  $i$ -tego wyjścia w warstwie  $m$ -tej.

Istota metody sprowadza się do zdefiniowania kryteriów wyboru odpowiednich komórek w warstwie ukrytej. W [Sietsma i Dow, 1991] sugeruje się, aby przyjąć przedziały [0.00, 0.35] oraz [0.65, 1.00] i analizować wyjścia komórek w kategoriach: wartość wyjścia komórki należy lub nie należy do jednego z tych przedziałów. W [Sokołowski, 1995] zaproponowano modyfikację sposobu wyboru komórek - kandydatek do odrzucenia. Rozbudowano metodę pruningu o wyznaczanie wartości średnich wyjść poszczególnych komórek warstwy ukrytej  $a_{m,i}$  (zob. (4.7)). Wskazanie komórki do odrzucenia następuje po stwierdzeniu, iż wartości wyjścia komórki należą do przedziału  $a_{m,i} \pm pr_K$ . Wielkość  $pr_K$  nazywana jest parametrem pruningu komórek, a jej wartość ustalana jest na drodze arbitralnego wyboru (najczęściej  $pr_K = 0.2 \div 0.3$ ).

Odrzucenie wybranych komórek wiąże się z koniecznością wprowadzenia zmian wartości wag i wartości progowych pozostałych komórek sieci:

- jeżeli wyjście  $i$ -tej komórki zachowuje w przybliżeniu stałą wartość, to wartość ta stanowi dodatkową wartość progową komórek w warstwie wyższej. Odrzucając  $i$ -tą komórkę należy uaktualnić wartości progowe komórek w warstwie wyższej zgodnie z (4.7).
- jeżeli wartości wyjść komórki  $p$  są zbliżone do wartości wyjść komórki  $q$ , to odrzucając komórkę  $p$  należy uaktualnić wagi komórki  $q$  w warstwie wyższej zgodnie z (4.8).

Oprócz opisanych dwóch przypadków może również wystąpić "naśladowanie się" komórek  $p$  i  $q$  poprzez przyjmowanie przeciwnych wartości wyjść (4.9). Aby odrzucić komórkę  $p$ , należy uaktualnić wagi i wartości progowe zgodnie z (4.10).

### Metoda SW+GS ([STATISTICA-NN])

Przytaczając za dostępnym w [STATISTICA-NN] opisem, oszacowanie liczby komórek ukrytych realizowane jest w dwóch krokach. W pierwszym kroku ustalana jest maksymalna liczba komórek ukrytych, a w kolejnym kroku stosowane jest podejście bazujące na symulowanym wyżarzaniu (SW). Maksymalna liczba komórek określana jest na podstawie założeń heurystycznych uwzględniających liczbę wejść i wyjść oraz liczbę wektorów trenujących. Następnie stosowany jest algorytm bisekcji w celu wyboru początkowej liczby komórek ukrytych. Po ustaleniu początkowej liczby komórek realizowany jest trening sieci FFBP o różnych strukturach algorytmem gradientów sprzężonych (GS). Stosowane są jednocześnie dwa warunki zakończenia treningu. Trening uznaje się za zakończony po zrealizowaniu 100 iteracji lub w przypadku, gdy w kolejnych 5 iteracjach nie występują istotne zmiany wartości błędu treningu. Sugeruje się, aby zakończenie treningu określane było z zastosowaniem zbioru weryfikującego, jakkolwiek zastosowanie tego zbioru nie jest konieczne. Ponieważ jedną z wad algorytmu gradientów sprzężonych jest możliwość łatwego utknięcia w lokalnych minimach funkcji błędu treningu, symulacje każdej z sieci powtarza się 3-krotnie i najlepsze rozwiązanie jest uważane za reprezentanta tych symulacji.

Zasadniczą wielkością wpływającą na uzyskiwane wyniki jest współczynnik kary  $UP_K$  (Unit Penalty Factor). Iloczyn liczby komórek ukrytych i arbitralnie ustalonej wartości współczynnika  $UP_K$  dodawany jest do błędu treningu sieci, co odpowiada forsowaniu metody do wyboru mniejszej liczby komórek w warstwie ukrytej.

#### 4.1.3. Metody oceny istotności danych bazujące na sieci neuronowej FFBP

##### Metoda pruningu wag (np. [Sokołowski i Dornfeld, 1994], [Sokołowski, 1995])

Idea zastosowana w metodzie pruningu wag bazuje na jednej z podstawowych cech sieci neuronowej FFBP, tj. dużej mocy obliczeniowej skonstruowanej sieci uzyskiwanej dzięki liczным, wzajemnym połączeniom komórek. Przyjmuje się, że miarą istotności poszczególnych komórek wejściowych jest liczba aktywnych połączeń (wag) danej komórki z komórkami w warstwie ukrytej. Zakłada się, że w przypadku gdy istnieje możliwość istotnego zmniejszenia liczby wag łączących daną komórkę wejściową z komórkami w warstwie ukrytej, bez wprowadzenia radykalnych zmian w przyjętych, dopuszczalnych wartościach błędów treningu, to dana komórka wejściowa może być odrzucona.

Metoda pruningu wag realizowana jest krokowo. W każdym kroku testowane są kolejno wszystkie wagi łączące komórki wejściowe z komórkami ukrytymi. Test danej wagi polega na odrzuceniu tej wagi (nadaniu jej wartości zerowej) i wyznaczeniu błędów  $E_{RMS}$  (4.3) i  $E_{MAX}$  (4.4). Po wyznaczeniu błędów wadze przywracana jest jej poprzednia wartość. W efekcie uzyskuje się zestawienie, w którym poszczególne wagi reprezentowane są przez błędy  $E_{RMS}$  i  $E_{MAX}$ . Następnie wybiera się tylko te wagi, dla których błąd  $E_{MAX}$  jest mniejszy od

założonej wartości parametru pruningu wag  $pr_w$ . Dany krok pruningu kończy się odrzuceniem wagi, dla której błąd  $E_{RMS}$  ma najmniejszą wartość oraz  $E_{MAX} \leq pr_w$ . Jak można zauważyć, w kolejnych krokach stopniowo zmniejsza się liczba nieistotnych w świetle przyjętego kryterium wag, łączących komórki warstwy wejściowej z komórkami warstwy ukrytej. Pruning wag uznaje się za zakończony, gdy nie jest możliwy wybór wagi, której odrzucenie pozwałoby na spełnienie kryterium  $E_{MAX} \leq pr_w$ . Ostatecznie, istotność wejść do sieci FFBP (istotność danych reprezentowanych przez wejścia) wyraża się liczbą wag, które „przetrzywały” proces eliminacji.

#### Metoda sumy wag ([Sokołowski, 1996], [Sokołowski i Kosmol, 1996a])

Metoda sumy wag<sup>(1)</sup> opiera się na podobnych przesłankach jak metoda pruningu wag. W metodzie tej ocenia się istotność poszczególnych wejść poprzez analizę wartości wag łączących komórki wejściowe z komórkami w warstwie ukrytej. Zakłada się, że wagi o małych wartościach bezwzględnych powodują filtrowanie informacji wprowadzanych przez rozpatrywaną komórkę wejściową, czyli wejście to może być odrzucone. Istotność wejścia (danej wejściowej) reprezentowana jest przez sumę wartości bezwzględnych wag „wychodzących” z rozpatrywanej komórki wejściowej.

#### Metoda A-Karina

Metoda A-Karina opiera się na adaptowanej przez autora metodzie optymalizacji struktury sieci neuronowej FFBP proponowanej w [Karin, 1991]. W [Karin, 1991] oceniana jest wrażliwość błędu sieci na eliminację wag. Jeżeli wrażliwość jest niska, to rozpatrywaną wagę można odrzucić. W niniejszej pracy dokonuje się oceny wag łączących warstwę wejściową z warstwą ukrytą, zgodnie z zależnością (4.11). Proponuje się, aby istotność danego wejścia wyrażać maksymalną, bezwzględną wartością wrażliwości  $WW_i$  (4.12) charakteryzujących wagi łączące rozpatrywane wejście z komórkami w warstwie ukrytej.

$$WW_i = - \sum_{k=1}^N \left( \frac{\partial E^k}{\partial w_i^k} \cdot \Delta w_i^k \right) \cdot \frac{w_i^{(f)}}{w_i^{(f)} - w_i^{(p)}} \quad (4.11)$$

$$IK = \max_{i=1 \dots M} \{ ABS(WW_i) \}, \quad (4.12)$$

gdzie:  $E^k$  - błąd treningu sieci FFBP (4.1);  $M$  - liczba komórek ukrytych;  
 $N$  - liczba zrealizowanych zmian wag;  $IK$  - istotność rozpatrywanego wejścia;

oraz dla rozpatrywanego wejścia :

$w_i^{(p)}$  - początkowa wartość i-tej wagi;  $w_i^{(f)}$  - końcowa wartość i-tej wagi;  
 $\Delta w_i$  - zmiana i-tej wagi;  $WW_i$  - wrażliwość błędu treningu sieci na eliminację i-tej wagi.

<sup>(1)</sup> Inspiracje metody sumy wynikają z dyskusji autora prowadzonych podczas spotkań i konferencji w latach 1993-1995 oraz sugestii, które można znaleźć w [Żurada, 1992]. Natomiast sobie autor przypisuje praktyczną implementację i testy tej metody.

#### Metoda analizy wrażliwości ([Żurada et al., 1994])

Wyznaczenie istotności danych metodą analizy wrażliwości dokonywane jest po przeprowadzeniu treningu sieci neuronowej FFBP. Wrażliwość p-tego wyjścia sieci na m-ty element n-tego wektora trenującego wyraża się zależnością (4.13), co uwzględniając proces przetwarzania informacji w sieci FFBP prowadzi do zależności (4.14). Aby uwzględnić wszystkie wektory trenujące, stosuje się w kolejnym kroku normę euklidesową i wyznacza się ogólną wrażliwość p-tego wyjścia na zmiany m-tego wejścia (4.15).

$$D_{p,m}^{(n)} = \frac{\partial o_p}{\partial x_m} \quad (4.13)$$

$$D_{p,m}^{(n)} = f_p^{(3)} \sum_{k=1}^K w_{3,p,k} \cdot \frac{\partial u_k}{\partial x_m} = f_p^{(3)} \sum_{k=1}^K f_k^{(2)} \cdot w_{3,p,k} \cdot w_{2,k,m} \quad (4.14)$$


$$D_{p,m}^{(*)} = \sqrt{\frac{\sum_{n=1}^N [D_{p,m}^{(n)}]^2}{N}} \quad (4.15)$$

$$D = \begin{bmatrix} D_{1,1}^{(*)} & \dots & D_{1,M}^{(*)} \\ \dots & \dots & \dots \\ D_{P,1}^{(*)} & \dots & D_{P,M}^{(*)} \end{bmatrix} \quad (4.16)$$

$$IW_m = \max_{p=1, \dots, P} \{ D_{p,m} \}, \quad (4.17)$$

gdzie:  $o_p$  - p-te wyjście z sieci;  $x_m$  - m-te wejście do sieci;  
 $u_k$  - k-ta komórka w warstwie ukrytej;  $f_p^{(i)}$  - pochodna funkcji aktywacji p-tej  
 $w_{z,j,i}$  - waga łącząca i-tą komórkę komórki w i-tej warstwie;  
 (warstwa z-1) z komórką j-tą  $p$  - indeks komórki wyjściowej  $p=1 \dots P$ ;  
 w z-tej warstwie;  $n$  - indeks wektora trenującego  $n=1 \dots N$ ;  
 $m$  - indeks komórki wejściowej  $k$  - indeks komórki ukrytej  $k=1 \dots K$ .  
 $m=1 \dots M$ ;

Wyznaczenie wrażliwości zgodnie z (4.15) pozwala na utworzenie macierzy wrażliwości  $D$  (4.16). Elementy m-tego wiersza macierzy  $D$  określają wrażliwość m-tego wyjścia sieci na zmiany wartości elementów wektora wejściowego. Analogicznie, m-ta kolumna macierzy  $D$  określa wrażliwość wyjść sieci na zmiany wartości m-tego wejścia. Istotność m-tego wejścia  $IW_m$  wyraża się maksymalną wartością elementów m-tej kolumny macierzy  $D$  (4.17).



Rys. 4.2. Wybrane typy krzyżowania  
Fig. 4.2. Selected crossover types

## 4.2. Algorytmy genetyczne

Charakteryzując algorytmy genetyczne (AG) dogodnie jest przyjąć, iż poszukiwane jest maksimum funkcji reprezentującej pewien rozpatrywany problem. Funkcję tę nazywa się funkcją przystosowania. Poszukiwanie maksimum funkcji przystosowania rozpoczyna się od losowej inicjalizacji założonej liczby rozwiązań. Zbiór rozwiązań nazywany jest populacją. Każde rozwiązanie (osobnik populacji) reprezentowane jest w postaci chromosomu składającego się z pewnej liczby genów o wartościach binarnych (0, 1). Jak można zauważyć, rozwiązania reprezentowane są w AG w formie kodowanej. W kolejnym kroku dla każdego chromosomu (osobnika) wyznaczana jest wartość funkcji przystosowania.

Istota poszukiwania maksimum funkcji przystosowania sprowadza się do reprodukcji (tworzenia) nowych populacji, bazując na osobnikach danej (bieżącej) populacji. W fazie reprodukcji realizowane są trzy zasadnicze operacje. W pierwszym kroku wybiera się rodziców (2 chromosomy) metodą koła ruletki o nierównomiernym podziale. Rodzicom o największych wartościach funkcji przystosowania przypisuje się pola koła ruletki o największej szerokości. W ten sposób rodzice o najlepszych cechach (najwyższych wartościach funkcji przystosowania) biorą udział w reprodukcji najczęściej. Następnie realizowane jest krzyżowanie (z prawdopodobieństwem  $p_K$ ) polegające na utworzeniu potomków posiadających części chromosomów każdego z rodziców (rys. 4.2). Ostatecznie realizowana jest mutacja polegająca na zmianie wartości genu potomka z prawdopodobieństwem  $p_M$ . W efekcie procesu reprodukcji tworzy się nową populację i opisuje każdego osobnika tej populacji wartością funkcji przystosowania. Zakłada się, że w nowej populacji występuje więcej osobników o wyższych wartościach funkcji przystosowania. Oznacza to, że kolejne populacje zbliżają się do poszukiwanego maksimum. Zakończenie symulacji AG nie jest jednoznacznie określone. Zazwyczaj przyjmuje się liczbę generowanych populacji lub obserwuje się „najlepsze” osobniki i w przypadku, gdy w kilku kolejno utworzonych nowych populacjach nie zostanie wykryty osobnik o wyższej wartości funkcji przystosowania, symulację uznaje się za zakończoną.

Algorytm genetyczny stosowany w pracy rozbudowano o normalizację liniową wartości funkcji przystosowania [Davis, 1991]. Stosując normalizację liniową przypisuje się

„najlepszymu” osobnikowi wybraną wartość, a kolejnym osobnikom przypisuje się wartości zmniejszające się liniowo z zadaniem krokiem. Unika się w ten sposób wybierania podczas reprodukcji osobników „najgorszych” i „najlepszych” z takim samym prawdopodobieństwem, co występuje w przypadku zbliżonych wartości funkcji przystosowania poszczególnych osobników. Zastosowano także zasadę elityzmu [Davis, 1991], zgodnie z którą „najlepszy” osobnik bieżącej populacji jest każdorazowo kopiowany do nowej populacji. Zapobiega to pomijaniu osobników „najlepszych” w kolejnych populacjach.

W badaniach testowano także wybór rodziców metodą rankingową, reprodukcję z częściową wymianą populacji (ang. steady-state) oraz przyporządkowanie operatorom genetycznym stałych i interpolowanych wartości funkcji przystosowania. W rozważanych w pracy zastosowaniach nie wykazano jednakże znaczącego wpływu tych rozwiązań.

Podsumowując należy zaznaczyć, że brak jest jednoznacznych wskazań sposobu doboru wartości parametrów algorytmów genetycznych. Stąd też w symulacjach arbitralnie przyjęto stosować populacje o liczebności 50÷100 osobników, generując 500÷1000 populacji z parametrami  $p_K=0.8$  i  $p_M=0.05$ . Zastosowano krzyżowanie dwupunktowe oraz powyżej scharakteryzowaną zasadę elityzmu i normalizację liniową funkcji przystosowania. Algorytm ten nazywany jest dalej klasycznym algorytmem genetycznym w celu odróżnienia od algorytmów dostosowywanych do specyfiki rozważanych w kolejnych częściach pracy problemów.

## 4.3. System logiki rozmytej

Jak wskazano we wprowadzeniu do niniejszego rozdziału, w badaniach stosowany jest system logiki rozmytej, bazujący na podejściu zaproponowanym w [Lin i Lee, 1991]. Rozpoczynając opis systemu pomocne jest odniesienie się do podstawowych założeń teorii zbiorów rozmytych i wnioskowania rozmytego. Zmienne (dane wejściowe) są w systemie logiki rozmytej tzw. zmiennymi lingwistycznymi. Każdej zmiennej lingwistycznej (np. „prędkość”) przypisana jest jej wartości lingwistyczna, np. „niska”, „średnia”, „wysoka”, będąca równocześnie nazwą zbioru rozmytego przyporządkowanego tej wartości. Zmienna lingwistyczna jest charakteryzowana zatem przez zbiory rozmyte i odpowiadające im funkcje przynależności (4.18). W systemie logiki rozmytej następuje mapowanie przestrzeni wejściowej na zbiory rozmyte w ten sposób, iż wartość zmiennej  $x_i$  mapowana jest na zbiór rozmyty  $T_{x_i}^1$  w stopniu  $M_{x_i}^1(x_i)$  i na zbiór rozmyty  $T_{x_i}^2$  w stopniu  $M_{x_i}^2(x_i)$  itd.

$$T(x_i) = \{T_{x_i}^1, T_{x_i}^2, \dots, T_{x_i}^{K_i}\} \quad \text{oraz} \quad M(x_i) = \{M_{x_i}^1, M_{x_i}^2, \dots, M_{x_i}^{K_i}\}, \quad (4.18)$$

gdzie:  $x_i$  - i-ta zmienna lingwistyczna;

$T_{x_i}^k$  - zbiór rozmyty o funkcji przynależności  $M_{x_i}^k$ ;

$K_i$  - liczba zbiorów rozmytych przyporządkowanych i-tej zmiennej lingwistycznej.

Opisując i interpretując w pełni analogicznie wyjścia systemu logiki rozmytej, przykładową k-tą regułę systemu o jednym wyjściu  $y$  (w badaniach stosowane są tylko systemy o jednym wyjściu) opisuje zależność (4.19).

$$R_k : \text{Jeżeli } x_1 \text{ jest } T_{x_1}^1 \text{ i } x_2 \text{ jest } T_{x_2}^2 \text{ i } \dots \text{ to } y \text{ jest } T_y^1 \quad (4.19)$$

#### 4.3.1. Struktura systemu logiki rozmytej

Analizując strukturę systemu logiki rozmytej (rys. 4.3) wskazuje się na analogie do struktury sieci neuronowej FFBP. Zarówno sieć FFBP, jak i system FL składają się z odpowiednio ze sobą połączonych warstw. Różnice sprowadzają się natomiast do różnego znaczenia połączeń pomiędzy warstwami oraz do różnych funkcji aktywacji komórek poszczególnych warstw. W systemie logiki rozmytej połączenia pomiędzy warstwami nie są połączeniami ważonymi, czyli służą do bezpośredniego przesyłania informacji. Istotna jest natomiast struktura połączeń, która reprezentuje wiedzę w systemie FL. Postaci funkcji aktywacji komórek systemu FL zależą natomiast od warstwy, do której należą komórki.

WARSTWA 1 : warstwa wejściowa z komórkami opisanymi funkcją tożsamościową.

WARSTWA 2 : warstwa wejściowych funkcji przynależności ( $MF_{WE}$ ). Każdą funkcję przynależności interpretuje się jako niezależną komórkę opisaną funkcją Gaussa (4.20). Na wyjściu poszczególnych komórek wyznaczana jest wartość funkcji przynależności wyrażająca stopień przynależności wartości wejścia (danej wejściowej) do zbioru rozmytego.

$$M_{x_i}^j(x_i) = \exp \left[ - \left( \frac{x_i - C_{x_i}^j}{\sigma_{x_i}^j} \right)^2 \right], \quad (4.20)$$

gdzie:  $M_{x_i}^j(x_i)$  - j-ta funkcja przynależności i-tego wejścia  $x_i$  (i-tej zmiennej lingwistycznej);


$C_{x_i}^j, \sigma_{x_i}^j$  - parametry j-tej funkcji przynależności i-tego wejścia.

$$\alpha_k = M_{x_1}^1(x_1) \wedge M_{x_2}^2(x_2) \wedge \dots = \min \{ M_{x_1}^1(x_1), M_{x_2}^2(x_2), \dots \}, \quad (4.21)$$

gdzie:  $\wedge$  - rozmyty operator AND;

$\alpha_k$  - stopień aktywności k-tej reguły.

WARSTWA 3 : warstwa reprezentująca bazę reguł systemu logiki rozmytej. Każda z komórek w tej warstwie reprezentuje jedną regułę. Liczba komórek odpowiada więc liczbie reguł. Połączenia komórek z WARSTWĄ 2 stanowią przesłanki reguł, a połączenia z WARSTWĄ 4 stanowią konkluzje reguł. Na wyjściach komórek tej warstwy wyznaczane są stopnie aktywności odpowiednich reguł. Na przykładzie reguły opisanej zależnością (4.19) wyznaczyć można stopień aktywności tej reguły zgodnie z (4.21).



Rys. 4.3. Ogólna struktura systemu logiki rozmytej

Fig. 4.3. General structure of the fuzzy logic system

$$\alpha^{(j)} = \min \{ 1, (\alpha_1^{(j)} + \alpha_2^{(j)} + \alpha_3^{(j)} + \dots) \} \quad \text{oraz} \quad \alpha^{(j)} \rightarrow M_y^j(y), \quad (4.22)$$

gdzie:  $j$  - indeks konkluzji utożsamiany z indeksem wyjściowej funkcji przynależności;

$\alpha_1^{(j)}, \alpha_2^{(j)}, \alpha_3^{(j)}, \dots$  - stopnie aktywności reguł o j-tej konkluzji;

$M_y^j(y)$  - wartość j-tej wyjściowej funkcji przynależności; stopień przynależności wartości wyjścia do j-tego wyjściowego zbioru rozmytego.

$$y = \frac{\sum_{j=1}^M C_y^j \cdot \sigma_y^j \cdot \alpha^{(j)}}{\sum_{j=1}^M \sigma_y^j \cdot \alpha^{(j)}}, \quad (4.23)$$

gdzie:  $M$  - liczba wyjściowych funkcji przynależności;

$C_y^j, \sigma_y^j$  - parametry j-tej wyjściowej funkcji przynależności (por. (4.20)).

WARSTWA 4 : komórki w tej warstwie reprezentują wyjściowe funkcje przynależności  $MF_{WY}$  (por. (4.20)). W WARSTWIE 4 stosowany jest rozmyty operator OR (4.22), co prowadzi do wyznaczenia wartości wyjściowych funkcji przynależności, a tym samym stopni przynależności wartości wyjścia do wyjściowych zbiorów rozmytych.

WARSTWA 5 : w warstwie realizowana jest operacja wyostrzania (defazyfikacji). Przez wyostrzanie rozumie się transformację z przestrzeni liczb rozmytych do przestrzeni liczb rzeczywistych. Zastosowano wyostrzanie metodą środka ciężkości, której przybliżenie opisuje zależność (4.23).

### 4.3.2. Konstruowanie systemu logiki rozmytej

Konstruując system logiki rozmytej rozpatruje się dwa zbiory wielkości o nieznanach wartościach. Pierwszy zbiór reprezentuje reguły systemu (reprezentuje bazę reguł rozmytych). Drugi zbiór zawiera natomiast liczby i parametry zarówno wejściowych, jak i wyjściowych funkcji przynależności.

Konstruowanie systemu FL realizowane jest w 2 etapach. W pierwszym etapie stosowane są algorytmy treningu konkurencyjnego (algorytmy treningu ze współzawodnictwem) oraz algorytmy genetyczne w celu inicjalizacji funkcji przynależności oraz wyznaczenia reguł systemu. Zaznaczyć należy, że przez inicjalizację funkcji przynależności rozumie się określenie liczby oraz wartości parametrów tych funkcji. W drugim etapie następuje udokładnienie wartości parametrów funkcji przynależności, pozwalające na zmniejszenie różnic pomiędzy wzorcowymi i obliczonymi (bieżącymi) wartościami wyjścia systemu FL. Stosowany jest w tym przypadku algorytm propagacji wstecznej błędu (BP).


#### Inicjalizacja funkcji przynależności metodą RN i metodą KFM

W celu określenia początkowych wartości parametrów funkcji przynależności w [Lin i Lee, 1991] stosowany jest algorytm zbliżony do algorytmu treningu sieci KFM [Kohonen, 1988]. Liczba funkcji przynależności przyporządkowanych każdemu z wejść i wyjściu ustalana jest arbitralnie. W niniejszej pracy zastosowano standardową sieć neuronową KFM, podejmując próbę określenia nie tylko początkowych wartości parametrów funkcji przynależności, ale również liczby MF przyporządkowanych każdemu z wejść i wyjściu (metoda KFM). Stosując metodę KFM, każde z wejść (lub wyjście) rozpatrywane jest niezależnie. Przypomnieć można, że sieć neuronowa KFM dokonuje klasyfikacji wartości danych. Zatem zastosowanie KFM prowadzi do możliwości podziału zbioru wartości wejść na  $N$  klas (w pracy ograniczono liczbę klas do  $N \leq 5$ ). Liczba klas ( $N$ ) stanowi liczbę funkcji przynależności rozpatrywanego wejścia lub wyjścia. Wyznaczone wartości wag sieci KFM stanowią natomiast wartości parametru  $C$  (4.20) funkcji przynależności.

Po wyznaczeniu początkowych wartości parametru  $C$  (tzw. środka funkcji przynależności) wyznacza się drugi z parametrów MF, tj. parametr  $\sigma$  (4.20) (tzw. szerokość funkcji przynależności). Stosowana jest w tym przypadku metoda  $N$  najbliższych sąsiadów, którą w rozważanym zastosowaniu ogranicza się do określenia *pierwszego najbliższego sąsiada* (4.24).

$$\sigma_{x_i}^m = \frac{ABS(C_{x_i}^m - C_{x_i}^{nb})}{r}, \quad (4.24)$$

gdzie:  $m$  - indeks rozpatrywanej funkcji przynależności  $i$ -tego wejścia;  
 $nb$  - indeks *najbliższego sąsiada* rozpatrywanej funkcji przynależności;  
 $r$  - parametr określający stopień nakładania się funkcji (w pracy przyjęto  $r=2$ ).



Rys. 4.4. Przykład równomiernie (RN) zainicjalizowanych funkcji przynależności

Fig. 4.4. An example of uniformly initialised (RN) membership functions

Alternatywną metodą inicjalizacji funkcji przynależności jest tzw. metoda inicjalizacji równomiernej (RN) ze współczynnikiem nakładania  $r=2$  (zob. (4.24)). Przykład postaci zainicjalizowanych równomiernie funkcji przynależności przedstawiono na rys. 4.4. Dodaje się, iż wybór liczby funkcji przynależności dokonywany jest w metodzie RN arbitralnie, bez uwzględnienia rozkładu wartości danych.

#### Konstruowanie bazy reguł metodą WTA(\*)

Konstruując bazę reguł generuje się w pierwszym kroku przesłanki reguł wykorzystując zainicjalizowane w poprzednim etapie wejściowe funkcje przynależności. Ponieważ reguły nie są znane, łączy się wejściowe funkcje przynależności z komórkami w WARSTWIE 3 tak, aby uzyskać wszystkie możliwe kombinacje. Początkową liczbę reguł systemu określa zatem zależność (4.25).

$$L_R = L_{MF}^{(1)} \cdot L_{MF}^{(2)} \cdot \dots \cdot L_{MF}^{(N)}, \quad (4.25)$$

gdzie:  $L_R$  - początkowa liczba reguł;

$L_{MF}^{(i)}$  - liczba funkcji przynależności przyporządkowanych  $i$ -temu wejściu;

$N$  - liczba wejść.

$$SK_{k,m}^{i+1} = SK_{k,m}^i + \Delta SK_{k,m}^i \quad (4.26)$$

$$\Delta SK_{k,m}^i = \eta_{WTA} \cdot M_y^m(y) \cdot (\alpha_k - SK_{k,m}^i), \quad (4.27)$$

gdzie:  $SK_{k,m}$  - siła połączenia (siła konkluzji)  $k$ -tej komórki w WARSTWIE 3 i  $m$ -tej komórki w WARSTWIE 4;

$\alpha_k$  - wyjście  $k$ -tej komórki w WARSTWIE 3 (stopień aktywności  $k$ -tej reguły (4.21));

$M_y^m(y)$  -  $m$ -ta wyjściowa funkcji przynależności, zob. (4.20);

$\eta_{WTA}$  - współczynnik treningu;

$i$  - indeks kroku treningu.

W kolejnym kroku wyznaczane są konkluzje reguł z zastosowaniem algorytmu treningu konkurencyjnego. Przed zastosowaniem algorytmu każda komórka w WARSTWIE 3 łączona jest z każdą wyjściową funkcją przynależności (komórką w WARSTWIE 4). Oczywiście,

w ostatecznie skonstruowanym systemie każda reguła może mieć tylko jedną konkluzję. Wyboru konkluzji dokonuje się na podstawie wartości tzw. siły konkluzji wyznaczonej w procesie treningu opisanego zależnościami (4.26) i (4.27).

W tym miejscu należy zaznaczyć, że zależność (4.27) stosowana jest w niniejszej pracy w postaci zmodyfikowanej w stosunku do [Lin i Lee, 1991]. Modyfikacja polega na wprowadzeniu współczynnika treningu  $\eta_{WTA}$ , co zdecydowanie poprawia stabilność i powtarzalność treningu. Trening prowadzono do zrealizowania 1000 iteracji. Przyjęto relatywnie małą wartość współczynnika treningu  $\eta_{WTA}=0.00025$  i zmniejszano liniowo wartość  $\eta_{WTA}$  do  $\eta_{WTA}=0.0$ , począwszy od 800 iteracji. Ponieważ zależności (4.26) i (4.27) odzwierciedlają istotę treningu z zastosowaniem algorytmu Winer-Take-All [Kohonen, 1988], przyjęto ogólne oznaczenie WTA(\*) rozpatrywanej w tym miejscu metody konstruowania bazy reguł (MKBR).

Po zakończeniu treningu dla każdej z komórek WARSTWY 3 wybierane jest reprezentujące konkluzję reguły jedno połączenie o największej wartości siły SK (4.26). Siłę reguły (SR) opisuje zależność (4.28).

$$SR_k = \max_{m=1 \dots M} \{SK_{k,m}\}, \quad (4.28)$$

gdzie:  $SR_k$  - siła k-tej reguły systemu FL;

$M$  - liczba wyjściowych funkcji przynależności.

W celu ostatecznego określenia liczby reguł systemu FL przeprowadzana jest eliminacja reguł o małych wartościach SR (reguł o małej sile). Etap ten, bardzo korzystny ze względu na możliwość zmniejszenia liczby reguł, jest jednak zdecydowanie kłopotliwy w praktycznej realizacji. Kłopotliwe jest przyjęcie wartości progowej siły reguł (SRP), tj. wartości, powyżej której reguły uznaje się za znaczące. Intuicyjnie, łatwo wyobrazić sobie przypadek, gdy w zbiorze reguł występuje podzbiór reguł o zbliżonej sile. Arbitralny (przybliżony) wybór wartości progowej siły reguł prowadzić może do odrzucenia reguł istotnych dla rozwiązania danego zadania. Jak wykazano, dla każdego z testowanych zadań (głównie zadań analizowanych w niniejszej pracy) należało indywidualnie dobierać wartość SRP i weryfikować skonstruowane systemy FL ze względu na wyznaczone w zbiorze trenującym błędy  $E_{MAX}$  i  $E_{RMS}$  (błędy definiowane są analogicznie do przypadku sieci neuronowej FFBP, zależności (4.3) i (4.4)). Jednakże podejście takie nie gwarantowało wysokiej jakości integracji danych (np. sprawności klasyfikacji systemu FL) ocenionej z zastosowaniem zbioru testującego. Stosowanie zbioru testującego ujawniło także występowanie niemonotonicznych zmian jakości integracji wraz ze stopniowym zwiększaniem wartości SRP.

Dążąc do ujednoczenia stosowanych w pracy podejść, przyjęto wyznaczać wartość progową siły reguł SRP zgodnie z zależnością (4.29). Wartość współczynnika A ustalono na podstawie wcześniejszych prac i badań autora. Oznaczenie szczegółowe rozpatrywanej metody konstruowania bazy reguł przyjmuje w tym przypadku postać WTA(0.1). W przypadkach niestosowania eliminacji reguł oznaczenie przyjmuje postać WTA(0.0).

$$SRP = SR_{MIN} + A \cdot (SR_{MAX} - SR_{MIN}), \quad (4.29)$$

gdzie:  $SRP$  - wartość progowa siły reguł systemu FL;

$SR_{MIN}$ ,  $SR_{MAX}$  - minimalna i maksymalna wartość siły reguł systemu FL;

$A$  - współczynnik ( $A=0.1$  lub  $A=0.0$ ).

*Konstruowanie bazy reguł z zastosowaniem algorytmu genetycznego (met. AG i AG-H\*)*

Jako alternatywną metodę konstruowania bazy reguł zaproponowano podejście opierające się na algorytmie genetycznym (np. [Sokołowski i Kosmol, 1995d], również [Domański et al., 1995]). Algorytm genetyczny stosowany jest do wyznaczenia konkluzji reguł podobnie jak w przypadku metody WTA(\*). Początkową liczbę reguł opisuje zatem zależność (4.25). Algorytm genetyczny poszukuje takich konkluzji reguł, które pozwalają na minimalizację wartości błędu skutecznego  $E_{RMS}$  zgodnie z funkcją przystosowania (4.30).

$$FP = \frac{1}{1 + E_{RMS}} \quad (4.30)$$

W proponowanym podejściu (metoda AG) każdy chromosom reprezentuje konkluzje reguł systemu FL, tj. każdy gen koduje konkluzję jednej reguły. Geny przyjmują wartości liczb naturalnych z przedziału  $[0, M]$ , gdzie  $M$  jest liczbą wyjściowych funkcji przynależności. Jak można zauważyć, przyjęty sposób kodowania różni się od kodowania stosowanego w klasycznym algorytmie genetycznym. Następnie, poszczególne wartości genu odpowiadają indeksom wyjściowych funkcji przynależności. Wyjątkiem jest w tym przypadku wartość „0”, która wskazuje na odrzucenie danej reguły. Zastosowanie algorytmu genetycznego pozwala więc nie tylko na wyznaczenie konkluzji reguł, ale również zmniejszenie liczby reguł. Ze względu na zastosowanie sposobu kodowania charakterystycznego dla szeroko rozumianych algorytmów ewolucyjnych, konieczna była zmiana operatora mutacji, co wyrażono zależnością (4.31).

$$WG \rightarrow WG + RAND(\pm 1) \text{ oraz } \text{Jeżeli } WG > M \text{ to } WG = 0 \text{ i } \text{Jeżeli } WG < 0 \text{ to } WG = M, \quad (4.31)$$

gdzie:  $WG$  - wartość genu;

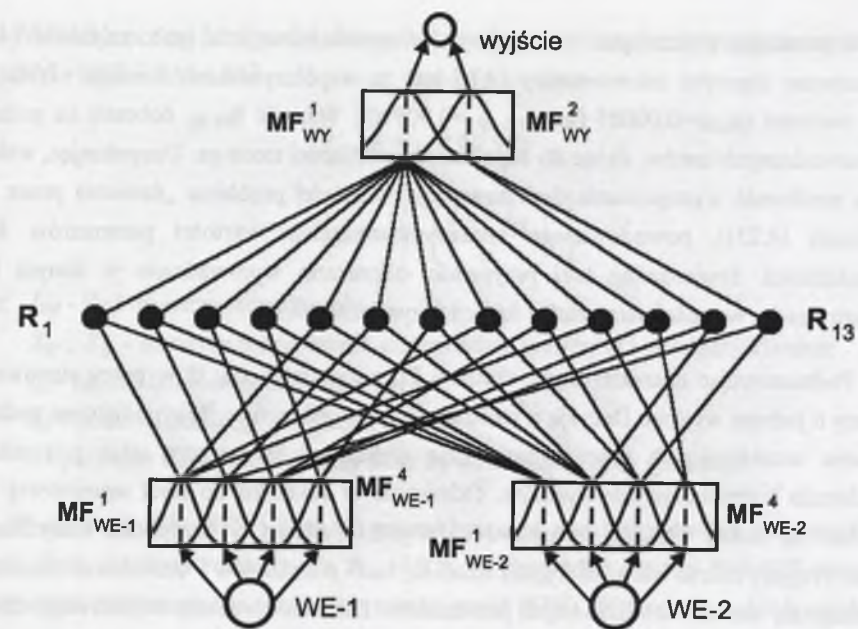
$RAND(\pm 1)$  - losowo generowana liczba  $-1$  lub  $+1$ ;

$M$  - liczba wyjściowych funkcji przynależności.

Zastosowanie algorytmu genetycznego powodować może wystąpienie specyficznych problemów w realizacji obliczeń dokonywanych w systemie FL. Eliminacja reguł prowadzi do przypadku, w którym brak jest możliwości wyznaczenia wartości wyjścia ze względu na problem „dzielenia przez zero”, ujawniający się w zależności (4.23). Stwierdzając taki przypadek, odrzucano dane rozwiązanie przypisując mu wartość funkcji przynależności  $FP=0.0$  (4.30). Obserwowano także przypadki eliminacji reguł o tych samych konkluzjach, tj. przypadki, w których pewna wyjściowa funkcja przynależności nie była połączona z komórkami WARSTWY 3. Podobnie jak wyżej, rozwiązania takie odrzucano.

W niniejszej pracy proponuje się hybrydyzację przeszukiwania przestrzeni rozwiązań (np. [Orantek i Burczyński, 2000], [Burczyński, 2000]), potencjalnie pozwalającą na uzyskiwanie rozwiązań „bardziej zbliżonych” do rozwiązań optymalnych. Dąży się także do zwiększenia powtarzalności wyznaczania zbioru reguł systemu FL oraz eliminacji reguł, które w mniejszym stopniu wpływają na wartość (zmniejszenie) błędu skutecznego  $E_{RMS}$ . Po wyborze „najlepszego” rozwiązania z zastosowaniem algorytmu genetycznego, podejmowane są próby eliminacji konkluzji (a tym samym reguł) w celu zmniejszenia wartości błędu  $E_{RMS}$  (metoda AG-H1). Eliminacja reguł prowadzona jest iteracyjnie, eliminując w każdej iteracji regułę, której odrzucenie pozwala na największe zmniejszenie wartości  $E_{RMS}$ . Eliminację reguł uznaje się za zakończoną, gdy odrzucenie kolejnej reguły nie powoduje zmniejszenia wartości  $E_{RMS}$ . W kolejnym kroku proponuje się podjąć eliminację tych reguł, których odrzucenie powoduje najmniejszy wzrost wartości błędu  $E_{RMS}$  (metoda AG-H2). Eliminację ogranicza się do tych reguł, których odrzucenie nie powoduje wzrostu wartości  $E_{RMS}$  powyżej wartości wyznaczonej dla rozpatrywanego („najlepszego”) rozwiązania uzyskanego z zastosowaniem algorytmu genetycznego. Dokonując eliminacji reguł stosuje się także ograniczenie dotyczące liczby reguł związanych z wyjściowymi funkcjami przynależności. Ograniczenie to wynika z przeprowadzonych testów, w których wykazano, iż zastosowanie metod AG-H\* prowadzić może do eliminacji zbyt dużej liczby reguł i braku możliwości realizacji treningu systemu z zastosowaniem algorytmu wstecznej propagacji błędu (BP). Wydaje się, że komentowany przypadek odpowiada „sprowadzeniu” systemu FL do lokalnego minimum funkcji błędu. Stwierdzając brak możliwości realizacji treningu podejmowano próby powtórzenia symulacji AG, w których odrzucano rozwiązania o mniej niż 3 regułach związanych z każdą wyjściową funkcją przynależności. Zaznacza się, że przypadki braku możliwości realizacji treningu spowodowane eliminacją zbyt dużej liczby reguł obserwowano głównie konstruując systemy FL o małej początkowej liczbie reguł.

Uzupełniając powyższy opis dodaje się, iż w symulacjach stosowano zasadniczo wartości parametrów algorytmu genetycznego przyjęte w podrozdziale 4.2. W przypadku zbiorów reguł o liczności powyżej 150÷200 stosowano jednak populacje o zwiększonej liczności (150÷200 osobników) i zwiększano liczbę generacji (1000÷2000 generacji).



Rys. 4.5. Przykład struktury systemu logiki rozmytej przed łączeniem reguł

Fig. 4.5. An example of structure of the fuzzy logic system before fuzzy rule junction

#### Łączenie reguł

Łączenie reguł rozmytych polega na wyborze reguły, które zastępuje się jedną regułą reprezentatywną. Wybierany jest podzbiór reguł o takiej samej konkluzji, wspólnych niektórych przesłankach oraz niektórych przesłankach stanowiących kompletny zbiór nazw wartości lingwistycznych pewnej zmiennej wejściowej. W formie przykładu odwołać się można do struktury systemu FL przedstawionej na rys. 4.5. Zwraca się uwagę na pierwszą funkcję przynależności wejścia WE-2 ( $MF_{WE-2}^1$ ). Przesłanki odnoszące się do tej funkcji przynależności związane są z pierwszymi czterema regułami o tej samej konkluzji. Rozpatrywane reguły związane są również z funkcjami przynależności wejścia WE-1, tzn. kolejne funkcje przynależności związane są z kolejnymi, rozpatrywanymi regułami systemu FL. Interpretacja takiej konfiguracji reguł sprowadza się do stwierdzenia, iż niezależnie od informacji wprowadzanych przez wejście WE-1, system FL generuje analogiczną konkluzję. Wskazuje to na możliwość pominięcia informacji z WE-1 i pozostawienia tylko jednej (spośród czterech) reguły o przesłance związanej z  $MF_{WE-2}^1$ .

#### Wyznaczenie końcowych wartości parametrów funkcji przynależności

Wyznaczenie końcowych wartości parametrów funkcji przynależności realizowane jest z zastosowaniem algorytmu wstecznej propagacji błędu BP. Na tym etapie konstruowania systemu FL wartości parametrów funkcji przynależności zmieniane są tak, aby minimalizować



różnice pomiędzy obliczonymi i wzorcowymi wartościami wyjścia (zob. zależność (4.1)). Zastosowano algorytm inkrementalny (ATS-inc) ze współczynnikiem treningu o relatywnie małej wartości  $\eta_{FL-BP}=0.00005$  (lub  $\eta_{FL-BP}=0.00010$ ). Wartość  $\eta_{FL-BP}$  dobrano na podstawie przeprowadzonych testów, dążąc do zapewnienia stabilności treningu. Uzupełniając, wskazuje się na możliwość występowania dyskutowanego wcześniej problemu „dzielenia przez zero” (zależność (4.23)), powodowanego znacznymi zmianami wartości parametrów funkcji przynależności. Stwierdzając taki przypadek, odrzucano wprowadzane w danym kroku treningu zmiany wartości parametrów funkcji przynależności.

Podsumowując charakterystykę systemu FL przypomina się, iż w pracy stosowane są systemy o jednym wyjściu. Decyzję o stosowaniu tylko jednego wyjścia podjęto na podstawie wyników wcześniejszych prac autora, gdzie wykazano, iż systemy takie pozwalały na uzyskiwanie korzystniejszych wyników. Odmienne w stosunku do sieci neuronowej FFBP określane są zatem wartości wzorcowe na wyjściu systemu w przypadku klasyfikacji do  $N$  klas. Przyjęty zakres wartości wyjścia dzieli się na  $N$  przedziałów i wartościom wzorcowym przypisuje się wartości środkowe tych przedziałów. Zaliczenie wektora wejściowego do danej klasy następuje w przypadku, gdy wartość obliczona na wyjściu systemu FL należy do odpowiedniego przedziału.

#### 4.4. Hybrydowa metoda oceny istotności danych SR+AG

Hybrydowa metoda SR+AG zaimplementowana w [STATISTICA-NN] bazuje na klasycznym algorytmie genetycznym (podrozdział 4.2), który stosowany jest do minimalizacji wartości błędu treningu probabilistycznych sieci neuronowych w przypadku zadań klasyfikacji lub sieci regresyjnych w przypadku zadań aproksymacji. Przytaczając za [STATISTICA-NN], zastosowane sieci neuronowe charakteryzuje względnie szybki trening, co zmniejsza czas konieczny do wyznaczenia istotności danych, oraz sieci te są „czułe” na istotne dane. Podzbiory danych kodowane są bezpośrednio w chromosomie, tj. każdy gen reprezentuje jedną daną, której występowanie w rozpatrywanym podzbiórze wyrażane jest wartością „1” i konsekwentnie wartością „0” w przypadku odrzucenia danej. Parametrem metody SR+AG jest współczynnik kary  $UP_w$ . Zadawana przez Użytkownika wartość  $UP_w$  mnożona jest przez liczbę wejść i dodawana do błędu treningu sieci neuronowej. Dodać należy, że zakończenie treningu sieci określane jest z zastosowaniem, wymaganego w przypadku tej metody, zbioru weryfikującego.

Zastosowanie metody SR+AG polega na realizacji kolejnych symulacji z jednoczesnym zwiększaniem wartości  $UP_w$ . Oznacza to, iż dysponując podzbiorem danych o pewnej liczności, należy realizować symulacje dobierając wartości  $UP_w$  tak, aby odrzucić kolejną daną. W efekcie zastosowania metody SR+AG uzyskuje się podzbiory danych o malejącej liczności.

#### 4.5. Metody oceny istotności danych bazujące na macierzy rozproszenia SM+SFS i SM+AG

$$J_{SM} = \text{trace}(S_W^{-1} S_B) \quad (4.32)$$

$$FP = J_{SM} \cdot \exp \left[ - \left( \frac{L_D - L_Z}{\sigma} \right)^2 \right], \quad (4.33)$$

gdzie:  $J_{SM}$  - ślad macierzy rozproszenia;

$S_W, S_B$  - macierze rozproszenia, odpowiednio wewnątrz i pomiędzy klasami;

$L_Z$  - zadana liczność podzbioru danych;

$L_D$  - liczność bieżącego podzbioru danych;

$\sigma$  - parametr funkcji zmniejszany wraz ze wzrastającą liczbą generacji.

W metodach SM+SFS i SM+AG poszukiwane są podzbiory danych maksymalizujące wartość śladu macierzy rozproszenia  $J_{SM}$  (4.32). W przypadku metody SM+SFS stosowany jest algorytm sekwencyjnego przeszukiwania w przód (SFS). W pierwszym kroku wybierana jest dana charakteryzująca się maksymalną wartością  $J_{SM}$ . Następnie poszukiwany jest element rozpatrywanego zbioru danych pozwalający na utworzenie dwuelementowego podzbioru maksymalizującego  $J_{SM}$ . Analogicznie tworzone są kolejne podzbiory o wzrastającej liczności. Zauważyć należy, że algorytm SFS nie ma charakteru algorytmu optymalizującego. Dla wybranej liczby danych możliwe jest zatem istnienie podzbioru danych, który pozwala na uzyskanie wyższych wartości  $J_{SM}$  niż podzbiór wybrany z zastosowaniem SFS.

Próbą eliminacji tej potencjalnej wady jest skojarzenie metody macierzy rozproszenia z algorytmem genetycznym [Sokołowski i Rehse, 1994], [Sokołowski i Dornfeld, 1994]. Skojarzenie to reprezentuje drugą z metod oceny istotności danych (metoda SM+AG), opisywanych w niniejszym podrozdziale. Podobnie jak w przypadku metody SR+AG, zastosowano klasyczny algorytm genetyczny, w którym chromosomy reprezentują analogicznie kodowane podzbiory danych.

Zastosowanie algorytmu genetycznego wiąże się ze specyficznym określeniem funkcji przystosowania, zależność (4.33). Wartości śladu macierzy rozproszenia wzrastają wraz ze wzrostem liczności podzbiorów danych, co oznacza, że wyrażając funkcję przystosowania zależnością (4.32), jako rozwiązanie otrzymywano by każdorazowo zbiór wszystkich dostępnych danych. Jak można zauważyć, w zależności (4.33) autor wykorzystał znaną z teorii sieci neuronowej KFM koncepcję zawężanego sąsiedztwa (np. [Sokołowski, 2000]). Zastosowanie metody SM+AG polega na realizacji kolejnych symulacji AG z różnymi zadanymi licznosciami podzbiorów  $L_Z$  (4.33). W każdej symulacji następuje forsowanie algorytmu genetycznego do wyboru „najlepszego” podzbioru danych o ściśle określonej liczności, podobnie jak w przypadku metody SR+AG.

#### 4.6. Zestawienie zastosowanych metod i algorytmów


Zestawienie metod i algorytmów zastosowanych w pracy przedstawiono na rys. 4.6. Zasadniczym, naturalnym podziałem dokonany na rys. 4.6 jest podział na metody selekcji danych (metody oceny istotności danych) oraz metody integracji danych. Następnie, w przypadku metod selekcji danych dokonano podziału na metody bazujące na sieci neuronowej FFBP oraz pozostałe metody. Natomiast w przypadku metod integracji danych zasygnalizowano dodatkowo podejścia (metody i algorytmy) stosowane do konstruowania sieci neuronowych FFBP i systemów logiki rozmytej. Jak można zauważyć, przedstawione na rys. 4.6 metody i algorytmy umożliwiają przeprowadzenie wielokierunkowo zorientowanych badań. Stąd też w dalszej części podrozdziału charakteryzuje się głównie przyjęte w pracy zasady realizacji testów. Niemniej jednak, aby uściślić zasady realizacji testów, podejmuje się w pierwszym kroku dyskusję zagadnienia oceny istotności danych i selekcji istotnych danych.

Dość należy, iż zestawienie zastosowanych metod i algorytmów oraz przyjęte zasady realizacji testów odzwierciedlają próbę podejmowanego w pracy usystematyzowania stosowanych podejść.

##### 4.6.1. Ocena istotności danych i selekcja istotnych danych

Rozważając metody oceny istotności danych (MOI) uwypuklić należy zróżnicowanie wielkości reprezentujących istotności danych. Koncentrując się na metodach bazujących na sieci neuronowej FFBP, wartość istotności danych stanowi, przykładowo, liczba wag, które przetrwały eliminację (metoda pruningu wag) lub istotność opisywana jest sumą wartości bezwzględnych wag łączących dane wejście z komórkami ukrytymi (metoda sumy wag). Znaczące jest, iż istotności danych wyrażane są wielkościami o wartościach z przedziału  $[0.0, ID_{MAX}]$ , gdzie wartość  $ID_{MAX}$  zależna jest od stosowanej metody. Aby ujednoczyć zakresy wartości istotności, w pracy istotność danych wyraża się w skali procentowej przypisując  $ID_{MAX}$  wartość 100%, tj. przedziałowi  $[0.0, ID_{MAX}]$  odpowiada przedział  $[0.0\%, 100.0\%]$ . Przyjęty przedział wartości istotności danych stanowi podstawę ogólnej oceny istotności prowadzącej się zazwyczaj do uporządkowania danych według rosnących istotności, wskazania danych najmniej (lub najbardziej) istotnych czy też porównywania danych ze względu na wyznaczone wartości istotności oraz porównania istotności danych wyznaczonych różnymi metodami.

Przeprowadzenie oceny istotności danych pozwala na dokonanie selekcji (wyboru) danych istotnych. Rozważa się 3 możliwe podejścia. Naturalna, nie wymagająca komentarza jest bazująca na uporządkowaniu danych eliminacja (odrzuć) kolejnych danych i weryfikacja uzyskiwanych w ten sposób podzbiorów. Zaznacza się, że w tym miejscu nie porusza się problemu sposobu weryfikacji podzbiorów danych. Kontynuując, podejście



Rys. 4.6. Metody i algorytmy zastosowane w pracy

Fig. 4.6. The methods and algorithms applied in the dissertation

takie nie można oczywiście uznać za efektywne. Korzystniejsze jest przyjęcie progu istotności danych ( $ID_p$ ) i odrzucenie w pierwszym kroku tych danych, których istotności przyjmują wartości poniżej wartości  $ID_p$ . Następnie eliminowane są kolejne dane o najniższych wartościach istotności. Ostatecznie, najbardziej korzystne byłoby jednorazowe wskazanie na optymalny podzbiór danych.

Komentując powyższe podejścia należy zaznaczyć, że ostatnie z zasygnalizowanych jest, zdaniem autora, podejściem hipotetycznym ze względu na brak możliwości jednoznacznego zdefiniowania optymalnego podzbioru danych. Przykładowo, podzbiorem optymalnym może być podzbiór o założonej liczności lub podzbiór zapewniający uzyskanie założonej jakości integracji danych. Uważa się, że na tym etapie badań brak jest podstaw, aby jednoznacznie określić wartości  $ID_p$  umożliwiające wskazanie optymalnych podzbiorów danych, których sposób definiowania zależy jest od trudnego do przewidzenia charakteru rozwiązywanego zadania czy też specyficznych oczekiwań potencjalnego Użytkownika. Dlatego też w pracy podjęto próbę zastosowania jednolitego podejścia prowadzącego się do przyjęcia jednej wartości progu istotności  $ID_p$ , potencjalnie pozwalającej na wybór quasi-optymalnego podzbioru danych. Zagadnienia wyboru quasi-optymalnego podzbioru danych oraz wyboru wartości progu istotności  $ID_p$  rozważane są szczegółowo w podrozdziale 4.7.1.

Ujednoczenie sposobu selekcji istotnych danych oraz sposobu wyrażania wartości istotności danych, a także nierozłączność oceny istotności i selekcji danych umożliwia, zdaniem autora, przyjęcie uproszczeń w stosowanych w dalszej części pracy nazwach i określeniach. Przyjęto, aby nie wprowadzać odrębnych określeń (nazw) metod selekcji danych (MS), a posilkować się dotychczas przytaczanymi. Na przykładzie metody sumy wag, w pracy mówi się o „... ocenie istotności metodą sumy wag...” i równocześnie używa się określeń „...selekcja danych z zastosowaniem metody sumy wag...”, „...selekcja danych bazująca na metodzie sumy wag...” lub też, w celu uproszczenia komentarzy, mówi się bezpośrednio o „...selekcji danych metodą sumy wag...”. W przypadku reprezentacji graficznych uzyskiwanych wyników stosuje się natomiast oznaczenie *MS(MOI)*, odpowiadające powyżej przyjętym określeniom.

Przeprowadzona dyskusja odnosi się również do pomijanych dotychczas metod SM+SFS, SM+AG i SR+AG. Niemniej jednak przypomnieć należy, iż zastosowanie tych metod prowadzi zazwyczaj do wyznaczenia nominalnych, uporządkowanych wartości istotności danych. Oznacza to, że dokonując selekcji danych brak jest możliwości przyjęcia progu istotności  $ID_p$ . W pracy podejmowana jest jednakże próba pośredniego przypisania danym rzeczywistych wartości istotności, co rozpatrywane jest w podrozdziale 4.7.1.

#### 4.6.2. Zasady realizacji testów

Opisując zasady realizacji testów dogodne jest odnieść się w pierwszym kroku do integracji danych z zastosowaniem sieci neuronowej FFBP. Bez umniejszania ogólności opisów przyjąć również można, że rozważane jest przykładowe zadanie klasyfikacji danych (rys. 4.7). Rozwiązywanie zadania rozpoczynało się od próby integracji wszystkich dostępnych danych. Celem integracji danych było wyznaczenie sprawności klasyfikacji (ogólnie jakości integracji), której wartość stanowiła wartość odniesienia dla kolejnych symulacji sieci. Zaznaczyć należy, że sprawności sieci FFBP podawane na rys. 4.7 wyznaczano z zastosowaniem zbioru testującego. Stosowanie zbioru testującego miało zasadniczo odzwierciedlać przypadki praktycznego zastosowania danego rozwiązania. Niemniej jednak, w wielu testach podejście takie nie było możliwe, ponieważ zbiór testujący wymagany był do wykazania ogólnie rozumianej poprawności zarówno selekcji, jak i integracji danych.

W celu skonstruowania sieci neuronowej FFBP dokonywano oszacowania liczby komórek ukrytych stosując metodę pruningu komórek, algorytm ATS-des i metodę SW+GS. W przypadku metody pruningu przyjmowano relatywnie dużą, początkową liczbę komórek ukrytych (Etap 1, rys. 4.7) i następnie podejmowano próby odrzucenia zbędnych komórek. Ostateczną liczbę komórek w warstwie ukrytej (Etap 2, rys. 4.7) określano porównując uzyskiwane wyniki oraz weryfikując możliwość realizacji treningu sieci o przyjętej strukturze. Podejmowano także próby arbitralnego zmniejszania liczby komórek ukrytych.

X	Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego												Sprawność sieci FFBP													
		A1	A2	A3	A4	B1	B2	B3	B4	C1	C2	C3	C4		D1	D2	D3	D4	E1	E2	E3	E4	F1	F2	F3	F4	M
Etap 1	26-10-3	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	95.5%
Etap 2	26-6-3	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	94.2%
Etap 3	7-8-3	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	98.0%
Etap 4	7-5-3	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	█	98.2%

Rys. 4.7. Przykładowe zobrazowanie realizacji testów z zastosowaniem sieci neuronowej FFBP

Fig. 4.7. An exemplary presentation of the tests conducted with the FFBP neural network

W kolejnym kroku dokonywano selekcji istotnych danych jedną z rozważanych w pracy metod. Wybierano, jeżeli było to możliwe, podzbiór danych z zastosowaniem progu istotności  $ID_p$  i następnie podejmowano próby eliminacji kolejnych danych. W przypadku metod bazujących na sieci neuronowej FFBP, istotności danych wyznaczano z zastosowaniem sieci o strukturze określonej w Etapie 2 (rys. 4.7), nazywanej strukturą (siecią) podstawową. W większości testów stosowano kumulacyjny algorytm treningu ATS-cum. Przyjmowano zazwyczaj  $\eta_F \approx 0.1$  i dokonywano zmian wartości współczynnika treningu dążąc do przyspieszenia treningu z jednoczesnym zachowaniem stabilnych zmian wartości błędów  $E_{RMS}$  i/lub  $E_{MAX}$ . Zastosowanie na tym etapie algorytmu ATS-cum wynika z potencjalnej możliwości zmniejszenia (uśredniania) wpływu wejść nieistotnych (zob. podrozdział 4.1.1). Warunek zakończenia treningu uzależniano od charakteru rozwiązywanego zadania. W przypadku zadań klasyfikacji trening sieci realizowano do uzyskania błędu  $E_{MAX}=0.15$ . Natomiast w przypadku zadań aproksymacji warunek zakończenia treningu ustalany był niezależnie dla każdego z rozwiązywanych zadań. Dokonując selekcji danych podejmowano w niektórych testach próby ponownego wyznaczenia istotności wybranych danych.

Po wyborze istotnych danych ponownie określano liczbę komórek ukrytych sieci FFBP (zob. Etap 1 i 2, rys. 4.7). Dodać można, iż stosując metodę pruningu komórek kierowano się liczbą komórek przyjętą w Etapie 2. Zwiększano liczbę komórek ukrytych o 2-3 komórki (Etap 3, rys. 4.7) i podejmowano próby pruningu komórek ukrytych. Dokonując integracji wyselekcjonowanych danych stosowano zazwyczaj algorytm inkrementalny ATS-inc, zakładając, że gros z wejść wprowadzających nieistotne informacje zostało usuniętych i korzystne jest dokonywanie zmian wag w kierunkach wyznaczanych przez kolejne, losowo uporządkowane wektory trenujące. Ustalając warunek zakończenia treningu dążono do zmniejszenia błędu treningu, np. dla zadań klasyfikacji, jeżeli było to możliwe, przyjmowano błąd treningu  $E_{MAX}=0.10$ . Ostateczne wyniki opisywano strukturą sieci neuronowej FFBP, podzbiorem istotnych danych oraz uzyskaną sprawnością klasyfikacji (Etap 4, rys. 4.7).

Podkreślić należy, że w każdym z etapów przedstawionych na rys. 4.7 symulacje sieci neuronowej FFBP powtarzano 5-krotnie i uśredniano uzyskiwane wyniki. Oznacza to, że rozważane w pracy sprawności klasyfikacji (jakości integracji) są sprawnościami średnimi. Także istotności danych wyznaczone z zastosowaniem metod bazujących na sieci neuronowej FFBP wyrażane są wartościami średnimi. Specyficznie w przypadku metody pruningu wag uśredniano liczby wag, które przetrwały proces eliminacji i następnie skalowano wartości średnie w przedziale [0.0%, 100.0%]. Uśrednianie liczby wag związane jest także z tzw. rozdzielczością metody pruningu. Wyrażanie istotności danych całkowitą liczbą wag utrudniać może zróżnicowanie istotności wejść i ustalenie kolejności eliminacji danych. Wyrażanie istotności wartościami średnimi może być w niektórych przypadkach zdecydowanie pomocne.

Powtórzenia symulacji stosowano także dokonując selekcji bazującej na metodach SR+AG i SM+AG. Dokonując selekcji z zastosowaniem metody SM+AG, symulacje algorytmu genetycznego powtarzano 3-krotnie i do dalszych rozważań wybierano rozwiązanie o najwyższej wartości funkcji przystosowania. W przypadku metody SR+AG 3-krotne powtórzenia miały na celu weryfikację powtarzalności tej metody.

Próby integracji danych z zastosowaniem systemu logiki rozmytej rozpoczynano od inicjalizacji funkcji przynależności metodą RN lub KFM. Następnie konstruowano bazy reguł metodami WTA(\*) i AG-H\*. Jak można zauważyć, testy systemu FL umożliwiły porównywanie stosowanych metod inicjalizacji funkcji przynależności i metod konstruowania baz reguł. Starano się w tym przypadku wskazać najkorzystniejszą kombinację metod. Stosując metody AG-H\*, symulacje algorytmu genetycznego również powtarzano 3-krotnie. Za rozwiązanie końcowe uznawano rozwiązanie charakteryzujące się najniższą wartością błędów  $E_{RMS}$ , wyznaczonego w zbiorze trenującym. Dodać należy, iż system logiki rozmytej traktowany jest jako alternatywne podejście do integracji danych. Dlatego też w testach systemu FL stosowano głównie podzbiory wyselekcjonowanych danych i porównywano wynik z wynikami uzyskiwanymi stosując sieć neuronową FFBP.

Testy prowadzono z zastosowaniem oprogramowania opracowanego w ramach [Projekt Badawczy KBN, 1997], [Projekt Badawczy KBN, 1999] oraz oprogramowania dostępnego w pakiecie [STATISTICA-NN] na komputerze klasy PC, Pentium III, 450 MHz, 128 RAM.

#### 4.7. Kryteria i sposoby oceny zastosowanych metod selekcji i integracji danych

Rozważając zagadnienie wyboru kryteriów oceny metod selekcji i integracji danych zwraca się uwagę na możliwość wieloaspektowego potraktowania tego zagadnienia. Kryteria oceny zależą mogą od celu prowadzonych badań lub specyficznych wymagań Użytkownika. Wskazuje się także na możliwość występowania zależności pomiędzy metodami selekcji i integracji danych. Problematiczne jest również dokonanie bezpośredniej oceny metod selekcji danych, tj. oceny nie uwzględniającej jakości integracji wyselekcjonowanych danych.

W pracy dokonano podziału kryteriów oceny na kryteria zasadnicze (nadrzędne) oraz kryteria uzupełniające. Za nadrzędne uznano kryterium *wysokiej jakości integracji wyselekcjonowanych danych* i kryterium *małej liczby istotnych danych*. Spełnienie innych (uzupełniających) kryteriów wydaje się mniej znaczące w przypadku, gdy niemożliwy jest poprawny wybór podzbioru istotnych danych o małej liczności lub nie jest możliwe dokonanie integracji podzbioru istotnych danych. Podkreślić należy, że przyjęte kryteria mają charakter kryteriów porównawczych. Stopień spełnienia kryteriów oceniany jest w odniesieniu do danego zadania, rozwiązując które porównuje się podzbiory danych wybrane różnymi metodami poprzez porównanie wyników integracji dokonanej jedną, tą samą metodą. Analogicznie, rozważając metody integracji porównuje się jakość integracji danych wyselekcjonowanych jedną, tą samą metodą selekcji. Przyjmując zasadność niezależnych porównań metod selekcji i integracji danych, kłopotliwe jest jednoczesne uwzględnienie liczności podzbiorów wyselekcjonowanych danych. Zwraca się uwagę na zastosowanie w badaniach 7 metod selekcji danych i 2 metod integracji danych, co prowadzi do konieczności rozważenia 14 kombinacji. Ponieważ uwzględnienie liczności podzbiorów powodowałoby brak możliwości przejrzystej interpretacji uzyskiwanych wyników, stopień spełnienia kryteriów nadrzędnych przyjęto oceniać na podstawie tzw. zastępczej jakości integracji danych.

Sposób wyznaczania zastępczej jakości integracji danych opisuje się na przykładzie zadania klasyfikacji. Zastępcza jakość integracji, w tym przypadku zastępcza sprawność klasyfikacji, stanowi średnią ważoną (4.34) sprawności klasyfikacji wybranych podzbiorów danych (4.35). Sprawność zastępczą wyznacza się dla rozpatrywanej metody selekcji danych i rozpatrywanej metody integracji danych. Wyznaczenie sprawności  $S_Z$  wymaga arbitralnego wyboru liczności podzbiorów danych oraz wyboru wartości progu sprawności  $S_P$  (4.37).

$$S_Z = \frac{1}{\omega} \cdot \sum_{i=1}^N \omega_i \cdot S^*(k_i) \quad (4.34)$$

$$\{ S(k_1), S(k_2), \dots, S(k_N) \} \quad (4.35)$$

oraz: 
$$\omega_i = \frac{1}{k_i} \quad i \quad \omega = \sum_{i=1}^N \omega_i \quad (4.36)$$

$$S^*(k_i) = \begin{cases} S(k_i), & \text{jeżeli } S(k_i) \geq S_P \\ 0 & \text{– w pozostałych przypadkach,} \end{cases} \quad (4.37)$$

gdzie:  $k_i$  - licznosc i - tego podzbioru danych;  
 $S(k_i)$  - sprawnosć klasyfikacji  $k_i$  danych;

$S_P$  - próg sprawności;

$N$  - liczba analizowanych podzbiorów danych.

Wybór wartości progu sprawności ( $S_p$ ) ma również charakter arbitralny. Pomocna może być analiza rozkładu wartości rozważanych sprawności i uwzględnienie „wyraźnych” zmian wartości sprawności lub też przyjęcie wartości progu w odniesieniu do sprawności klasyfikacji wszystkich, analizowanych w przypadku rozwiązywanego zadania danych.

Podsumowując podkreśla się, że w przypadku zadań aproksymacji zastosować można analogiczne podejście. Ponieważ dla zadań aproksymacji możliwe jest zróżnicowane wyrażanie jakości integracji, konieczne może być jednakże wprowadzenie modyfikacji. Przykładowo, wyrażając jakość integracji sumą kwadratów różnic należy odpowiednio zmodyfikować zależność (4.37). Jakkolwiek, przyjmując jako wielkość kryterialną współczynnik korelacji obliczonych i wzorcowych wartości wyjść, bezpośrednio stosuje się podejście opisane zależnościami (4.34) ÷ (4.37).

#### 4.7.1. Uzupełniające kryteria i sposoby oceny metod selekcji danych

Przyjęte w pracy uzupełniające kryteria oceny metod selekcji danych zestawiono w tab. 4.1. Wyprzedzając charakterystykę poszczególnych kryteriów zaznacza się, iż przyjmując kryteria dążono do umożliwienia oceny ogólnie rozumianego sposobu uzyskiwania wyników. Przykładowo, dążono do umożliwienia wskazania metody pozwalającej na dokonanie selekcji danych jak najniższym *kosztem obliczeniowym*, przy jednoczesnym zapewnieniu *dużej powtarzalności wyznaczania istotności danych*. Następnie, stopień spełnienia kryteriów przyjęto oceniać w skali 0÷2 punktów, co odpowiada ocenom: kryterium niespełnione, kryterium częściowo spełnione i kryterium spełnione. Przyznając każdemu kryterium ten sam przedział punktacji, uznaje się ich równoważność. Podejście takie wynika z kłopotliwego uznania danego kryterium (lub kryteriów) za istotniejsze w stosunku do pozostałych. W niektórych zastosowaniach najistotniejszy może być *niski koszt obliczeniowy* albo *możliwość wyboru podzbioru quasi-optimalnego* ze względu na brak jakichkolwiek informacji dotyczących liczby istotnych danych. Ponownie podkreśla się, iż oceny stopnia spełnienia kryteriów dokonuje się porównawczo, tj. w odniesieniu do analizowanego zadania.

W uzupełnieniu skomentować należy nieuwzględnienie kryterium związanego z możliwością odzyskiwania wiedzy na etapie selekcji danych. Uznano, iż poprawnie przeprowadzona selekcja stanowi formę odzyskiwania wiedzy o współzależności danych i wielkości opisujących rozpatrywane zjawisko. Poprawność selekcji danych oceniana jest na podstawie przyjętych kryteriów zasadniczych i uzupełniających. Zatem stopień spełnienia kryteriów zasadniczych i uzupełniających odzwierciedla stopień spełnienia kryterium możliwości odzyskania wiedzy na rozważanym w tym miejscu etapie projektowania układów diagnostycznych.

Przyjęte uzupełniające kryteria oceny metod selekcji danych

Kryteria		Metody selekcji danych					
		MS(pruning wag)	MS(suma wag)	MS(met. A-Karina)	MS(anal. wzajemności)	MS(SM+SFS)	MS(SM+AG)
1	duża powtarzalność wyznaczania istotności						
2	możliwość nie tylko jakościowej ale również ilościowej oceny istotności danych						
3	możliwość wskazania parametru metody selekcji pozwalającego na wybór quasi-optimalnego podzbioru danych						
4	niski koszt obliczeniowy metody						
Suma (max. 8 pkt) :							

#### Charakterystyka przyjętych kryteriów uzupełniających

**Kryterium 1:** duża powtarzalność wyznaczania istotności danych. Kryterium związane jest zasadniczo z powtarzalnością wyznaczania istotności danych z zastosowaniem metod bazujących na sieci neuronowej FFBP. Oceny stopnia spełnienia kryterium dokonuje się na podstawie wartości maksymalnego i średniego błędu powtarzalności wyznaczania istotności. Rozpatrując j-te wejście, błąd maksymalny  $BPI_{MAX}^{(j)}$  wyznacza się zgodnie z zależnością (4.38), a błąd średni  $BPI_{AV}^{(j)}$  zgodnie z (4.39).

$$BPI_{MAX}^{(j)} = \max_{i=1..P} \{ ID_i^{(j)} \} - \min_{i=1..P} \{ ID_i^{(j)} \} \quad (4.38)$$

$$BPI_{AV}^{(j)} = \frac{1}{P} \cdot \sum_{i=1}^P ABS( ID_i^{(j)} - ID^{(j)} ) \quad (4.39)$$

oraz:

$$ID^{(j)} = \frac{1}{P} \cdot \sum_{i=1}^P ID_i^{(j)}, \quad (4.40)$$

gdzie:  $ID_i^{(j)}$  - istotność j-tego wejścia w i-tej symulacji;

$P$  - liczba powtórzeń symulacji (w badaniach przyjęto  $P=5$ ).

Dążąc do oceny metody selekcji, uogólnia się powyższe błędy poprzez uwzględnienie wszystkich rozpatrywanych wejść i zdefiniowanie maksymalnego  $BPI_{MAX}$  oraz średniego  $BPI_{AV}$  (4.41) błędu powtarzalności wyznaczania istotności danych rozważaną metodą.

$$BPI_{MAX} = \max_{j=1..K} \{ BPI_{MAX}^{(j)} \} \quad \text{oraz} \quad BPI_{AV} = \frac{1}{K} \sum_{j=1}^K BPI_{AV}^{(j)} \quad (4.41)$$

$$ID_i^{(j)} = LAW_i^{(j)}, \quad (4.42)$$

gdzie:  $K$  - liczba wejść;

$LAW_i^{(j)}$  - liczba aktywnych wag  $j$ -tego wejścia w  $i$ -tej symulacji.

Zaznacza się, że w przypadku metody pruningu wag powtarzalność wyznaczania istotności analizowano na podstawie liczby aktywnych wag. Dlatego też  $ID_i^{(j)}$  w zależnościach (4.38) i (4.40) nie wyraża bezpośrednio istotności  $j$ -tego wejścia w skali procentowej, a wyraża liczbę aktywnych wag tego wejścia zgodnie z (4.42).

Uwzględniając charakter treningu sieci neuronowej FFBP, a przede wszystkim losową inicjalizację wartości wag i wartości progowych, w badaniach za naturalne i tym samym dopuszczalne uznaje się maksymalne błędy powtarzalności wyznaczania istotności danych na poziomie  $BPI_{MAX}=1+2$  w przypadku metody pruningu wag oraz  $BPI_{MAX}=10+15\%$  w przypadku pozostałych metod selekcji bazujących na sieci FFBP.

Odwołując się ostatecznie do pozostałych metod selekcji zwraca się uwagę na pełną powtarzalność wyznaczania istotności metodą SM+SFS. Natomiast powtarzalność metody SM+AG i SR+AG związana jest z powtarzalnością algorytmu genetycznego. Przez powtarzalność rozumie się w tym przypadku powtarzalność wyboru podzbiorów danych. W niniejszej pracy powtarzalność metody SM+AG i SR+AG nie wyraża się ilościowo i arbitralnie stwierdza się uzyskiwanie powtarzalnych (lub niepowtarzalnych) wyników.

*Kryterium 2: możliwość nie tylko jakościowej ale również ilościowej oceny istotności danych.* Spełnienie niniejszego kryterium zapewniają metody selekcji bazujące na sieci neuronowej FFBP. Istotności danych przyjmują w tym przypadku wartości rzeczywiste w przedziale [0.0%, 100.0%]. Natomiast ocena ilościowa nie jest bezpośrednio możliwa stosując metody bazujące na macierzy rozproszenia (SM+SFS i SM+AG) i metodę SR+AG. W formie założenia, potwierdzenia którego poszukuje się w ramach badań, przyjmuje się możliwości przypisania danym wartości wielkości wpływających na wybór podzbiorów istotnych danych. Przypomnieć można, że wielkością taką jest ślad macierzy rozproszenia  $J_{SM}$  (metody SM+SFS i SM+AG) oraz współczynnik kary  $UP_w$  (metoda SR+AG). Przykładowo, jeżeli metoda SR+AG pozwala na wyznaczenie nominalnych, uporządkowanych wartości istotności, to poszczególnym danym przypisać również można rzeczywiste wartości współczynnika kary  $UP_w$  zastosowanego do wyboru odpowiednich podzbiorów danych. Jednocześnie zakłada się możliwość zróżnicowania tak określonych istotności danych ze względu na zakładane w tym miejscu zróżnicowanie wartości  $J_{SM}$  i  $UP_w$ . W przypadku braku możliwości uporządkowania danych uznaje się brak możliwości ilościowej oceny istotności danych.

*Kryterium 3 : możliwość wskazania parametru metody selekcji pozwalającego na wybór quasi-optymalnego podzbioru istotnych danych.* Rozważane kryterium odzwierciedla przyjęte w badaniach podejście do wskazania (i w efekcie odrzucenia) nieistotnych danych. Przyjęto, że podzbiór *quasi-optymalny* to podzbiór, który umożliwia uzyskanie jakości integracji zbliżonej do jakości uzyskiwanej z zastosowaniem wszystkich rozważanych danych. Pojęcie „*quasi-optymalny*” oznacza możliwość istnienia korzystniejszego podzbioru danych, tj. podzbioru o mniejszej liczności, pozwalającego na uzyskiwanie analogicznej jakości integracji. Niemniej jednak, oczekuje się jak najmniejszego zróżnicowania liczności tych podzbiorów. Spełnienie kryterium rozważane jest w świetle dwóch wzajemnie powiązanych zagadnień. W pierwszym kroku należy wskazać parametr metod selekcji, który potencjalnie umożliwiłby wybór podzbioru *quasi-optymalnego*. Przyjmuje się, że spełnione musi być w tym przypadku *kryterium 2*. Parametrem takim jest zatem wielkość pozwalająca na ilościową ocenę istotności danych. Następnie, spełnienie kryterium wymaga określenia wartości wybranego parametru. W przypadku metod selekcji bazujących na sieci neuronowej FFBP zakłada się, że odrzucając dane o istotnościach mniejszych niż 50% (przyjęto zatem wartość progu istotności  $ID_p \cong 50\%$ ) zachowana będzie jakość integracji zbliżona do jakości uzyskiwanej z zastosowaniem wszystkich dostępnych danych. Wartość  $ID_p$  przyjęto na podstawie dotychczasowych badań metod selekcji danych. W przypadku pozostałych metod nie przyjmuje się jednoznacznych wartości, co wynika z konieczności wykazania w pierwszym kroku spełnienia *kryterium 2*.

Ogólnie, poczynione założenia reprezentują sposób oceny stopnia spełnienia rozważanego kryterium. Podejmowane badania pozwolą natomiast na weryfikację proponowanego podejścia i potwierdzenie możliwości oceny metod selekcji z zastosowaniem tak zdefiniowanego kryterium. Innymi słowy, weryfikowana będzie możliwość ujednoczenia sposobu wyboru *quasi-optymalnego* podzbioru danych w zróżnicowanych zadaniach.

*Kryterium 4 : niski koszt obliczeniowy metody.* Koszt obliczeniowy metody wyrażony może być czasem lub liczbą operacji arytmetycznych konieczną do wyznaczenia istotności danych. W niniejszych badaniach porównania metod prowadzi się na podstawie czasu koniecznego do wyznaczenia istotności danych, co odzwierciedla bardziej praktyczne, korzystne z punktu widzenia potencjalnego Użytkownika podejście. Zaznacza się, że koszt obliczeniowy metod selekcji bazujących na sieci neuronowej FFBP nie uwzględnia czasu symulacji mających na celu określenie struktury sieci czy też parametrów treningu sieci. Problem ten uwzględniany jest w uzupełniających kryteriach oceny metod integracji danych. Następnie, już w tym miejscu stwierdzić można, że najniższym kosztem obliczeniowym charakteryzuje się metoda SM+SFS. Wskazuje się także na specyfikę metody pruningu wag, wymagającej wielokrotnego prezentowania sieci zbioru trenującego w celu wyznaczenia istotności danych.

Tabela 4.2

Przyjęte uzupełniające kryteria oceny metod integracji danych

Kryteria		Sieć neuronowa FFBP	System logiki rozmytej
1	niski koszt obliczeniowy w fazie konstruowania		
2	duża powtarzalność wartości parametrów		
3	łatwość odzyskiwania wiedzy	—	+
4	mała złożoność procesu konstruowania	+	—
5	duża zdolność uczenia		
6	duża zdolność generalizacji wiedzy		

#### 4.7.2. Uzupełniające kryteria i sposoby oceny metod integracji danych

Uzupełniające kryteria oceny metod integracji danych przedstawiono w tab. 4.2. Przyjęty sposób oceny metod ma charakter porównawczy. W badaniach dąży się do wskazania tej metody integracji, której zastosowanie jest korzystniejsze w świetle danego kryterium. Przykładem może być kryterium *łatwości odzyskiwania wiedzy*, którego spełnienie analizuje się w tym miejscu bazując na cechach rozpatrywanych metod. Korzystniej ocenia się w tym przypadku system logiki rozmytej, którego elementy, tj. zbiór reguł rozmytych wraz z funkcjami przynależności stanowią naturalną reprezentację wiedzy diagnostycznej. Zauważa się jednakże, że możliwość realizacji treningu sieci neuronowych, a praktycznie brak możliwości realizacji treningu, wskazywać może na występowanie sprzeczności w danych lub niewystarczającą liczbę danych koniecznych do opisu zjawiska. Jest to forma odzyskania informacji o zjawisku. Podobnie rozważyć można kryterium *małej złożoności procesu konstruowania*. Odwołując się do dokonanych w niniejszym rozdziale opisów, za korzystniejszą uznaje się sieć neuronową FFBP (tab. 4.2).

Charakteryzując pozostałe kryteria zauważa się, że *kryteria 5 i 6* odzwierciedlają ogólnie pożądane cechy metod sztucznej inteligencji. *Powtarzalność wartości parametrów* związana jest z powtarzalnością metod i algorytmów stosowanych do wyznaczenia wartości parametrów zarówno sieci neuronowych jak i systemów logiki rozmytej. Powtarzalność oceniana jest na podstawie zróżnicowania wartości stosowanej miary jakości integracji, mogącego ujawniać się w powtarzanych symulacjach. Kryterium *kosztów obliczeniowych* interpretowane jest zgodnie z opisem z podrozdziału 4.7.1. Podkreśla się, że *koszt obliczeniowy* związany jest z czasem konstruowania zastosowanych metod integracji danych. Nie dokonuje się zatem porównań sieci neuronowej FFBP i systemu logiki rozmytej w odniesieniu do kosztów obliczeniowych („szybkości działania”) w przypadku praktycznych zastosowań.

## 5. TESTY WSTĘPNE

Wstępne testy metod selekcji i integracji danych przeprowadzono z zastosowaniem dwóch zadań klasyfikacji. W pierwszym kroku do testów zastosowano zadanie parzystości (np. [Sokołowski i Kosmoł, 1998a]). W przypadku zadania parzystości analizowano głównie istotności danych wyznaczone z zastosowaniem metod bazujących na sieci neuronowej FFBP. W kolejnym kroku przedstawiono wyniki testów tzw. zadania graficznego (np. [Sokołowski i Kosmoł, 2001b]). W przypadku tego zadania dyskusję metod selekcji bazujących na sieci neuronowej FFBP rozszerzono o zagadnienia powtarzalności wyznaczania istotności z uwzględnieniem wpływu liczby komórek ukrytych oraz wpływu algorytmu treningu. Przedstawiono także przykład zastosowania systemu logiki rozmytej. Jak można zauważyć, testy wstępne skoncentrowano na wybranych, istotnych w uznaniu autora zagadnieniach. Dlatego też niniejszy rozdział nie podsumowuje się ogólną oceną zastosowanych metod selekcji danych, a skupia się na próbach uogólnienia najistotniejszych wniosków.

Testy z zastosowaniem zadania parzystości i zadania graficznego polegały na wprowadzaniu do sieci neuronowej FFBP wejść dodatkowych, tj. wejść dodatkowych w stosunku do wejść zasadniczych, i analizie wyznaczanych istotności. Zastosowane wejścia dodatkowe reprezentowały :

- wartości stałe (wejście oznaczone jako CONST);
- wartości losowe (SZUM);
- powtórzenie wartości jednego z wejść zasadniczych (POWT oraz POWT-1 i POWT-2);
- wartości stanowiące kombinacje liniowe wartości wybranych wejść zasadniczych (KOMB lub SUMA).

Charakteryzując ogólnie wejścia dodatkowe należy zaznaczyć, że spośród wielu możliwych typów wejść wybrano te, które po wstępnych analizach uznano za wejścia mogące powodować problematyczną interpretację wyznaczanych istotności. Wskazać również należy na zróżnicowanie charakteru wejść dodatkowych. Wejścia CONST i SZUM uznaje się za założenia za wejścia, których wartości nie wykazują współzmienności z wartościami wyjść. Oczywiste jest, że istotności takich wejść powinny być zdecydowanie niższe niż istotności wejść zasadniczych. W drugim przypadku (POWT, KOMB i SUMA) wejścia dodatkowe są wejściami skorelowanymi z wejściami zasadniczymi. Celem analiz powyższego przypadku jest wykazanie potencjalnego wpływu występowania takich wejść na ocenę istotności danych. Równie interesująca wydaje się być weryfikacja możliwości wskazania wejść wprowadzających nadmiarowe informacje. Zaznaczyć należy, że w poniższych podrozdziałach prowadzona jest wstępna, jakościowa analiza istotności wejść skorelowanych. Analiza ilościowa dokonywana jest natomiast w podsumowaniu rozdziału.

Poniżej przedstawiono opisy uściślające sposób generowania wartości wejść dodatkowych:

- CONST – przyjęcie założenia, że wartości danego wejścia są stałe (pomijając błąd w przetwarzaniu danych) ma charakter hipotetyczny. Możliwy natomiast jest przypadek, w którym w zbiorze wartości danej reprezentowanej przez rozpatrywane wejście występują jedna lub dwie wartości znacznie różniące się od pozostałych wartości. Powoduje to, że po przeskalowaniu do przedziału [0.0, 1.0] pozostałe wartości wejścia przyjmują wartości zbliżone do wartości stałej. W niniejszych testach zastosowano wejście CONST, któremu wstępnie nadano wartość stałą 0.5. Następnie do wartości tej dodawano wartości losowe generowane w przedziale  $\pm 0.05$ . Ostatecznie, do zbioru wartości wejścia wprowadzono wartości 0.0 i 1.0, odpowiadające przedziałowi uzyskiwanemu po skalowaniu. Jak można zauważyć, niniejszy przypadek odpowiada występowaniu w zbiorze wartości rozpatrywanej danej dwóch wartości znacznie różniących się od pozostałych wartości danej.
- POWT – wejście POWT podobnie jak wejście CONST ma charakter wejścia hipotetycznego. W praktyce natomiast wystąpić mogą wejścia, których zróżnicowanie wartości sprowadza się do zróżnicowania poziomu szumu. Stąd też oprócz wejścia POWT zastosowano także wejścia dodatkowe, reprezentujące wartości wejścia zasadniczego z dodanymi wartościami losowymi generowanymi w przyjętym przedziale, tj. wejście dodatkowe reprezentujące wartości pierwszego wejścia zasadniczego (WE-1) z dodanymi wartościami losowymi generowanymi w przedziale  $\pm 0.05$  (POWT-1) i  $\pm 0.10$  (POWT-2).
- KOMB / SUMA – wartości niniejszych wejść stanowią kombinacje liniowe wartości dwóch wejść zasadniczych. Oczywiście wyznaczyć można nieskończenie wiele tego typu wejść. Dlatego też przyjęto arbitralnie, aby wartości wejść SUMA i KOMB wyznaczać zgodnie z zależnościami (5.1) i (5.2). Jak można zauważyć, wejście SUMA w tym samym stopniu uwzględnia wartości wejść WE-1 i WE-2. Natomiast w przypadku wejścia KOMB następuje zmniejszenie wpływu wartości wejścia WE-2.

$$W_{SUMA} = W_{WE-1} + W_{WE-2} \quad (5.1)$$

$$W_{KOMB} = W_{WE-1} - 0.2 \cdot W_{WE-2}, \quad (5.2)$$

gdzie:  $W_{SUMA}$ ,  $W_{KOMB}$ ,  $W_{WE-1}$ ,  $W_{WE-2}$  - wartości wejść dodatkowych, odpowiednio, SUMA i KOMB oraz wartości wejść zasadniczych, odpowiednio, WE-1 i WE-2.

Uogólniając przedstawioną charakterystykę uwypuklić należy specyfikę zastosowanego podejścia. W przypadku testów z zastosowaniem danego, jednoznacznie zdefiniowanego, zadania wprowadzenie wejść dodatkowych może spowodować zmianę charakteru zadania. W konsekwencji zdecydowanie kłopotliwa może być interpretacja wartości wyznaczanych

istotności wejść. Przykładowo, po wprowadzeniu do sieci neuronowej FFBP wejścia dodatkowego uzyskać można wynik wskazujący na wysoką istotność tego wejścia z jednoczesnym wskazaniem na możliwość odrzucenia wejść zasadniczych. Przyjmuje się, że poprawnie zrealizowana selekcja danych umożliwi wprowadzenie do sieci FFBP informacji reprezentowanych przez wejścia zasadnicze oraz umożliwi realizację treningu sieci neuronowej o przyjętej strukturze do uzyskania założonych wartości błędów treningu. W pozostałych przypadkach stwierdza się zmianę charakteru rozwiązywanego zadania. Stwierdzając zmianę charakteru zadania przyjmuje się jednak ewentualność uznania selekcji danych za względnie poprawną. Potwierdzeniem selekcji względnie poprawnej jest możliwość realizacji treningu sieci FFBP do założonych wartości błędów po odrzuceniu wejść o najniższych istotnościach, nie wyłączając zarówno wejść zasadniczych, jak i wejść wprowadzających informacje zbliżone do tych wprowadzanych przez wejścia zasadnicze.


### 5.1. Zadanie parzystości

Zadanie parzystości sprowadza się do „nauczenia” sieci neuronowej FFBP rozpoznawania w wektorze wejściowym parzystej liczby wejść o przyjętych wartościach. Wartości wejść do sieci mają zazwyczaj charakter binarny (wartości 0.0 lub 1.0), co sprowadza zadanie parzystości do „nauczenia” sieci FFBP rozpoznawania parzystej liczby wejść o wartościach 1.0. Przytaczając za [Rumelhardt et al., 1986], struktura sieci rozwiązującej zadanie parzystości zależy od liczby wejść. Oznacza to, że przyjmując w poniższych testach 4 wejścia zasadnicze (wejścia oznaczane WE-1÷WE-4, 16 wektorów trenujących) należy zastosować również 4 komórki ukryte. Wstępne symulacje sieci neuronowej wykazały jednakże możliwość realizacji treningu sieci o 3 komórkach ukrytych. Stąd też za podstawową strukturę sieci stosowanej do rozwiązania zadania parzystości przyjęto strukturę 4-3-1. Oczywiście, struktury sieci analizowanych w dalszej części podrzdziału różnią się od struktury podstawowej liczbą komórek wejściowych zależną od liczby wprowadzanych wejść dodatkowych.

Treningi sieci neuronowej FFBP realizowano z zastosowaniem algorytmu inkrementalnego ATS-inc (współczynnik uczenia  $\eta_c=0.2$ ) do uzyskania błędu  $E_{MAX}=0.1$ . Pruning wag realizowano z parametrem  $pr_w=0.25$ . Wartości wzorcowe wyjść 0.1 i 0.9 odpowiadały nieparzystej i parzystej liczbie wejść przyjmujących wartość 1.0.


Testy rozpoczęto od wprowadzenia do sieci wejścia dodatkowego CONST (rys. 5.1). Analizując wyniki przedstawione na rys. 5.1, wyraźnie dostrzega się niższą istotność wprowadzonego wejścia w porównaniu z istotnością wejść zasadniczych. Niemniej jednak kłopotliwe w interpretacji wydaje się być relatywnie małe zróżnicowanie istotności wejść zasadniczych i wejścia CONST. Próbą wyjaśnienia przypisywania wysokiej istotności wejściu CONST jest przyjęcie założenia o możliwości uznania tego wejścia za wejście wprowadzające do sieci FFBP dodatkową wartość progową komórek w warstwie ukrytej. W takim przypadku





Rys. 5.1. Istotności wejść wyznaczone w przypadku wprowadzenia wejścia dodatkowego CONST

Fig. 5.1. Input importance determined while introducing the CONST additional input



Rys. 5.2. Istotności wejść wyznaczone w przypadku wprowadzenia wejścia dodatkowego SZUM


Fig. 5.2. Input importance determined while introducing the SZUM additional input

metody selekcji danych bazujące na sieci FFBP mogą przypisywać relatywnie wysoką istotność wejściu CONST, pomimo że wejście to nie jest wymagane do rozwiązania zadania parzystości. Zaznacza się, że przedstawiona dyskusja nie powinna być uogólniana, ponieważ istotność wejścia CONST może być w znacznym stopniu zależna od charakteru rozwiązywanego zadania (zob. podrozdział 5.2).

W kolejnym teście wprowadzono do sieci FFBP wejście dodatkowe SZUM. Analizując uzyskane wyniki (rys. 5.2) stwierdzono, że za poprawną uznać można jedynie ocenę istotności dokonaną z zastosowaniem metody pruningu wag. Natomiast w przypadku pozostałych metod konieczne jest przeprowadzenie dyskusji wyznaczonych istotności

w szerszym ujęciu. Porównując symulacje sieci podstawowej 4-3-1 oraz sieci z wprowadzonym wejściem SZUM, zauważono przede wszystkim znaczne zmniejszenie średniej liczby iteracji koniecznej do uzyskania założonej wartości błędu treningu. Następnie wykazano możliwość zmniejszenia liczby komórek w warstwie ukrytej i realizacji treningu sieci 5-2-1. Należy także wskazać na znaczne zróżnicowanie istotności wejść wyznaczanych w kolejnych symulacjach. Ostatecznie możliwa była realizacja treningu sieci po odrzuceniu wejść o najniższych istotnościach, tj. wejść WE-2 i WE-4 (sieć 3-3-1), co wskazuje na wspomniany we wprowadzeniu przypadek zmiany charakteru rozwiązywanego zadania. Równocześnie uznaje się w niniejszym teście względnie poprawne wyznaczenie istotności wejść, o czym świadczy możliwość realizacji treningu sieci 3-3-1. Dodać również należy, że próby kilkakrotnego generowania wartości wejścia SZUM nie zmieniały charakteru uzyskiwanych wyników.

Na rys. 5.3 przedstawiono wyniki uzyskane w przypadku wprowadzenia do sieci wejścia dodatkowego POWT, tj. wejścia przyjmującego te same wartości jak wejście zasadnicze WE-1. Charakteryzując wyznaczone istotności stwierdza się, iż metody selekcji bazujące na sieci neuronowej FFBP nie umożliwiają wskazania jednego z wejść, WE-1 lub POWT, jako wejścia do odrzucenia. W przypadku metody sumy wag, metody A-Karina i metody analizy wrażliwości wartości istotności wejść WE-1 i POWT różniły się maksymalnie o 3.5%. Natomiast przedstawione na rys. 5.3 istotności wejść wyznaczone z zastosowaniem metody pruningu wag traktować należy jako przykład uzyskiwanych wyników. Jak wykazały wielokrotnie powtórzone symulacje sieci FFBP, możliwe jest uzyskiwanie zbliżonych istotności wejść WE-1 i POWT lub wskazanie na możliwość odrzucenia jednego z rozpatrywanych wejść.



Rys. 5.3. Istotności wejść wyznaczone w przypadku wprowadzenia wejścia dodatkowego POWT

Fig. 5.3. Input importance determined while introducing the POWT additional input

Ze względu na zdecydowanie problematyczną interpretację wyników przedstawionych na rys. 5.3 zaproponowano oryginalne podejście, nazywane testem podobieństwa wag, umożliwiające wskazanie wejść o charakterze wejść (WE-1, POWT). Przesłanki do zaproponowania testu podobieństwa wag stanowiły wnioski z analiz wartości wag łączących dyskutowane wejścia z komórkami w warstwie ukrytej. Test podobieństwa wag polega na porównywaniu wartości wag łączących komórki wejściowe z komórkami ukrytymi. W przypadku gdy odpowiadające wagi dwóch wejść różnią się o nie więcej niż przyjętą wartość  $WP$ , tj. spełniona jest nierówność (5.3), to wejścia takie uznać można za wejścia o charakterze wejść (WE-1, POWT) i odrzucić jedno z nich.

$$WP \geq \max_{t=1..5} \left\{ \max_{j=1..N} \left\{ \frac{\Delta w_j^{(t)}}{w_{j,AV}^{(t)}} \cdot 100 \right\} \right\} \quad [\%], \quad (5.3)$$

gdzie:

$$w_{j,AV}^{(t)} = ABS \left( \frac{w_{m,j}^{(t)} + w_{n,j}^{(t)}}{2} \right) \quad i \quad \Delta w_j^{(t)} = ABS(w_{m,j}^{(t)} - w_{n,j}^{(t)}) = ABS(w_{n,j}^{(t)} - w_{j,AV}^{(t)}), \quad (5.4)$$

gdzie:  $WP$  - przyjęte, graniczne zróżnicowanie wartości wag;

$m, n$  - indeksy analizowanych komórek wejściowych;


$w_{m,j}, w_{n,j}$  - odpowiednio,  $j$ -ta waga  $m$ -tej i  $n$ -tej komórki wejściowej;

$N$  - liczba komórek w warstwie ukrytej;

$t$  - indeks symulacji sieci FFBP (uwzględniając realizowane w pracy pięciokrotne powtarzanie treningu sieci  $t=1..5$ ).

W przypadku testu, którego wyniki przedstawiono na rys. 5.3, wystąpienie podobieństwa wag wejść WE-1 i POWT stwierdzone może być dla wartości  $WP \cong 1\%$ . Zaznacza się, że przyjętą wartość  $WP$  nie uznaje się za reprezentatywną ze względu na możliwość wyznaczania w przypadku zadania parzystości specyficznych wartości wag [Rumelhardt et al., 1986]. Stąd też próby bardziej ogólnej oceny testu podobieństwa wag przedstawione będą w podsumowaniu niniejszego rozdziału po przeprowadzeniu dyskusji wyników kolejnych testów.

Istotności wejść wyznaczone w przypadku wprowadzenia wejścia dodatkowego POWT-1 (współczynnik korelacji wartości wejść WE-1 i POWT-1 wynosił  $R_{WE-1,POWT-1}=0.997$ ) przedstawiono na rys. 5.4. W porównaniu z rys. 5.3 wyznaczone istotności wejść wykazywały znaczne zróżnicowanie, co umożliwiło uznanie wejścia POWT-1 za wejście mniej istotne. Stwierdzenie to nie odnosi się jednak do wyników uzyskanych z zastosowaniem metody A-Karina.

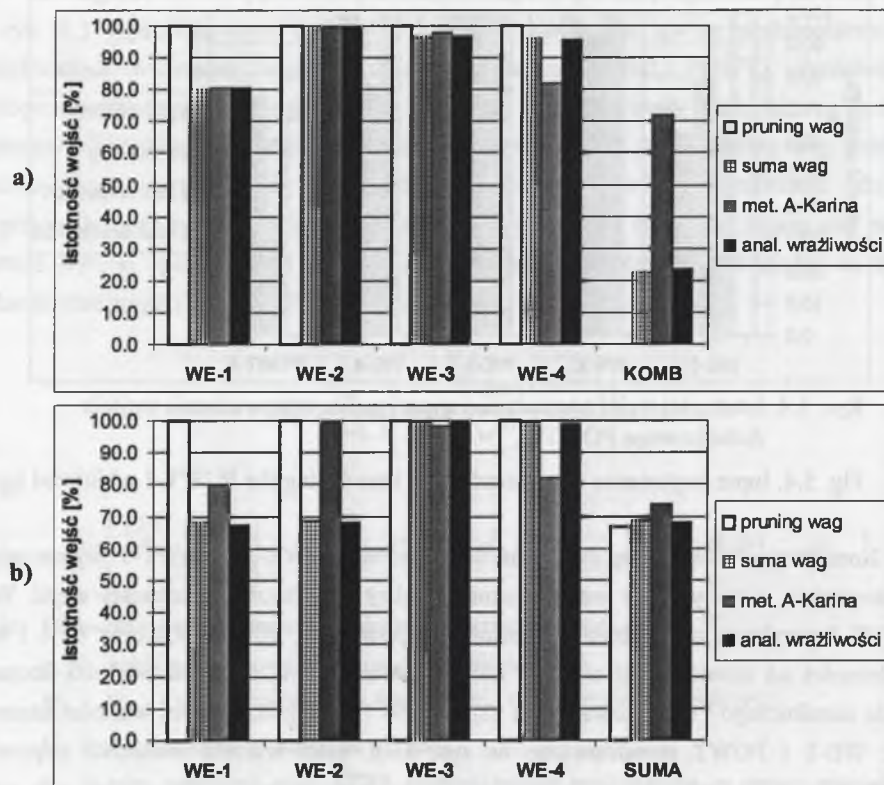


Rys. 5.4. Istotności wejść wyznaczone w przypadku wprowadzenia wejścia dodatkowego POWT-1

Fig. 5.4. Input importance determined while introducing the POWT-1 additional input

Kontynuując, zwraca się uwagę na istotności wejść WE-1 i POWT-1 wyznaczone z zastosowaniem metody sumy wag i metody analizy wrażliwości. Istotności wejść WE-1 i POWT-1 przyjmują w przybliżeniu wartości, odpowiednio, 70% i 30% oraz 60% i 40%, w zależności od zastosowanej metody. Łatwo jest zauważyć, że suma wartości istotności wejścia zasadniczego i dodatkowego jest zbliżona do 100% (zob. również wartości istotności wejść WE-1 i POWT przedstawione na rys. 5.3). Taka wartość istotności odpowiada natomiast wartości istotności wejścia zasadniczego wyznaczanej w przypadku, gdy nie są wprowadzane skorelowane wejścia dodatkowe. Wydaje się, że w powyżej dyskutowanych testach (rys. 5.3 i rys. 5.4) zaobserwować można „rozpływ” istotności na dwa, wprowadzające zbliżone informacje wejścia. Zasygnalizowany w tym miejscu efekt, nazywany konsekwentnie efektem rozptyłu istotności, dyskutowany jest w kolejnych częściach pracy.

Ostatnim z testów polegających na wprowadzeniu do sieci FFBP pojedynczego wejścia dodatkowego był test, w którym wejście dodatkowe (SUMA lub KOMB) reprezentowało przekształcone liniowo wartości wejść zasadniczych. Analiza uzyskanych wyników przeprowadzona może być z uwzględnieniem wcześniejszych uwag i komentarzy. W przypadku wejścia KOMB ( $R_{WE-1,KOMB}=0.981$ ) (rys. 5.5a) wskazuje się na wystąpienie efektu rozptyłu istotności analogicznie do przypadku wejścia POWT-1. Uwypuklić natomiast należy relatywnie niską istotność wejścia KOMB, co ułatwia ogólną ocenę istotności rozpatrywanych danych. Podkreśla się także jednoznaczne wskazanie na możliwość odrzucenia wejścia KOMB, bazując na istotnościach wyznaczanych z zastosowaniem metody pruningu wag. Niemniej jednak wskazuje się równocześnie na niekorzystnie wysoką istotność tego wejścia wyznaczoną z zastosowaniem metody A-Karina.




Rys. 5.5. Istotności wejść wyznaczone w przypadku wprowadzenia wejścia dodatkowego KOMB (a) i SUMA (b)

Fig. 5.5. Input importance determined while introducing the KOMB (a) and SUMA (b) additional inputs

Wprowadzając wejście SUMA ( $R_{WE-1,SUMA}=R_{WE-2,SUMA}=0.707$ ) (rys. 5.5b) wykazano natomiast, że przypadek ten jest zbliżony do przypadku wejścia POWT ze względu na występowanie podobieństwa wag wejść WE-1, WE-2 i SUMA ( $WP \cong 2\%$ ). Wskazuje to na możliwość odrzucenia dwóch z trzech wejść, łącznie z możliwością realizacji treningu sieci 3-3-1 (wejścia : WE-3, WE-4 i SUMA). Istotne jest, aby podkreślić, iż możliwość realizacji treningu sieci 3-3-1 nie jest interpretowana w kategoriach zmiany charakteru zadania parzystości ze względu na reprezentowanie informacji wprowadzanych do sieci przez wejścia WE-1 i WE-2 w postaci wartości wejścia SUMA. Zaznacza się również niewystępowanie w niniejszym teście efektu rozplywu istotności.

W ostatnim etapie testów realizowanych z zastosowaniem zadania parzystości wprowadzono do sieci FFBP 3 dodatkowe wejścia (struktura sieci : 7-3-1, rys. 5.6), pomijając dyskutowane wcześniej wejście SZUM ze względu na wykazanie zmiany charakteru analizowanego zadania. Pomija się także dyskusję wejść POWT i SUMA. Zaznacza się natomiast, że uzyskane wyniki były w pełni analogiczne do wyników przedstawionych na rys. 5.3 i rys. 5.5b. Kontynuując stwierdza się, że również istotności przedstawione na rys. 5.6 odzwierciedlają wyniki uzyskiwane wprowadzając indywidualnie wejścia dodatkowe. W przypadku metody pruningu wag wyznaczone istotności pozwalają jednoznacznie wskazać wejścia zasadnicze i wejścia dodatkowe. Niemniej jednak podkreśla się relatywnie niewielkie zróżnicowanie wartości istotności wejść POWT-1 i CONST, utrudniające ogólną ocenę istotności danych.

Niezależnych komentarzy wymagają wyniki uzyskane z zastosowaniem metody sumy wag i metody analizy wrażliwości. Problematyczne jest w tym przypadku obniżenie istotności wejścia WE-1 związane z wystąpieniem efektu rozplywu istotności spowodowanego wprowadzeniem wejść POWT-1 i KOMB. Jak można zauważyć, prowadzi to do sytuacji, w której wejścia WE-1 i CONST charakteryzują się zbliżoną istotnością lub też istotność wejścia CONST wyznaczona z zastosowaniem metody analizy wrażliwości jest wyższa niż istotność wejścia WE-1. W konsekwencji wystąpić może krytyczny błąd eliminacji wejść. Jednakże wskazać należy na konieczność zachowania odpowiedniej kolejności eliminacji wejść. Potencjalny Użytkownik odrzucić może wejścia POWT-1 i KOMB bazując na progu istotności wejść (danych)  $ID_p \cong 50\%$ . Następnie, ze względu na zbliżone istotności wejść WE-1 i CONST, podjęte powinno być powtórne wyznaczenie istotności pozostałych 5 wejść, prowadzące do poprawnego uznania wejścia CONST za wejście do odrzucenia (zob. rys. 5.1).



Rys. 5.6. Istotności wejść wyznaczone w przypadku wprowadzenia 3 dodatkowych wejść

Fig. 5.6. Input importance determined while introducing 3 additional inputs

Przedstawioną charakterystykę można w ogólnym zarysie odnieść do oceny istotności wejść dokonanej z zastosowaniem metody A-Karina. Niemniej jednak dodatkowo uwypuklić należy niekorzystne, kłopotliwe w interpretacji obniżenie istotności wejścia WE-4 oraz zdecydowanie niewielkie zróżnicowanie istotności wejść zasadniczych i dodatkowych. Dlatego też, w przeciwieństwie do diskutowanych powyżej wyników, problematyczne jest uznanie poprawności oceny istotności wejść z zastosowaniem tej metody.

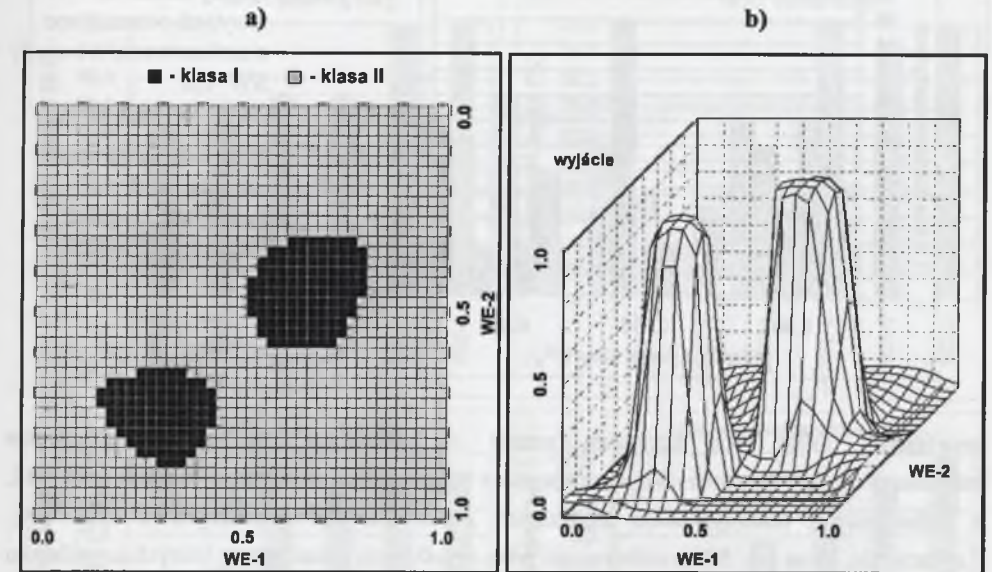
Podsumowując dyskutowane w niniejszym podrozdziale badania, sygnalizuje się wykazanie w pełni zadowalającej powtarzalności wyznaczania istotności danych. Przykładowo, w przypadku indywidualnie wprowadzanego wejścia CONST, maksymalny błąd powtarzalności wyznaczania istotności z zastosowaniem metody A-Karina wynosił  $BPI_{MAX}=5.2\%$ . Natomiast metody sumy wag i analizy wrażliwości umożliwiały wyznaczanie istotności z błędem maksymalnym poniżej 2.0%. Zbliżoną powtarzalność uzyskiwano wprowadzając 3 wejścia dodatkowe. Błąd  $BPI_{MAX}$  wzrósł nieznacznie do wartości 3.1% w przypadku metod sumy wag i analizy wrażliwości oraz  $BPI_{MAX}=12.2\%$  w przypadku metody A-Karina. Metoda pruningu wag, pomijając wejście POWT, pozwalała na uzyskiwanie w pełni powtarzalnych wyników zarówno w testach z wejściami dodatkowymi wprowadzanymi indywidualnie, jak i w testach przeprowadzonych z zastosowaniem 3 wejść dodatkowych.

## 5.2. Zadanie graficzne

Drugim zadaniem analizowanym w niniejszym rozdziale jest tzw. zadanie graficzne. W zadaniu tym sieć neuronową FFBP stosuje się do wykazania przynależności punktów (zadanie klasyfikacji) do dwóch klas, których reprezentację przedstawiono na rys. 5.7a. Reprezentację klas z rys. 5.7a oraz powierzchnię z rys. 5.7b wygenerowano z zastosowaniem sieci FFBP. Zbiór trenujący zawierał dwuelementowe wektory wejściowe, reprezentujące współrzędne punktów w układzie XY. Wejście zasadnicze WE-1 stanowiła współrzędna  $x$  danego punktu, a wejście zasadnicze WE-2 stanowiła współrzędna  $y$ . W celu utworzenia zbioru trenującego w pierwszym kroku wygenerowano losowo współrzędne 60 punktów w przedziale wartości  $[0.0, 1.0]$ . Następnie punkty uporządkowano tak, aby umożliwić przyporządkowanie wektorom wejściowym wartości wzorcowych 0.9 i 0.1 wskazujących na przynależność punktu do, odpowiednio, klasy I i klasy II z rys. 5.7a. Dodaje się, że ten etap generowania zbioru trenującego wpłynął na przyjęcie umownej nazwy niniejszego zadania – zadanie graficzne. Ostatecznie do zbioru trenującego dodano wektory reprezentujące punkty o współrzędnych  $(0.0, 0.0)$ ,  $(0.0, 1.0)$ ,  $(1.0, 0.0)$  i  $(1.0, 1.0)$ , co odpowiada przeskalowaniu wartości wejść do przedziału  $[0.0, 1.0]$ .

### 5.2.1. Zastosowanie metod selekcji danych bazujących na sieci neuronowej FFBP

W przypadku zadania graficznego symulacje sieci neuronowej FFBP przeprowadzono z zastosowaniem algorytmu ATS-cum,  $\eta_F=0.1$  oraz  $E_{MAX}=0.1$ . Pruningu wag dokonywano

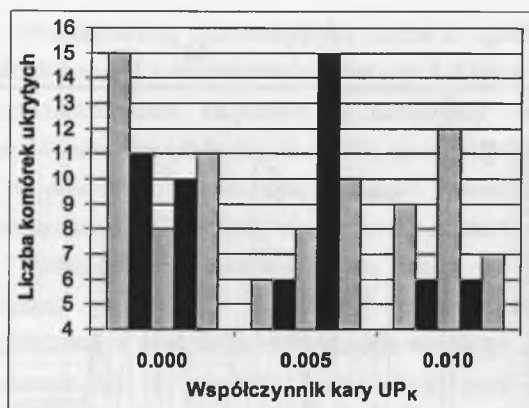


Rys. 5.7. Zadanie graficzne; (a) reprezentacja klas, (b) powierzchnia generowana przez sieć neuronową FFBP

Fig. 5.7. The graphical task; (a) representation of the classes, (b) surface generated with the FFBP neural network

z parametrem  $pr_w=0.25$ . Testy rozpoczęto od oszacowania liczby komórek w warstwie ukrytej sieci FFBP. W pierwszym kroku zastosowano metodę pruningu komórek przyjmując wstępnie 15 komórek ukrytych. Przeprowadzone symulacje (treningi sieci i szacowanie liczby komórek ukrytych z zastosowaniem metody pruningu komórek) wskazywały na możliwość zmniejszenia liczby komórek do 8÷9. Przyjęcie 8 komórek ukrytych i powtórzenie symulacji sieci pozwoliło na zredukowanie liczby komórek do 6 z jednoczesnym uzyskaniem 100% sprawności treningu. Zbliżone wyniki uzyskiwano z zastosowaniem algorytmu ATS-des. Analizując zmiany wartości błędów treningu wskazano na stabilizację wartości błędu  $E_{RMS}$  po wprowadzeniu 8 komórki ukrytej. Natomiast w przypadku błędu  $E_{MAX}$  stabilizacja wartości błędu następowała po wprowadzeniu 6 komórki ukrytej. Zaznacza się, że wprowadzenie 6 komórki ukrytej (a także kolejnych komórek) nie powodowało obniżenia błędu maksymalnego  $E_{MAX}$  do wartości wskazującej na uzyskanie 100% sprawności treningu. Praktycznie oznacza to, że w przedziale od 6 do 12 komórek ukrytych wprowadzanych podczas treningu z zastosowaniem algorytmu ATS-des obserwowano 1 błąd klasyfikacji.

Do oszacowania liczby komórek ukrytych zastosowano także metodę SW+GS [STATISTICA-NN]. Jak można zauważyć (rys. 5.8), wyznaczone liczby komórek ukrytych wykazywały znaczne zróżnicowanie, co zdecydowanie utrudniało określenie struktury sieci



Rys. 5.8. Liczby komórek ukrytych oszacowane z zastosowaniem metody SW+GS [STATISTICA-NN]

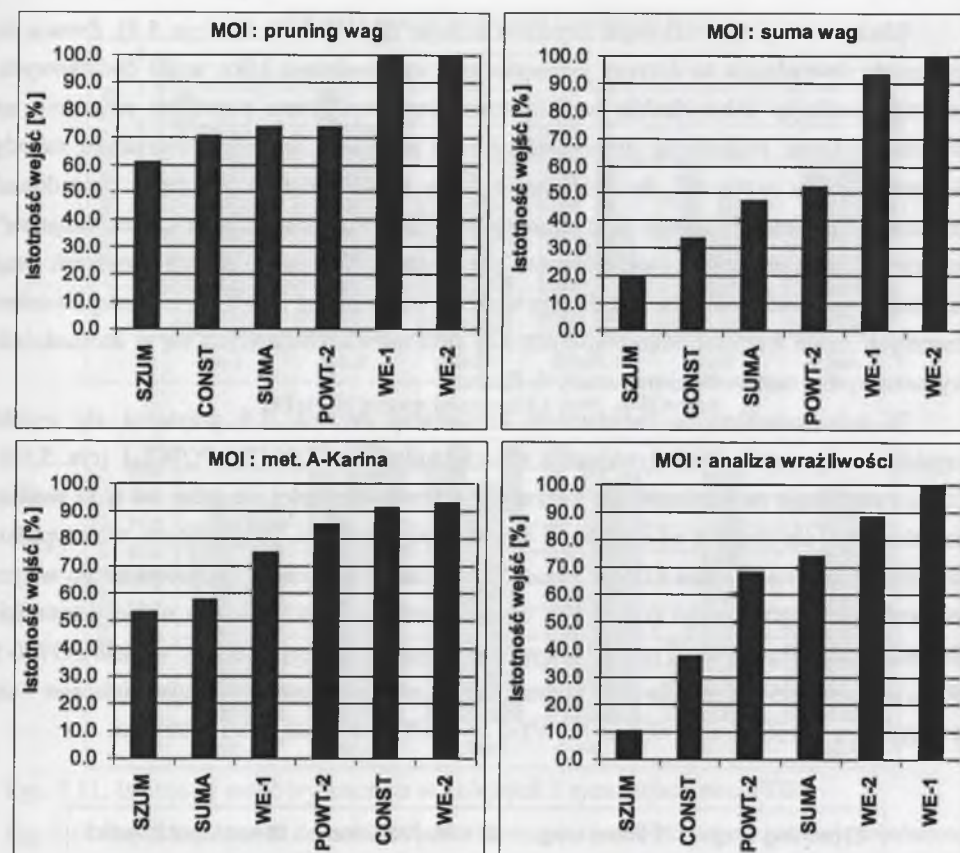
Fig. 5.8. Hidden node numbers estimated with the SW+GS method [STATISTICA-NN]

neuronowej FFBP. Za korzystną uznaje się natomiast możliwość oszacowania minimalnej liczby komórek ukrytych poprzez wielokrotne stosowanie metody SW+GS, z jednoczesnym dokonywaniem arbitralnych zmian wartości współczynnika kary  $UP_k$ . Zaznacza się, że na rys. 5.8 przedstawiono tylko wyniki tych symulacji, w których uzyskiwano 100% sprawności treningu.

Uwzględniając scharakteryzowane powyżej wyniki zdecydowano się zastosować sieć neuronową FFBP o podstawowej strukturze 2-8-1, co odzwierciedla często występujący w praktyce przypadek jedynie zgrubnego oszacowania liczby komórek w warstwie ukrytej i stanowi podstawę do przedstawionej w dalszej części rozdziału dyskusji wpływu liczby komórek ukrytych na wartości wyznaczanych istotności danych.

Podjmując dyskusję przeprowadzonych testów skoncentrowano się zasadniczo na testach, w których do sieci neuronowej FFBP wprowadzano jednocześnie kilka wejść dodatkowych (rys. 5.9). Podejście takie wynika z uzyskania w niniejszym przypadku mniej korzystnych wyników. Przykładowo, istotności wprowadzanych indywidualnie wejść dodatkowych wyznaczone z zastosowaniem metody sumy wag i analizy wrażliwości przyjmowały wartości od 10% do 30% niższe od tych, które przedstawiono na rys. 5.9.

W celu ułatwienia dalszej dyskusji na rys. 5.9 przedstawiono wejścia uporządkowane według wzrastającej istotności. Analizując wstępnie uzyskane wyniki zauważa się występowanie obniżenia istotności wejść zasadniczych. Obniżenie istotności wejść (89% - 93%) uznaje się jednak za relatywnie niewielkie, a tym samym nie wpływające na wnioski wynikające z przeprowadzonych testów. Zasadniczą charakterystykę wyników przedstawionych na rys. 5.9 przeprowadzić można w dwóch krokach. Przede wszystkim należy stwierdzić, że stosując metodę pruningu wag, metodę sumy wag oraz metodę analizy wrażliwości uzyskano poprawne przypisanie istotności poszczególnym wejściom. Poprawne jest przypisanie najwyższych istotności wejściom zasadniczym oraz relatywnie wysokich istotności wejściom reprezentującym informacje zbliżone do informacji wprowadzanych przez



Rys. 5.9. Wejścia uporządkowane według wzrastającej istotności

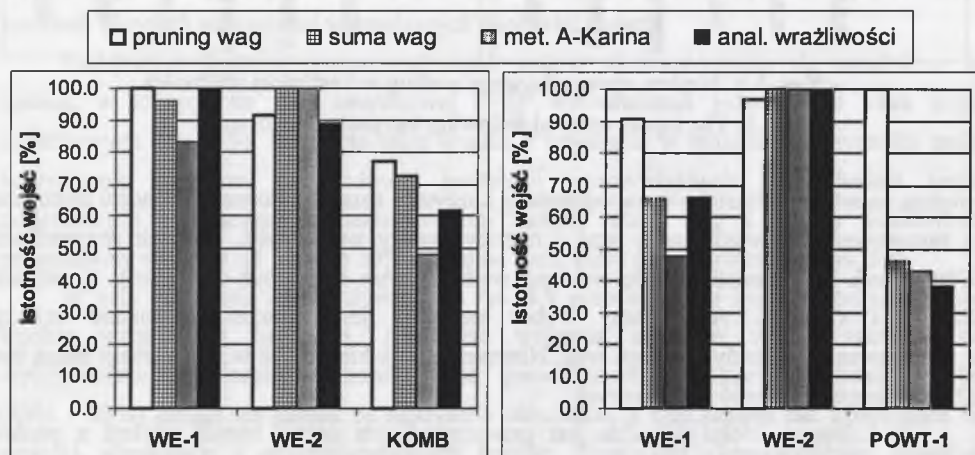
Fig. 5.9. The inputs ordered following increasing importance

wejścia zasadnicze. Następnie, za najbardziej korzystną uznaje się ocenę istotności dokonaną z zastosowaniem metody sumy wag i metody analizy wrażliwości. W tych przypadkach Użytkownik może jednoznacznie wskazać wejścia, które mogą być odrzucone, tj. wejścia SZUM i CONST. Analogiczny wybór możliwy jest poprzez dokonanie selekcji z zastosowaniem metody pruningu wag. Niemniej jednak kłopotliwe w interpretacji mogą być zbliżone istotności wejść dodatkowych.

W kolejnym kroku dogodnie jest przeprowadzenie oceny metod selekcji z punktu widzenia zróżnicowania wartości istotności wejść zasadniczych i wejść dodatkowych. W tym świetle ponownie wskazuje się na metodę sumy wag, w przypadku której wartości istotności wejść WE-1 i POWT-2 różniły się o ~40%. Następnie, wyżej ocenić należy metodę pruningu wag (zróżnicowanie istotności ~25%, wejścia WE-1 i POWT-2) w porównaniu z metodą analizy wrażliwości (zróżnicowanie istotności wejść WE-2 i SUMA wynosiło jedynie 14.4%).

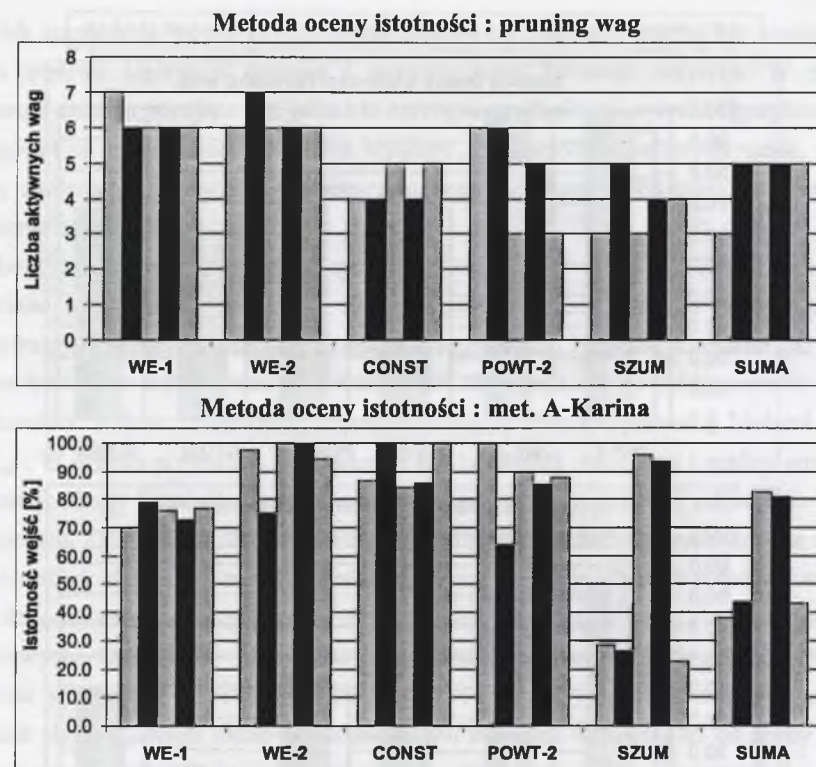
Błędną ocenę istotności wejść uzyskano stosując metodę A-Karina (rys. 5.9). Zwraca się uwagę, że stwierdzenie to dotyczy jednoczesnego wprowadzenia kilku wejść dodatkowych, tzn. wprowadzając indywidualnie wejścia dodatkowe uzyskiwano poprawne wskazania na wejścia nieistotne. Podejmując próbę dyskusji tego przypadku w świetle charakteru metody A-Karina, należy zaznaczyć, że zwiększenie liczby wejść dodatkowych może powodować znaczne „utrudnienie” treningu sieci neuronowej FFBP. Podczas treningu „przeszukuje się” wielowymiarową przestrzeń wag, „testując” jednocześnie wiele potencjalnych rozwiązań. Stąd też, mając na uwadze losową inicjalizację wartości wag, można liczyć się z występowaniem znacznych zmian wartości poszczególnych wag sieci odzwierciedlających się w istotnościach wyznaczanych z zastosowaniem metody A-Karina.

W celu umożliwienia rozszerzenia komentarzy do rys. 5.9 przytacza się wyniki uzyskiwane wprowadzając indywidualnie wejścia dodatkowe KOMB i POWT-1 (rys. 5.10). Zwraca się uwagę na zależność wartości wyznaczanych istotności nie tylko od typu wejścia dodatkowego, ale również od charakteru analizowanego zadania. Przykładowo, w przypadku zadania parzystości, wejście KOMB (rys. 5.5), w przeciwieństwie do rozpatrywanego w tym miejscu zadania graficznego (rys. 5.10), zostało ocenione jako wejście o niskiej istotności. Natomiast przedstawienie na rys. 5.10 wyników uzyskanych wprowadzając wejścia POWT-1 ( $R_{WE-1,POWT-1}=0.995$ ) pozwala na wizualizację występowania nie ujawniającego się w przypadku wprowadzenia wejścia POWT-2 (rys. 5.9) efektu rozplywu istotności.



Rys. 5.10. Istotności wejść wyznaczone w przypadku wprowadzenia wejść dodatkowych KOMB i POWT-1

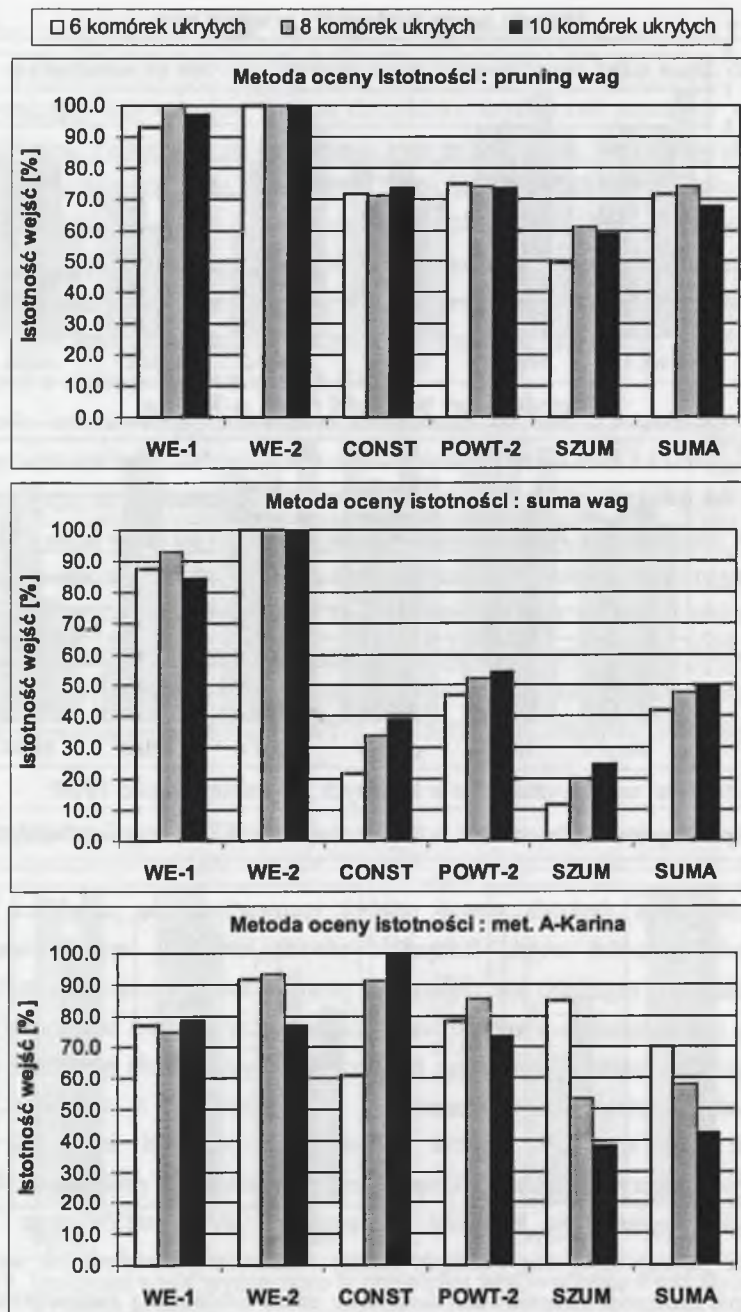
Fig. 5.10. Input importance determined while introducing the KOMB and POWT-1 additional inputs



Rys. 5.11. Istotności wejść wyznaczone w kolejnych 5 symulacjach sieci FFBP

Fig. 5.11. Input importance determined in the 5 consecutive FFBP neural network simulations

Dotychczasowa dyskusja metod selekcji sprowadzała się zasadniczo do analiz wyznaczanych istotności wejść. Jednym z równie istotnych, sygnalizowanych także w podrozdziale 5.1, zagadnień jest zagadnienie powtarzalności wyznaczania istotności wejść analizowane z uwzględnieniem wpływu liczby komórek ukrytych sieci neuronowej FFBP oraz wpływu algorytmu treningu. Analizując powtarzalność wyznaczania istotności w 5-krotnie powtórzonych symulacjach stwierdzono, że w porównaniu z zadaniem parzystości (podrozdział 5.1) wystąpiło większe zróżnicowanie wartości istotności wejść. Za reprezentatywne przyjąć można akceptowane w niniejszej pracy wartości błędów powtarzalności wyznaczania istotności na poziomie  $BPI_{MAX} \cong 15\%$  oraz  $BPI_{AV} \cong 3\%$  w przypadku metody sumy wag i metody analizy wrażliwości. Podobnie jak wyżej większe zróżnicowanie istotności obserwowano dokonując oceny istotności z zastosowaniem metody pruningu wag (rys. 5.11). Wskazać należy na wejście POWT-2, dla którego wyznaczono  $BPI_{MAX}^{(POWT-2)}=3$ . Zdecydowanie niską powtarzalność wykazano natomiast w przypadku metody A-Karina (rys. 5.11). Praktycznie, kłopotliwa jest analiza powtarzalności, ponieważ błędy powtarzalności  $BPI_{MAX}=73.2\%$  i  $BPI_{AV}=13.0\%$  są nie do zaakceptowania.



Rys. 5.12. Istotności wejść wyznaczone w przypadku symulacji sieci neuronowej FFBP o 6, 8 i 10 komórkach ukrytych

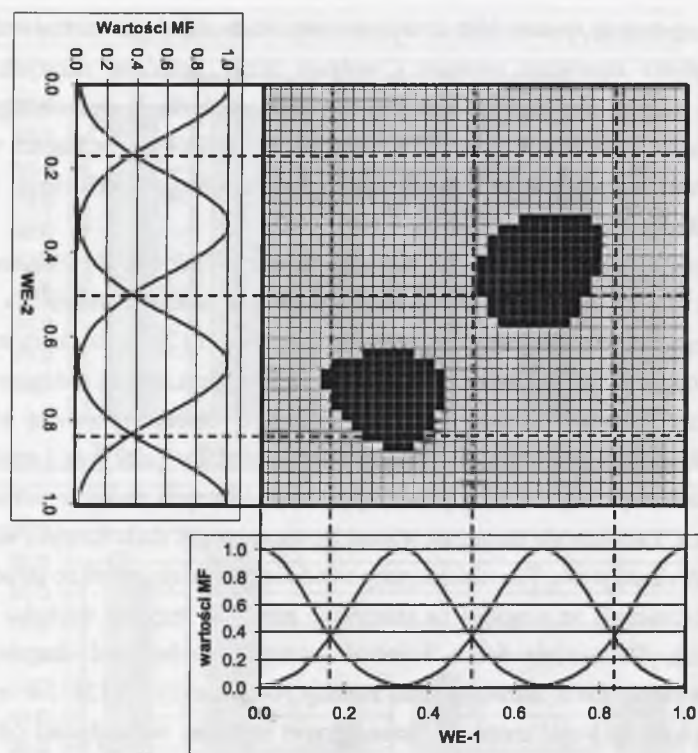
Fig. 5.12. Input importance determined while simulating the FFBP neural network with 6, 8 and 10 hidden nodes

Jak zaznaczono, powtarzalność wyznaczania istotności wejść analizować można także w świetle wpływu algorytmu treningu i wpływu liczby komórek ukrytych. W przypadku niniejszego zadania pomijana jest jednakże szczegółowa dyskusja wpływu algorytmu treningu ze względu na uzyskiwanie zbliżonych wyników, tj. zbliżonych istotności wejść, realizując trening zarówno z zastosowaniem algorytmu kumulacyjnego (ATS-cum), jak i algorytmu inkrementalnego (ATS-inc).

Istotności wejść wyznaczone w symulacjach sieci FFBP o 6, 8 i 10 komórkach ukrytych zestawiono na rys. 5.12. Analizując uzyskane wyniki wskazać można na trzy przypadki. W pierwszym przypadku (metoda pruningu wag, rys. 5.12) liczba komórek ukrytych nie wpływa istotnie na wyznaczone istotności wejść. Przyjmuje się, że zróżnicowanie istotności ma charakter wahań związanych z powtarzalnością charakteryzowaną błędami  $BPI_{MAX}$  i  $BPI_{AV}$ . W drugim przypadku, odnoszącym się do metody sumy wag i analizy wrażliwości, zwiększanie liczby komórek ukrytych nie powoduje istotnych zmian w odniesieniu do wejść zasadniczych. Zauważa się natomiast wzrost istotności wejść dodatkowych wraz ze wzrostem liczby komórek ukrytych. Ten niekorzystny trend nie powoduje jednakże utrudnień w wyborze wejść do odrzucenia ze względu na relatywnie niewielki przyrost wartości istotności wejść dodatkowych. Ostatecznie liczba komórek ukrytych może mieć decydujący wpływ na istotności wyznaczone z zastosowaniem metody A-Karina (rys. 5.12). Jak można zauważyć, kolejność eliminacji wejść może ulec zasadniczym zmianom w zależności od liczby komórek ukrytych, co oczywiście traktuje się jako zdecydowaną negatywną cechę tej metody.

### 5.2.2. Przykład zastosowania systemu logiki rozmytej

Zastosowanie systemu logiki rozmytej ma w tej części pracy charakter przykładowy i zorientowane jest na porównanie wybranych cech metod konstruowania baz reguł (MKBR). Wejścia do sytemu FL stanowiły dwa wejścia zasadnicze WE-1 i WE-2. Każdemu z wejść przypisano inicjalizowane równomiernie (RN) 4 funkcje przynależności ( $MF_{WE}$ ), co prowadziło do możliwości wygenerowania 16 reguł. Na wyjściu systemu FL zastosowano 2 funkcje przynależności ( $MF_{WY}$ ), również inicjalizowane równomiernie. Bazy reguł konstruowano z zastosowaniem metody WTA(0.0) oraz algorytmu genetycznego AG, pomijając metody hybrydowe AG-H\*. Jak można zauważyć, nie realizowano redukcji liczby reguł ze względu na siłę reguł. Specyficznie w niniejszym rozdziale nie realizowano również eliminacji reguł w przypadku zastosowania algorytmu genetycznego. Podejście takie umożliwiło bezpośrednie porównanie dwóch metod konstruowania bazy reguł w zbliżonych warunkach, tj. bazy przed operacją łączenia zawierały 16 reguł. Ogólnie, konstruowane systemy logiki rozmytej opisać można jako  $FL\langle RN, WTA(0.0) \rangle$  oraz  $FL\langle RN, AG \rangle$ .

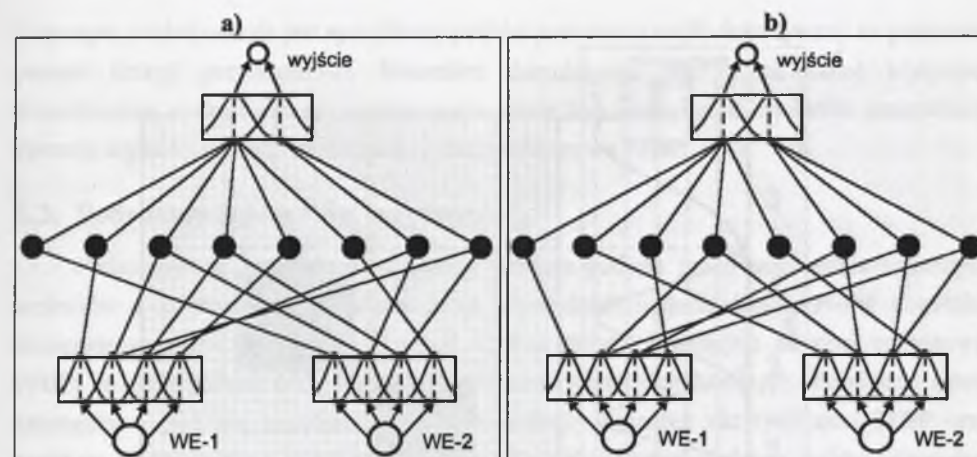


Rys. 5.13. Umowny podział przestrzeni wejść dokonany na podstawie postaci równomiernie zainicjalizowanych funkcji przynależności

Fig. 5.13. Conventional partition of the input space carried out based on the shape of the uniformly initialised membership functions

Przed charakterystyką uzyskanych wyników zwraca się uwagę na możliwość intuicyjnego określenia optymalnej liczby i postaci reguł systemu FL. Dokonując umownego podziału przestrzeni wejść przedstawionego na rys. 5.13 oraz uwzględniając możliwość zmiany (dopasowania) parametrów funkcji przynależności w fazie zastosowania algorytmu BP, stwierdzić można, że baza reguł systemu FL powinna zawierać 8 reguł, w tym 2 reguły wskazujące na przynależność punktu do klasy I (zob. rys. 5.7).

Powyższe rozważania potwierdziły się w przypadku systemu FL konstruowanego z zastosowaniem algorytmu genetycznego (rys. 5.14a). Natomiast stosując metodę WTA(0.0) uzyskano również 8 reguł, jakkolwiek 3 z tych reguł związane były ze wskazaniem przynależności punktu do klasy I (rys. 5.14b). Konsekwencją tego zróżnicowania było zróżnicowanie wartości błędów  $E_{RMS}$  i  $E_{MAX}$  uzyskiwanych w poszczególnych etapach konstruowania systemu FL oraz zróżnicowanie liczby iteracji w przypadku zastosowania algorytmu BP. W tab. 5.1 przedstawiono wybrane wielkości charakteryzujące system FL po



Rys. 5.14. Reprezentacja bazy reguł systemu logiki rozmytej skonstruowanej z zastosowaniem algorytmu genetycznego AG (a) oraz metody WTA(0.0) (b)

Fig. 5.14. Representation of the fuzzy logic system rule base designed with the genetic algorithm AG (a) and the WTA(0.0) method (b)


Tabela 5.1

Wybrane wielkości charakteryzujące skonstruowane systemy logiki rozmytej

MKBR	Etap I			Etap II	
	$E_{RMS}$	$E_{MAX}$	$S_{FL}$ (trening)	liczba iteracji	$E_{RMS}$
WTA	0.357	0.743	71.9%	10586	0.120
AG	0.314	0.698	78.1%	784	0.116

skonstruowaniu bazy reguł (Etap I) oraz po zastosowaniu algorytmu wstecznej propagacji błędów BP (Etap II). Zaznacza się, że w tab. 5.1 sprawność systemu FL ( $S_{FL}$ ) jest sprawnością treningu, tj. sprawnością wyznaczaną w zbiorze trenującym. Istotne jest również, że wartości błędów  $E_{RMS}$  charakteryzujące Etap II odpowiadają najmniejszej liczbie iteracji (przedstawionej również w tab. 5.1), umożliwiającej spełnienie warunku  $E_{MAX} < 0.4$ , czyli umożliwiającej uzyskanie 100% sprawności treningu. Podejście takie wynika z wykazania kolejnych zróżnicowań analizowanych systemów FL. W przypadku zastosowania metody WTA(0.0) kontynuacja treningu z zastosowaniem algorytmu BP prowadzi do nieznacznego zmniejszenia wartości błędu skutecznego  $E_{RMS}$  i jednoczesnego pojawienia się jednego błędu klasyfikacji. Natomiast kontynuacja treningu systemu skonstruowanego z zastosowaniem AG pozwala na zmniejszenie błędów treningu po 9355 iteracjach do wartości  $E_{RMS} = 0.062$  i  $E_{MAX} = 0.200$  (rys. 5.15).





Rys. 5.15. Umowny podział przestrzeni wejść dokonany na podstawie ostatecznych postaci funkcji przynależności

Fig. 5.15. Conventional partition of the input space carried out based on the final shape of the membership functions

Podsumowując przykład zastosowania systemu logiki rozmytej zwraca się ponownie uwagę na uzyskiwanie zróżnicowanych wyników w przypadku, jak można przyjąć, relatywnie prostego zadania. Podkreśla się nie tylko niezadowalające wyniki uzyskane z zastosowaniem metody WTA(0.0), ale również sygnalizuje się brak możliwości uzyskania założonej wartości błędu maksymalnego (analogicznie do przypadku sieci neuronowych przyjęto, aby realizować trening do wartości błędu  $E_{MAX}=0.1$ ). Przykładowo, próba zmniejszenia błędu  $E_{MAX}$  w przypadku systemu FL(RN, AG) sprowadzała się do konieczności znacznego wydłużenia treningu, tzn. po 23423 iteracjach uzyskano  $E_{RMS}=0.042$  i  $E_{MAX}=0.164$ , po czym zmiany wartości błędów ulegały zdecydowanemu zmniejszeniu. Ostatecznie zwraca się uwagę na odmienność postaci obszarów reprezentujących klasę I. Porównuje się w tym przypadku postaci obszarów wyznaczanych z zastosowaniem sieci neuronowej FFBP (rys. 5.7 i rys. 5.13) oraz z zastosowaniem systemu logiki rozmytej (rys. 5.15).

Przyczyną zróżnicowania jest specyficzny podział przestrzeni wejść dokonywany na podstawie postaci funkcji przynależności. Natomiast domniemaną, jak można uznać krytyczną, konsekwencją dyskutowanego zróżnicowania może być zmniejszenie zdolności generalizacji systemu logiki rozmytej w porównaniu z siecią neuronową FFBP.

### 5.3. Podsumowanie testów wstępnych

Podsumowując przeprowadzone testy wstępne podjęto próbę uogólnienia wybranych wniosków i komentarzy przytoczanych w poprzednich podrozdziałach. Próby uogólnień skoncentrowano na porównaniach metod selekcji danych bazujących na sieci neuronowej FFBP, ze szczególnym uwzględnieniem problemu wejść skorelowanych. Pominięto zatem szczegółową dyskusję zagadnienia szacowania liczby komórek ukrytych sieci FFBP oraz problemu powtarzalności wyznaczania istotności wejść. Również skrótowo traktuje się w tym miejscu dyskusję systemu logiki rozmytej i sieci neuronowej FFBP. Odwołując się do poprzedniego podrozdziału jednoznacznie stwierdzić można, że system logiki rozmytej charakteryzował się w niniejszych testach mniejszą zdolnością uczenia, wyższym kosztem obliczeniowym i, jak założono, może wykazywać mniejszą zdolność generalizacji. Powyższe wnioski stanowią o porównaniu sieci neuronowej FFBP i systemu logiki rozmytej w świetle wybranych, uzupełniających kryteriów oceny metod integracji danych.

Dokonując porównania metod selekcji danych bazujących na sieci neuronowej FFBP uzasadnione jest, aby wskazać na niezadowalające wyniki uzyskiwane z zastosowaniem metody A-Karina. Stwierdzenie to odnosi się głównie do błędnego wyznaczania istotności w przypadku wprowadzania kilku wejść dodatkowych. Równie niekorzystnie ocenia się metodę A-Karina w świetle kryterium powtarzalności wyznaczania istotności wejść oraz ze względu na wykazanie znacznego wpływu liczby komórek ukrytych na uzyskiwane wyniki. Stąd też dyskusja metody A-Karina nie jest kontynuowana w dalszej części podsumowania. Niemniej jednak uznaje się, że negatywna ocena nie stanowi o konieczności definitywnego odrzucenia tej metody w kolejnych testach. Przyjmuje się, że ostateczna decyzja o przydatności metody A-Karina do selekcji danych może być podjęta po uwzględnieniu wyników uzyskiwanych w przypadku zadań analizowanych w kolejnych rozdziałach pracy.

Porównując pozostałe metody selekcji danych bazujące na sieci neuronowej FFBP, wskazuje się na metodę pruningu wag jako metodę, której zastosowanie w zdecydowanej większości przeprowadzonych testów umożliwiało wybór istotnych wejść. Konieczne jest natomiast podkreślenie możliwych niedogodności w ilościowej interpretacji uzyskiwanych wyników. Zastosowanie metody pruningu wag może prowadzić do wyznaczania relatywnie mało zróżnicowanych wartości istotności, co w konsekwencji powodować może utrudnienia w ocenie istotności poszczególnych danych.

Za zadowalające uznaje się także wyniki uzyskiwane z zastosowaniem metody sumy wag i metody analizy wrażliwości. Uszczegółowienie charakterystyk tych metod wymaga

uwzględnienia charakteru wprowadzanych wejść dodatkowych. Przyjmując, że metody selekcji umożliwiają poprawne wskazanie wejść nie wykazujących współzmienności z wyjściami (wejścia SZUM i CONST), dyskusyjne mogą być wyniki uzyskiwane w przypadku wprowadzania do sieci FFBP zbliżonych informacji. Jak wykazano, obecność wejść skorelowanych może powodować występowanie efektu rozplywu istotności, co wymaga szerszego komentarza, potencjalnie pozwalającego na uogólnienie wniosków wynikających z przeprowadzonych badań.

Analizując oceny istotności danych dokonane z zastosowaniem metody sumy wag i metody analizy wrażliwości wyróżnić można trzy poniżej dyskutowane przypadki. Na potrzeby niniejszego opisu przyjmuje się, że analizowany jest zbiór wejść, w którym występują dwa wejścia o charakterze wejścia zasadniczego i dodatkowego.

Pierwszy przypadek przejawia się występowaniem wejść, których istotności przyjmują zbliżone wartości. Oczywiście, w danym podzbiorze wejść wystąpić mogą wejścia o „naturalnie” zbliżonych istotnościach. Przyczyną jednakże może być również skorelowanie wartości wejść i występowanie efektu rozplywu istotności lub specyficzne relacje pomiędzy wejściami i wyjściami. Autor sugeruje, aby analizę wejść o zbliżonych istotnościach przeprowadzać z zastosowaniem opisanego w podrozdziale 5.1 testu podobieństwa wag. Niemniej jednak zaznaczyć należy, że zgodnie z wynikami przeprowadzonych badań test podobieństwa wag pozwala jedynie na wskazanie skorelowanych wejść o zdecydowanie wysokiej wartości współczynnika korelacji (zwykle  $R \geq 0.999$ ), a tym samym zróżnicowaniu wartości istotności rzędu kilku procent. Wysoka wartość współczynnika korelacji nie stanowi jednak warunku koniecznego do praktycznego zastosowania testu podobieństwa wag. Test ten może być z powodzeniem stosowany w przypadkach występowania wspomnianych specyficznych relacji pomiędzy wejściami i wyjściami, powodujących przypisywanie zbliżonych istotności. Typowym przykładem jest zadanie parzystości i wprowadzenie wejścia dodatkowego SUMA (rys. 5.5). Test podobieństwa wag ujawnił możliwość odrzucenia dwóch z trzech wejść {WE-1, WE-2, SUMA}. Zaznacza się jednak, że współczynnik korelacji wartości par wejść (WE-1, SUMA) i (WE-2, SUMA) wynosił  $R=0.707$ .

Drugi przypadek odnosi się do uzyskiwania zróżnicowanych wartości istotności wejść skorelowanych. Zróżnicowanie wartości istotności zgodne jest z cechami efektu rozplywu istotności (zob. komentarz do rys. 5.4), a współczynnik korelacji przyjmuje wartości w przedziale [0.980, 0.999], np. wejścia WE-1 i POWT-1 z rys. 5.4 ( $R_{WE-1,POWT-1}=0.997$ ) lub rys. 5.10 ( $R_{WE-1,POWT-1}=0.995$ ). Podkreśla się, że podane wartości graniczne przedziału zmian współczynnika korelacji są wartościami przybliżonymi, wyznaczonymi na podstawie przeprowadzonych testów. Ogólnie, niniejszy przypadek uznaje się za krytyczny, ponieważ prowadzi do odrzucenia istotnego wejścia, co dyskutowano w komentarzu do rys. 5.6.

Trzeci przypadek może być równie problematyczny, jakkolwiek nie ma charakteru przypadku krytycznego. Jak wykazano, dla wejść skorelowanych o współczynniku korelacji  $R < 0.980$  nie występował efekt rozplywu istotności. Praktycznie oznacza to, że nie następowało obniżenie istotności wejścia zasadniczego w obecności skorelowanego wejścia dodatkowego (np. wejścia WE-1 i POWT-2,  $R_{WE-1,POWT-2}=0.977$ , rys. 5.9 lub wejścia WE-1 i KOMB,  $R_{WE-1,KOMB}=0.928$ , rys. 5.10). Wartość istotności wejścia dodatkowego zależna była nie tylko od wartości współczynnika korelacji, ale również od charakteru analizowanego zadania (zob. dyskusja wejścia KOMB, rys. 5.10). Równocześnie oznacza to, że nie wykazano jednoznacznych zależności pomiędzy wartością współczynnika korelacji  $R$  i wyznaczonymi wartościami istotności wejścia dodatkowego. Kontynuując, wskazuje się na możliwe, niekorzystne konsekwencje niniejszego przypadku. Zakładając przykładowo występowanie wejścia zasadniczego o istotności rzędu 100% i wejścia dodatkowego o istotności rzędu 70%, przyjąć można, że nie dochodzi do odrzucenia obu wejść, jak to mogło mieć miejsce w opisanym powyżej przypadku krytycznym. Jednakże wysoka istotność wejścia dodatkowego powodować może zaliczenie tego wejścia do podzbioru wejść wymaganych do rozwiązania danego zadania, a tym samym zawyżenie liczności podzbioru ostatecznie wyselekcjonowanych danych.

W tym miejscu dogodnie jest, aby powrócić do oceny wyników uzyskiwanych z zastosowaniem metody pruningu wag. Stwierdza się, że występowanie wejść skorelowanych ma znacznie mniejszy wpływ na wyznaczone z zastosowaniem tej metody istotności danych. Ten w pełni zadowolający wniosek odzwierciedlać może korzystną cechę metody pruningu wag związaną z uważaną za dyskusyjną rozdzielczością metody (por. rozdział 4). Natomiast praktyczną konsekwencją tej cechy jest zdecydowane zredukowanie możliwości wystąpienia krytycznej eliminacji istotnych wejść (zob. rys. 5.6 lub rys. 5.10). Niemniej jednak, problematyczna jest w dalszym ciągu możliwość zawyżenia liczności podzbioru wyselekcjonowanych danych.

Podsumowując problem wejść skorelowanych potwierdza się konieczność stosowania analizy korelacji danych wejściowych (np. [Diagnostyka techniczna, 2001]). Autor zaznacza jednakże, że analiza ta nie może być prowadzona w sposób bezkrytyczny. W pierwszym kroku wskazuje się na problem wyboru wejścia do odrzucenia. Jak wykazano, odrzucenie dowolnego wejścia skorelowanego może powodować wydłużenie treningu sieci neuronowej, pogorszenie powtarzalności wyznaczania istotności oraz przypuszcza się, że może powodować obniżenie zdolności generalizacji. Stąd też autor sugeruje, aby decyzję o wyborze wejścia do odrzucenia podejmować na podstawie analizy wyznaczonych istotności, tj. odrzucić to wejście skorelowane, którego istotność jest niższa. Po dokonaniu eliminacji wejść skorelowanych korzystne jest powtórne wyznaczenie istotności danych. Równie problematyczna jest analiza

danych wejściowych z punktu widzenia wartości współczynnika korelacji. Przyjęcie poziomu wartości współczynnika korelacji, od którego wejścia uznaje się za skorelowane, wydaje się być zależne wyłącznie od Użytkownika realizującego selekcję danych.

Podsumowując niniejszy rozdział autor zwraca uwagę na obszerność i wielowątkowość przeprowadzonej dyskusji oraz ponownie podkreśla uzyskanie relatywnie zróżnicowanych wyników. Obszerność i wielowątkowość przeprowadzonej dyskusji powodować może powstanie wątpliwości odnoszących się do przydatności metod selekcji danych bazujących na sieci neuronowej FFBP w przypadku prób rozwiązania stosunkowo, jak może się wydawać, prostych zadań. Niemniej jednak przypomnieć należy, że zgodnie z celem niniejszego rozdziału szczegółowa analiza uzyskanych wyników zorientowana była głównie na uwypuklenie potencjalnych, ogólnie rozumianych problemów związanych z zastosowaniem wspomnianych metod. Następnie, zasadne w tym miejscu jest porównanie uzyskanych wyników z wynikami oceny istotności danych przeprowadzonej z zastosowaniem metod bazujących na macierzy rozproszenia (SM+SFS i SM+AG) oraz metody SR+AG. Podkreśla się, że uzyskane wyniki niekorzystnie odbiegały od wyżej analizowanych, szczególnie w przypadku występowania kilku wejść dodatkowych. Jak wykazano w testach z zastosowaniem zadania graficznego, żaden z wyselekcjonowanych podzbiorów 2 wejść nie zawierał wejść zasadniczych (WE-1 i WE-2), a realizacja treningu sieci neuronowej FFBP możliwa była jedynie w przypadku pary wejść dodatkowych (POWT-2, SUMA) wybranej z zastosowaniem metody SM+AG.

## 6. DIAGNOSTYKA STANU WIERTEŁ PODCZAS WIERCENIA WIELOWRZECIONOWEGO

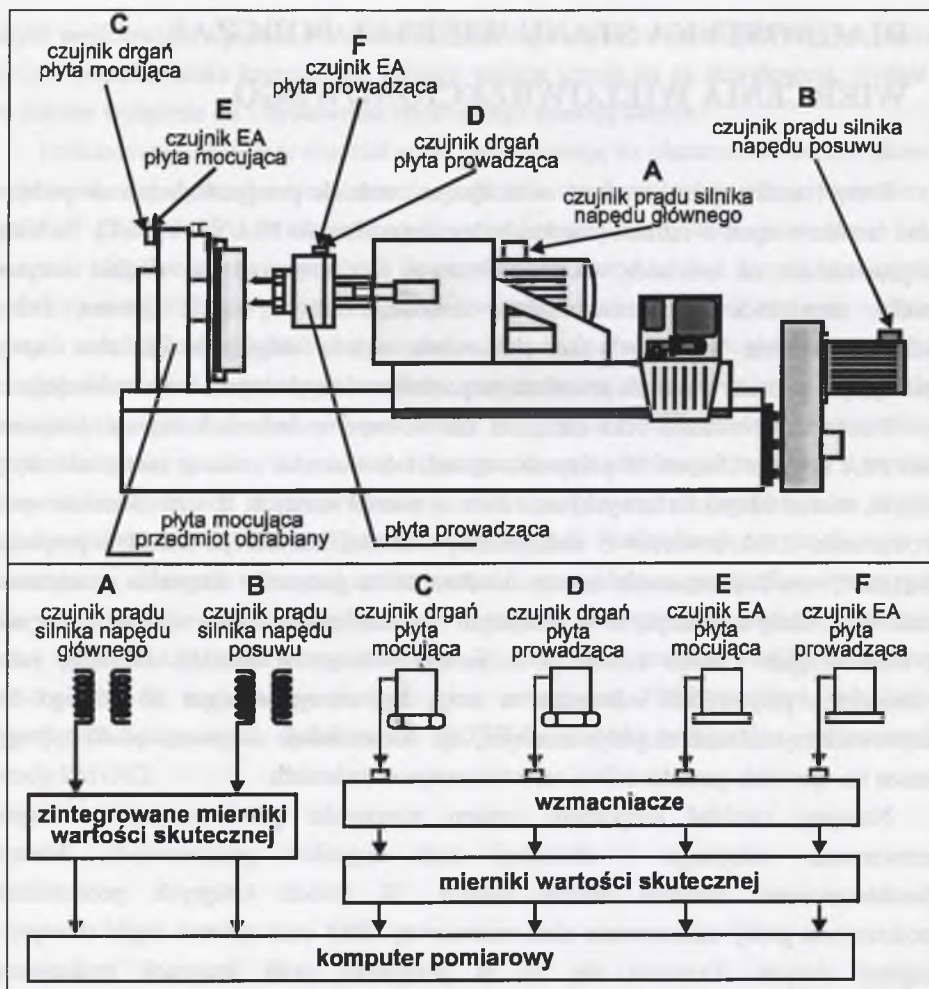
Testy i analizy przedstawione w niniejszym rozdziale przeprowadzono na podstawie badań zrealizowanych w ramach projektu badawczego [Projekt PSA/RENAULT]. Badania te przeprowadzono na wiertarce wielowrzecionowej (10 wrzecion) do obróbki korpusów silników samochodowych, stosowanej w zakładach PSA Peugeot Citroen, Francja. Nadrzędnym celem badań było zaprojektowanie układu diagnozującego stan narzędzi skrawających podczas wiercenia ze zmiennym posuwem różnych materiałów obrabianych.

Przedmioty obrabiane oraz narzędzia zastosowane w badaniach zostały dostarczone przez PSA Peugeot Citroen. W przypadku narzędzi dostarczono zestawy wiertel nieużytych (ostrzych, wiertel fabrycznie nowych) oraz zestawy wiertel zużytych, tj. wiertel zastosowanych do wierceniu 2500 otworów o maksymalnej wartości zużycia powierzchni przyłożenia  $VB_{MAX} \approx 0.7$  mm. Jednocześnie zostały określone także parametry skrawania przedstawione w tab. 6.1. Należy zaznaczyć, że w niniejszym rozdziale uwzględniono wszystkie otrzymane od PSA Peugeot Citroen informacje dotyczące parametrów obróbki. Niemniej jednak, w niektórych przypadkach informacje te mogą być niewystarczające do pełnego opisu przeprowadzonych badań eksperymentalnych, np. dokumentacja otrzymana od PSA Peugeot Citroen nie ujawniała gatunku żeliwa zastosowanego w badaniach.

Niniejszy rozdział rozpoczęto opisem stanowiska pomiarowego oraz opisem przetwarzania wstępnego i ekstrakcji cech sygnałów pomiarowych. Następnie scharakteryzowano wstępne analizy danych. W dwóch kolejnych podrozdziałach przedstawiono próby zastosowania sieci neuronowej FFBP oraz systemu logiki rozmytej do integracji danych. Zaznacza się, że w przypadku prób integracji realizowanych z zastosowaniem sieci FFBP przeprowadzono także zasadnicze testy metod selekcji. Stąd też we wspomnianym podrozdziale dokonywano najpierw wyboru istotnych danych i następnie realizowano integrację wybranych danych. Analogiczne podzbiory danych zastosowano w testach systemu logiki rozmytej. Rozdział podsumowano oceną zastosowanych metod selekcji i integracji.

### 6.1. Opis stanowiska pomiarowego i ekstrakcji cech sygnałów pomiarowych

Konfigurując układ pomiarowy dążono do zastosowania jak największej liczby możliwie zróżnicowanych czujników pomiarowych [König et al., 1995]. Podejście takie związane jest nie tylko z próbą jak najpełniejszego opisu zjawisk związanych ze zużyciem narzędzi (np. [Hong et al., 1992]), ale wynika przede wszystkim ze zdecydowanie ograniczonej ilości informacji, które umożliwiałyby wstępny dobór torów pomiarowych w przypadku badań prowadzonych na specyficznej, specjalizowanej obrabiarce.



Rys. 6.1. Schemat stanowiska pomiarowego i konfiguracja torów pomiarowych  
 Fig. 6.1. Schematics of the measuring set-up and configuration of the measuring lines

Tabela 6.1

Tabelaryczne zestawienie parametrów obróbki

Prędkość skrawania : 25.6 m/min		średnica wiertła : 10.5 mm	
Materiał obrabiany : żeliwo		Materiał obrabiany : stal J45	
posuw : 0.194; 0.156; 0.128; 0.101 mm/obr		posuw : 0.117; 0.097; 0.086; 0.078 mm/obr	
Zestawy wiertel :			
- zestaw 10 wiertel nieużytych			
- zestaw wiertel częściowo zużytych (5 wiertel nieużytych i 5 wiertel zużytych)			
- zestaw 10 wiertel zużytych ( $V_{B_{MAX}} \approx 0.7$ mm)			

Tabela 6.2

Reprezentacja wektora wejściowego

WEJŚCIA 1 - 13												
posuw	czujnik prądu silnika napędu głównego				czujnik prądu silnika posuwu				czujnik drgań płyta mocująca			
1	2	3	4	5	6	7	8	9	10	11	12	13
f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4

WEJŚCIA 14 - 26												
czujnik drgań płyta prowadząca				czujnik EA płyta mocująca				czujnik EA płyta prowadząca				materiał obrabiany
14	15	16	17	18	19	20	21	22	23	24	25	26
D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-3	M

Zastosowany układ pomiarowy przedstawiono na rys. 6.1 ([König et al., 1995]). Przyjęto, aby oddziaływania siłowe w strefie skrawania analizować na podstawie pomiarów prądu w silniku napędu głównego oraz posuwowego. Zdecydowano się także na pomiar drgań i emisji akustycznej (EA) po stronie narzędzi oraz po stronie przedmiotu obrabianego. Podejście takie prowadzi do układu pomiarowego, w którym zastosowano 6 czujników pomiarowych. Sygnały z czujników pomiarowych przetwarzano z zastosowaniem analogowych mierników wartości skutecznej, a następnie rejestrowano na komputerze pomiarowym. Zaznacza się, że układ pomiarowy przedstawiony na rys. 6.1 należy traktować jako układ skonfigurowany wstępnie pod względem liczby zastosowanych czujników. Ustalenie ostatecznej liczby czujników stanowiło natomiast jeden z zasadniczych celów badań.

Udostępnione parametry obróbki wraz opisem zastosowanych zestawów wiertel przedstawiono w tab. 6.1. Podkreśla się, że w badaniach eksperymentalnych, oprócz zestawów wiertel dostarczonych przez PSA Peugeot Citroen, zastosowano także zestaw, w którego skład wchodziło 5 wiertel nieużytych i 5 wiertel zużytych. Przyjęto, że zestaw taki posłużyć może jako zestaw symulujący wiercenie wiertłami częściowo zużyтыми. Jak można zauważyć, diagnozowanie stanu narzędzi sprowadza się w świetle przeprowadzonych badań eksperymentalnych do zadania klasyfikacji 3 poziomów zużycia zestawów wiertel.

Przetwarzanie wstępne oraz ekstrakcję cech każdego z zarejestrowanych sygnałów pomiarowych przeprowadzono w analogiczny sposób. W pierwszym kroku wybrano podrealizacje (części) zarejestrowanych sygnałów odpowiadające zasadniczej fazie wiercenia, tj. odrzucono części odpowiadające wejściu wiertła w materiał obrabiany oraz wycofaniu wiertła. W kolejnym kroku dokonano ekstrakcji 4 cech każdej z wybranych podrealizacji :

- cecha 1 : wartość średnia;
- cecha 2 : odchylenie standardowe;
- cecha 3 : współczynnik kierunkowy trendu liniowego;
- cecha 4 : odchylenie standardowe podrealizacji sygnału z usuniętym trendem liniowym.

W efekcie przeprowadzonej ekstrakcji każdy z pomiarów reprezentowany był przez 24 cechy sygnałów pomiarowych oraz posuwu (f) i gatunek materiału obrabianego (M). Cechy sygnałów pomiarowych oraz wspomniane parametry obróbki zestawiono w tab. 6.2 w postaci wektora wejściowego stosowanych w dalszej części rozdziału metod selekcji i integracji danych. Dodaje się, że wejście reprezentujące gatunek materiału obrabianego przyjmowało wartości (0.0, 1.0) w przypadku, odpowiednio, wiercenia żeliwa i stali J45.

W ramach badań przeprowadzono 160 pomiarów. Pomiary przeprowadzono w 2 seriach (powtórzeniach) stanowiących podstawę utworzenia zbioru uczącego i zbioru testującego. Zbiór uczący utworzono bazując na pomiarach przeprowadzonych w pierwszej serii (80 pomiarów), a kolejne 80 pomiarów przeprowadzonych z analogicznymi parametrami obróbki zastosowano do utworzenia zbioru testującego.

## 6.2. Wstępne analizy danych

Celem wstępnych analiz danych było określenie charakteru zmian wartości cech sygnałów pomiarowych powodowanych zużyciem narzędzi. Przyjęto, że określenie charakteru zmian wartości cech umożliwi wybór cech wykazujących największą współzmiennność ze zużyciem wiertła. Jak można zauważyć, uwzględnienie parametrów obróbki w przyjętym podejściu prowadzi praktycznie do podjęcia wstępnych prób selekcji istotnych danych.

Ponieważ ogólnie rozumiana ocena selekcji danych dokonywana jest zasadniczo na podstawie uzyskiwanych sprawności sieci neuronowej FFBP, dogodnie jest w tym miejscu określić strukturę podstawową sieci oraz wyznaczyć odpowiadające tej strukturze sprawności klasyfikacji. Przyjmując 3 komórki wyjściowe, co stanowi konsekwencję podjęcia analiz 3 poziomów zużycia narzędzi, zagadnienie określenia struktury podstawowej sprowadza się do wyboru liczby komórek w warstwie ukrytej.

Wyboru liczby komórek ukrytych dokonano porównując relatywnie zbliżone wyniki uzyskane z zastosowaniem metody pruningu komórek, algorytmu ATS-des i metody SW+GS. Dodać można, że pruning komórek przeprowadzono z parametrem  $pr_k=0.25$  przyjmując w strukturze początkowej 10 komórek ukrytych (rys. 6.2). Ostatecznie zastosowano 6 komórek w warstwie ukrytej, co prowadzi do sieci o strukturze podstawowej 26-6-3 (rys. 6.2). Zaznacza się, iż możliwe było przeprowadzenie treningu sieci o 5 komórkach ukrytych. Niemniej jednak, konsekwencją zmniejszenia liczby komórek było wielokrotne blokowanie treningu i konieczność powtarzania symulacji. Podana na rys. 6.2 sprawność sieci neuronowej,  $S_{FFBP} \approx 95\%$ , wyznaczona z zastosowaniem zbioru testującego, stanowi wartość odniesienia dla sprawności analizowanych w kolejnych podrozdziałach. Przypomnieć można, że zasadniczym celem selekcji danych jest odrzucenie jak największej liczby danych z jednoczesnym zachowaniem sprawności klasyfikacji na poziomie zbliżonym do wyżej przytoczonej wartości.

Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego																								Sprawność sieci FFBP
a) 26-10-3																									95.5%
b) 26-6-3																									94.2%

Rys. 6.2. Struktura początkowa (a) i podstawowa (b) oraz sprawności sieci neuronowej FFBP  
Fig. 6.2. The initial (a) and basic (b) structures and the respective performances of FFBP neural network

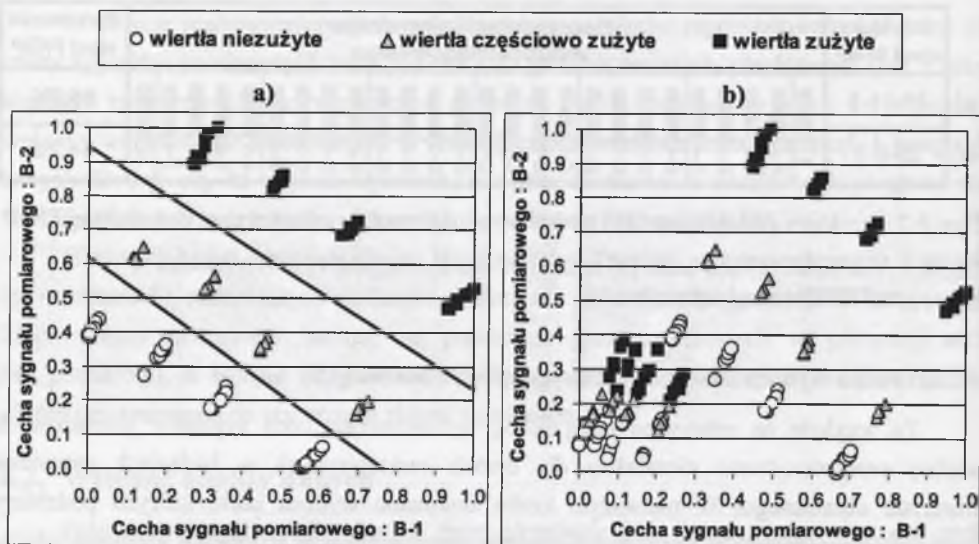
### 6.2.1. Próba wyboru istotnych cech sygnałów pomiarowych

Ze względu na relatywnie dużą liczbę wyznaczonych cech sygnałów pomiarowych analizy przeprowadzono niezależnie dla dwóch zastosowanych w badaniach gatunków materiału obrabianego. W pierwszym kroku dokonano wyboru cech, których podzbiory wartości wyznaczonych w przypadku skrawania zestawem wiertła zużytych i zestawem wiertła niezaużytych stanowiły podzbiory rozłączne [König et al., 1995]. W kolejnym kroku podjęto próbę oceny wybranych cech sygnałów pomiarowych poprzez porównanie wartości średnich i odchyłeń standardowych wyznaczanych we wspomnianych podzbiórach. Preferowano te cechy, których podzbiory wartości umożliwiały wyznaczenie wartości średnich, wykazujących największe przyrosty ze wzrostem zużycia wiertła oraz charakteryzowały się najniższą wartością odchyłeń standardowych. W kolejnym kroku badań zweryfikowano wstępnie wybrane cechy poprzez uwzględnienie wartości cech reprezentujących obróbkę zestawem wiertła częściowo zużytych. Dokonano w ten sposób kolejnej eliminacji cech poprzez odrzucenie tych cech, których zmiany wartości nie były zmianami monotonicznymi ze zmianami wartości zużycia narzędzi. Ostatecznie wybrane cechy sygnałów pomiarowych zestawiono w tab. 6.3, niezależnie dla przypadku skrawania żeliwa i stali J45.

Analiza cech z tab. 6.3 z uwzględnieniem posuwu (f) wykazała istnienie 4 par danych umożliwiających klasyfikację stanu wiertła podczas obróbki żeliwa : (B-1, B-2), (A-1, f) (B-1, f) i (B-2, f). Przestrzeń wartości pary cech (B-1, B-2) przedstawiono na rys. 6.3a.

Tabela 6.3  
Wybrane cechy sygnałów pomiarowych (oznaczenia wg tab. 6.2)

Cechy sygnałów pomiarowych							
	A-1	A-2	A-3	A-4	B-1	B-2	B-4
Żeliwo	+	+	+	+	+	+	+
Stal J45	-	-	-	-	+	+	+



Rys. 6.3. Przestrzeń skalowanych wartości pary cech (B-1, B-2); a) wiercenie żeliwa, b) wiercenie żeliwa i stali J45; (oznaczenia wg tab. 6.2)

Fig. 6.3. Space of scaled values of the (B-1, B-2) feature pair; a) cast iron drilling, b) cast iron and steel J45 drilling; (denotation according to tab. 6.2)

Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego																Sprawność sieci FFBP	
9-5-3																		87.5%
5-8-3																		81.2%
7-7-3																		83.5%

Rys. 6.4. Zestawienie wyników integracji wybranych danych

Fig. 6.4. The results of integration of the selected data

Nie wykazano natomiast możliwości klasyfikacji stanu wiertła podczas skrawania stali J45, co prowadzi do braku możliwości wskazania danych pozwalających na klasyfikację stanu wiertła bez względu na gatunek materiału obrabianego (rys. 6.3b). Wniosek ten odnosi się oczywiście do możliwości wskazania dwóch danych, analogicznie do przypadku skrawania żeliwa. Stąd też za nie wymagające uzasadnienia uznaje się podjęcie charakteryzowanej dalej próby wyboru większej liczby danych i integracji danych z zastosowaniem sieci neuronowej FFBP.


Symulacje sieci neuronowej FFBP przeprowadzono z zastosowaniem podzbiorów danych o różnej liczności (rys. 6.4). W pierwszym kroku wprowadzono do sieci dane reprezentujące wybrane zgodnie z tab. 6.3 cechy sygnałów pomiarowych oraz posuw ( $f$ ) i gatunek materiału obrabianego ( $M$ ). Następnie zredukowano liczbę danych poprzez zastosowanie cech wybranych zarówno w przypadku wiercenia stali, jak i żeliwa. Ostatecznie, wejścia do sieci stanowiły jedynie cechy sygnałów pomiarowych przedstawione w tab. 6.3.

Zestawione na rys. 6.4 sprawności sieci neuronowej FFBP uznaje się za relatywnie niskie w porównaniu ze sprawnością  $S_{FFBP} \cong 95\%$ , uzyskaną w wyniku wprowadzenia do sieci 26 danych (rys. 6.2). Wskazuje się w tym przypadku na możliwe konsekwencje uproszczonego sposobu przeprowadzenia selekcji danych. Eliminacja pojedynczych cech sygnałów pomiarowych bez uwzględnienia wzajemnych relacji pomiędzy cechami prowadzić może do utraty znaczących informacji. Zwraca się także uwagę na interpretację uzyskanych wyników. Oczekuje się, że testowane w pracy metody selekcji umożliwią wybór podzbiorów danych pozwalających na wyznaczenie charakteryzującego się wyższą sprawnością klasyfikatora stanu wiertła. Uwypukla się również pracochłonność zastosowanego podejścia, co traktowane jest jako kolejne uzasadnienie konieczności zastosowania bardziej efektywnych metod selekcji danych.

### 6.2.2. Próba selekcji danych z zastosowaniem analizy korelacji rangowej

Zastosowanie analizy korelacji rangowej związane jest zasadniczo z typem wartości cechy stanu zestawu wiertła (zużycia  $VB_{MAX}$ ). Wartości {wierćła nieużyte, wiertła częściowo użyte, wiertła użyte} stanowią uporządkowany zbiór wartości nominalnych, co zgodnie z [Diagnostyka techniczna, 2001] pozwala na zastosowanie miary nieparametrycznej korelacji rangowej Spearmana lub  $\tau$ -Kendalla w celu dokonania oceny istotności danych. W niniejszej pracy zastosowano korelację  $\tau$ -Kendalla ze względu na mniejszą wrażliwość współczynnika korelacji (statystyki  $\tau$ ) na lokalne oscylacje wartości elementów szeregu analizowanych wielkości. Zaznacza się jednakże, że stosując analizę korelacji rangowej Spearmana wykazano możliwość uporządkowania danych prowadzącą do wyboru zbliżonych podzbiorów potencjalnie istotnych danych (zob. rys. 6.5). Zróżnicowanie uporządkowania ujawniało się jedynie w przypadku 4 danych o najwyższych wartościach bezwzględnych współczynników korelacji.

Dokonując wyboru podzbioru danych przyjęto analizować te dane, które charakteryzowały się wartościami bezwzględnymi współczynnika korelacji  $\tau$ -Kendalla powyżej wartości 0.25 (rys. 6.5). Podejście takie prowadzi do wyboru podzbioru 9 danych. Następnie, z podzbioru 9 danych odrzucono cechę A-2 ze względu na jej „silne”, jak uznano, skorelowanie z cechą A-4 ( $R_{A-2,A-4}=0.934$ ). Podzbiór wyselekcjonowanych w ten sposób 8 danych (wejść) stanowił podstawę podjęcia prób integracji z zastosowaniem sieci neuronowej FFBP.



Rys. 6.5. Dane uporządkowane według wzrastających wartości bezwzględnych współczynnika korelacji rangowej  $\tau$ -Kendalla

Fig. 6.5. The data ordered following increasing absolute values of the  $\tau$ -Kendall rang correlation factor

Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego	Sprawność sieci FFBP
8-5-3	f, A-1, A-2, A-3, A-4, B-1, B-2, B-3, B-4, C-1, C-2, C-3, C-4, D-1, D-2, D-3, D-4, E-1, E-2, E-3, E-4, F-1, F-2, F-3, F-4, M	90.0%
7-6-3	f, A-1, A-2, A-3, A-4, B-1, B-2, B-3, B-4, C-1, C-2, C-3, C-4, D-1, D-2, D-3, D-4, E-1, E-2, E-3, E-4, F-1, F-2, F-3, F-4, M	86.5%
6-6-3	f, A-1, A-2, A-3, A-4, B-1, B-2, B-3, B-4, C-1, C-2, C-3, C-4, D-1, D-2, D-3, D-4, E-1, E-2, E-3, E-4, F-1, F-2, F-3, F-4, M	84.2%
(A) 8-6-3	f, A-1, A-2, A-3, A-4, B-1, B-2, B-3, B-4, C-1, C-2, C-3, C-4, D-1, D-2, D-3, D-4, E-1, E-2, E-3, E-4, F-1, F-2, F-3, F-4, M	93.5%

Rys. 6.6. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem analizy korelacji rangowej  $\tau$ -Kendalla

Fig. 6.6. The results of integration of the data selected based on the  $\tau$ -Kendall rang correlation analysis

Wyniki, tj. struktury sieci neuronowych FFBP oraz uzyskane sprawności, przedstawiono na rys. 6.6. Symulacje sieci przeprowadzono w dwóch krokach. W pierwszym kroku wprowadzono do sieci 8, 7 oraz 6 danych. Jak można zauważyć, podjęto w ten sposób próbę redukcji liczby danych zgodnie z kolejnością wynikającą z rys. 6.5. Dodać można, że odrzucenie kolejnej danej (próba wyboru podzbioru 5 wejść) uniemożliwiło realizację

treningu sieci FFBP. Analizując wyniki przedstawione na rys. 6.6 podkreśla się uzyskanie zadowalającej sprawności  $S_{FFBP}=90\%$  w przypadku wprowadzenia 8 danych. Niemniej jednak próby zmniejszenia liczby danych powodowały, podobnie jak w przypadku testów przedstawionych w podrozdziale 6.2.1, wyraźne obniżenie sprawności klasyfikacji.


Obniżenie sprawności klasyfikacji wskazywać może na konieczność wprowadzenia do sieci odpowiednio dużej liczby danych w celu uzyskania sprawności powyżej 90%. Jednakże symulacje przeprowadzone w drugim kroku testów wykazały, że przyczyną może być również jedynie częściowo poprawna ocena istotności danych. We wspomnianych symulacjach do podzbioru 6 wejść wybranych na podstawie wyników przedstawionych na rys. 6.5, dodano wejścia reprezentujące posuw (f) i materiał obrabiany (M). Strukturę sieci neuronowej o arbitralnie dodanych wejściach oznaczono na rys. 6.6 symbolem „(A)”. Jak wykazano, arbitralne uznanie istotności parametrów obróbki spowodowało pożądaną wzrost sprawności klasyfikacji.

Uogólniając problem wyboru parametrów obróbki stwierdza się, iż uznawanie tych wielkości za mniej istotne w przypadku prób oceny istotności danych z zastosowaniem analizy korelacji rangowej jest zrozumiałe, ponieważ parametry obróbki mogą „z założenia” nie wykazywać współzmienności z cechami stanu analizowanego zjawiska. Niemniej jednak nie stanowi to o możliwości pominięcia informacji o parametrach obróbki w ogólnie rozumianym modelu zjawiska. Następnie, w przypadku analizowanego zadania, podjęcie arbitralnej decyzji o uwzględnieniu parametrów obróbki wydaje się być w pełni uzasadnione ze względu na jedynie nieznaczne zwiększenie liczności podzbiorów wybranych danych. Zdecydowanie problematyczne może być natomiast podjęcie takiej decyzji w przypadku dużej liczby parametrów obróbki. Uwypuklić również należy znaczący z punktu widzenia potencjalnego Użytkownika brak możliwości odzyskania informacji o istotności parametrów obróbki w zbiorze danych charakteryzujących analizowane zjawisko.

### 6.3. Integracja danych z zastosowaniem sieci neuronowej FFBP


#### 6.3.1. Integracja danych wyselekcjonowanych z zastosowaniem metod bazujących na sieci neuronowej FFBP

Symulacje sieci neuronowej analizowane w niniejszej części pracy przeprowadzono zgodnie z wytycznymi przedstawionymi w rozdziale 4. W fazie selekcji danych trening sieci FFBP o strukturze 26-6-3 (zob. rys. 6.2) realizowano z zastosowaniem algorytmu kumulacyjnego (ATS-cum) i  $\eta_F=0.1$ , do uzyskania błędu maksymalnego  $E_{MAX}=0.15$ . Pruning wag realizowano z parametrem  $pr_w=0.25$ . Natomiast w fazie integracji wyselekcjonowanych danych stosowano algorytm inkrementalny (ATS-inc) i  $\eta_F=0.15$ , przyjmując  $E_{MAX}=0.10$  lub  $E_{MAX}=0.15$  w zależności od możliwości uzyskiwania powyższych wartości błędu.



Rys. 6.7. Istotności wejść wyznaczone z zastosowaniem metod bazujących na sieci neuronowej FFBP

Fig. 6.7. Input importance determined with the FFBP neural network based methods



Rys. 6.8. Wejścia uporządkowane według wzrastającej istotności

Fig. 6.8. The inputs ordered following increasing importance

Wyznaczone istotności wejść (danych) przedstawiono na rys. 6.7. Oceniając ogólnie wyznaczone istotności zauważa się, że zastosowane metody selekcji wskazywały na zbliżone cechy sygnałów pomiarowych. Najwyższe istotności uzyskiwały cechy sygnałów reprezentujących prądy w silnikach napędu głównego i napędu posuwowego. Istotne są także pojedyncze cechy sygnałów reprezentujących drgania i emisję akustyczną. Z punktu widzenia Użytkownika ważne jest, że już ogólna ocena istotności pozwala na wstępną ocenę przydatności czujników zastosowanych w układzie pomiarowym. Przykładowo wskazuje się czujnik emisji akustycznej (czujnik F), w przypadku którego wszystkie cechy sygnału pomiarowego charakteryzują się niską istotnością.

Przed przystąpieniem do charakterystyki integracji danych dogodne jest odniesienie się do zagadnienia korelacji danych wejściowych. Analizę korelacji przeprowadzono zgodnie z uwagami i sugestiami przedstawionymi w rozdziale 5, co uznać można za potwierdzenie trafności uogólnień dokonanych w wyżej wspomnianym rozdziale. Jak wykazano, w zbiorze danych wejściowych występowały 4 pary danych o współczynnikach korelacji powyżej uznanej za krytyczną wartości  $R \approx 0.980$ , tj. (C-2, C-4), (D-2, D-4), (F-2, F-4) i (E-2, E-4). Znaczące jest, iż sumy wartości istotności powyższych par wejść nie przekraczały 50%. Zatem eliminacja wybranych wejść i ponowne wyznaczenie istotności powodowały, zgodnie z cechami efektu rozplywu istotności, zwiększenie istotności wejść nieodrzuconych do wartości nie przekraczających poziomu 50%. Stąd też efekt rozplywu istotności nie wpływał na wybór podzbiorów danych przeprowadzany z zastosowaniem przyjętego w pracy progu istotności  $ID_p \approx 50\%$ . Zaznacza się również, że nie wykazano zawyżania liczności dyskutowanych poniżej podzbiorów danych ze względu na występowanie danych uznanych za skorelowane (przyjęto  $R \geq 0.8$ ).

Dokonując wyboru podzbiorów danych korzystne jest uporządkowanie wejść według wzrastającej istotności, co przykładowo przedstawiono na rys. 6.8. Jak zaznaczono, wyboru pierwszego z podzbiorów wejść dokonywano bazując na progu istotności  $ID_p \approx 50\%$ .



MS(pruning wag)																											
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego												Sprawność sieci FFBP														
7-5-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	98.2%
6-4-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	98.2%
5-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	98.7%
4-5-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	93.7%
(A) 4-5-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	95.5%
(A) 3-8-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	86.5%

Rys. 6.9. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metody pruningu wag  
Fig. 6.9. Results obtained while integrating data selected based on the weight pruning method

MS ( suma wag )																											
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego												Sprawność sieci FFBP														
7-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	97.0%
6-8-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	97.5%
5-7-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	87.0%
4-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	79.5%

Rys. 6.10. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metody sumy wag  
Fig. 6.10. Results obtained while integrating data selected based on the weight sum method

Następnie podejmowano próby eliminacji kolejnych wejść. Wyniki integracji danych wyselekcjonowanych z zastosowaniem metody pruningu wag przedstawiono na rys. 6.9. Analizując uzyskane wyniki podkreślić należy wysokie sprawności sieci FFBP o 7, 6 i 5 wejściach. Zwraca się uwagę na sprawność rzędu 98%, która jest sprawnością wyższą od tej, uzyskanej w przypadku symulacji sieci o 26 wejściach (rys. 6.2). Potwierdza to negatywny wpływ wejść wprowadzających redundantne informacje i uwypukla celowość stosowania selekcji danych. Dokonując eliminacji wejść uzyskano ostatecznie podzbiór jedynie 4 wejść z zachowaniem wysokiej sprawności rzędu 94%. Ze względu na przypisanie wejściom E-1 i B-4 analogicznych istotności (zob. rys. 6.8), dokonanie wyboru 4 wejść wymagało jednak przeprowadzenia dodatkowych symulacji sieci FFBP. Symulacje wykazały brak możliwości realizacji treningu sieci w przypadku odrzucenia wejścia B-4, co oczywiście wskazywało na wyższą istotność tego wejścia.

Zadowalające wyniki uzyskano także dokonując eliminacji wejść zgodnie z istotnościami wyznaczonymi z zastosowaniem metody sumy wag (rys. 6.10). Podkreśla się możliwość wyboru podzbioru 6 wejść i uzyskania wysokiej sprawności klasyfikacji. Eliminacja kolejnego wejścia powodowała jednakże znaczne obniżenie sprawności. Potencjalną przyczyną mógł być błąd w kolejności eliminacji wejść spowodowany niewielkim zróżnicowaniem istotności wejść B4, D3 i M. Niemniej jednak próby arbitralnego ustalenia kolejności eliminacji wejść nie potwierdziły tego przypuszczenia.

Dyskusji uzyskanych wyników dokonać można także w świetle możliwości zmniejszenia liczby czujników w projektowanym układzie diagnostycznym. Przykładowo, dokonując wyboru 5 wejść metodą pruningu wag, potencjalny Użytkownik zastosować może jedynie 3 czujniki. Jeżeli liczba czujników jest nadal zbyt wysoka, możliwe jest zastosowanie 2 czujników z równoczesnym, akceptowalnym zmniejszeniem sprawności klasyfikacji. Znaczne zmniejszenie liczby analizowanych danych stanowi także o możliwości podjęcia próby arbitralnego wyboru danych, ukierunkowanej na wskazanie odmiennych od wyżej zasygnalizowanych konfiguracji czujników pomiarowych. Podejście takie przedstawiono na rys. 6.9, oznaczając skonstruowane sieci neuronowe symbolem „(A)”. Jak można zauważyć, w efekcie arbitralnego wyboru wejść wskazuje się kolejną parę czujników, których zastosowanie potencjalnie pozwala na uzyskiwanie sprawności rzędu 95%. Równie interesujące jest rozwiązanie jednoczujnikowe (sieć 3-8-3 (A), rys. 6.9), które porównać można do rozwiązania z rys. 6.4. Jednakże uwypuklić należy korzystne zmniejszenie liczby wejść w analizowanym w tym miejscu rozwiązaniu z jednoczesnym uzyskaniem sprawności rzędu 87%. Uzupełniając komentarze zwraca się uwagę na odmienny niż w podrozdziale 6.2.2 charakter arbitralnego wyboru wejść. Ingerencja Użytkownika nie wynika z konieczności podniesienia sprawności klasyfikacji, a stanowi próbę wyboru alternatywnego podzbioru danych o analogicznej liczności, umożliwiającego uzyskiwanie zbliżonych sprawności.

MS( met. A-Karina )																											
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego																		Sprawność sieci FFBP								
7-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	92.8%
6-7-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	92.0%
5-7-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	82.0%
4-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	79.5%
(A) 5-5-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	88.7%

Rys. 6.11. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metody A-Karina

Fig. 6.11. Results obtained while integrating data selected based on the A-Karin method

MS( anal. wrażliwości )																											
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego																		Sprawność sieci FFBP								
8-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	93.2%
7-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	86.2%
6-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	83.5%
5-8-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	82.0%
4-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	79.5%



Rys. 6.12. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metody analizy wrażliwości

Fig. 6.12. Results obtained while integrating data selected based on the sensitivity analysis

Zestawienia wyników uzyskanych w testach kolejnych metod bazujących na sieci neuronowej FFBP przedstawiono na rys. 6.11 i rys. 6.12. Akceptowalne rezultaty uzyskano z zastosowaniem metody A-Karina (rys. 6.11). W tym przypadku wskazać można na specyficzną konfigurację wejść, tj. podzbiory wejść nie zawierały wejść reprezentujących posuw (f) i materiał obrabiany (M), podobnie jak podzbiory dyskutowane w podrozdziale 6.2.1 i 6.2.2. Jednakże wprowadzenie do sieci neuronowej FFBP 7 lub 6 danych pozwalało w niniejszym przypadku na uzyskanie korzystniejszych (powyżej 90%) sprawności klasyfikacji. Natomiast kontynuacja eliminacji wejść i pominięcie wejścia D-1 powodowało wyraźne obniżenie sprawności klasyfikacji. Jak wykazały próby arbitralnego wyboru wejść, kolejność eliminacji wejść wynikająca z istotności wyznaczonych z zastosowaniem metody A-Karina nie może być uznana za w pełni zadowalającą (zob. sieć 5-5-3 (A), rys. 6.11).

Ostatnia z zastosowanych metod selekcji, tj. metoda bazująca na analizie wrażliwości, odbiega, w świetle uzyskanych wyników, od metod powyżej scharakteryzowanych. Jak można zauważyć (rys. 6.12), sprawność klasyfikacji powyżej 90% uzyskano jedynie w przypadku wprowadzenia do sieci FFBP 8 danych. Następnie wskazać można na uznanie za istotne zbliżonych cech sygnałów pomiarowych jak w przypadku metody sumy wag (podzbiory 6 i 5 wejść z rys. 6.12). Zasadniczą różnicę stanowiło nieuwzględnienie informacji o gatunku materiału obrabianego (wejście M). Podzbiory danych można także porównać do podzbiorów danych wybranych z zastosowaniem metody A-Karina, a tym samym podzbiorów dyskutowanych w podrozdziale 6.2.1 i 6.2.2. W przypadku 7 i 6 wejść różnice stanowiły jedynie wejścia D-1 i D-3 (por. rys. 6.11 i rys. 6.12). Niemniej jednak wejścia te, a w zasadzie wejście D-1 decyduje o uzyskiwaniu wyraźnie wyższych sprawności klasyfikacji.

Podobnie jak w rozdziale 5, dyskusję zastosowań metod selekcji danych bazujących na sieci neuronowej FFBP podsumowuje się analizą powtarzalności wyznaczania istotności z uwzględnieniem wpływu algorytmu treningu. Oceniając ogólnie powtarzalność wyznaczania istotności wykazano występowanie znacznego zróżnicowania w zależności od analizowanego wejścia. W przypadku metody sumy wag i metody analizy wrażliwości powtarzalność wyznaczania istotności charakteryzuje błąd maksymalny  $BPI_{MAX} \cong 25.0\%$  i błąd średni  $BPI_{AV} \cong 3.0\%$ . Koncentrując dyskusję na wynikach uzyskanych z zastosowaniem metody sumy wag (zob. rys. 6.13), zaznacza się, że najwyższe wartości maksymalnego błędu powtarzalności odnoszą się do uznanych za jedne z najistotniejszych wejść M ( $BPI_{MAX}^{(M)} = 25.7\%$ ) oraz A-1 ( $BPI_{MAX}^{(A-1)} = 20.5\%$ ). W przypadku pozostałych wejść  $BPI_{MAX}^{(j)} < 16\%$ . Szczególną uwagę należy zwrócić na wejście M, ponieważ zróżnicowanie wartości istotności wyznaczanych w kolejnych symulacjach powodować może zmianę kolejności eliminacji wejść M, D-3 i B-4. Zmiana kolejności nie ma jednak w rozpatrywanym przypadku znaczącego wpływu na uzyskiwane sprawności sieci FFBP, co stwierdzono w komentarzu do rys. 6.10.




Rys. 6.13. Istotności wejść wyznaczone w 5 kolejnych symulacjach sieci neuronowej FFBP

Fig. 6.13. Input importance determined in the 5 consecutive simulation of FFBP neural network

Zróznicowaną powtarzalność wyznaczania istotności wejść wykazano także analizując wyniki uzyskane z zastosowaniem metody pruningu wag. Dla zdecydowanej większości wejść, błąd maksymalny powtarzalności wyznaczania istotności przyjmował w pełni akceptowalne wartości  $BPI_{MAX}^{(l)} \leq 1$ . Wskazać jednakże należy na  $BPI_{MAX}^{(D-1)} = BPI_{MAX}^{(B-3)} = 3$  (wejścia D-1 i B-3). Zakładając podjęcie próby ponownej oceny istotności danych, konsekwencją wyższych wartości błędów jest możliwość uzyskania wyników powodujących zaliczenie wejścia D-1 do podzbioru istotnych wejść lub niekorzystne, utrudniające podjęcie decyzji o kolejności eliminacji danych, przypisanie zbliżonych istotności wejściom B-3, B-4 i E-1.

W formie podsumowania powyższych rozważań wskazuje się na możliwość odmiennego podejścia do oceny powtarzalności wyznaczania istotności danych. Za zdecydowanie korzystniejsze uważa się uzyskiwanie zadowalającej powtarzalności w przypadku wejść mniej istotnych, co potencjalnie pozwala na redukcję liczby wejść bez przypadkowego odrzucenia wejścia istotnego. Z punktu widzenia Użytkownika oznacza to, że możliwe jest jednoznaczne wskazanie podzbioru istotnych danych o relatywnie małej liczności. Następnie, w przypadku wykazania niezadowalającej powtarzalności wyznaczania istotności, Użytkownik może dokonać powtórnej oceny istotności w uzyskanym podzbiore danych lub może zweryfikować kolejność eliminacji danych kierując się istotnościami wyznaczanymi w kolejnych symulacjach.



Rys. 6.14. Istotności wejść wyznaczone w przypadku symulacji sieci neuronowej FFBP zrealizowanych z zastosowaniem inkrementalnego algorytmu treningu (ATS-inc)


Fig. 6.14. Input importance determined while performing the FFBP neural network simulations with use of the incremental training algorithm (ATS-inc)

Powyższych uwag nie można odnieść do wyników uzyskanych z zastosowaniem metody A-Karina (rys. 6.13). W zasadzie kłopotliwe jest analizowanie powtarzalności wyznaczania istotności ze względu na możliwość występowania radykalnych zmian wartości istotności, o czym świadczą błędy  $BPI_{MAX} = 85.0\%$  oraz  $BPI_{AV} = 6.5\%$  (por. rozdział 5). Tak niska powtarzalność wiąże się nie tylko z  $BPI_{MAX}^{(A-2)} = 85.0\%$ , ponieważ zauważyć można jeszcze 5 innych wejść, dla których  $BPI_{MAX}^{(l)} > 40\%$ . Równie niekorzystnie ocenia się metodę A-Karina z punktu widzenia wpływu algorytmu treningu sieci FFBP (rys. 6.14). Przede wszystkim zauważa się zupełnie odmienne w porównaniu z rys. 6.7 zróżnicowanie istotności, zdecydowanie utrudniające podjęcie decyzji o kolejności eliminacji danych.

Nie stwierdzono natomiast zasadniczego wpływu algorytmu treningu sieci FFBP w odniesieniu do metody pruningu wag, metody sumy wag i metody analizy wrażliwości. Stwierdzenie to wskazuje na możliwość wyboru zbliżonych podzbiorów istotnych danych bazując na symulacjach sieci zrealizowanych z zastosowaniem zarówno algorytmu kumulacyjnego (ATS-cum), jak i inkrementalnego (ATS-inc). Uznano, że wykazane w niektórych symulacjach zróżnicowanie wartości istotności nie stanowią o wpływie algorytmu treningu, a związane są z analizowanymi powyżej błędami  $BPI_{MAX}$  i  $BPI_{AV}$ .

### 6.3.2. Integracja danych wyselekcjonowanych z zastosowaniem metod bazujących na macierzy rozproszenia i metody SR+AG

Przystępując do dyskusji wyników integracji danych wyselekcjonowanych z zastosowaniem metod bazujących na macierzy rozproszenia przypomina się, że w metodach SM+SFS i SM+AG dokonywany jest wybór podzbiorów danych umożliwiających uzyskanie maksymalnych wartości śladu macierzy rozproszenia  $J_{SM}$ . Metody różnią się natomiast sposobem wyboru podzbiorów danych, tj. stosowany jest algorytm przeszukiwania w przód



Rys. 6.15. Ślad macierzy rozproszenia  $J_{SM}$  podzbiorów danych wybranych z zastosowaniem metod SM+SFS i SM+AG

Fig. 6.15. Scatter matrix trace  $J_{SM}$  determined for the data sub-sets selected with the SM+SFS and SM+AG methods

(SFS) lub algorytm genetyczny (AG). Wybrane wartości śladu macierzy rozproszenia przedstawiono na rys. 6.15. Jak można zauważyć, zastosowanie algorytmu genetycznego (AG) pozwoliło na uzyskiwanie wyższych wartości  $J_{SM}$ , co, jak zakładano, umożliwi uzyskiwanie wyższych sprawności klasyfikacji. Porównując sprawności sieci FFBP z rys. 6.16 w świetle wartości śladu macierzy rozproszenia z rys. 6.15, dochodzi się do nieco zaskakujących wniosków. Pomimo wyższych wartości  $J_{SM}$ , odpowiednie podzbiory wejść nie pozwalały na uzyskiwanie wyższych sprawności sieci FFBP. Przykładowo, dokonując selekcji metodą SM+AG, uzyskanie sprawności klasyfikacji rzędu 90% możliwe było jedynie z zastosowaniem podzbioru 7 danych. Kontynuując, wydaje się, iż wbrew założeniom przyjętym w pracy pozytywnie należy ocenić wybór kolejnych podzbiorów danych z zastosowaniem algorytmu SFS, tzn. wybór najistotniejszego wejścia i zapewnienie „obecności” tego wejścia w kolejnych podzbiórach. Zaznacza się jednak, że analizowane w tym miejscu zagadnienie może mieć związek z sygnalizowanym kilkakrotnie w pracy wpływem charakteru rozwiązywanego zadania, a powyższe konkluzje wymagają potwierdzenia w kolejnych testach.


Na rys. 6.16 przedstawiono także wyniki uzyskane z zastosowaniem metody SR+AG. Zgodnie z wymogami tej metody selekcję przeprowadzono z zastosowaniem zbioru weryfikującego, do którego wybrano losowo 20% wektorów uczących. Kolejne podzbiory wejść uzyskiwano zwiększając wartości współczynnika kary  $UP_w$ . Komentarze dotyczące sprawności klasyfikacji ogranicza się w tym miejscu do stwierdzenia o uzyskaniu niezadowolających wyników. Szczególnie niezadowolająca jest sprawność rzędu 83%, uzyskana w przypadku relatywnie liczego podzbioru 7 wejść. W formie uzupełnienia zwraca się natomiast uwagę na podzbiór 11 wejść ( $UP_w=0.005$ , rys. 6.16) i uzyskaną sprawność  $S_{FFBP}=90.2\%$ . Podzbiór ten zawiera między innymi wejścia B-3, B-4, E-1 i M, które pozwalają, zgodnie z wynikami z rys. 6.9, na uzyskiwanie sprawności klasyfikacji rzędu 95%. Przypadek ten ponownie potwierdza negatywny wpływ wejść o niższych istotnościach skomentowany w podrozdziale 6.3.1.

		MS( SM+SFS )																									
Struktura sieci FFBP		Reprezentacja elementów wektora wejściowego																Sprawność sieci FFBP									
4-7-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	79.5%
		A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	
5-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	89.5%
		A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	
6-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	88.7%
		A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	
7-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	92.2%
		A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	
		MS( SM+AG )																									
5-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	79.2%
		A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	
6-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	79.5%
		A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	
7-5-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	90.2%
		A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	

		MS( SR+AG )																										
Wsp. kary $UP_w$	Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego																Sprawność sieci FFBP										
0.005	11-7-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	90.2%
			A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	
0.007	7-6-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	82.7%
			A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	
0.010	5-7-3	f	A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	82.0%
			A-1	A-2	A-3	A-4	B-1	B-2	B-3	B-4	C-1	C-2	C-3	C-4	D-1	D-2	D-3	D-4	E-1	E-2	E-3	E-4	F-1	F-2	F-3	F-4	M	

Rys. 6.16. Zestawienie wyników integracji danych wyselekcjonowanych metodami bazującymi na macierzy rozproszenia oraz z zastosowaniem metody SR+AG

Fig. 6.16. Results obtained while integrating data selected with the scatter matrix based methods and the SR+AG method



Rys. 6.17. Uzyskane sprawności klasyfikacji sieci neuronowej FFBP w funkcji liczby wejść  
 Fig. 6.17. The obtained FFBP neural network classification performance against input number

### 6.3.3. Podsumowanie

Podsumowując przeprowadzone testy zestawiono uzyskane sprawności klasyfikacji w funkcji liczby wejść (rys. 6.17). Analizowany przedział liczby wejść dobrano tak, aby uwypuklić zróżnicowanie wyników i ułatwić dokonanie wstępnej oceny testowanych metod selekcji danych. Zaznacza się, że na rys. 6.17 nie uwzględniono przypadków arbitralnego wyboru podzbiorów wejść. W celu porównania przedstawiono natomiast wyniki integracji danych wyselekcjonowanych z zastosowaniem analizy korelacji rangowej  $\tau$ -Kendalla.

Już bardzo ogólna analiza sprawności klasyfikacji z rys. 6.17 umożliwia wskazanie metod selekcji danych, których zastosowanie pozwoliło na uzyskiwanie w pełni zadowalających wyników. Jednoznacznie wskazać można na metody pruningu wag i sumy wag jako metody umożliwiające zdecydowane zmniejszenie liczby danych z jednoczesnym zachowaniem sprawności klasyfikacji na poziomie nie niższym niż 95%. W tym miejscu należy przypomnieć, że wprowadzając do sieci FFBP 26 danych uzyskano sprawność  $S_{FFBP}=94.2\%$  (rys. 6.2). Następnie, uzasadnione jest, aby wyraźnie uwypuklić wyniki uzyskane

z zastosowaniem metody pruningu wag. W świetle przeprowadzonych analiz oraz zestawienia sprawności z rys. 6.17 uznaje się metodę pruningu wag za metodę pozwalającą na uzyskiwanie najkorzystniejszych wyników i pomija się tę metodę w prowadzonej poniżej dyskusji.

Drugą grupę metod umożliwiających uzyskiwanie niższych, jakkolwiek powyżej 90%, sprawności klasyfikacji stanowią metoda A-Karina oraz metoda SM+SFS. Uwzględnienie w tym miejscu metody A-Karina wymaga jednakże szerszego komentarza. Odwołując się do poprzednich podrozdziałów przypomina się, że metoda A-Karina nie pozwalała na uzyskiwanie akceptowalnej powtarzalności wyznaczania istotności danych. Wskazuje się także na zależność wyznaczanych istotności od algorytmu treningu sieci FFBP (rys. 6.14). Dlatego też dyskusja tej metody prowadzona jest jedynie w świetle podsumowania przeprowadzonych testów, a wyniki selekcji danych zrealizowanej z zastosowaniem metody A-Karina nie są praktycznie stosowane w kolejnych podrozdziałach oraz metoda ta nie jest oceniana w podsumowaniu rozdziału.

Kontynuując, powyższa próba oceny metod selekcji nie uwzględnia liczby wejść, co interpretować można jako akceptację dowolnej liczby wejść z analizowanego przedziału i skoncentrowanie się jedynie na sprawności klasyfikacji. Oceny metod selekcji można również dokonać przyjmując pożądaną liczbę wejść i porządkując metody według wzrastającej sprawności. Przykładowo, przyjmując 5 wejść, wskazuje się na metodę SM+SFS i metodę sumy wag. Natomiast przyjmując za dopuszczalne zastosowanie 6 wejść, za najkorzystniejszą należy uznać selekcję z zastosowaniem, kolejno, metody sumy wag, metody A-Karina i metody SM+SFS. Odmiernym podejściem jest przyjęcie zadowalającej wartości sprawności klasyfikacji i ocena metod selekcji zgodnie z kryterium minimalnej liczby wejść. Przyjmując za zadowalającą sprawność  $S_{FFBP}>90\%$ , najwyżej ocenia się metodę sumy wag i metodę A-Karina pozwalające na uzyskanie tego poziomu sprawności klasyfikacji z zastosowaniem 6 wejść. W przypadku metody SM+SFS wymagane jest natomiast 7 wejść.

Uogólniając komentarze zaznacza się, że przeprowadzona dyskusja odzwierciedlać może praktyczne podejście Użytkownika do uzyskanych wyników. Użytkownik dążyć może do wyboru dogodnej konfiguracji torów pomiarowych, pozwalającej na uzyskiwanie możliwie najwyższych sprawności klasyfikacji. Przez dogodną konfigurację torów pomiarowych rozumie się przykładowo konfigurację spełniającą oczekiwania ekonomiczne Użytkownika lub torów, w których stosowane są czujniki łatwe w montażu na danej maszynie. W tym świetle za jak najbardziej korzystne należy uznać uzyskiwanie zróżnicowanych rozwiązań, tzn. możliwość wyboru zbliżonych pod względem liczności podzbiorów zróżnicowanych danych, pozwalających na uzyskiwanie zbliżonych sprawności klasyfikacji. Zróżnicowanie danych oraz relatywnie mała liczność podzbiorów dogodne są także dla prób arbitralnego wyboru danych. Reprezentatywnym przykładem takiego podejścia Użytkownika jest arbitralny wybór danych przedstawiony na rys. 6.9 (sieć neuronowa FFBP o strukturze 4-5-3(A)).

Ingerencję Użytkownika zorientowaną na wybór alternatywnego podzbioru danych uzasadnić można zasygnalizowanym we wprowadzeniu ogólnym celem badań, których częścią była przedmiotem analiz w niniejszym rozdziale. Odwołując się do [Sokołowski et al., 1994], zwraca się uwagę na badania dotyczące katastroficznego zużycia (złamań) wiertel. Zasadniczym wynikiem tych badań był wybór czujnika emisji akustycznej do diagnostyki zużycia katastroficznego narzędzi. Stąd też próba wyboru cechy sygnału pomiarowego z czujnika emisji akustycznej (wejście E-1) miała na celu określenie minimalnej liczby czujników umożliwiających zaprojektowanie układu diagnozującego nie tylko zużycie naturalne, ale również zużycie katastroficzne wiertel.

#### 6.4. Zastosowanie systemu logiki rozmytej do integracji danych

Dokonując analizy wyników uzyskanych z zastosowaniem systemu logiki rozmytej konieczne jest skomentowanie specyficznych problemów ujawnionych podczas prób konstruowania systemu FL. W tym celu na rys. 6.18 przedstawiono wybrane wielkości charakteryzujące poszczególne etapy konstruowania systemu. Przedstawiono wartości błędu  $E_{RMS}$ , sprawności systemu wyznaczane w zbiorze testującym ( $S_{FL}$ ) oraz liczby funkcji przynależności przyporządkowanych poszczególnym wejściom, np.  $MF_{WE} : 3-3-3-2$  (rys. 6.18a) oznacza, że każdemu z trzech pierwszych wejść przyporządkowano 3 funkcje przynależności, a wejściu czwartemu przyporządkowano 2 funkcje przynależności. Przedstawiono także początkowe liczby reguł oraz liczby reguł uzyskiwane po zastosowaniu danej metody konstruowania bazy reguł (MKBR) i operacji łączenia reguł (końcowe liczby reguł). Symulacje przeprowadzono z zastosowaniem podzbioru 4 danych wyselekcjonowanych metodą pruningu wag (zob. sieć neuronowa FFBP o strukturze 4-5-3, rys. 6.9).

Zasadniczy problem wpływający na tok przeprowadzonych badań wyraża się brakiem możliwości realizacji treningu systemu FL do założonych wartości błędów  $E_{MAX}=0.10$  lub  $E_{MAX}=0.15$ . Zaznaczyć należy, że nie tylko nie osiągnięto założonych wartości błędów treningu, ale również w zdecydowanej większości symulacji nie uzyskiwano 100% sprawności treningu. Stąd też już w tym miejscu potwierdzić można (zob. rozdział 5), że system FL charakteryzuje się mniejszą zdolnością uczenia w porównaniu z siecią neuronową FFBP.

Prowadząc badania zdecydowano się realizować trening systemu FL z zastosowaniem algorytmu BP do uzyskania możliwie najniższej wartości błędu  $E_{RMS}$ . Trening przerywano, gdy nie obserwowano wyraźnych zmian (zmniejszania) błędu  $E_{RMS}$  lub następowała destabilizacja treningu przejawiająca się szybkimi zmianami (zazwyczaj wzrostem) wartości błędu  $E_{RMS}$  lub  $E_{MAX}$ . Natomiast trening uznawano za poprawnie zakończony w przypadku uzyskania sprawności treningu nie niższej niż 95%. Oznacza to, że w fazie treningu systemu FL za dopuszczalne uznano występowanie 4 błędów klasyfikacji. W pozostałych przypadkach stwierdzano brak możliwości skonstruowania systemu.

a)						b)					
$MF_{WE} : 3-3-3-2$ ; początkowa liczba reguł : 54						$MF_{WE} : 4-4-4-2$ ; początkowa liczba reguł : 128					
Etap I				Etap II		Etap I				Etap II	
MKBR	Końcowa licz.reguł	$E_{RMS}$	$S_{FL}$	$E_{RMS}$	$S_{FL}$	MKBR	Końcowa licz.reguł	$E_{RMS}$	$S_{FL}$	$E_{RMS}$	$S_{FL}$
WTA(0.0)	25	0.199	70.0%	0.085	91.2%	WTA(0.0)	54	0.217	57.5%	0.078	87.5%
WTA(0.1)	18	0.192	70.0%	0.091	---	WTA(0.1)	27	0.219	57.5%	0.076	---
AG	23	0.170	81.2%	0.083	92.5%	AG	55	0.122	82.5%	0.053	85.0%
AG-H1	21	0.170	81.2%	0.085	92.5%	AG-H1	42	0.120	86.2%	0.057	86.2%
AG-H2	19	0.170	81.2%	0.085	92.5%	AG-H2	19	0.121	82.5%	0.063	90.0%

c)					
$MF_{WE} : 4-5-4-2$ ; początkowa liczba reguł : 160					
Etap I				Etap II	
MKBR	Końcowa licz.reguł	$E_{RMS}$	$S_{FL}$	$E_{RMS}$	$S_{FL}$
WTA(0.0)	65	0.158	71.2%	0.065	82.5%
WTA(0.1)	30	0.162	71.2%	0.065	86.2%
AG	78	0.106	76.2%	0.060	80.0%
AG-H1	46	0.098	80.0%	0.055	85.0%
AG-H2	17	0.105	77.5%	0.059	83.7%

Rys. 6.18. Wybrane wielkości charakteryzujące etapy konstruowania systemu FL; liczba  $MF_{WE}$  ustalona arbitralnie (a) i (b) oraz wyznaczona z zastosowaniem metody KFM (c)

Fig. 6.18. Selected quantities characterising the phases of fuzzy logic system design; arbitrary decided number of  $MF_{WE}$  (a), (b) and  $MF_{WE}$  number determined with the KFM method (c)

W pierwszym kroku dyskusji wyników przedstawionych na rys. 6.18 zwraca się uwagę na zdecydowanie negatywną zależność uzyskiwanej sprawności systemu FL od liczby wejściowych funkcji przynależności, a tym samym od początkowej liczby reguł. Zwiększając liczbę funkcji przynależności  $MF_{WE}$  (rys. 6.18a, b, c) zauważa się, że nawet w przypadkach wyznaczenia zbliżonej końcowej liczby reguł występowało wyraźne zmniejszenie zdolności generalizacji systemu FL. Najbardziej niekorzystnie należy ocenić metodę KFM inicjalizacji funkcji przynależności. Zwykle metoda ta wskazywała na relatywnie dużą liczbę  $MF_{WE}$ , co w konsekwencji powodowało obniżenie sprawności systemu FL.

W świetle powyższych uwag zdecydowano się przypisywać wstępnie każdemu z wejść dwie funkcje przynależności ( $MF_{WE}$ ) i zwiększać liczbę  $MF_{WE}$  w przypadkach, gdy niemożliwa była realizacja treningu systemu FL z zastosowaniem algorytmu BP. Przyjęto, aby liczby funkcji przynależności ograniczać do nie większych od tych, które wyznaczano z zastosowaniem metody KFM. Zaznacza się, że w niektórych przypadkach ustalano liczbę  $MF_{WE}$  zgodnie z liczbą wartości, jakie przyjmowało dane wejście, np. wejściu M, reprezentującemu gatunek materiału obrabianego, przypisywano w każdej symulacji dwie  $MF_{WE}$ , ponieważ wejście to przyjmowało jedynie dwie wartości. Podkreśla się, że zwiększanie

liczby wejściowych funkcji przynależności nie może być realizowane bezkrytycznie. Problematiczna jest w tym przypadku początkowa liczba reguł systemu logiki rozmytej, odniesiona do liczby wektorów trenujących. Przykładowo, w przypadku 5 wejść, przypisanie dwóch MF<sub>WE</sub> każdemu z wejść prowadzi do wygenerowania 32 reguł. Zwiększenie liczby MF<sub>WE</sub> do 4 prowadzi do 1024 reguł, dla których próby określenia konkluzji reguł w oparciu o 80 wektorów trenujących wydają się być mało wiarygodne. Jak wykazały przeprowadzone testy, możliwe jest uzyskiwanie relatywnie małej, końcowej liczby reguł i zadowalającej sprawności klasyfikacji przy założeniu, że początkowa liczba reguł nie jest „zbyt wysoka” w porównaniu z liczbą wektorów trenujących. Określenia „zbyt wysoka” użyto celowo, aby zaznaczyć, że nie stwierdzono jednoznacznych zależności pomiędzy początkową liczbą reguł, liczbą wektorów trenujących oraz ogólnie rozumianą zdolnością generalizacji systemu logiki rozmytej. Dodać również należy, iż próba ograniczenia analiz do jedynie analiz systemów FL o początkowej liczbie reguł nie większej od liczby wektorów trenujących powodowałaby konieczność stwierdzenia braku możliwości konstruowania systemów FL w zdecydowanej większości testów.

Odnosząc się w kolejnym kroku do zagadnienia konstruowania bazy reguł za oczywiste należy uznać dążenie Użytkownika do wyznaczenia jak najmniejszej końcowej liczby reguł. Stąd też konstruowanie bazy reguł realizowano w dwóch fazach. W pierwszej fazie stosowano metodę WTA(0.0) lub AG-H1. Jeżeli możliwe było przeprowadzenie treningu systemu FL, w drugiej fazie podejmowano próby zastosowania metody, odpowiednio, WTA(0.1) lub AG-H2. Zauważa się, że zaniechano bezpośredniego stosowania algorytmu genetycznego (AG), co jednoznacznie uzasadniają analizy porównawcze sprawności klasyfikacji przeprowadzone w świetle liczby reguł skonstruowanych systemów FL (zob. rys. 6.18). Dodać można, iż zmniejszenie liczby reguł nie tylko nie powodowało wyraźnego zmniejszenia sprawności klasyfikacji, ale obserwowano również korzystny wzrost sprawności S<sub>FL</sub>, np. systemy konstruowane z zastosowaniem AG, AG-H1 i AG-H2, rys. 6.18b.


Na rys. 6.19 zestawiono wyniki integracji wybranych podzbiorów danych. Zaznacza się, że do testów zastosowano takie same podzbiory danych jak w przypadku integracji z zastosowaniem sieci neuronowej FFBP (podrozdział 6.3). Stąd też na rys. 6.19 nie przedstawia się reprezentacji wektorów wejściowych, a sygnalizuje się jedynie liczbę wejść. Następnie, na rys. 6.19 nie uwzględniono metody analizy wrażliwości i metody SM+AG oraz jedynie przykładowo przytoczono wyniki integracji danych wyselekcjonowanych metodą SR+AG. Bezpośrednią przyczyną pomijania w dalszej dyskusji wspomnianych metod jest wykazanie w większości testów braku możliwości konstruowania systemów FL lub uzyskiwanie zdecydowanie niższych sprawności klasyfikacji.

Liczba wejść	MS( pruning wag )					MS( suma wag )				
	MKBR	MF <sub>WE</sub>	Liczba reguł		S <sub>FL</sub>	MKBR	MF <sub>WE</sub>	Liczba reguł		S <sub>FL</sub>
			pocz.	końc.				pocz.	końc.	
7	WTA(0.0)	2-2-2-2-2-2	128	37	87.5%	WTA(0.0)	2-2-2-2-2-2	128	41	87.5%
	AG-H2	2-2-2-2-2-2	128	7	92.5%	AG-H2	2-2-2-2-2-2	128	8	82.5%
6	WTA(0.1)	3-3-3-3-3-2	486	58	93.7%	WTA(0.1)	3-3-3-3-3-2	486	62	95.0%
	AG-H2	2-2-2-2-2-2	64	11	92.5%	AG-H2	3-3-3-3-3-2	486	27	93.7%
5	WTA(0.1)	2-2-2-2-2	32	11	91.2%	WTA(0.1)	3-3-3-3-2	162	42	95.0%
	AG-H2	2-2-2-2-2	32	8	90.0%	AG-H2	2-2-2-2-2	32	8	92.5%
4	WTA(0.0)	3-3-3-2	54	25	91.2%	WTA(0.1)	4-4-4-4	256	47	75.0%
	AG-H2	3-3-3-2	54	19	92.5%	AG-H2	3-3-3-3	81	18	78.7%
×	MS( SM+SFS)					MS( SR+AG )				
7	WTA(0.0)	2-2-2-2-2-2	128	28	86.2%	WTA(+)	-----	---	---	---
	AG-H2	2-2-2-2-2-2	128	9	87.5%	AG-H+	-----	---	---	---
6	WTA(0.0)	2-2-2-2-2-2	64	16	92.5%	WTA(+)	-----	---	---	---
	AG-H2	2-2-2-2-2-2	64	8	90.0%	AG-H2	3-3-3-3-3-3	729	9	78.7%
5	WTA(0.1)	3-3-3-3-2	162	40	86.2%	WTA(+)	-----	---	---	---
	AG-H2	2-2-2-2-2	32	9	88.7%	AG-H2	3-3-3-3-3	243	10	77.5%
4	WTA(+)	-----	---	---	---	WTA(+)	-----	---	---	---
	AG-H2	4-4-4-4	256	11	81.2%	AG-H+	-----	---	---	---

Rys. 6.19. Zestawienie wybranych wyników integracji danych przeprowadzonej z zastosowaniem systemu logiki rozmytej

Fig. 6.19. The selected results of data integration performed with the fuzzy logic system

Analizując wyniki z rys. 6.19 (także z rys. 6.18) przeprowadzić można ogólne porównanie metod konstruowania baz reguł. Za najistotniejsze uznaje się w tym przypadku uzyskiwanie korzystnie mniejszej liczby reguł z zastosowaniem metod hybrydowych AG-H1 i AG-H2, bazujących na algorytmie genetycznym. Jak można zauważyć, zastosowanie metody AG+H2 pozwalało w wielu symulacjach na konstruowanie systemów FL o kilkakrotnie mniejszej liczbie reguł w porównaniu z metodą WTA(\*) i uzyskiwanie zazwyczaj zbliżonych sprawności klasyfikacji. Uwypukla się także symulacje, w których trening systemów FL możliwy był tylko w przypadku, gdy baza reguł konstruowana była z zastosowaniem metody AG-H1 lub AG-H2 (rys. 6.19).



Rys. 6.20. Sprawności systemu logiki rozmytej uzyskane w przypadku konstruowania baz reguł z zastosowaniem metody WTA(\*) (a) oraz metody AG-H\* (b)

Fig. 6.20. Performance of the fuzzy logic system achieved in the case of designing the fuzzy rule base with the WTA(\*) method (a) and the AG-H\* method (b)

Analizując sprawności skonstruowanych systemów logiki rozmytej dogodne jest odwołać się do zestawienia przedstawionego na rys. 6.20. Ponownie uwypuklić można wyraźne zróżnicowanie sprawności klasyfikacji w zależności od metody selekcji danych. Podejmując próbę wyboru metod selekcji pozwalających na uzyskiwanie najkorzystniejszych wyników, wskazuje się metodę sumy wag ( $S_{FL}=95.0\%$ , rys. 6.20a). Równocześnie wskazuje się na metodę pruningu wag, w przypadku której uzyskiwano nieznacznie niższe sprawności klasyfikacji, jakkolwiek nie niższe niż 90%, bez względu na liczbę wejść (rys. 6.20b). Przypomina się, że stosując sieć neuronową FFBP do integracji danych uzyskiwano maksymalne sprawności rzędu 99% (rys. 6.17). Domniemywać można, iż niższa sprawność systemu FL spowodowana jest mniejszą zdolnością uczenia, odzwierciedlającą się brakiem możliwości uzyskania 100% sprawności treningu systemu. Niemniej jednak uwypuklić

należy testy, w których zastosowanie systemu logiki rozmytej było korzystniejsze. Wskazuje się w tym przypadku podzbiór 5 danych wyselekcjonowany metodą sumy wag (rys. 6.20a). Dokonując integracji danych uzyskano sprawność klasyfikacji o blisko 10% wyższą niż z zastosowaniem sieci neuronowej FFBP (rys. 6.17). Zbliżony przypadek zaobserwować można analizując wyniki integracji danych wyselekcjonowanych z zastosowaniem metody SM+SFS. Jednakże zróżnicowanie sprawności klasyfikacji jest jedynie kilkuprocentowe.


Podsumowując powyższą dyskusję zwraca się uwagę na zdecydowanie niekorzystne zjawisko obniżenia sprawności klasyfikacji wraz ze wzrostem liczby wejść, np. systemy FL konstruowane z zastosowaniem metody WTA(\*), rys. 6.20a. Wydaje się, że w przeciwieństwie do sieci neuronowej FFBP, system FL wyraźnie traci zdolność generalizacji wraz ze zwiększeniem liczby wejść. Próby wyjaśnienia występowania tego zjawiska poprzez przeprowadzenie rozszerzonych analiz nie wskazały jednoznacznie na przyczyny obniżenia sprawności. Negatywny wpływ zwiększania liczby wejść na sprawność klasyfikacji stanowić może zarówno specyficzną, niekorzystną cechę systemu logiki rozmytej, jak i związany może być z niedoskonałością zastosowanych metod konstruowania systemów FL.

### 6.5. Ocena końcowa zastosowanych metod selekcji i integracji danych

Zgodnie z przyjętym przez autora podejściem, zasadniczej oceny metod selekcji i integracji danych dokonuje się poprzez porównanie wartości sprawności zastępczych  $S_z$ , a następnie dyskutuje się uzupełniające kryteria oceny tych metod. Przystępując do wyznaczenia sprawności zastępczych zdecydowano się rozpatrywać podzbiory o licznosci od 4 do 7 danych (por. rys. 6.17 i rys. 6.20) oraz przyjęto dwie wartości progu sprawności  $S_p=85\%$  i  $S_p=90\%$ . Przyjęcie dwóch wartości progu sprawności  $S_p$  związane jest z uzyskaniem relatywnie zróżnicowanych wyników (zróżnicowanych sprawności klasyfikacji). Przyjęcie sprawności progowej  $S_p=85\%$  ma na celu umożliwienie uwzględnienia w prowadzonych analizach najmniej korzystnych z uzyskanych wyników. Natomiast zasadnicza ocena (porównanie) metod dokonywana jest w oparciu o  $S_p=90\%$ . Autor zaznacza, że przyjęcie przybliżonej wartości progu sprawności  $S_p=90\%$  odnosi się do analiz wyników integracji danych zrealizowanej z zastosowaniem sieci neuronowej FFBP. W tym przypadku praktycznie stosowany próg sprawności przyjmował wartości rzędu 91%, co, uwzględniając powtarzalność klasyfikacji, potencjalnie pozwala wybrać tylko te rozwiązania, które w jak największym stopniu zapewniają uzyskiwanie sprawności nie niższych niż 90%.

Dokonując porównania metod selekcji danych pominięto metodę A-Karina zgodnie z uwagami z podrozdziału 6.3.3. Dodać można, że uwzględnienie metody A-Karina prowadziłoby do wyznaczenia relatywnie wysokich sprawności zastępczych, zbliżonych do sprawności charakteryzujących metodę SM+SFS i metodę sumy wag (zob. rys. 6.21).





Rys. 6.21. Uporządkowanie metod selekcji danych według wzrastającej wartości sprawności zastępczej  $S_z$ , wyznaczonej z zastosowaniem progu sprawności  $S_p=85\%$  (a) i  $S_p \approx 90\%$  (b)

Fig. 6.21. The order of the data selection methods following increasing substitute performance values  $S_z$  determined with use of the performance threshold  $S_p=85\%$  (a) and  $S_p \approx 90\%$  (b)

Na rys. 6.21 przedstawiono uporządkowanie metod selekcji według wzrastających wartości sprawności zastępczej, wyznaczonej w przypadku integracji danych z zastosowaniem sieci neuronowej FFBP. W zbliżony sposób uporządkować można metody selekcji bazując na sprawnościach systemu logiki rozmytej. Występujące zróżnicowanie uporządkowania nie wpływa, jak uznano, na ocenę rozpatrywanych metod. Przedstawione na rys. 6.21 uporządkowanie oraz wartości sprawności zastępczej odzwierciedlają ogólnie rozumiane oceny przyznane metodom selekcji danych. Odwołując się do przyjętego w pierwszej części niniejszego podrozdziału podejścia, zdecydowanie dominujące w świetle uzyskanych wyników metody pruningu wag, sumy wag oraz SM+SFS oceniane są zgodnie z rys. 6.21b, a pozostałe metody zgodnie z rys. 6.21a.

W kolejnym kroku porównano zastosowane metody integracji danych. Koncentrując się na sprawnościach zastępczych wyznaczanych z zastosowaniem progu  $S_p \approx 90\%$  (rys. 6.21b), potwierdza się w niniejszych badaniach możliwość uznania systemu logiki rozmytej za alternatywną w stosunku do sieci neuronowej FFBP metodę integracji. Wskazać należy na wyższe sprawności zastępcze systemu FL, wyznaczone w przypadku integracji danych wyselekcjonowanych z zastosowaniem metody sumy wag i SM+SFS (zob. podrozdział 6.4). Uwypukla się szczególnie przypadek metody sumy wag, ponieważ podejmując niniejsze badania autor zakładał, że najkorzystniejszą, naturalną konsekwencją selekcji danych metodą bazującą na sieci neuronowej FFBP jest zastosowanie sieci FFBP do integracji danych, jak to ma miejsce w przypadku metody pruningu wag. Kontynuując, zasadne jest jednakże podkreślenie wpływu analizowanego przedziału liczby danych na jednoznacznie korzystną ocenę systemu logiki rozmytej. Przypomina się w tym miejscu dyskutowany w podrozdziale 6.4 problem utraty zdolności generalizacji, ujawniający się w przypadku systemów FL o dużej liczbie wejść. Problematiczne jest także konstruowanie systemów FL z zastosowaniem danych, których wybór nie można uznać za w pełni poprawny. Uogólniając, wnioskuje się, iż w porównaniu z siecią neuronową FFBP system logiki rozmytej jest znacznie bardziej „czuły” na zarówno jakość, jak i ilość wprowadzanych informacji.

Podsumowując ocenę bazującą na wyznaczonych sprawnościach zastępczych autor stwierdza, że najwyższe sprawności klasyfikacji zużycia wiertel podczas wiercenia wielowrzecionowego uzyskać można dokonując wyboru istotnych danych metodą pruningu wag i realizując integrację danych z zastosowaniem sieci neuronowej FFBP. Akceptowalnie niższe sprawności klasyfikacji uzyskać można stosując do integracji wspomnianych danych system logiki rozmytej konstruowany z wykorzystaniem hybrydowej metody AG-H2.

Kontynuację niniejszych rozważań stanowi dyskusja uzupełniających kryteriów oceny metod selekcji i integracji danych (tab. 6.4 i tab. 6.5). Mając na uwadze opisy i wnioski przytaczane w poprzednich podrozdziałach przyjęto, że zestawienia z tab. 6.4 i tab. 6.5 nie wymagają rozbudowanych komentarzy. Stąd też dyskusję ogranicza się do wybranych zagadnień, głównie tych, które nie były dotychczas analizowane.

Komentując zestawienie z tab. 6.4, w pierwszym kroku zwraca się uwagę na kryterium kosztów obliczeniowych. W przypadku metod bazujących na sieci neuronowej FFBP, 5-krotne powtórzenie treningu sieci 26-6-3 wymagało czasu rzędu 2-3 minut. Następnie zbliżony czas wymagany był do przeprowadzenia pruningu wag. Uznano, że tak znikome czasy treningu upoważniają do takiej samej oceny metod sumy wag i analizy wrażliwości jak metody SM+SFS. Natomiast w przypadku metody pruningu wag obniżono punktację wyrażającą stopień spełnienia rozważanego w tym miejscu kryterium. Zdecydowanie najdłuższy czas wymagany był do dokonania oceny istotności danych metodami SM+AG i SR+AG. Zaznacza się, że czas trwania pojedynczej symulacji algorytmu genetycznego był relatywnie niewielki,

Zestawienie uzupełniających kryteriów oceny metod selekcji danych

Tabela 6.4

Kryteria		Metody selekcji danych						
		MS(pruning wag)	MS(suma wag)	MS(met. A-Karlina)	MS(anal. wrażliwości)	MS(SM+SFS)	MS(SM+AG)	MS(SR+AG)
1	duża powtarzalność wyznaczania istotności	0	0	-	0	2	1	1
2	możliwość nie tylko jakościowej ale również ilościowej oceny istotności danych	2	2	-	2	0	0	0
3	możliwość wskazania parametru metody selekcji pozwalającego na wybór quasi-optimalnego podzbioru danych	2	2	-	1	0	0	0
4	niski koszt obliczeniowy metody	1	2	-	2	2	0	0
Suma (max. 8 pkt) :		5	6	-	5	4	1	1

Tabela 6.5

Uzupełniające porównanie sieci neuronowej FFBP i systemu logiki rozmytej

Kryteria		Sieć neuronowa FFBP	System logiki rozmytej
1	niski koszt obliczeniowy w fazie konstruowania	+	+ / -
2	duża powtarzalność wartości parametrów	+ / -	+ / -
3	łatwość odzyskiwania wiedzy	-	+
4	mała złożoność procesu konstruowania	+	-
5	duża zdolność uczenia	+	-
6	duża zdolność generalizacji wiedzy	+	-

tj. 0.5+1.5 minuty, w zależności od liczby danych. Krytyczne było natomiast wielokrotne powtarzanie symulacji AG, wynikające z konieczności niezależnego wyboru podzbiorów danych o zadanej liczbie wejść (SM+AG) lub żmudnego poszukiwania wartości  $UP_w$ , umożliwiających wybór kolejnych podzbiorów danych (SR+AG).

Analizując pozostałe kryteria uznano powtarzalność metod selekcji bazujących na sieci FFBP za najniższą spośród analizowanych. Następnie, nie wykazano możliwości wyboru quasi-optimalnego podzbioru danych poprzez analizę wartości śladu macierzy rozproszenia  $J_{SM}$  i współczynnika kary  $UP_w$ . Oznacza to, że wartości  $J_{SM}$  i  $UP_w$  nie odzwierciedlały wyraźnych zmian sprawności klasyfikacji (zob. rys. 6.15 i rys. 6.16). Potwierdzono natomiast możliwość zastosowania progu istotności  $ID_p \cong 50\%$  do wyboru quasi-optimalnych podzbiorów danych w przypadku metody sumy wag i pruningu wag, tj. stosując  $ID_p \cong 50\%$  uzyskiwano podzbiory 6+7 wejść i sprawności powyżej 95%. Dodaje się, iż możliwe było

zwiększenie wartości progu w odniesieniu do metody pruningu wag ( $ID_p \cong 60\%+70\%$ ). W przypadku metody analizy wrażliwości uzyskanie sprawności powyżej 90% wymagało obniżenia wartości progu ( $ID_p \cong 40\%$ ), co też spowodowało obniżenie oceny stopnia spełnienia rozważanego kryterium.

Porównanie sieci neuronowej FFBP i systemu logiki rozmytej w świetle uzupełniających kryteriów oceny metod integracji danych przedstawiono w tab. 6.5. Dokonując wybiórczych komentarzy zwraca się uwagę na kryterium *powtarzalności wyznaczania parametrów* i kryterium *kosztów obliczeniowych*. W pierwszym przypadku wykazano, że konstruowanie zarówno sieci neuronowej FFBP, jak i systemu logiki rozmytej charakteryzuje się zbliżoną, jakkolwiek nie zawsze w pełni zadowalającą powtarzalnością. Wskazuje się na przypadki występowania zróżnicowania uzyskiwanych sprawności klasyfikacji o więcej niż 3 błędy klasyfikacji. Zaznacza się jednakże, że wspomniane zróżnicowanie występowało głównie w symulacjach sieci neuronowej FFBP, w których uzyskiwano niskie sprawności klasyfikacji oraz w symulacjach systemu FL, w których nie uzyskiwano zbliżonych wartości  $E_{RMS}$  w fazie konstruowania bazy reguł z zastosowaniem metod hybrydowych AG-H\*.

Porównanie sieci neuronowej i systemu logiki rozmytej w świetle kryterium kosztów obliczeniowych jest zdecydowanie utrudnione ze względu na znaczny wpływ liczby wejść, liczby reguł i metod konstruowania bazy reguł systemu FL. Porównując czas konstruowania sieci FFBP i systemu FL o 5 wejściach nie dostrzega się wyraźnego zróżnicowania (wymagany był czas rzędu 10+15 minut). Natomiast zwiększenie liczby wejść, a szczególnie zwiększenie początkowej liczby reguł, powodowało zdecydowany wzrost czasu koniecznego do skonstruowania systemu logiki rozmytej. Wskazuje się w tym przypadku na szczególnie długotrwałe symulacje algorytmu genetycznego (czas rzędu godzin). Długotrwały był także trening z zastosowaniem algorytmu BP w przypadku konstruowania bazy reguł z zastosowaniem metody WTA(\*) i zazwyczaj dużej liczby reguł.

Podejmując ostatecznie próbę skojarzenia ocen metod selekcji i integracji danych w świetle wyznaczonych sprawności zastępczych oraz kryteriów uzupełniających zauważa się zbieżność ocen w przypadku metod integracji. Uznanie sieci neuronowej FFBP za metodę korzystniejszą znajduje swoje odzwierciedlenie w ocenie bazującej na kryteriach uzupełniających. Szczególnie uwypukla się większą zdolność uczenia i generalizacji, a także niższy koszt obliczeniowy. Natomiast próba uogólnienia oceny metod selekcji wydaje się być znacznie bardziej kłopotliwa. Analizując sumaryczną punktację z tab. 6.4, wskazać można na zbieżność ocen metod charakteryzujących się niskimi wartościami sprawności zastępczej. Pominąć jednakże należy metodę analizy wrażliwości, której ocena z tab. 6.4 wskazywać może na atrakcyjność tej metody. W przypadku pozostałych metod występuje małe zróżnicowanie sumarycznej punktacji z tab. 6.4, co nie w pełni odpowiada jednoznacznej ocenie bazującej na sprawności zastępczej.

## 7. DIAGNOSTYKA PRZEDMIOTU OBRABIANEGO – PROBLEM ZADZIORÓW POOBRÓBKOWYCH

### 7.1. Wprowadzenie


W formie wprowadzenia do niniejszego rozdziału dokonuje się wybiórczej charakterystyki zjawiska tworzenia się zadziorów poobróbkowych, co pozwala na uwypuklenie istotności tego zagadnienia w świetle ogólnie rozumianej obróbki skrawaniem, a zarazem umożliwia wskazanie na specyfikę i oryginalność przeprowadzonych przez autora badań. Zadziór poobróbkowy jest ciałem o małej, w porównaniu z przedmiotem obrabianym, objętości, powstającym w chwili wejścia lub wyjścia narzędzia z materiału obrabianego (rys. 7.1). Zadziory mogą wraz z wiórami powodować duże trudności w automatyzacji procesów obróbki skrawaniem. Mogą stwarzać problemy podczas montażu pasowanych części, jak również w czasie użytkowania wyrobu [Dornfeld, 1992] [Stein et al., 1993]. Ponieważ tworzenie się zadziorów poobróbkowych jest nierozłącznie związane z procesem skrawania, podejmowane są szeroko zakrojone badania (np. [CODEF]) zorientowane na zredukowanie negatywnego wpływu tego zjawiska na jakość przedmiotu obrabianego. Zasadniczym celem badań jest wskazanie sposobów minimalizacji wybranych wielkości charakteryzujących zadziory [Narayanawami i Sokołowski, 1994], [Stein i Dornfeld, 1997].

Minimalizację wielkości zadziorów uzyskać można poprzez oddziaływanie na proces skrawania lub odpowiednie projektowanie części maszyn i planowanie procesów technologicznych [Narayanawami i Dornfeld, 1994]. Powyższe podejścia wymagają znajomości mechanizmów tworzenia się zadziorów, tzn. konieczna jest, między innymi, znajomość wiarygodnych modeli opisujących zjawisko tworzenia się zadziorów. Dyskutowane w literaturze próby modelowania bazują zazwyczaj na zweryfikowanym przy użyciu mikroskopu skaningowego (np. [Chern, 1993]) założeniu o powstawaniu zadziorów w wyniku



Rys. 7.1. Przykładowe postaci zadziorów tworzących się w procesie wiercenia; zadziór równomierny (a) i koronowy (b) [Min et al., 2001]

Fig. 7.1. Examples of drilling burr shapes; uniform (a) and crown (b) burrs [Min et al., 2001]



Rys. 7.2. Tworzenie się zadzioru w wyniku zginania (a) i w wyniku ścinania (b)

Fig. 7.2. Burr formation due to bending (a) and shearing (b)

zginania lub ścinania (rys. 7.2). W pierwszym przypadku tworzenie się zadziorów jest inicjowane powstaniem pęknięcia w tzw. ujemnej płaszczyźnie ścinania, reprezentowanej na rys. 7.2a przez odcinek A-B. W drugim przypadku występuje poślizg w ujemnej płaszczyźnie ścinania i tworzenie się tzw. zadziorów wtórnych (rys. 7.2b). Pierwsze dyskutowane w literaturze modele stanowiły modele analityczne, wyznaczone w odniesieniu do skrawania ortogonalnego (np. [Gillespie i Blotter, 1976]). Obecnie analizy tworzenia się zadziorów poobróbkowych prowadzone są najczęściej z zastosowaniem Metody Elementów Skończonych, np. [Ueda i Manabe, 1993], [Guo i Dornfeld, 1998], [CODEF]. Wskazać można także na próby wyznaczania modeli empirycznych wybranych wielkości charakterystycznych zadziorów w funkcji parametrów obróbki, np. [Sokołowski et al., 1994a], [Kim i Dornfeld, 1999], [Kim, 2000], [Min et al., 2001].

Pomimo podejmowania zróżnicowanych podejść i sygnalizowania obiecujących wyników, nie wydaje się, aby proponowane sposoby minimalizacji wielkości zadziorów umożliwiły pominięcie stosowanej w praktyce produkcyjnej operacji usuwania zadziorów. Uznaje się, że zarówno badania z zastosowaniem Metody Elementów Skończonych, jak i wspomniane próby wyznaczania modeli empirycznych nie zapewniają uzyskania zadziorów o zadowalającej Użytkownika postaci (wielkości). Zasadniczą przyczyną jest w tym przypadku brak możliwości uwzględnienia stochastycznego charakteru procesu skrawania oraz konieczność stosowania uproszczeń wynikających z trudnego do opisu, trójwymiarowego stanu odkształceń występującego podczas skrawania. Istotna jest także zależność wielkości charakterystycznych tworzących się zadziorów od większości parametrów obróbki [Sokołowski et al., 1996].

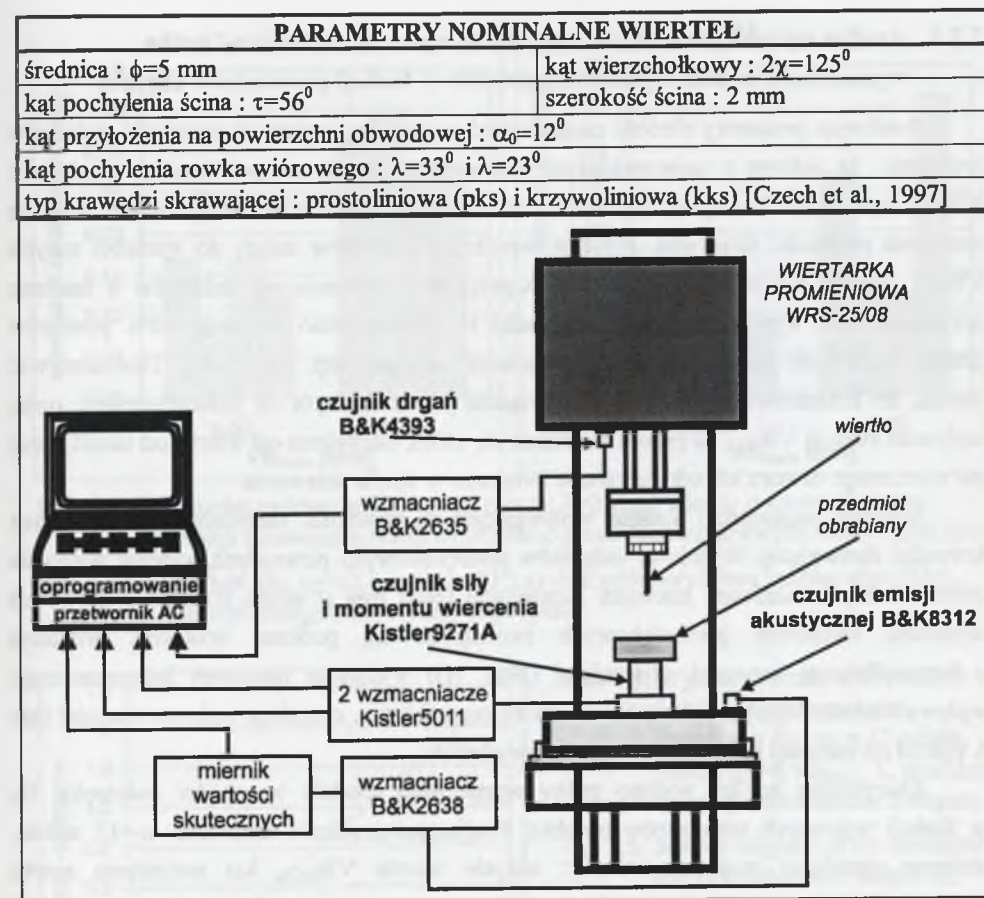
W efekcie uznania braku możliwości pominięcia operacji usuwania zadziorów zasadne staje się uwypuklenie znaczenia diagnostyki przedmiotu obrabianego. W ramach diagnostyki przedmiotu obrabianego istotne jest dokonanie identyfikacji wybranej wielkości charakterystycznej zadziorów, co potencjalnie umożliwia podjęcie decyzji zarówno

o konieczności przeprowadzeniu operacji usuwania zadziorów, jak i o sposobie przeprowadzenia tej operacji. Rozpatrując następnie hipotetyczny układ diagnostyczny, za dogodniejsze uznaje się zastosowanie pośrednich metod identyfikacji wielkości zadziorów. W konsekwencji ponownie wskazuje się na konieczność wyznaczenia modelu rozważanej wielkości charakterystycznej zadziorów, co stanowi o celu przedstawianych w niniejszym rozdziale badań. Celem nadrzędnym badań było wyznaczenie modelu wysokości zadzioru powstającego podczas wiercenia przelotowego w funkcji cechy sygnału pomiarowego i wybranych parametrów obróbki. Zaznacza się, że uszczegółowienia celu badań dokonuje się w podrozdziale 7.3. W tym miejscu istotne jest natomiast, aby podkreślić, że odmiennie w stosunku do cytowanych prac podjęto próbę uwzględnienia cechy sygnału pomiarowego jako wejścia modelu. Podejście takie stanowi, zdaniem autora, o oryginalności przeprowadzonych badań, wyrażającej się tezą o możliwości poprawy jakości rozpatrywanego modelu poprzez uwzględnienie informacji charakteryzujących *on-line* proces skrawania [Kubowicz i Sokołowski, 1997], [Sokołowski i Kosmo, 1998].

Opisy w dalszej części rozdziału rozpoczęto od charakterystyki przeprowadzonych badań eksperymentalnych. Następnie opisano przetwarzanie sygnału pomiarowego dla celów wyznaczania modeli wysokości zadziorów poobróbkowych. Jak wykazano, rozwiązanie ogólnie rozumianego zadania poszukiwania modelu wysokości zadziorów wymaga wyboru cechy sygnału pomiarowego z równoczesnym uwzględnieniem wyboru parametrów metod przetwarzania wstępnego. Wyboru tych wielkości dokonano, w pierwszym kroku, z zastosowaniem metod statystycznych. Następnie zastosowano metody selekcji bazujące na sieci neuronowej FFBP oraz metodę SR+AG. Ze względu na charakter rozwiązywanego zadania, tj. zadania aproksymacji, nie dokonywano selekcji danych z zastosowaniem metod bazujących na macierzy rozproszenia. W końcowej części rozdziału przeprowadzono dyskusję wybranych zagadnień związanych z zastosowaniem sieci neuronowej FFBP i systemu logiki rozmytej do wyznaczenia modelu wysokości zadziorów.

## 7.2. Opis badań eksperymentalnych i wstępna analiza wyników

Badania eksperymentalne przeprowadzono podczas wiercenia przelotowego na wiertarce promieniowej typu WRS-25/08 (rys. 7.3), ze stałym posuwem  $f=0.06$  mm/obr oraz prędkościami skrawania:  $v_c=10, 12$  i  $14$  m/min [Projekt Badawczy KBN, 1997]. Przedmioty obrabiane stanowiły elementy o postaci płaskownika o wymiarach  $120 \times 25 \times 25$  mm, wykonane ze stali austenitycznej 00H18N10 (X5CrNi1810 wg DIN). W badaniach zastosowano 8 wiertel krętych niepokrywanych, których wybrane parametry przedstawiono na rys. 7.3. Oprócz wielkości wskazanych na rys. 7.3, wiertła zróżnicowane były pod względem wartości zużycia  $VB_{MAX}$ , tj. zastosowano 4 wiertła fabrycznie nowe i 4 wiertła o zużyciu  $VB_{MAX}=0.51, 0.55, 0.61$  i  $0.65$  mm. Wiercenie każdym z wiertel powtarzano 4-krotnie, co uwzględniając 3 stosowane prędkości skrawania prowadziło do 96 pomiarów zrealizowanych w ramach badań.



Rys. 7.3. Schemat układu pomiarowego i wybrane parametry zastosowanych wiertel

Fig. 7.3. Schematics of the measuring set-up and selected parameters of the drills applied

Podczas badań dokonywano pomiaru posuwowej siły wiercenia, momentu wiercenia, drgań wrzeciennika wiertarki oraz emisji akustycznej na stole wiertarki (rys. 7.3). Zaznacza się jednak, że w dalszej części rozdziału analizowany jest jedynie sygnał reprezentujący posuwową siłę wiercenia, który wybrano opierając się na analizach zmian sygnałów pomiarowych występujących podczas wychodzenia wiertła z materiału obrabianego [Kubowicz i Sokołowski, 1997]. Pomiaru wysokości zadziorów dokonywano czujnikiem zegarowym w trzech miejscach na obwodzie otworu (co  $120^\circ$ ). Jako wysokość zadzioru ( $H_z$ ) analizowaną w dalszej części niniejszego rozdziału przyjęto wartość średnią z dokonanych pomiarów. Dodać należy, że w dalszej części rozdziału używa się pojęć „zmierzona wysokość zadziorów” i „obliczona wysokość zadziorów” w celu odróżnienia wartości  $H_z$  wyznaczonych w powyżej scharakteryzowanych pomiarach od wartości  $H_z$  obliczanych z zastosowaniem modeli wysokości zadziorów.


### 7.2.1. Analiza wpływu parametrów obróbki na wysokość zadziorów i próba wyznaczenia modelu wysokości zadziorów w funkcji parametrów obróbki

Analizując parametry obróbki mogące mieć potencjalny wpływ na wysokość zadziorów wykazano, że jednym z najistotniejszych jest zużycie wiertła na powierzchni przyłożenia  $VB_{MAX}$  (rys. 7.4). Następnie wykazano, że wysokość zadziorów zwiększa się wraz ze wzrostem prędkości skrawania. Przyrost wysokości zadziorów zależy do wartości zużycia  $VB_{MAX}$ . Istotne jest również wskazanie na przypadki tworzenia się zadziorów o znacznie zróżnicowanych wysokościach  $H_Z$ . Przypadki te obserwowano w około 10% pomiarów przeprowadzanych podczas wiercenia wiertłami zużytymi (np. rys. 7.4b). Domniemywać można, że zróżnicowanie wartości  $H_Z$  związane jest z trudnym do jednoznacznego opisu wpływem zużycia  $VB_{MAX}$  na proces tworzenia się wióra, odchylenie osi wiertła od teoretycznej osi wierconego otworu lub oddziaływania termiczne w strefie skrawania.

Istotnym parametrem obróbki wpływającym na wysokość zadziorów  $H_Z$  jest kształt krawędzi skrawającej. Wysokość zadziorów poobróbkowych powstałych podczas wiercenia wiertłami o prostoliniowej krawędzi skrawającej (pks) była o około 0.1 mm większa niż wysokość zadziorów poobróbkowych tworzących się podczas wiercenia wiertłami o krzywoliniowej krawędzi skrawającej (kks). Nie wykazano natomiast jednoznacznego wpływu wartości kąta pochylenia rowka wiórowego ( $\lambda$ ), tzn. charakter wpływu wartości kąta  $\lambda$  zależał od wartości pozostałych parametrów obróbki.


Kontynuując analizy podjęto próby wyznaczenia modelu wysokości zadziorów  $H_Z$  w funkcji wybranych parametrów obróbki. Przyjmując prędkość skrawania  $v_C=12$  m/min, zmienne niezależne modelu stanowiły: zużycie wiertła  $VB_{MAX}$ , kąt pochylenia rowka wiórowego ( $\lambda$ ) oraz typ krawędzi skrawającej reprezentowany przez wartości 1 i 2 odpowiednio dla prostoliniowej (pks) i krzywoliniowej (kks) krawędzi skrawającej. Wyznaczenie modelu sprowadza się do rozwiązania zadania poszukiwania modelu danych [Diagnostyka techniczna, 1997]. Stąd też w pierwszym kroku dokonano wyboru postaci modelu, a następnie przeprowadzono identyfikację parametrów modelu z zastosowaniem metody Quasi-Newtona [STATISTICA].

Jako miarę jakości wyznaczanych modeli przyjęto współczynnik korelacji  $R_M$ , określający natężenie związku ([Mańczak, 1976]) pomiędzy zmierzonymi i obliczonymi wartościami  $H_Z$ . Obliczano także mające znaczenie fizyczne (wymiar [mm]) wartości skuteczne reszt ( $WS_R$ ), tzn. wartości skuteczne różnic pomiędzy zmierzoną i obliczoną z zastosowaniem modelu wartością wysokości zadzioru. Zastąpienie klasycznie przyjmowanej wielkości kryterialnej, tj. sumy kwadratów różnic, wartościami skutecznymi reszt  $WS_R$  umożliwia porównywanie jakości modeli wyznaczanych dla różnej liczby danych.



Rys. 7.4. Wysokości zadziorów  $H_Z$ ;  $v_C=12$  m/min;  $\lambda=33^\circ$ ; a) wiertło o krzywoliniowej krawędzi skrawającej (kks), b) wiertło o prostoliniowej krawędzi skrawającej (pks)


Fig. 7.4. Burr height  $H_Z$ ;  $v_C=12$  m/min;  $\lambda=33^\circ$ ; a) drill with curvilinear cutting edge (kks), b) drill with straight-line cutting edge (pks)



Rys. 7.5. Wykres rozrzutu zmierzonych i obliczonych wysokości zadziorów  $H_Z$ ;  $v_C = 12$  m/min, model  $H_Z=f(VB_{MAX}, \lambda, pks/kks)$  opisany wielomianem 2 stopnia

Fig. 7.5. Scatter diagram of the measured and calculated burr height  $H_Z$ ;  $v_C = 12$  m/min, model  $H_Z=f(VB_{MAX}, \lambda, pks/kks)$  described with the 2 order polynomial

Przyjmując model opisany wielomianem 2 stopnia uzyskano  $WS_R=0.153$  mm oraz  $R_M=0.805$  (rys. 7.5). Dodaje się, że zwiększenie stopnia wielomianu powodowało jedynie nieznaczną poprawę jakości modelu. Następnie zaznacza się, iż uzyskane wartości  $WS_R$  i  $R_M$  nie można uznać za zadowalające, co stanowi o celowości prowadzenia dalszych badań i analiz. Natomiast przytoczenie uzyskanych wartości wielkości kryterialnych  $WS_R$  i  $R_M$  istotne jest w świetle możliwości ich porównania z wartościami charakteryzującymi modele dyskutowane w kolejnych podrozdziałach pracy.




Rys. 7.6. Schematyczne zobrazowanie wyznaczenia drogi narzędzia  $D_N$

Fig. 7.6. Schematic representation of the drill path  $D_N$  determination

### 7.3. Przetwarzanie sygnału pomiarowego dla celów wyznaczenia modeli wysokości zadziorów poobróbkowych

Zastosowanie cechy sygnału pomiarowego reprezentującego posuwową siłę wiercenia jako zmiennej niezależnej modelu wysokości zadziorów poobróbkowych wymaga, w pierwszym kroku, wyboru podrealizacji sygnału poddawanego przetwarzaniu. Wybór podrealizacji równoznaczny jest z wyborem tzw. drogi narzędzia  $D_N$ , wyznaczonej w odniesieniu do pozycji wiertła w chwili wyjścia wiertła z materiału obrabianego (rys. 7.6). Wyznaczenia analizowanych wartości  $D_N$  dokonywano bazując na wielokrotnościach przemieszczenia narzędzia następującego w czasie  $\Delta t \approx 0.25$  s. Przykładowo, w przypadku diskutowanych głównie w poniższych podrozdziałach pomiarów przeprowadzonych podczas skrawania z prędkością  $v_c = 12$  m/min, wyznaczono 9 dróg narzędzia o wartościach  $D_N = 0.57; 0.76; 1.14; 1.52; 1.90; 2.28; 2.66; 3.04; 3.23$  mm.

W kolejnym kroku dokonano wyboru metod wstępnego przetwarzania podrealizacji sygnału pomiarowego. W celu uproszczenia podrealizacji sygnału pomiarowego nazywa się sygnałami podstawowymi. Mając na uwadze relatywnie wolnozmienny charakter tworzenia się zadzioru podczas wychodzenia wiertła z materiału obrabianego, zdecydowano się zastosować wygładzanie sygnałów podstawowych metodą ruchomej średniej (rys. 7.7a). Następnie, dążąc do uwypuklenia wpływu zjawisk występujących podczas wychodzenia wiertła z materiału obrabianego, wygładzone sygnały podstawowe poddano różniczkowaniu (rys. 7.7b). W ostatniej fazie wstępnego przetwarzania sygnału pomiarowego powtórnie zastosowano wygładzanie metodą ruchomej średniej (rys. 7.7c). Szerokości okien wygładzających sygnały podstawowe ( $T_O$ ) i sygnały zróżniczkowane ( $T_R$ ) przedstawiono w tab. 7.1. Przyjęte wartości  $T_O$  i  $T_R$  wynikają bezpośrednio z zastosowanej częstotliwości próbkowania sygnałów



Rys. 7.7. Kolejne etapy przetwarzania sygnału pomiarowego reprezentującego posuwową siłę wiercenia

Fig. 7.7. Consecutive phases of the processing of measured signal representing drilling feed force


Tabela 7.1

Zestawienie wariantów wartości szerokości okien  $T_O$  i  $T_R$  zastosowanych do wygładzenia, odpowiednio, sygnału podstawowego i zróżniczkowanego

	A	B	C
D	$T_O = 0.097$ s $T_R = 0.000$ s	$T_O = 0.097$ s $T_R = 0.097$ s	$T_O = 0.097$ s $T_R = 0.195$ s
E	$T_O = 0.195$ s $T_R = 0.000$ s	$T_O = 0.195$ s $T_R = 0.097$ s	$T_O = 0.195$ s $T_R = 0.195$ s
F	$T_O = 0.389$ s $T_R = 0.000$ s	$T_O = 0.389$ s $T_R = 0.097$ s	$T_O = 0.389$ s $T_R = 0.195$ s

analogowych  $f = 513.4$  Hz ([Cholewa et al., 1988]) oraz liczb dyskretnych wartości sygnału pomiarowego, którymi również można wyrazić szerokości okien wygładzających, tj. 50, 100 i 200, co odpowiada wartościom szerokości okien wygładzających 0.097; 0.195; 0.389 s. Zaznacza się, że  $T_R = 0.0$  s w tab. 7.1 wskazuje na warianty, w których nie stosowano wygładzania sygnału zróżniczkowanego.

Po zrealizowaniu przetwarzania wstępnego dokonano ekstrakcji cech przetworzonego sygnału pomiarowego reprezentującego posuwową siłę wiercenia, wyznaczając wartości skuteczne ( $W_{RMS}$ ), wartości średnie ( $W_{WS}$ ) oraz odchylenia standardowe ( $W_{OS}$ ) (rys. 7.8).




Rys. 7.8. Schemat blokowy przetwarzania sygnału pomiarowego  
Fig. 7.8. Block diagram of the measured signal processing

Jak można zauważyć, przyjęcie 9 wariantów wartości szerokości okien wygładzających, 9 wartości drogi narzędzia  $D_N$  ( $v_c=12$  m/min) oraz 3 cech sygnału pomiarowego prowadzi do zbioru 243 wielkości wyznaczanych w przypadku każdego z przeprowadzonych pomiarów. Stąd też, stanowiące cel nadrzędny badań, wyznaczenie modelu wysokości zadziórów poobróbkowych wymaga rozwiązania dwóch zadań. W pierwszym kroku wymagany jest wybór optymalnej cechy przetworzonego sygnału pomiarowego ( $W_{RMS}$ ,  $W_{ws}$ ,  $W_{0s}$ ) (rys. 7.8). Konieczność wyboru optymalnej cechy równoznaczna jest z koniecznością wyboru (w rozpatrywanych zbiorach) optymalnej wartości drogi narzędzia  $D_N$  i optymalnych wartości parametrów metod przetwarzania wstępnego  $T_O$  i  $T_R$ . Przez wielkości optymalne rozumie się te, które umożliwiają wyznaczenie modelu wysokości zadziórów o najwyższej jakości. W kolejnym kroku rozwiązywane jest zadanie poszukiwania modelu danych, czyli dokonywany jest wybór postaci modelu oraz przeprowadzana jest identyfikacja parametrów modelu.


Podkreśla się, że w poniższych podrozdziałach skoncentrowano się na zadaniu wyboru optymalnej cechy przetworzonego sygnału pomiarowego, a tym samym wartości  $D_N$  oraz  $T_O$  i  $T_R$ . Zagadnienia związane z zadaniem poszukiwania modelu danych traktowane są natomiast jako dopełnienie prowadzonych badań.

#### 7.4. Zastosowanie metod statystycznych w zadaniu wyznaczenia modelu wysokości zadziórów

W niniejszym podrozdziale charakteryzowane są próby wyboru optymalnej cechy sygnału pomiarowego oraz wartości  $D_N$ ,  $T_O$  i  $T_R$  z wykorzystaniem konwencjonalnych metod statystycznych. Zastosowano dwa podejścia. W pierwszym przypadku podjęto próby wyboru wielkości optymalnych z zastosowaniem analizy korelacji wartości danych wejściowych i wyjściowych modelu wysokości zadziórów. W drugim przypadku rozwiązywano zadanie poszukiwania modelu danych, a wyboru wielkości optymalnych dokonano poprzez porównanie jakości wyznaczonych modeli. Analizy przeprowadzono z zastosowaniem danych uzyskanych z pomiarów zrealizowanych podczas wiercenia z prędkością skrawania  $v_c=12$  m/min. Dyskusji pomiarów przeprowadzonych podczas wiercenia z pozostałymi prędkościami skrawania dokonano w podsumowaniu podrozdziału.



Rys. 7.9. Wartości współczynnika korelacji R obliczone w przypadku analiz wartości skutecznych  $W_{RMS}$  (oznaczenia według tab. 7.1)  
Fig. 7.9. Values of correlation factor R calculated while analysing the root-mean-square  $W_{RMS}$  (denotations according to tab. 7.1)



Rys. 7.10. Wartości współczynnika korelacji R; wariant CF, tab. 7.1

Fig. 7.10. Values of the correlation factor R; the CF variant, tab. 7.1

#### 7.4.1. Zastosowanie analizy korelacji

Analizę korelacji przeprowadzono niezależnie dla każdej z rozpatrywanych cech przetworzonego sygnału pomiarowego. Wartości współczynnika korelacji R obliczone w przypadku analiz wartości skutecznej  $W_{RMS}$  przedstawiono na rys. 7.9. Przypomnieć można, że współczynnik korelacji R określa w niniejszej części badań natężenie związku pomiędzy wartościami danych wejściowych i wyjściowych, a nie jak w podrozdziale 7.2.1 natężenie związku pomiędzy wartościami zmierzonych i obliczonych wysokości zadziorów ( $R_M$ ). Analizując wyniki z rys. 7.9 łatwo jest zauważyć, że zwiększanie szerokości okna wygładzającego sygnał podstawowy jak i sygnał zróżniczkowany powoduje wzrost wartości współczynnika korelacji R (potencjalne poprawienie jakości modelu). Współczynnik korelacji osiąga najwyższą wartość  $R=0.659$  dla  $T_O=0.389$  s i  $T_R=0.195$  s, zgodnie z wariantem CF z tab. 7.1. Wskazać również należy na dominujący wpływ wygładzania sygnału zróżniczkowanego ( $T_R=0.195$  s), uwypuklający się uzyskiwaniem najwyższych wartości współczynnika korelacji bez względu na wartość  $T_O$ . Ostatecznie, bez względu na wartości  $T_O$  i  $T_R$ , za optymalną drogę narzędzia, w świetle wartości współczynnika korelacji R, uznać należy  $D_N=1.52$  mm.


Dokonując analogicznych analiz wartości średniej  $W_{ws}$  i odchylenia standardowego  $W_{os}$  potwierdzono wybór wariantu CF (tab. 7.1) jako optymalnego wariantu wartości parametrów  $T_O$  i  $T_R$ . Następnie, dążąc do wyboru optymalnej cechy sygnału pomiarowego zestawiono na rys. 7.10 wybrane wartości współczynnika korelacji R. Porównując wartości R, jednoznacznie odrzucono odchylenie standardowe  $W_{os}$  jako daną wejściową modelu wysokości zadziorów. Dodaje się, że analizując  $W_{os}$  wykazano zależność optymalnej wartości drogi narzędzia od wartości parametrów  $T_O$  i  $T_R$ . W przypadku wariantu CF (tab. 7.1) optymalną wartością jest  $D_N=0.76$  mm (rys. 7.10). Kontynuując porównanie, wskazano na wartość średnią  $W_{ws}$ , w przypadku której współczynnik korelacji osiągał największą wartość

$R=0.663$  (por.  $W_{RMS}$ ,  $R=0.659$ ). Uznano zatem, że najwyższą jakość modelu wysokości zadziorów poobróbkowych, w świetle przyjętego w niniejszym podrozdziale kryterium, uzyskać można stosując jako daną wejściową, wyznaczoną dla  $D_N=1.52$  mm, wartość średnią  $W_{ws}$  sygnału pomiarowego przetwarzanego zgodnie z wariantem CF z tab. 7.1 ( $T_O=0.389$  s i  $T_R=0.195$  s).

#### 7.4.2. Zastosowanie miar jakości modeli jako wielkości kryterialnych

Badania z zastosowaniem miary jakości modeli przeprowadzono zgodnie z wariantami przedstawionymi w tab. 7.1. Oznacza to, że w przypadku każdego z wariantów z tab. 7.1 podejmowano próbę poszukiwania modelu danych analizując niezależnie cechy sygnału pomiarowego  $W_{RMS}$ ,  $W_{ws}$ , i  $W_{os}$ , wyznaczane dla przyjętych w badaniach dróg narzędzia  $D_N$  (rys. 7.11). Następnie zestawiono wartości stosowanych miar jakości modeli ( $R_M$  i  $WS_R$ ), co umożliwiło wybór wartości drogi narzędzia ( $D_N$ ) i parametrów metod przetwarzania wstępnego sygnału pomiarowego ( $T_O$ ,  $T_R$ ) oraz wybór cechy sygnału pomiarowego. Zaznacza się, że badania ukierunkowane były na weryfikację wniosków wynikających z analiz przedstawionych w podrozdziale 7.4.1. Domniemywano, iż porównanie jakości identyfikowanych modeli wysokości zadziorów wskazać może inne niż w przypadku zastosowania analizy korelacji wielkości optymalne. Dlatego też dyskusję w niniejszym podrozdziale prowadzi się w sposób wybiórczy, koncentrując się na potwierdzeniu wyżej wspomnianych wniosków lub wykazaniu odmienności uzyskanych wyników.

W ramach badań analizowano zróżnicowane, arbitralnie dobrane postaci modeli dążąc do zminimalizowania potencjalnego wpływu postaci na uzyskiwane wyniki. Do dalszej dyskusji wybrano reprezentatywne, w uznaniu autora, postaci opisane zależnościami 7.1 ÷ 7.4.



Rys. 7.11. Modele wysokości zadziorów  $H_z=f(W_{RMS})$ ; zależność (7.1), wariant CF, tab. 7.1

Fig. 7.11. Burr height models  $H_z=f(W_{RMS})$ ; formula (7.1), the CF variant, tab. 7.1



$$H_Z = A \cdot (W_{RMS})^B \quad (7.1)$$

$$H_Z = A \cdot \exp(B \cdot W_{WS}) + C \quad (7.2)$$

$$H_Z = A \cdot (W_{OS})^B + C \quad (7.3)$$


$$H_Z = A \cdot (W_I)^4 + B \cdot (W_I)^3 + C \cdot (W_I)^2 + D \cdot (W_I) + E, \quad (7.4)$$

gdzie:  $H_Z$  - wysokość zadziorów [mm];

A, B, C, D, E - parametry modeli wyznaczane metodą Quasi-Newtona [STATISTICA];


$W_{RMS}$ ,  $W_{WS}$ ,  $W_{OS}$  - cechy przetworzonego sygnału pomiarowego, odpowiednio, wartość skuteczna, wartość średnia i odchylenie standardowe;

$W_I$  - zmienna niezależna, tj.  $W_{RMS}$ ,  $W_{WS}$  i  $W_{OS}$ .



Rys. 7.12. Wartości współczynnika korelacji  $R_M$  oraz wartości  $W_{SR}$ ; wariant CF, tab. 7.1; a) modele  $H_Z=f(W_{RMS})$ , zależność (7.1), b) modele  $H_Z=f(W_{OS})$ , zależność (7.3)

Fig. 7.12. Values of the correlation factor  $R_M$  and  $W_{SR}$  values; the CF variant, tab. 7.1; a)  $H_Z=f(W_{RMS})$  models, formula (7.1), b)  $H_Z=f(W_{OS})$  models, formula (7.3)




Rys. 7.13. Zestawienie wybranych wartości  $R_M$  i  $W_{SR}$ ; A - modele opisane zależnościami (7.1), (7.2) i (7.3), B - modele opisane zależnością (7.4);  $D_N=1.52$  mm; wariant CF, tab. 7.1

Fig. 7.13. Selected  $R_M$  and  $W_{SR}$  values; A - models described with formulas (7.1), (7.2), (7.3); B - models described with formula (7.4);  $D_N=1.52$  mm; the CF variant, tab. 7.1

Porównując jakość wyznaczonych modeli stwierdzono, że najwyższe wartości współczynnika korelacji  $R_M$  i najniższe wartości  $W_{SR}$  uzyskuje się wygładzając sygnał pomiarowy z zastosowaniem okien wygładzających o szerokości  $T_O=0.389$  s i  $T_R=0.195$  s, wybranych zgodnie z wariantem CF z tab. 7.1 (por. podrozdział 7.4.1). Analizując wartości średnie  $W_{WS}$  i wartości skuteczne  $W_{RMS}$  (np. rys. 7.12a), potwierdzono także wybór drogi narzędzia  $D_N=1.52$  mm jako wartości optymalnej.

Odmienne wyniki uzyskano porównując modele  $H_Z=f(W_{OS})$ . Zwraca się uwagę na zasadnicze zróżnicowanie charakteru zmian wartości współczynników korelacji  $R_M$  i  $R$  wraz ze zmianami wartości drogi narzędzia  $D_N$  (rys. 7.12b i rys. 7.10). Wskazuje się w ten sposób na zróżnicowanie kolejności uporządkowania wartości  $D_N$  według malejących lub rosnących wartości  $R_M$  i  $R$ . Następnie podkreślić należy zróżnicowanie wartości optymalnych dróg narzędzia  $D_N$ . W przypadku zastosowania współczynnika korelacji  $R$  jako wielkości kryterialnej (podrozdział 7.4.1) wskazano na drogę narzędzia  $D_N=0.76$  mm (rys. 7.10). Natomiast bazując na wartościach  $R_M$ , za optymalną drogę narzędzia uznaje się  $D_N=1.52$  mm. Stwierdza się zatem, iż wybór cechy sygnału z zastosowaniem miary korelacji  $R$  niekoniecznie prowadzić musi do uzyskiwania najwyższych wartości miary jakości  $R_M$  wyznaczanych modeli.

Ostateczny wybór optymalnej cechy sygnału pomiarowego umożliwia zestawienie przedstawione na rys. 7.13. Komentując niniejsze zestawienie potwierdza się mniejszą przydatność odchylenia standardowego  $W_{OS}$  jako danej wejściowej modelu wysokości zadziorów. Na zasadzie zaprzeczenia stwierdzić można, że najkorzystniejsze wyniki uzyskuje się wyznaczając wielomianowy model wysokości zadziorów  $H_Z$  w funkcji wartości średniej  $W_{WS}$  przetworzonego sygnału pomiarowego ( $R_M=0.964$  i  $W_{SR}=0.069$  mm).



Rys. 7.14. Wykres rozrzutu zmierzonych i obliczonych wartości wysokości zadziorów  $H_Z$ ;  $v_c=12$  m/min,  $D_N=1.52$  mm, wariant CF, tab. 7.1; a) model  $H_Z=f(W_{ws})$ , zależność (7.4), b) model  $H_Z=f(W_{ws}, VB_{MAX}, \lambda, pks/kks)$ , zależność (7.5)

Fig. 7.14. Scatter diagram of the measured and calculated burr height values  $H_Z$ ;  $v_c=12$  m/min,  $D_N=1.52$  mm, the CF variant, tab. 7.1; a)  $H_Z=f(W_{ws})$  model, formula (7.4), b)  $H_Z=f(W_{ws}, VB_{MAX}, \lambda, pks/kks)$  model, formula (7.5)

#### 7.4.3. Podsumowanie

Podsumowując niniejszy podrozdział dokonano porównania jakości wybranych modeli wysokości zadziorów. W pierwszym kroku odwołano się do podrozdziału 7.2.1 (rys. 7.5), gdzie przeprowadzono identyfikację modelu wysokości zadziorów w funkcji parametrów obróbki. Jakość modelu wyrażono wartościami wielkości kryterialnych  $R_M=0.805$  oraz  $WS_R=0.153$  mm. Następnie, w podrozdziale 7.4.2 wyznaczono model wysokości zadziorów w funkcji wartości średniej przetworzonego sygnału reprezentującego posuwową siłę wiercenia  $W_{ws}$  i uzyskano znacznie korzystniejsze wartości  $R_M=0.964$  i  $WS_R=0.069$  mm (zob. rys. 7.14a). Ostatecznie, wskazuje się na możliwość jednoczesnego uwzględnienia parametrów obróbki i cechy sygnału pomiarowego w modelu o arbitralnie dobranej postaci opisanej zależnością (7.5) (rys. 7.14b). W przypadku tego modelu uzyskano  $R_M=0.991$  i  $WS_R=0.034$  mm, co ewidentnie uwidacznia wyższą jakość modeli bazujących na cechach sygnału pomiarowego, a tym samym potwierdza poprawność zaproponowanego przez autora podejścia (podrozdział 7.1).

$$H_Z = f_1(W_{ws}) + f_2(VB_{MAX}, \lambda, pks/kks) \quad (7.5)$$

$$H_Z = f_1(W_{ws}) + f_2(v_c, VB_{MAX}, \lambda, pks/kks), \quad (7.6)$$

gdzie:  $f_1$  - wielomian 4 stopnia,  $f_2$  - wielomian 2 stopnia.

Tabela 7.2

Zestawienie wartości współczynnika korelacji  $R_M$  i wartości skutecznej reszt  $WS_R$

Model	$R_M$	$WS_R$ [mm]
$H_Z=f(v_c, VB_{MAX}, \lambda, pks/kks)$ , model opisany wielomianem 2 stopnia	0.789	0.149
$H_Z=f(W_{ws})$ , model opisany zależnością (7.4)	0.933	0.087
$H_Z=f(W_{ws}, v_c, VB_{MAX}, \lambda, pks/kks)$ , model opisany zależnością (7.6)	0.974	0.054

Charakteryzowane dotychczas analizy przeprowadzono z zastosowaniem danych uzyskanych z pomiarów zrealizowanych podczas wiercenia z prędkością skrawania  $v_c=12$  m/min. Analogiczne analizy przeprowadzono w przypadku skrawania z prędkościami  $v_c=10$  m/min i  $v_c=14$  m/min, co pozwoliło na wyznaczenie modelu wysokości zadziorów tworzących się podczas wiercenia z różnymi prędkościami skrawania. Obliczone wartości wielkości kryterialnych ponownie uwypukliły istotność informacji reprezentowanych przez sygnał pomiarowy rejestrowany podczas obróbki (tab. 7.2). Dodać należy, że potwierdzono także wcześniejsze wnioski odnoszące się do optymalnych wartości parametrów metod wstępnego przetwarzania sygnałów pomiarowych oraz optymalnej cechy sygnału pomiarowego. Wykazano natomiast zróżnicowanie optymalnych wartości dróg narzędzia w zależności od prędkości skrawania. Prędkościom skrawania  $v_c=10$ ; 12 i 14 m/min odpowiadały optymalne wartości drogi narzędzia  $D_N=1.27$ ; 1.52 i 2.22 mm. Zróżnicowanie optymalnych wartości drogi narzędzia wydaje się być związane z wpływem prędkości skrawania i posuwu minutowego na stan naprężeń (spiętrzenie naprężeń) w strefie skrawania.

Powyższa część podsumowania koncentrowała się na uwypukleniu zadowalających, zdaniem autora, wyników. Oprócz charakterystyki wyników konieczne jest także podjęcie dyskusji sposobu uzyskania tych wyników. Powodzenie rozwiązania zadania wyznaczenia modelu wysokości zadziorów poobróbkowych uzależnione jest od poprawności wyboru optymalnej cechy sygnału pomiarowego, a tym samym wyboru optymalnych wartości parametrów metod przetwarzania wstępnego sygnału pomiarowego i drogi narzędzia. Zastosowane w pierwszym kroku podejście opierające się na analizie korelacji (podrozdział 7.4.1) wydaje się być najprostsze, jakkolwiek nie zawsze skuteczne. Autor odwołuje się do uwag z podrozdziału 7.4.2, gdzie wyboru wielkości optymalnych dokonano z zastosowaniem miar jakości modelu jako wielkości kryterialnych. Jak wykazano, przyjęcie takich wielkości kryterialnych prowadzić może od uzyskiwania odmiennych niż w podrozdziale 7.4.1 wyników. W tym miejscu autor uznaje zastosowanie miar jakości modelu za bardziej wiarygodne ze względu na dokonywanie wyboru wielkości optymalnych bazując bezpośrednio na jakości wyznaczonego modelu a nie jedynie potencjalnych relacjach pomiędzy wejściami i wyjściami szacowanych z zastosowaniem miary korelacji R. Uznając celowość podejmowania prób rozwiązania zadania poszukiwania modelu danych należy jednakże wskazać na zakres

przeprowadzonych badań. Przykładowo, aby dokonać analiz 9 wartości drogi narzędzia  $D_N$ , 3 cech sygnału pomiarowego oraz 9 wariantów wartości parametrów  $T_O$  i  $T_R$ , należało wyznaczyć 243 modele o przyjętej postaci. Mając jednakże na uwadze brak informacji o postaci modelu i przyjmując, że testowano jedynie modele opisane zależnościami (7.1÷7.4), konieczna była identyfikacja blisko 500 modeli. Przeprowadzenie badań i analiz w takim zakresie jest zdecydowanie czasochłonne i nie może być uznane za efektywne. W tym świetle zasadne wydaje się podjęcie, charakteryzowanych w kolejnych podrozdziałach, prób zastosowania rozważanych w pracy metod selekcji danych.

## 7.5. Zastosowanie metod selekcji danych bazujących na sieci neuronowej FFBP

Jak zaznaczono w podsumowaniu poprzedniego podrozdziału, zastosowanie metod selekcji danych sprowadza się zasadniczo do próby wskazania efektywniejszego sposobu rozwiązania zadania wyboru wielkości optymalnych koniecznych do wyznaczenia modelu wysokości zadziórów poobróbkowych. Za nie mniej istotną uznaje się także możliwość przeprowadzenia testów metod selekcji w przypadku zadania o innym w porównaniu z dotychczas dyskutowanymi charakterze. Zadanie wyznaczenia modelu wysokości zadziórów jest zadaniem aproksymacji w przeciwieństwie do dyskutowanych w poprzednich rozdziałach zadań klasyfikacji. Istotne jest również, że selekcja danych prowadzona jest w niniejszym przypadku pod kątem jednoznacznego wskazania na jedną, optymalną cechę sygnału pomiarowego. Zagadnienie takie jest odmienne w stosunku do poprzednio analizowanych zadań, gdzie zadowolający Użytkownika był podzbiór istotnych danych.

Symulacje sieci FFBP zrealizowano z zastosowaniem algorytmu inkrementalnego ATS-inc i współczynnikiem uczenia  $\eta_c=0.4$ . Zaznacza się jednak, że algorytm treningu (ATS-inc lub ATS-cum) nie miał znaczącego wpływu na uzyskiwane wyniki. W warstwie ukrytej sieci FFBP stosowano 2 lub 3 komórki w zależności od liczby wejść, a tym samym od liczby parametrów sieci wyznaczanych podczas treningu. Selekcję danych metodą pruningu wag prowadzono z parametrem  $pr_w=0.25$  lub  $pr_w=0.30$ , dążąc do forsowania eliminacji wag, a tym samym jak największego zróżnicowania istotności wejść. W symulacjach zastosowano zbiór uczący, zawierający 32 wektory wejściowe reprezentujące pomiary przeprowadzone podczas wiercenia z prędkością skrawania  $v_c=12$  m/min.


Uzupełniając opisy wprowadzające do testów metod selekcji bazujących na sieci neuronowej FFBP zaznacza się, że w podrozdziale nie jest analizowana metoda A-Karina ze względu na uzyskanie zdecydowanie niezadowolających, odbiegających od poniżej charakteryzowanych wyników. Nie jest również dyskutowane zagadnienie wpływu skorelowania danych wejściowych na wyznaczone istotności wejść. Dodaje się jedynie, iż pomimo wykazania relatywnie wysokiego skorelowania par danych wejściowych wynikającego z zastosowanych metod wstępnego przetwarzania sygnału pomiarowego,

nie obserwowano efektu rozplywu istotności, np. rys. 7.15, współczynnik korelacji wartości danych odpowiadających  $D_N=1.14$  mm i  $D_N=1.52$  mm wynosił  $R=0.985$ . Wskazuje to na zależność przyjętego w rozdziale 5 poziomu wartości współczynnika korelacji ( $R \approx 0.980$ ) od charakteru rozwiązywanego zadania. Za korzystne uznać oczywiście należy zwiększenie w niniejszym przypadku wartości  $R$ , powyżej której wystąpić może efekt rozplywu istotności.

### 7.5.1. Problem wyboru wartości drogi narzędzia



Podjęcie próby wyboru wartości drogi narzędzia przyjęto wartości parametrów metod wstępnego przetwarzania sygnału pomiarowego ( $T_O$ ,  $T_R$ ) zgodnie z wariantem CF z tab. 7.1. Wyboru drogi narzędzia dokonywano niezależnie dla każdej z 3 rozpatrywanych cech przetworzonego sygnału pomiarowego  $W_{RMS}$ ,  $W_{WS}$  i  $W_{OS}$ . Niemniej jednak, mając na uwadze wyniki dyskutowane w poprzednich podrozdziałach, poniższe opisy skoncentrowano na charakterystyce analiz wartości skutecznej  $W_{RMS}$  i wartości średniej  $W_{WS}$ .

Na rys. 7.15 przedstawiono istotności wejść wyznaczone w przypadku analiz wartości skutecznej  $W_{RMS}$ . Jak można zauważyć, wszystkie metody selekcji jednoznacznie wskazały na  $W_{RMS}$  wyznaczoną dla drogi narzędzia  $D_N=1.52$  mm, co utożsamiane jest z wyborem optymalnej wartości  $D_N$ . Również istotności pozostałych wejść odzwierciedlają wyniki przedstawione na rys. 7.9 i rys. 7.12. Podkreślić można uporządkowanie 4 najistotniejszych wejść odpowiadające uporządkowaniu wynikającemu z badań przeprowadzonych z zastosowaniem miar jakości modeli (rys. 7.12). Ten zadowolający, w uznaniu autora, wynik wymaga jednak szerszego komentarza odnoszącego się do zagadnienia ustalenia warunku zakończenia treningu sieci neuronowej FFBP.



Rys. 7.15. Istotności wejść wyznaczone w przypadku analiz wartości skutecznej  $W_{RMS}$ ; sieć neuronowa FFBP o strukturze 9-3-1, wariant CF, tab. 7.1

Fig. 7.15. Input importance determined while analysing the root-mean-square  $W_{RMS}$ ; FFBP neural network structure : 9-3-1, the CF variant, tab. 7.1



Rys. 7.16. Istotności wejść wyznaczone w przypadku analiz wartości średniej  $W_{WS}$ ; sieć FFBP o strukturze 9-3-1, wariant CF, tab. 7.1

Fig. 7.16. Input importance determined while analysing mean value  $W_{WS}$ ; FFBP neural network structure : 9-3-1, the CF variant, tab. 7.1

W przypadku zadań aproksymacji zakończenie treningu sieci neuronowej następuje zazwyczaj po osiągnięciu zadanej wartości błędu skutecznego  $E_{RMS}$ . Przyjmuje się, że zastosowanie błędu  $E_{MAX}$  prowadzić może do zbytniego „dopasowania” sieci do danych i w konsekwencji do utraty zdolności generalizacji. Zasadniczym problemem jest natomiast ustalenie wartości błędu  $E_{RMS}$  mogącej mieć wpływ na wyznaczone istotności wejść, co przedstawiono na rys. 7.16. Zmniejszenie wartości błędu skutecznego treningu z  $E_{RMS}=0.045$  do  $E_{RMS}=0.035$  spowodowało, przede wszystkim, zmniejszenie zróżnicowania wartości wyznaczonych istotności danych oraz zmianie uległa kolejność uporządkowania wejść według rosnącej istotności. Wystąpiło także, uznane za krytyczne, wskazanie na optymalną drogę narzędzia  $D_N=3.04$  mm w przypadku oceny istotności danych metodą analizy wrażliwości.

Podkreśla się, że krytyczna ocena występowania zależności pomiędzy błędem  $E_{RMS}$  i wartościami wyznaczanych istotności związana jest jednoznacznie z dążeniem Użytkownika do wyboru jednej, optymalnej wielkości. Natomiast w ogólnym ujęciu niniejsza zależność stanowić może cenną zaletę metod selekcji bazujących na sieci neuronowej FFBP. Przyjmując zróżnicowane wartości błędu  $E_{RMS}$  uzyskiwać można jednoznaczne wskazania na jedno, najistotniejsze wejście lub podzbiór istotnych wejść. Z punktu widzenia Użytkownika oznacza to, że dążąc do wyznaczenia modelu o wyższej jakości wyrażanej niższą wartością błędu  $E_{RMS}$ , konieczne może być zwiększenie liczby danych wejściowych rozpatrywanego modelu.

Kontynuując rozważania podejmuje się próbę wyjaśnienia przyczyny uzyskiwania powyżej komentowanych wyników poprzez przeprowadzenie intuicyjnej analizy przebiegu treningu sieci neuronowej FFBP. Dokonując personifikacji sieci neuronowej przyjmuje się, że w początkowej fazie treningu sieć „wybiera” najbardziej „dogodną” drogę do spełnienia warunku zakończenia treningu, „uznając” wysoką istotność wejścia  $D_N=1.52$  mm. Wraz z postępującym treningiem odzwierciedlającym się w zmniejszaniu wartości błędu treningu, „wygodniejsze” lub też „konieczne” staje się „korzystanie” z informacji reprezentowanych przez inne wejścia, co w efekcie prowadzi do wzrostu istotności tych wejść.

Jako uzasadnienie tych rozważań przytacza się wyniki identyfikacji wybranych modeli wysokości zadziórów w funkcji dwóch zmiennych  $W_{WS1}$  i  $W_{WS2}$  (wartości średnich  $W_{WS}$ ), wyznaczonych dla dróg narzędzia  $D_{N1}$  i  $D_{N2}$  (tab. 7.3). Analizując wartości współczynnika korelacji  $R_M$  przedstawione w tab. 7.3, stwierdza się, iż wartość średnia  $W_{WS}$  wyznaczona dla drogi narzędzia  $D_N=1.52$  mm nie stanowi danej koniecznej do uzyskania wysokiej jakości modeli. Następnie zauważa się, że dane pozwalające na identyfikację modeli charakteryzujących się wysokimi wartościami  $R_M$  (np.  $D_N=3.23$ ,  $3.04$  i  $1.90$  mm, tab. 7.3) uzyskały także wysoką ocenę istotności zgodnie z rys. 7.16 ( $E_{RMS}=0.035$ ). Zaznacza się jednakże, iż dokonywane w tym miejscu porównanie ma charakter przybliżony, ponieważ wybór najistotniejszych danych uzależniony jest od postaci modelu (por. modele A i B, tab. 7.3). Stąd też nie należy oczekiwać, aby dane wyselekcjonowane z zastosowaniem sieci neuronowej FFBP jednoznacznie odpowiadały danym z tab. 7.3.

Tabela 7.3

Wartości współczynnika korelacji  $R_M$  modeli  $H_Z=f(W_{WS1}, W_{WS2})$

Lp.	Model A : $H_Z=f_1(W_{WS1})+f_1(W_{WS2})$ $f_1$ – wielomian 4 stopnia			Model B : $H_Z=f_2(W_{WS1}, W_{WS2})$ $f_2$ – wielomian 3 stopnia		
	$D_{N1}$ [mm]	$D_{N2}$ [mm]	$R_M$	$D_{N1}$ [mm]	$D_{N2}$ [mm]	$R_M$
1	3.23	2.28	0.9794	3.23	1.90	0.9773
2	3.23	1.90	0.9790	3.04	2.66	0.9770
3	3.04	2.66	0.9788	3.23	2.66	0.9751
4	3.04	2.28	0.9787	3.23	1.52	0.9744


Powracając do zasadniczego problemu ustalenia warunku zakończenia treningu sieci neuronowej FFBP zdecydowano się, aby w pierwszym kroku dokonywać oszacowania wartości błędu treningu  $E_{RMS}$  z zastosowaniem zbioru weryfikującego i następnie korygować wartość  $E_{RMS}$  w zależności od wartości wyznaczanych istotności. W efekcie przyjęto błąd  $E_{RMS}=0.045$  w symulacjach z zastosowaniem danych reprezentujących wartość średnią  $W_{WS}$  (rys. 7.16) oraz  $E_{RMS}=0.050$  w symulacjach z zastosowaniem wartości skutecznej  $W_{RMS}$  (rys. 7.15) i odchylenia standardowego  $W_{OS}$ . Dodać można, że przyjęte wartości  $E_{RMS}$  odpowiadają w przybliżeniu wartościom  $W_{SR}$  charakteryzującym modele wysokości zadziórów poobróbkowych o postaci wielomianu 4 stopnia.

Podsumowując dyskusję wyników z rys. 7.16 wskazać należy na uniemożliwiającą jednoznaczny wybór najistotniejszego wejścia ocenę dokonaną metodą pruningu wag. Konieczne jest w tym przypadku przeprowadzenie ponownej oceny istotności wejść uznanych wstępnie za najistotniejsze lub podjęcie prób pruningu wag z parametrem  $pr_w$  o większej wartości. Sygnalizowany w tym miejscu problem wydaje się być związany z dyskusyjną rozdzielczością metody pruningu, ujawniającą się głównie w symulacjach sieci o małej liczbie komórek ukrytych. Niemniej jednak konieczność powtórnej oceny istotności podzbiorów danych występować może także w przypadku pozostałych metod bazujących na sieci neuronowej FFBP, co dyskutowane jest w kolejnych podrozdziałach.

### 7.5.2. Problem wyboru cechy sygnału pomiarowego i wartości drogi narzędzia

Podjęciem próby jednoczesnego wskazania optymalnej wartości drogi narzędzia i cechy sygnału pomiarowego ponownie przyjęto, że wyboru wartości parametrów  $T_O$  i  $T_R$  metod wstępnego przetwarzania sygnału pomiarowego dokonano według wariantu CF z tab. 7.1. Wejście do sieci FFBP stanowił 27-elementowy wektor reprezentujący cechy  $W_{WS}$ ,  $W_{OS}$  i  $W_{RMS}$ , odpowiadające rozpatrywanym drogom narzędzia  $D_N$ . Istotności wejść wyznaczone z zastosowaniem sieci o strukturze 27-2-1 ( $E_{RMS}=0.050$ ) przedstawiono na rys. 7.17.

Analizując problem wyboru wartości drogi narzędzia stwierdza się uzyskanie w pełni zadowalającego wskazania na drogę narzędzia  $D_N=1.52$  mm. Podjęciem natomiast próby wyboru cechy sygnału pomiarowego zauważa się znaczne zróżnicowanie wyników. Zdecydowanie dyskusyjna jest ocena istotności danych z zastosowaniem metody sumy wag. Uzyskano w tym przypadku błędne, w świetle dotychczas przeprowadzonych analiz, przypisanie najwyższej istotności wartości skutecznej  $W_{RMS}$  z równoczesnym przypisaniem zbliżonych, relatywnie niskich istotności cechom  $W_{OS}$  i  $W_{WS}$ . Nie umniejszając znaczenia błędnego wyznaczenia istotności danych z zastosowaniem metody sumy wag, wskazuje się na możliwe, aczkolwiek wysoce hipotetyczne, podjęcie przez Użytkownika prób kontynuacji analiz. Przyczynkiem do kontynuacji analiz może być przypisanie cechom  $W_{OS}$  i  $W_{WS}$  zbliżonych istotności. Dążąc do jednoznacznego określenia istotności cech sygnału pomiarowego, Użytkownik odrzucić może wejścia o niższej istotności i podjąć próbę



Rys. 7.17. Istotności wejść wyznaczone z zastosowaniem metod bazujących na sieci neuronowej FFBP o strukturze 27-2-1; wariant CF, tab. 7.1

Fig. 7.17. Input importance determined based on the 27-2-1 FFBP neural network; the CF variant, tab. 7.1

ponownej oceny istotności pozostałych danych. Jak wykazały przeprowadzone symulacje, uzyskuje się w tym przypadku oczekiwane, jednoznaczne wskazanie na wartość średnią  $W_{WS}$  jako optymalną cechę sygnału pomiarowego.


Korzystniejsze, chociaż także dyskusyjne, wyniki uzyskano z zastosowaniem metody pruningu wag. Korzystne jest jednoznaczne wypuklenie istotności cech  $W_{WS}$  i  $W_{RMS}$ . Nie jest natomiast możliwy jednoznaczny, mając na uwadze powtarzalność metody, wybór optymalnej cechy sygnału pomiarowego ze względu na przypisanie zbliżonych istotności  $W_{WS}$  i  $W_{RMS}$ . Podobnie jak wyżej konieczne jest powtórne przeprowadzenie oceny istotności wybranych danych.

Za najkorzystniejszą ocenę istotności danych uznano ocenę dokonaną z zastosowaniem metody analizy wrażliwości. Użytkownik uzyskuje w tym przypadku poprawne, jednoznaczne wskazania na optymalną wartość drogi narzędzia oraz optymalną cechę sygnału pomiarowego. Problematiczne natomiast wydawać się może przypisanie zauważalnie wyższych istotności kilku wejściom reprezentującym  $W_{WS}$ , w porównaniu do istotności wejść reprezentujących  $W_{RMS}$ . Niemniej jednak uporządkowanie rozpatrywanych danych wynikające z wartości wyznaczonych istotności jest bardzo zbliżone do uporządkowania wynikającego z wartości  $R_M$  charakteryzujących modele o postaci wielomianu 4 stopnia (podrozdział 7.4.2). Potwierdza to zasadność uznania diskutowanych wyników za w pełni zadowalające.

### 7.5.3. Problem wyboru wartości parametrów metod wstępnego przetwarzania sygnału pomiarowego i drogi narzędzia

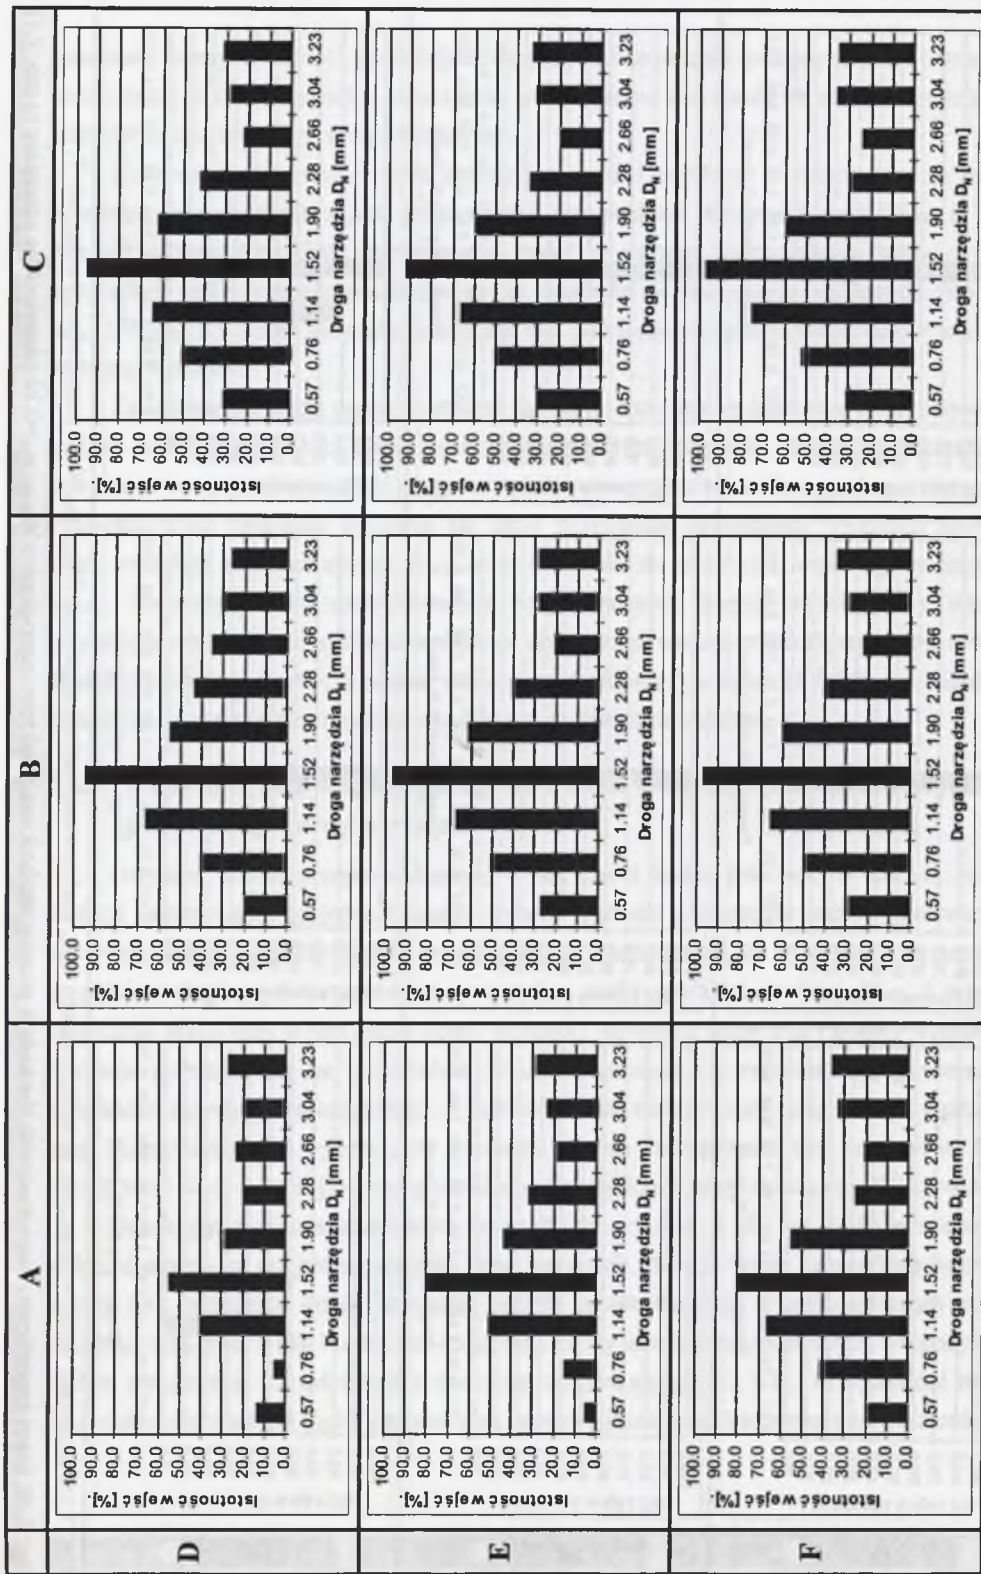
Ostatnim testem przeprowadzonym w tej części badań jest test, w którym metody selekcji zastosowano do jednoczesnego wyboru wartości parametrów metod przetwarzania wstępnego sygnału pomiarowego i drogi narzędzia. Zaznacza się, że ze względu na uzyskanie w pełni analogicznych wyników w przypadku analiz wartości średniej  $W_{WS}$  i wartości skutecznej  $W_{RMS}$  oraz w przypadku oceny istotności metodami sumy wag i analizy wrażliwości dyskusje prowadzi się na przykładzie  $W_{RMS}$  i ogranicza się reprezentację graficzną do przedstawienia wyników uzyskanych z zastosowaniem metody sumy wag i metody pruningu wag. Kontynuując, do wyznaczenia istotności danych zastosowano sieć neuronową FFBP o strukturze 81-2-1, której trening prowadzono do uzyskania błędu skutecznego  $E_{RMS}=0.050$ .

Dokonując analizy wyznaczonych istotności danych (rys. 7.18 i rys. 7.19) jednoznacznie wskazać można na optymalną wartość drogi narzędzia  $D_N=1.52$  mm. Szczególnie korzystna jest w tym przypadku ocena istotności danych przeprowadzona z zastosowaniem metody pruningu wag (rys. 7.18). Następnie, dokonując oceny jakościowej, potwierdza się pozytywny wpływ zwiększenia wartości szerokości okien wygładzających  $T_O$  i  $T_R$ . Przypomnieć można, że zwiększenie wartości  $T_O$  i  $T_R$  pozwala na poprawę jakości modelu wysokości zadziórów.



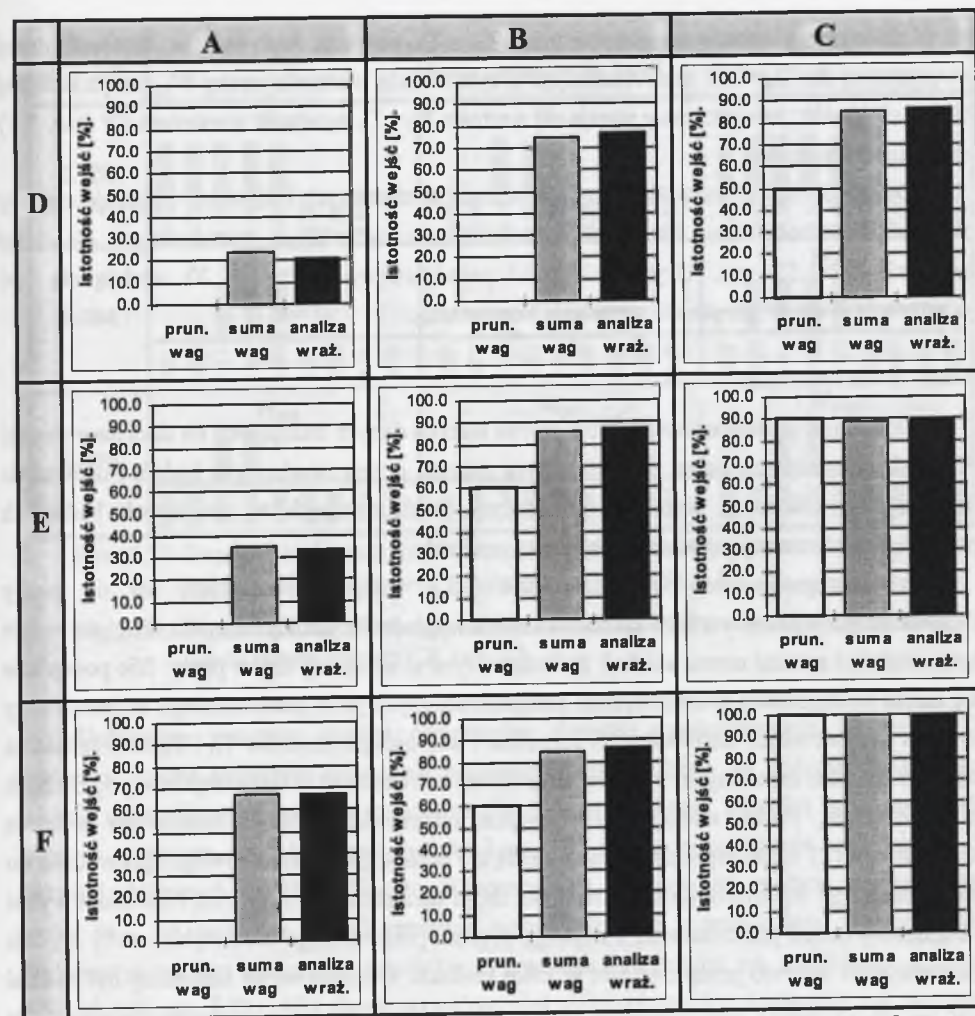
Rys. 7.18. Istotności wejść wyznaczone metodą pruningu wag; analizowana wartość skuteczna  $W_{RMS}$ ;  $P_w=0.30$  (oznaczenia według tab. 7.1)

Fig. 7.18. Input importance determined with the weight pruning method; analysed root-mean-square  $W_{RMS}$ ;  $P_w=0.30$  (descriptions according to tab. 7.1)



Rys. 7.19. Istotności wejść wyznaczone metodą sumy wag; analizowana wartość skuteczna  $W_{RMS}$  (oznaczenia według tab. 7.1)

Fig. 7.19. Input importance determined with the weight sum method; analysed root-mean-square  $W_{RMS}$  (descriptions according to tab. 7.1)



Rys. 7.20. Istotności wartości skutecznych  $W_{RMS}$  wyznaczonych dla  $D_N=1.52$  mm; (oznaczenia według tab. 7.1)

Fig. 7.20. Importance of root-mean-square  $W_{RMS}$  determined for  $D_N=1.52$  mm; (denotations according to tab. 7.1)

Kłopotliwy jest natomiast wybór wartości parametrów  $T_O$  i  $T_R$  ze względu na wyznaczenie zbliżonych istotności danych (np. warianty BE, CE, BF i CF, tab. 7.1). Dążąc do jednoznacznego wskazania optymalnych wartości  $T_O$  i  $T_R$ , zasugerować można dwa podejścia. W pierwszym przypadku przeprowadzić można próby analizy wyznaczonych istotności danych z zastosowaniem pomocniczego kryterium. Kryterium takie bazuje na uwzględnieniu istotności danych wyznaczonych dla dróg narzędzia o wartościach zbliżonych do  $D_N=1.52$  mm. Przyjmuje się, że jeżeli zmiana wartości  $T_O$  i  $T_R$  powoduje wzrost istotności danych wyznaczonych dla drogi narzędzia o wartościach zbliżonych do  $D_N=1.52$  mm,

to w analogiczny sposób zmiana wartości  $T_O$  i  $T_R$  powinna wpływać na istotność danej wyznaczonej dla  $D_N=1.52$  mm. Analizując w tym świetle istotności cechy  $W_{RMS}$  wyznaczonej dla  $D_N=1.41$  mm, jednoznacznie uznaje się wartości  $T_O$  i  $T_R$  zgodne z wariantem CF (tab. 7.1) za wartości optymalne.

Drugie podejście jest podejściem klasycznym w niniejszych badaniach. Sugeruje się, aby dokonać powtórnej oceny istotności wartości skutecznych  $W_{RMS}$  wyznaczanych dla drogi narzędzia  $D_N=1.52$  mm. Uzyskane wyniki przedstawione na rys. 7.20 wydają się być jednoznaczne, a tym samym nie wymagają komentarza.


#### 7.5.4. Podsumowanie

Dokonując podsumowania testów metod selekcji danych bazujących na sieci neuronowej FFBP skoncentrowano się na charakterystyce zakresu przeprowadzonych badań. Porównanie uzyskanych wyników z wynikami pozostałych, zastosowanych w niniejszych badaniach podejść, dokonywane jest w końcowej części rozdziału.

Jak zasygnalizowano w podrozdziale 7.5.3, testy sprowadzające się do próby jednoczesnego wyboru wartości szerokości okien wygładzających  $T_O$  i  $T_R$  oraz drogi narzędzia były ostatnimi testami metod selekcji diskutowanymi w niniejszej części pracy. Nie podejmuje się zatem szczegółowej charakterystyki przeprowadzonych prób jednoczesnego wyboru cechy sygnału pomiarowego, wartości drogi narzędzia i wartości parametrów  $T_O$  i  $T_R$  ze względu na możliwość opisu uzyskanych wyników na podstawie wniosków przytaczanych w poprzednich podrozdziałach. Próba selekcji w przypadku zastosowania 243-elementowego wektora wejściowego (81 wejść reprezentujących każdą z 3 cech sygnału pomiarowego) prowadziła do jednoznacznego wyboru optymalnej wartości drogi narzędzia  $D_N=1.52$  mm. Natomiast wybór parametrów metod przetwarzania wstępnego sygnału pomiarowego oraz wybór cechy sygnału pomiarowego należało przeprowadzić w kilku krokach. Oznacza to, że konieczny był podział danych na podzbiory reprezentujące cechy  $\{W_{WS}, W_{OS}, W_{RMS}\}$  i przeprowadzenie analiz opisanych w podrozdziałach 7.5.2 i 7.5.3.

#### 7.6. Zastosowanie metody SR+AG w zadaniu wyznaczania modelu wysokości zadziórów poobróbkowych

Badania charakteryzowane w niniejszym podrozdziale odzwierciedlają badania przeprowadzone z zastosowaniem metod selekcji bazujących na sieci neuronowej FFBP. Oznacza to, że podejmowano próby analiz tych samych problemów co w podrozdziałach 7.5.1, 7.5.2 i 7.5.3, przyjmując te same założenia i stosując te same zbiory danych. Uzyskane wyniki odbiegały jednak od wyników diskutowanych we wspomnianych podrozdziałach, co zobrazować można na przykładzie prób jednoczesnego wyboru wartości drogi narzędzia i cechy sygnału pomiarowego (rys. 7.21).



Rys. 7.21. Reprezentacja podzbiorów danych wyselekcjonowanych z zastosowaniem metody SR+AG;  $v_c=12$  m/min, wariant CF, tab. 7.1

Fig. 7.21. Representation of the data sub-sets selected based on the SR+AG method;  $v_c=12$  m/min, variant CF, tab. 7.1

Dokonując wstępnej analizy podzbiorów danych przedstawionych na rys. 7.21, stwierdzić można uzyskanie relatywnie zadowalających wyników. W początkowych fazach selekcji uwypuklane są cechy wyznaczone dla pewnego zakresu wartości drogi narzędzia. Wraz ze wzrostem wartości współczynnika kary  $UP_W$  następuje zawężanie tego zakresu do wartości zbliżonych do  $D_N=1.52$  mm. Równocześnie eliminowane są dane reprezentujące cechę  $W_{OS}$ , co wskazuje na ich mniejszą współzmiennność z wysokością zadziórów  $H_z$ . Problematiczne jest natomiast zakończenie prezentacji wyników na podzbiore 4 wejść ( $UP_W=0.120$ , rys. 7.21). Aby skomentować szerzej niniejszy problem konieczne jest ponowne przypomnienie wymogów metody SR+AG. Ocena istotności danych z zastosowaniem metody SR+AG wymaga podziału zbioru uczącego na zbiór trenujący oraz weryfikujący. W poniższych symulacjach zbiór weryfikujący generowano losowo, zaliczając każdorazowo do tego zbioru 25% wektorów zbioru uczącego. Jak wykazano, konieczność generowania zbioru weryfikującego miała zasadniczy wpływ na powtarzalność, a w zasadzie na ewidentny brak powtarzalności, selekcji danych prowadzonej z zastosowaniem metody SR+AG. W tym świetle podzbiory danych przedstawione na rys. 7.21 należy interpretować jako „wzorzec” najczęściej uzyskiwanych konfiguracji wejść, ustalony w wyniku kilkakrotnego generowania zbioru weryfikującego. Równocześnie zdecydowano się, aby nie wskazywać na najczęściej wybierane, „najistotniejsze” wejście, ponieważ mogłoby to prowadzić do prób jednoznacznej oceny istotności danych, która, jak uznano, nie jest w tym przypadku możliwa. W praktyce



oznacza to, że zwiększając wartość  $UP_w$  ( $UP_w > 0.120$ ) uzyskiwano wskazania na jedną z wartości drogi narzędzia, tj.  $D_N = 1.14$  mm lub  $D_N = 1.52$  mm, oraz na jedną z cech sygnału pomiarowego, tj.  $W_{ws}$  lub  $W_{RMS}$ .

Uogólniając wnioski stwierdza się, że selekcja danych metodą SR+AG ma w niniejszej aplikacji bardziej jakościowy niż ilościowy charakter. Możliwe jest wskazanie na pewien zakres wartości rozpatrywanych wielkości, w którym zawierają się wartości optymalne. Jak można zauważyć, niniejsze stwierdzenie wskazuje na brak możliwości spełnienia oczekiwań Użytkownika dążącego do jednoznacznego wyboru optymalnej cechy sygnału pomiarowego, umożliwiającej wyznaczenie modelu wysokości zadzioru o najwyższej jakości.

### 7.7. Modele wysokości zadziorów poobróbkowych o postaci sieci neuronowej FFBP i systemu logiki rozmytej

Charakterystykę modeli wysokości zadziorów poobróbkowych o postaci sieci neuronowej FFBP i systemu logiki rozmytej prowadzi się głównie pod kątem porównania uzyskanych wartości miar jakości  $R_M$  i  $WS_R$ . Podejmuje się również dyskusję wybranych zagadnień związanych z konstruowaniem sieci FFBP i systemów FL. W pierwszym kroku rozpatrywane są modele wysokości zadziorów poobróbkowych w funkcji wartości średniej  $W_{ws}$  przetworzonego sygnału pomiarowego ( $D_N = 1.52$  mm,  $T_O = 0.389$  s i  $T_R = 0.195$  s, wariant CF, tab. 7.1) i parametrów obróbki  $H_Z = f(W_{ws}, v_C, VB_{MAX}, \lambda, pks/kks)$ . Wybrane wielkości charakteryzujące wyznaczone modele zestawiono w tab. 7.4.


Dokonując porównania należy zwrócić uwagę na modele o postaci sieci neuronowej, które pozwalały na uzyskiwanie najkorzystniejszych wartości  $R_M$  i  $WS_R$ . Uwypukla się także relatywnie prostą, wyrażaną małą liczbą komórek ukrytych, strukturę zastosowanych sieci FFBP. Równie korzystne wartości miar jakości modeli uzyskano w przypadku zastosowania systemu logiki rozmytej. Jednakże za dyskusyjną uznać należy postać modelu FL, charakteryzowaną w tym miejscu relatywnie dużą liczbą reguł rozmytych. Stwierdzając uzyskanie zadowalających wartości  $R_M$  i  $WS_R$  odniesiono się do uwzględnionego w tab. 7.4 modelu opisanego zależnością (7.6). Zaznacza się, że przytaczany model nie jest uznawany za optymalny model wyznaczony z zastosowaniem metod statystycznych. Zwraca się uwagę na złożoność zadania wyboru postaci modelu, a tym samym praktyczny brak możliwości wykazania, że dana postać jest postacią optymalną. Dlatego też ponownie uwypuklić można atrakcyjność sieci neuronowych FFBP ze względu na relatywnie łatwy, w niniejszym przypadku, proces konstruowania. Szacując liczbę komórek ukrytych uzyskano jednoznaczne wskazanie na 3 komórki w warstwie ukrytej. Zgodnie z przyjętym w pracy podejściem stosowano także sieci o 2 komórkach ukrytych. Symulacje sieci o przyjętej liczbie komórek prowadzono do wystąpienia wyraźnie ujawniającego spowolnienia treningu (wyraźnego zmniejszenia zmian wartości błędów treningu). Czas realizacji treningu wynosił w przybliżeniu 4÷5 minut.

Wybrane modele wysokości zadziorów  $H_Z = f(W_{ws}, v_C, VB_{MAX}, \lambda, pks/kks)$ 

Model / Postać modelu	$R_M$	$WS_R$ [mm]
sieć neuronowa FFBP : 5-2-1	0.979	0.050
sieć neuronowa FFBP : 5-3-1	0.984	0.044
FL(RN, AG-H2); MF <sub>WE</sub> : 2-3-2-2-2; MF <sub>WY</sub> : 3; 18 reguł	0.978	0.051
FL(RN, WTA(0.04)); MF <sub>WE</sub> : 2-3-2-2-2; MF <sub>WY</sub> : 3; 12 reguł	0.975	0.054
FL(RN, WTA(0.0)); MF <sub>WE</sub> : 3-3-2-2-2; MF <sub>WY</sub> : 3; 23 reguły	0.978	0.051
model opisany zależnością (7.6) (podrozdział 7.4.3)	0.974	0.054

Zdecydowanie bardziej kłopotliwe było konstruowanie systemów logiki rozmytej. Przede wszystkim problematyczne było określenie liczby reguł systemu z zastosowaniem metody WTA(\*). Zastosowanie WTA(0.1) prowadziło do redukcji liczby reguł uniemożliwiającej uzyskanie wartości  $R_M$  i  $WS_R$  zbliżonych do wartości przedstawionych w tab. 7.4. Dążąc do zmniejszenia liczby reguł dokonywano stopniowego, żmudnego zwiększania progowej siły reguł, co powodowało wydłużenie czasu konstruowania systemu. Czas konstruowania z zastosowaniem metody WTA(\*) porównywalny było do czasu konstruowania w przypadku zastosowania metody AG-H\*, a zarazem dłuższy o około 70% od zasygnalizowanego powyżej czasu konstruowania sieci neuronowej FFBP.

Kontynuując dyskusję zastosowań sieci FFBP i systemu FL do wyznaczenia modelu wysokości zadziorów poobróbkowych podjęto próbę rozszerzonej analizy zagadnienia zdolności generalizacji. Przypomnieć można, że zagadnienie to związane jest z możliwością uznania wyznaczonego modelu za model uogólniający dane (model zjawiska), a nie jedynie za model stanowiący zapis danych w innej postaci [Diagnostyka techniczna, 1997]. Na potrzeby niniejszego opisu przyjmuje się, że model stanowiący zapis danych w innej postaci nazywany jest modelem zdegenerowanym. Koncentrując się na sieciach neuronowych przypomnieć można, że problem utraty zdolności generalizacji jest problemem złożonym, związanym głównie z przewymiarowaniem struktury sieci. Nie mniej istotny, aczkolwiek zdecydowanie rzadziej komentowany w literaturze, jest warunek zakończenia treningu sieci oraz rozkład danych stosowanych do wyznaczenia modelu. W celu rozwinięcia dyskusji zagadnienia generalizacji dogodne jest odwołać się do analizowanych w poprzednich podrozdziałach (np. podrozdział 7.4.2) modeli  $H_Z = f(W_{ws})$  i  $H_Z = f(W_{RMS})$  ( $v_C = 12$  m/min,  $D_N = 1.52$ , wariant CF z tab. 7.1). Zaznacza się, że podjęcie analiz tych modeli ma jednoznacznie na celu dyskusję (również wizualizację) utraty zdolności generalizacji sieci neuronowej i systemu logiki rozmytej. Zastosowanie sieci FFBP czy systemu FL nie jest oczywiście konieczne w niniejszym przypadku i może być uważane za próby rozwiązania trywialnego zadania.



Rys. 7.22. Modele wysokości zadziórów o postaci sieci neuronowej FFBP

Fig. 7.22.  $H_z=f(W_{ws})$  burr height models developed with FFBP neural network

Prowadząc symulacje sieci neuronowej FFBP jako warunek zakończenia treningu przyjęto realizację 2,000,000 iteracji. Przyjęta liczba iteracji jest kilkunastokrotnie większa od liczby iteracji, po zrealizowaniu której następowało zauważalne spowolnienie treningu sieci o strukturze 1-3-1. Wybrane spośród wyznaczonych modele wysokości zadziórów  $H_z=f(W_{ws})$  przedstawiono na rys. 7.22a i b. Symulując sieci o liczbie komórek ukrytych od 2 do 15 nie wykazano zasadniczego zróżnicowania krzywych reprezentujących modele. Szczególnie uwypuklić należy model wyznaczony z zastosowaniem sieci 1-15-1 (rys. 7.22a). Istotne jest w tym przypadku, iż liczba parametrów sieci, których wartości identyfikowane są podczas treningu (46 parametrów), jest większa od liczby wektorów wejściowych (32 wektory), co mogłoby wskazywać na wystąpienie, jednakże nie ujawniającej się, utraty zdolności generalizacji.

Zaznacza się, iż uznanie wyznaczonego modelu jako modelu zjawiska dokonywane jest arbitralnie, rozważając intuicyjnie możliwe postaci krzywej reprezentującej model. Przykładowo, zmianę postaci krzywej (rys. 7.22a) ujawniającą się dla wartości  $W_{ws} \approx -30$  N/s uznano za możliwą, nie będącą konsekwencją przewymiarowania struktury sieci neuronowej

(por. postać końcową modelu  $H_z=f(W_{ws})$  z rys. 7.23). Dodać również można, że przyjęcie przez potencjalnego Użytkownika struktury 1-15-1 wydaje się być mało prawdopodobne przy założeniu stosowania rozważanych w pracy metod szacowania liczby komórek ukrytych.

Na rys. 7.22b przedstawiono model o postaci sieci neuronowej 1-10-5-1. Wprowadzenie drugiej warstwy ukrytej (81 parametrów identyfikowanego modelu) doprowadziło do wyznaczenia modelu, który nie można uznać za model rozpatrywanego zjawiska (modelu zdegenerowanego). Jednakże zastosowanie sieci 1-10-5-1 należy traktować podobnie jak wyżej jako mało prawdopodobne, a zamieszczenie wyznaczonego modelu (w pracy stosuje się sieci FFBP o jednej warstwie ukrytej) służy głównie zobrazowaniu zagadnienia degeneracji modeli.

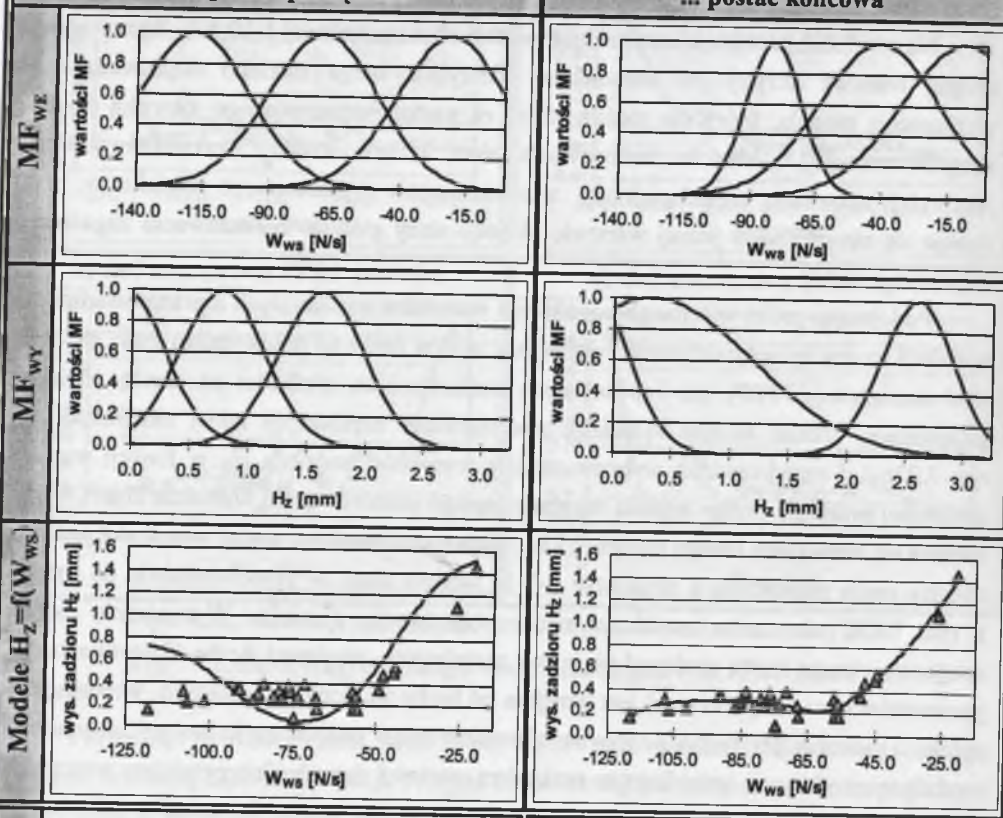
Podjęmą próbę wstępnego uogólnienia wniosków wynikających z przeprowadzonych symulacji można by optymistycznie pomniejszyć wpływ zarówno przewymiarowania struktury sieci neuronowej FFBP, jak i pozostałych analizowanych wielkości na utratę zdolności generalizacji. Jednak kolejne symulacje zdecydowanie zaprzeczyły takiej możliwości. Na rys. 7.22c i d przedstawiono wybrane modele wysokości zadzioru  $H_z$  w funkcji wartości skutecznej przetworzonego sygnału reprezentującego posuwową siłę wiercenia  $H_z=f(W_{RMS})$ . Zwraca się szczególną uwagę na rys. 7.22d, gdzie przedstawiono model wysokości zadzioru opisany siecią neuronową o strukturze 1-7-1. Modelu tego, w przeciwieństwie do modelu z rys. 7.22c, nie można uznać za model rozważanego zjawiska. Wyznaczenie modelu zdegenerowanego może wydawać się nieco zaskakujące, ponieważ liczba identyfikowanych parametrów sieci (22 parametry) jest mniejsza od liczby wektorów trenujących. Wnioskuje się zatem, iż nawet w przypadku poprawnie sformułowanego zadania może nastąpić degeneracja modelu spowodowana specyficznym rozkładem wartości danych i/lub przyjętym warunkiem zakończenia treningu sieci FFBP. Podkreśla się szczególne znaczenie warunku zakończenia treningu. Podobnie jak w symulacjach scharakteryzowanych w pierwszej części podrozdziału, podczas treningu sieci 1-7-1 (rys. 7.22d) występowało wyraźne spowolnienie zmian błędu  $E_{RMS}$ , ujawniające możliwość (lub konieczność) podjęcia przez Użytkownika decyzji o weryfikacji przyjętego warunku zakończenia treningu.

Testy systemu logiki rozmytej przeprowadzono analogicznie do testów sieci neuronowej FFBP. Na rys. 7.23 przedstawiono reprezentację wybranych wielkości opisujących jeden ze skonstruowanych systemów FL. Reprezentując system dokonano podziału na postaci początkowe i końcowe. Postaci początkowe odpowiadają postaciom uzyskiwanym po wyborze reguł rozmytych, a postaci końcowe są postaciami uzyskiwanymi po zastosowaniu treningu algorytmem BP. Komentując wyznaczony model wysokości zadziórów (rys. 7.23) wskazuje się na zbliżoną postać krzywych z rys. 7.23 i rys. 7.22a. Oczywiście jest w tym przypadku stwierdzenie o wyznaczeniu modelu, który uznaje się za model rozpatrywanego zjawiska.


System logiki rozmytej FL(RN, AG)

... postać początkowa

... postać końcowa



Reprezentacja zbioru reguł



Rys. 7.23. Reprezentacja wybranych wielkości opisujących system logiki rozmytej zastosowany do wyznaczenia modelu wysokości zadzioru  $H_z=f(W_{ws})$

Fig. 7.23. Representation of the selected quantities describing the fuzzy logic system applied for development of the burr height model  $H_z=f(W_{ws})$

Niemniej jednak konieczne jest wskazanie na końcową postać funkcji przynależności. Jak można zauważyć (rys. 7.23), faza treningu BP istotnie zmienia postaci funkcji w stosunku do postaci zainicjalizowanych metodą RN. Końcowa postać funkcji przynależności (szczególnie  $MF_{WY}$ ) sprawiać może znaczne trudności w interpretacji skonstruowanego systemu FL, co w efekcie znacznie utrudnia wyznaczenie reguł „Jeżeli ... to ...”, odzwierciedlających relacje pomiędzy cechą sygnału pomiarowego i wysokością zadzioru  $H_z$ . Przypomina się, iż relatywnie prosta interpretacja struktury systemu FL była wcześniej sygnalizowana jako jedna z istotnych cech uwypuklanych z punktu widzenia możliwości odzyskiwania wiedzy.

Dążąc do oceny możliwości wystąpienia zjawiska degeneracji podjęto próby konstruowania systemów FL o zwiększonej liczbie wejściowych funkcji przynależności. Zwiększenie liczby MF uznać można za analogię do zwiększenia liczby komórek ukrytych sieci FFBP, a tym samym za próbę przewymiarowania systemu. Jak wykazano, stosując 5 wejściowych funkcji przynależności  $MF_{WE}$ , w każdej z przeprowadzonych symulacji wyznaczano modele wysokości zadziorów zbliżone do modeli z rys. 7.22b i d. Jednakże struktur skonstruowanych systemów FL nie można uznać za przewymiarowane (16 parametrów identyfikowanych w fazie treningu algorytmem BP). Modele zdegenerowane uzyskiwano wprowadzając jako daną wejściową zarówno wartość średnią  $W_{ws}$ , jak i wartość skuteczną  $W_{RMS}$ . Nie ujawniał się zatem wpływ rozkładu wartości  $W_{ws}$  zmniejszający, jak to miało miejsce w przypadku symulacji sieci neuronowej FFBP, możliwość wyznaczenia modelu zdegenerowanego. Następnie, w fazie treningu algorytmem BP nie obserwowano korzystnego spowolnienia treningu umożliwiającego ingerencję Użytkownika. Wskazuje się także na zależność uzyskiwanych wyników od metody inicjalizacji parametrów funkcji przynależności. Szczególnie niekorzystne wyniki uzyskiwano stosując metodę KFM. Stwierdzono nieco zaskakująco, że uwzględnienie rozkładu wartości danej wejściowej poprzez inicjalizację funkcji przynależności metodą KFM powodowało wyznaczanie modeli zdegenerowanych nawet w przypadku stosowania 3 wejściowych funkcji  $MF_{WE}$ .

Podsumowując powyższe rozważania uwypukla się przede wszystkim większą podatność systemów logiki rozmytej na utratę zdolności generalizacji, na co wskazywano także w podsumowaniu rozdziału 6. Zaleci należy szczególną ostrożność w fazie wyboru liczby i postaci funkcji przynależności. Błąd popełniony w tej fazie może, bez względu na realizowany w kolejnym kroku trening z zastosowaniem algorytmu BP, doprowadzić do utraty zdolności generalizacji i brak ogólnych metod oceny modeli zjawisk. Hipotetyczny Użytkownik polegać musi na własnym doświadczeniu lub też oprzeć się może na stosowanych w pracy, jakkolwiek nie zapewniających uzyskania optymalnego rozwiązania, podejściach. Zastosować zatem może zbiór weryfikujący lub obserwować może zmiany błędu treningu. Sygnalizuje się również, iż pomocne w tym przypadku może być zastosowanie koncepcji modeli jednostronnych [Diagnostyka techniczna, 1997].

## 7.8. Wnioski podsumowujące rozdział

Podsumowanie badań przedstawionych w niniejszym rozdziale przeprowadzić można w dwóch krokach. W pierwszym kroku zwraca się uwagę na wykazanie poprawności proponowanego przez autora podejścia do ogólnie rozumianego zagadnienia modelowania zadziórów poobróbkowych z uwzględnieniem cech sygnałów rejestrowanych podczas obróbki. Zaproponowane metody przetwarzania sygnałów pomiarowych umożliwiły uwypuklenie informacji związanych z tworzeniem się zadziórów poobróbkowych, a tym samym pozwoliły na wyraźne podniesienie jakości modelu. Autor nie uznaje jednakże przedstawionych badań za zakończone. Uzyskane wyniki potwierdzają jedynie trafność tzw. pierwszego podejścia. Autor dostrzega zatem celowość kontynuacji prac zorientowanych na próby jednoczesnego zastosowania kilku cech sygnałów pomiarowych jako danych wejściowych modelu wysokości zadziórów poobróbkowych (zob. modele 2 zmiennych, podrozdział 7.5.1). Istotne jest również podjęcie prób szczegółowej analizy wpływu (selekcji) parametrów obróbki.

Odnosząc się w kolejnym kroku do zastosowania rozważanych w pracy metod selekcji i integracji danych, ponownie uwypuklić należy motywację zastosowania tych metod. Przypomnieć można, że zastosowanie metod selekcji danych motywowane było pracochłonnością, uznanego za konieczne, podejścia bazującego na mierze jakości modelu. Nie mniej znaczący był kłopotliwy wybór postaci modelu wyznaczanego z zastosowaniem metod statystycznych zarówno na etapie selekcji, jak i integracji danych.

Aby zobrazować powyższe komentarze autor odwołuje się do problemu jednoczesnego wyboru drogi narzędzia i wartości szerokości okien wygładzających  $T_O$  i  $T_R$  (podrozdział 7.5.3). W uznaniu autora, zastosowanie wybranych metod selekcji jest alternatywnym w stosunku do klasycznego, atrakcyjnym dla Użytkownika podejściem. Aby dokonać oceny istotności 81 danych należało oszacować liczbę komórek ukrytych sieci neuronowej FFBP oraz ustalić wartość błędu treningu  $E_{RMS}$ . W kolejnym kroku przeprowadzono 5 symulacji sieci FFBP w celu wyznaczenia istotności rozpatrywanych danych. Jak wykazano, konieczna była powtórna ocena istotności wybranych danych, prowadząca do jednoznacznego wyboru cechy sygnału pomiarowego. Wydawać się może, że powyższe etapy analiz wymagają zbliżonych nakładów obliczeniowych (są równie czasochłonne) jak podejście klasyczne. Niemniej jednak decydujący jest w tym przypadku czas symulacji sieci neuronowej FFBP, który nie przekraczał jednej minuty (w większości symulacji czas symulacji był rzędu kilkunastu sekund). Tak znikomy czas symulacji oraz jednoznaczność wyboru postaci modelu wydają się uzasadniać uznanie zastosowanego podejścia za atrakcyjne.

Ze względu na specyficzny charakter niniejszego zadania ocenę metod selekcji prowadzi się w odniesieniu do wybranych kryteriów. Oczywiście jest, że nie stosuje się w tym miejscu kryterium związanego z jakością integracji wyselekcjonowanych wejść. Fakt ten powoduje także, iż zasadnicza ocena metod selekcji ma charakter jakościowy i opiera się na wnioskach

Zestawienie uzupełniających kryteriów oceny metod selekcji danych

Kryteria		Metody selekcji danych						
		MS(pruning wag)	MS(suma wag)	MS(met. A-Karłina)	MS(anal. wrażliwości)	MS(SM+SFS)	MS(SM+AG)	MS(SR+AG)
1	duża powtarzalność wyznaczania istotności	2	1	-	2	-	-	0
2	możliwość nie tylko jakościowej ale również ilościowej oceny istotności danych	1	2	-	2	-	-	0
3	możliwość wskazania parametru metody selekcji pozwalającego na wybór quasi-optymalnego podzbioru danych	2	1	-	2	-	-	0
4	niski koszt obliczeniowy metody	1	2	-	2	-	-	0
Suma (max. 8 pkt) :		6	6	-	8	-	-	0

dyskutowanych w poprzednich podrozdziałach. W tym świetle jednoznacznie wskazać można na metodę analizy wrażliwości, która pozwalała na rozwiązanie każdego z analizowanych zadań. Równie korzystne wyniki uzyskiwano z zastosowaniem metody pruningu wag. Uwypuklić jednakże należy problem rozdzielczości tej metody, tj. przypisywanie maksymalnych istotności kilku wejściom i konieczność realizacji powtórnej oceny istotności. Dyskusyjna jest natomiast ocena istotności zbioru 27 danych przeprowadzona z zastosowaniem metody sumy wag (podrozdział 7.5.2). Równie dyskusyjna jest efektywność metody SR+AG ze względu na zależność uzyskiwanych wyników od zbioru weryfikującego i możliwość wyboru rozwiązania zdecydowanie odbiegającego od optymalnego.

Uzupełniając ocenę metod selekcji danych rozpoczęto od oceny stopnia spełnienia kryterium *powtarzalności wyznaczania istotności* (tab. 7.5). Podkreślić należy, iż powtarzalność wyznaczania istotności zależna jest od liczności rozpatrywanego zbioru danych. Wyznaczając istotności 9 danych, powtarzalność uznać należy za w pełni zadowalającą, tj. uzyskiwano pełną powtarzalność w przypadku metody pruningu wag oraz  $BPI_{MAX} < 15.0\%$  w przypadku metody sumy wag i metody analizy wrażliwości. Podejmując natomiast analizy zbioru 81 danych (np. rys. 7.18 i rys. 7.19) uzyskiwano  $BPI_{MAX} = 17.1\%$  i  $BPI_{AV} = 2.7\%$  w przypadku metody analizy wrażliwości oraz  $BPI_{MAX} = 24.8\%$  i  $BPI_{AV} = 3.5\%$  w przypadku metody sumy wag. Dodać można, iż wyższe wartości błędu  $BPI_{MAX}$  uzyskiwano w przypadku danych mniej istotnych. Dane istotne (dane o istotnościach powyżej 40%) charakteryzował maksymalny błąd powtarzalności wyznaczania istotności nie przekraczający 9%, bez względu na licznosc rozpatrywanego zbioru. Zadowalającą

powtarzalność wyznaczania istotności 81 danych uzyskano w przypadku metody pruningu wag  $BPI_{MAX}=1$ . Jednakże ten korzystny wynik nie powinien być szerzej dyskutowany ze względu na stosowanie jedynie 2 komórek w warstwie ukrytej sieci FFBP.

Kontynuując komentarze do tab. 7.5 wskazuje się na obniżenie oceny metody pruningu wag w świetle kryterium 2, co wynika z uwidocznionej w przeprowadzonych symulacjach niskiej rozdzielczości tej metody. Następnie, niżej oceniono metodę sumy wag w przypadku kryterium 3. Podkreśla się, że specyficznie w niniejszych badaniach ocena stopnia spełnienia tego kryterium jest oceną względną, odzwierciedlającą jednoznaczność wyboru jednej, najistotniejszej danej. Ostatnim z analizowanych w tym miejscu kryteriów jest kryterium kosztów obliczeniowych. Zróżnicowanie ocen w tab. 7.5 wiąże się głównie z czasem koniecznym do przeprowadzenia pruningu wag oraz zdecydowanie największymi nakładami obliczeniowymi związanymi z wielokrotnym stosowaniem metody SR+AG z różnymi wartościami współczynnika kary  $UP_w$ . Zastosowanie tej metody wymagało kilkakrotnie dłuższego czasu w porównaniu z metodami bazującymi na sieci FFBP.

Komentując porównanie sieci neuronowej FFBP i systemu logiki rozmytej przedstawione w tab. 7.6 należy odwołać się do podrozdziału 7.7, gdzie przeprowadzono szczegółową analizę metod integracji danych. Dokonane uogólnienia stanowiły podstawę przyjęcia ocen porównawczych w przypadku kryteriów 1, 4 i 6. Uzupełniając dodaje się, że wykazano zadowalającą powtarzalność wartości parametrów wyznaczanych zarówno w symulacjach sieci neuronowej FFBP, jak i systemu logiki rozmytej. Pomimo kłopotliwych w interpretacji postaci funkcji przynależności w dalszym ciągu uznaje się system FL za korzystniejszy w świetle kryterium łatwości odzyskiwania wiedzy. Uznanie większej zdolności uczenia sieci neuronowej FFBP wynika natomiast z uzyskiwania korzystniejszych wartości  $R_M$  i  $WS_R$ . Podsumowując, wskazanie na sieć neuronową FFBP jako korzystniejszą, w świetle porównania z tab. 7.6, metodę integracji danych wydaje się nie wymagać dodatkowego komentarza.

Tabela 7.6

Uzupełniające porównanie sieci neuronowej FFBP i systemu logiki rozmytej

	Kryteria	Sieć neuronowa FFBP	System logiki rozmytej
1	niski koszt obliczeniowy w fazie konstruowania	+	-
2	duża powtarzalność wartości parametrów	+	+
3	łatwość odzyskiwania wiedzy	-	+
4	mała złożoność procesu konstruowania	+	-
5	duża zdolność uczenia	+	-
6	duża zdolność generalizacji wiedzy	+	-

## 8. DIAGNOSTYKA ZUŻYCIA NARZĘDZIA PODCZAS TOCZENIA

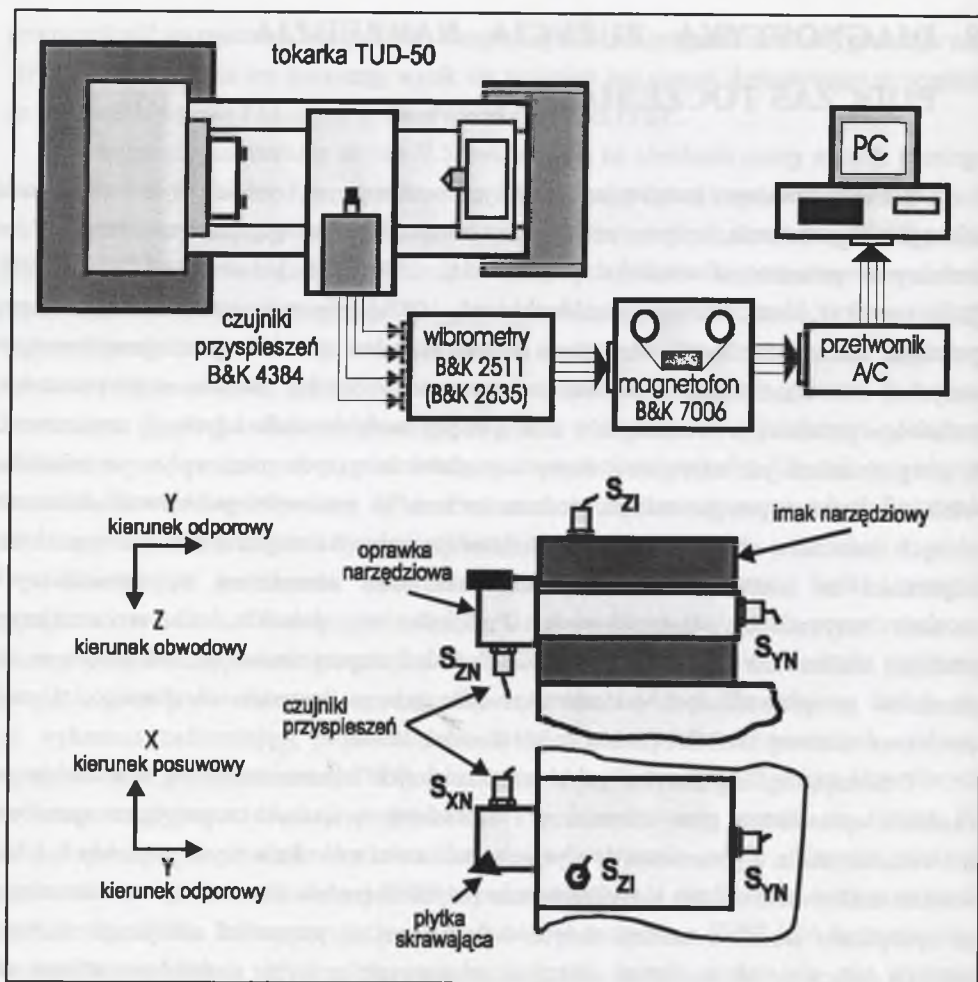
Celem nadrzędnym badań przedstawianych w niniejszym rozdziale było opracowanie strategii diagnozowania zużycia naturalnego ostrza skrawającego podczas skrawania ze zmiennymi parametrami obróbki [Sokołowski, 1995], [Sokołowski et al., 1995], [Sokołowski i Kosmol, 1996a], [Sokołowski et al., 1997a]. Hipotetyczny układ diagnostyczny powinien zatem umożliwiać odróżnienie zmian sygnałów pomiarowych spowodowanych zużyciem ostrza od zmian wywołanych parametrami obróbki. Badania eksperymentalne, stanowiące podstawę prowadzonych w dalszej części rozdziału analiz i dyskusji, zrealizowano z uwzględnieniem jak największej liczby czynników mogących mieć wpływ na mierzone wielkości. Pomiarów przeprowadzono podczas toczenia ze zmiennymi parametrami skrawania różnych materiałów obrabianych, płytkami skrawającymi wykonanymi z materiałów o różnej odporności na ścieranie, a także podczas skrawania narzędziami o zróżnicowanych cechach sztywnościowo-tłumieniowych. Podkreśla się jednakże, iż w niniejszym rozdziale analizowana jest część wspomnianych badań eksperymentalnych, odnosząca się do pomiarów przeprowadzonych podczas skrawania jednego materiału obrabianego, tj. stali chromowo-niklowej 30HN3A [Sokołowski i Kosmol, 1996a].

Dokonując ogólnej charakterystyki przedstawianych badań zaznacza się, iż w niniejszym rozdziale uproszczono gros komentarzy i uzasadnień związanych z przyjętym sposobem prowadzenia analiz. Uproszczenie to wynika z możliwości odwołania się do rozdziału 6, gdzie również analizowano zadanie klasyfikacji stanu zużycia narzędzia. Zwraca się natomiast uwagę na specyficzny charakter selekcji danych dokonywanej w przypadku niniejszego zadania. Selekcja danych nie ma charakteru selekcji ukierunkowanej na wybór czujników pomiarowych ze względu na zastosowanie, jak to zostanie przedstawione, jednoczynnikowego układu pomiarowego. Potencjalny Użytkownik może natomiast dążyć do eliminacji danych reprezentujących parametry obróbki jako wejść hipotetycznego układu diagnostycznego. Zasadne jest także podjęcie prób eliminacji danych reprezentujących cechy sygnału pomiarowego nie wykazujące współzależności z rozpatrywanym zjawiskiem.

### 8.1. Charakterystyka badań eksperymentalnych i wstępna analiza sygnałów pomiarowych

#### 8.1.1. Stanowisko pomiarowe i opis przeprowadzonych pomiarów

Badania eksperymentalne przeprowadzono na przebudowanej, wyposażonej w sterowaną numerycznie oś posuwu tokarce uniwersalnej TUD-50 [Sokołowski, 1995], [Sokołowski et al., 1995]. Schemat stanowiska pomiarowego oraz konfigurację czujników



Rys. 8.1. Schemat stanowiska pomiarowego

Fig. 8.1. Schematics of the measuring set-up

Tabela 8.1

Zestawienie przeprowadzonych prób skrawaniowych

Warianty pomiarowe	$v_c$ [m/min]	$f$ [mm/obr]	$a_p$ [mm]	$VB_B$ [mm]	Gatunek materiału ostrza
W 1	90; 120; 150	0.1; 0.2	1; 2	0.0; 0.4; 0.8;	S10S
W 2	120; 130; 150	0.2; 0.3	2	0.0-0.80	S10S; S40S
W 3	90; 140	0.2; 0.3; 0.4	2	0.0-0.74	S40S

pomiarowych (punkty pomiarowe  $S_{XN}$ ,  $S_{YN}$ ,  $S_{ZN}$  i  $S_{ZI}$ ) przedstawiono na rys. 8.1. We wszystkich pomiarach zastosowano oprawkę nożową hR.110.16-3225. Jak wspomniano, materiałem obrabianym była stal chromowo-niklowa przeznaczona na części maszyn o wysokich wymaganiach 30HN3A, o twardości 241 HB. Średnice toczenia mieściły się w zakresie 130-210 mm. Do skrawania użyto płytki skrawające z węglików spiekanych SNUN 120408 o stereometrii opisanej w układzie narzędzia kątami: kąt przyłożenia  $\alpha_o=6^\circ$ ; kąt natarcia  $\gamma_o=-6^\circ$ ; kąt pochylenia krawędzi skrawającej  $\lambda=4^\circ$ ; kąt przystawienia  $\chi=30^\circ$ .

Każdy pomiar realizowano w dwóch krokach. W pierwszym kroku rejestrowano prędkości drgań w wybranych punktach obrabiarki, a następnie, bezpośrednio po rejestracji, dokonywano pomiaru zużycia głównej powierzchni przyłożenia ( $VB_B$ ). Dodać można, że dyskretyzację i wstępne przetwarzanie sygnałów pomiarowych przeprowadzono z zastosowaniem pakietów oprogramowania [Cholewa et al., 1988] i [Tyrlik et al., 1989]. Większość pomiarów została przeprowadzona co najmniej dwukrotnie w celu oszacowania powtarzalności uzyskiwanych wyników. Sumarycznie przeprowadzono 117 pomiarów.

Poszczególne zestawy pomiarów przedstawiono w tab. 8.1. Pierwszy zestaw przeprowadzonych pomiarów stanowiły zasadnicze próby skrawaniowe (wariant W1, tab. 8.1). Pomiary przeprowadzono podczas skrawania z parametrycznie zmiennym zużyciem powierzchni przyłożenia ostrza skrawającego. Skrawanie z parametrycznie zmiennym zużyciem oznacza skrawanie wyselekcjonowanymi płytkami skrawającymi o zadanym zużyciu  $VB_B$ . Wartości  $VB_B$  starano się dobrać tak, aby odzwierciedlić 3 charakterystyczne fazy zużycia ostrza skrawającego, tj. początkową fazę zużycia (docieranie płytki skrawającej,  $VB_B \approx 0.0$  mm), fazę "plateau" zużycia ( $VB_B \approx 0.4$  mm) i fazę przyspieszonego zużycia ostrza skrawającego ( $VB_B \approx 0.8$  mm).

Kolejny zestaw pomiarów (wariant W2, tab. 8.1) stanowił rozszerzenie zasadniczych prób skrawaniowych. Pomiary przeprowadzono podczas skrawania płytkami wykonanymi z materiałów o różnej odporności na ścieranie (S10S i S40S). Istotną cechą tej części badań eksperymentalnych było dokonywanie rejestracji prędkości drgań i pomiarów zużycia  $VB_B$  po arbitralnie przyjętej liczbie przejść narzędzia. Uzyskano w ten sposób zwiększenie liczby pomiarów przypadających na obserwowany zakres zużycia, a co się z tym wiąże, bardziej dokładną reprezentację zmian prędkości drgań ze wzrastającym zużyciem ostrza.

Celem przeprowadzenia kolejnego zestawu pomiarów była ocena wpływu zmian w układzie obrabiarki na mierzone wielkości (wariant W3, tab. 8.1). Mając na uwadze drgania jako sygnały pomiarowe, przez zmiany w układzie obrabiarki rozumie się zmiany cech sztywnościowo-tłumieniowych elementów obrabiarki. Pomiary przeprowadzono podczas skrawania narzędziem o zwiększonym wysięgu. Praktycznie zwiększono wysięg oprawki narzędziowej poprzez przesunięcie jej w kierunku materiału obrabianego o 10 mm w stosunku do położenia odpowiadającego poprzednim wariantom pomiarowym. Podobnie jak w wariantcie W2, pomiary dokonywano po arbitralnie przyjętej liczbie przejść narzędzia.

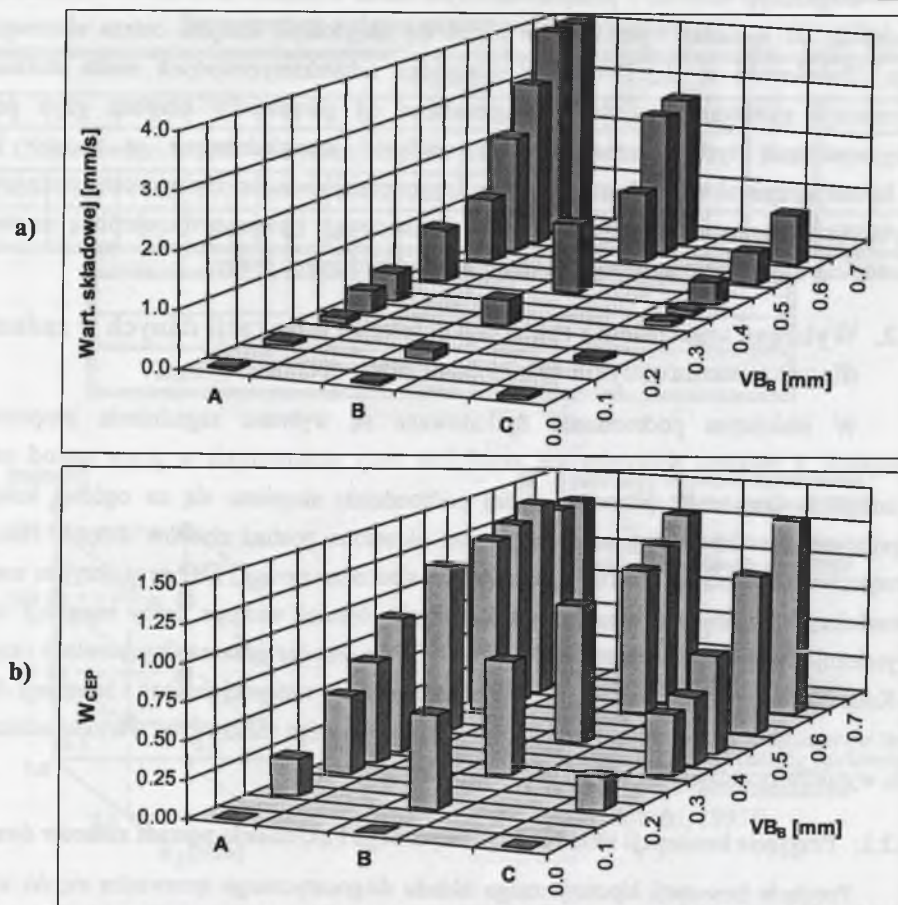
### 8.1.2. Konwencjonalne próby wyznaczenia symptomów zużycia ostrza

Charakteryzowane w niniejszym podrozdziale analizy oparto zasadniczo na widmach częstotliwościowych zarejestrowanych sygnałów pomiarowych [Sokołowski, 1995]. W pierwszym kroku wybrano składowe widm prędkości drgań charakteryzujące się największą współzmiernością ze zużyciem ostrza skrawającego ( $VB_B$ ). Jak stwierdzono, w każdym z punktów pomiarowych na oprawce narzędziowej ( $S_{XN}$ ,  $S_{YN}$ , i  $S_{ZN}$ ) wskazać można jedną, tę samą składową widma, nazywaną składową obserwowaną, której wartość ( $W_{SW}$ ) wykazywała największe przyrosty względne i monotoniczny charakter zmian wraz ze wzrostem  $VB_B$ . W przypadku wariantów pomiarowych W1 i W2 (tab. 8.1) wskazano na składową o częstotliwości  $f \approx 7200$  Hz, a w przypadku wariantu W3 (tab. 8.1) na składową o częstotliwości  $f \approx 4800$  Hz. Zmiana częstotliwości obserwowanej składowej związana była bezpośrednio ze zwiększeniem wysięgu oprawki narzędziowej. Wykazano także niemonotoniczny charakter zmian wartości  $W_{SW}$  w punkcie pomiarowym na imaku narzędziowym ( $S_{ZI}$ ) i zdecydowano się pomijać w dalszych analizach sygnał pomiarowy rejestrowany w tym punkcie.

W kolejnym kroku przeprowadzono analizę wpływu parametrów obróbki na rejestrowane sygnały pomiarowe. Najistotniejszy wniosek z tej części analiz odnosił się do wartości przyrostów obserwowanej składowej widma. Zwiększenie prędkości skrawania oraz zmiany posuwu  $f$  i głębokości skrawania  $a_p$  powodowały analogiczne przyrosty  $W_{SW}$  jak wzrost zużycia  $VB_B$ . Równie istotny wpływ na wartości obserwowanej składowej miał gatunek materiału płytki skrawającej. Istotny był w tym przypadku odmienny charakter zużycia mniej odpornej na ścieranie płytki wykonanej z S40S w porównaniu z płytką z S10S.

Ponieważ przeprowadzone analizy wskazywały na relatywnie skomplikowany model zależności pomiędzy obserwowaną składową widma (symptomem zużycia  $VB_B$ ) i parametrami obróbki, kolejny etap badań ukierunkowano na próby wyznaczenia symptomów zużycia ostrza niezależnych od parametrów skrawania. Podjęto próby filtracji sygnałów pomiarowych oraz analizowano dryft obserwowanej częstotliwości ze zużyciem  $VB_B$ . Następnie jako potencjalne symptomy zużycia  $VB_B$  testowano oceny punktowe dyskretnych sygnałów pomiarowych, np. współczynnik dewiacji i współczynnik spłaszczenia oraz częstotliwość przejść przez poziom zerowy ([Sokołowski, 1995], [Sokołowski et al., 1995]). Pomimo zastosowania zróżnicowanych podejść nie wyznaczono jednakże symptomu zużycia powierzchni przyłożenia ostrza, który wykazywałby niezależność od parametrów skrawania. Typowo, w przypadku gdy uzyskiwano redukcję wpływu parametrów skrawania, następowało równocześnie znaczne zmniejszenie czułości na postępujące z czasem skrawania zużycie  $VB_B$ . Korzystniejsze wyniki uzyskano natomiast z zastosowaniem analizy homomorficznej sygnałów pomiarowych [Sokołowski, 1995], [Sokołowski et al., 1995]. Jako symptom zużycia przyjęto wskaźnik cepstrum ( $W_{CEP}$ ), reprezentujący stopień rozbieżności pomiędzy sygnałami

A- $v_c=90$  m/min;  $f=0.3$  mm/obr; B- $v_c=140$  m/min;  $f=0.2$  mm/obr; C- $v_c=140$  m/min;  $f=0.3$  mm/obr



Rys. 8.2. Postępujące ze zużyciem  $VB_B$  zmiany wartości obserwowanej składowej widma (a) oraz zmiany wartości wskaźnika cepstrum (b); punkt pomiarowy  $S_{YN}$ , wariant W3, tab. 8.1

Fig. 8.2. Changes of the observed spectrum component (a) and changes of the cepstrum factors (b) progressing with tool flank wear  $VB_B$ ; measuring point  $S_{YN}$ , variant W3, tab. 8.1

rejestrowanymi podczas skrawania ostrym i zużytym narzędziem. Wyznaczone wartości  $W_{CEP}$  (rys. 8.2b) wykazywały bardziej spójny, w porównaniu z wartościami  $W_{SW}$  (rys. 8.2a), charakter zmian wraz z postępującym zużyciem  $VB_B$ . Wykazano także możliwość oceny wartości zużycia w zakresie  $VB_B \approx 0.6-0.8$  mm bez względu na parametry skrawania. Jednakże symptomy zużycia  $VB_B \approx 0.6-0.8$  mm wydają się mieć ograniczone zastosowanie ze względu na zbyt wysokie wartości  $VB_B$ . Podając za [Dmochowski, 1981], dla toczenia stali w przypadku obróbki średnodokładnej dopuszczalne zużycie ostrza waha się w zakresie  $VB_B = 0.4-0.6$  mm.

Uogólniając wnioski z przeprowadzonych analiz wskazano na konieczność reorientacji podejścia do sposobu wykorzystania drgań do diagnostyki zużycia ostrza skrawającego (np. [Sokołowski et al., 1995]). W przypadku scharakteryzowanych analiz starano się wyznaczyć symptomy zużycia  $VB_B$  niezależne od parametrów obróbki, czyli dążono do pominięcia tych parametrów jako wielkości uwzględnianych w sposób jawny w hipotetycznym układzie diagnostycznym. Innym podejściem jest równoczesne zastosowanie wybranych informacji dostępnych z układu pomiarowego i parametrów obróbki, co stanowi zasadnicze zagadnienie poruszane w kolejnych podrozdziałach pracy.

## 8.2. Wybrane zagadnienia realizacji selekcji i integracji danych w zadaniu diagnozowania zużycia ostrza podczas toczenia

W niniejszym podrozdziale dyskutowane są wybrane zagadnienia bezpośrednio związane, a zarazem poprzedzające zasadnicze testy stosowanych w pracy metod selekcji i integracji danych. W pierwszej części podrozdziału skupiono się na ogólnej koncepcji hipotetycznego układu diagnostycznego oraz określono postaci zbiorów danych. Następnie przeprowadzono analizę struktury podstawowej sieci neuronowej FFBP oraz przyjęto wartości zasadniczych parametrów symulacji sieci. Podjęto również wstępne próby integracji danych wyselekcjonowanych z zastosowaniem metody *leave-one-out* oraz analizy korelacji rangowej  $\tau$ -Kendalla. Przypomnieć można, że bezpośrednim celem wstępnej selekcji i integracji danych jest wyznaczenie liczby wejść i sprawności sieci FFBP, które stanowiłyby wartości odniesienia dla wyników przedstawionych w kolejnych podrozdziałach.


### 8.2.1. Przyjęcie koncepcji układu diagnostycznego i określenie postaci zbiorów danych

Przyjęcie koncepcji hipotetycznego układu diagnostycznego sprowadza się do wyboru liczby i miejsca zamocowania czujników pomiarowych oraz przyjęcia metod przetwarzania sygnałów pomiarowych. Dążąc do uproszczenia układu zdecydowano się, aby stanowiący przedmiot rozważań układ był układem jednoczynnikowym. Następnie, uwzględniając analizy scharakteryzowane w podrozdziale 8.1.2, zdecydowano się zastosować czujnik mocowany w punkcie pomiarowym  $S_{VN}$  (rys. 8.1). W kolejnym kroku przyjęto metody przetwarzania wstępnego oraz ekstrakcji cech sygnałów pomiarowych. W przypadku niniejszych badań zastosować można cechy sygnałów pomiarowych dyskutowane w podrozdziale 8.1.2. Podejście takie wymagałoby jednak zastosowania zasadniczo zróżnicowanych metod przetwarzania sygnałów pomiarowych lub też bardziej ogólnie - znacznego rozbudowania modułu wstępnego przetwarzania sygnałów pomiarowych rozważanego układu diagnostycznego. W efekcie przyjęto, aby dokonać ekstrakcji cech stosując tylko jedną metodę wstępnego przetwarzania sygnałów pomiarowych, tj. dokonywać ekstrakcji cech bazując na widmach częstotliwościowych prędkości drgań.

Reprezentacja wektora wejściowego i wyjściowego

Wejścia												
1	2	3	4	5	6	7	8	9	10	11	12	13
Częstotliwości środkowe wybranych pasm [Hz]								parametry skrawania			mat. ostrza	wysięg narz.
1906	3177	4448	5719	6991	8263	9534	10805	$v_c$	$f$	$a_p$	PS	WN
P1	P2	P3	P4	P5	P6	P7	P8					

Wyjścia		
1	2	3
$VB_B \cong 0.0$ mm	$VB_B \cong 0.4$ mm	$VB_B \cong 0.8$ mm



- - parametry skrawania zastosowane do treningu i testowania sieci FFBP
- - parametry skrawania zastosowane jedynie do testowania sieci FFBP

Rys. 8.3. Reprezentacja parametrów skrawania stosowanych w przeprowadzanych testach ([Sokołowski, 1995])

Fig. 8.3. Representation of cutting parameters applied in the tests conducted ([Sokołowski, 1995])

Analizując widma częstotliwościowe prędkości drgań wykazano, iż składowe widma o znaczących wartościach występują w paśmie  $f \cong 1.27 \pm 11.50$  kHz. Przedział  $f \cong 1.27 \pm 11.5$  kHz podzielono następnie na 8 pasm o szerokości  $\Delta f \cong 1271$  Hz i wyznaczono wartości skuteczne prędkości drgań w każdym z tych pasm. Uwzględniając parametry obróbki, wyznaczony zbiór cech sygnału pomiarowego przedstawiono w postaci wektora wejściowego w tab. 8.2. W tabeli tej przyporządkowano cechom sygnału pomiarowego (wejściom) oznaczenia P1-P8. Materiał ostrza skrawającego i wysięg oprawki narzędziowej reprezentowano w wektorach wejściowych wartościami 0.0 i 1.0. W tab. 8.2 przedstawiono także reprezentację wektora wyjściowego. Jak można zauważyć, przyjęto dokonywać klasyfikacji zużycia  $VB_B$  do klas odpowiadających 3 poziomom zużycia:  $VB_B \cong 0.0$  mm,  $VB_B \cong 0.4$  mm i  $VB_B \cong 0.8$  mm. Podejście takie wymagało pogrupowania pomiarów zgodnie z przyjętymi zakresami wartości zużycia:  $VB_B = 0.0 \div 0.25$  mm,  $VB_B = 0.25 \div 0.50$  mm oraz  $VB_B > 0.5$  mm ([Sokołowski, 1995]).




Podział danych na zbiór uczący i testujący oparto, przede wszystkim, na zasygnalizowanych wcześniej powtórzeniach pomiarów. Oznacza to, że w pierwszym kroku do zbioru uczącego wprowadzono losowo wektory, które umożliwiły reprezentację skrawania z każdą kombinacją parametrów skrawania oraz trzema poziomami zużycia. W kolejnym kroku odrzucono ze zbioru uczącego (przesunięto do zbioru testującego) wektory, których poprawną klasyfikację można założyć bazując na zdolności sieci neuronowej FFBP do interpolacji [Sokołowski, 1995]. W zbiorze uczącym pominięto dane odnoszące się do prędkości skrawania  $v_c=120$  m/min i zastosowano je jedynie jako dane testujące (rys. 8.3). Analogicznie postąpiono w przypadku posuwu, np. wariant W3 tab. 8.1. Ostatecznie uzyskano zbiór uczący, zawierający 42 wektory oraz zbiór testujący, zawierający 75 wektorów.

### 8.2.2. Struktura podstawowa oraz wybrane parametry symulacji sieci neuronowej FFBP

Symulacje sieci neuronowej FFBP, mające na celu wyznaczenie istotności danych, realizowano z zastosowaniem algorytmu ATS-cum i współczynnikiem treningu  $\eta_F=0.20$  do osiągnięcia błędu treningu  $E_{MAX}=0.15$ . Przyjęto parametr pruningu wag  $pr_w=0.25$  i parametr pruningu komórek  $pr_k=0.25$ . Natomiast symulacje sieci FFBP z podzbiórami wybranych wejść prowadzono z zastosowaniem algorytmu ATS-inc i współczynnikiem treningu  $\eta_F=0.15$  do osiągnięcia błędu treningu  $E_{MAX}=0.10$ . Zaznacza się jednak, że w niektórych symulacjach konieczne było radykalne zmniejszenie wartości  $\eta_F$  oraz zwiększenie wartości błędu treningu  $E_{MAX}$ . Symulacje te komentowane są w opisach przeprowadzonych testów.

W przypadku charakteryzowanych w niniejszym rozdziale symulacji sieci neuronowej FFBP niezależnej dyskusji wymaga zagadnienie oszacowania liczby komórek ukrytych. Zwraca się w ten sposób uwagę na mogące wystąpić rozbieżności w uzyskiwanych wynikach, uwypuklające szacunkowy charakter stosowanych metod. Oszacowanie liczby komórek ukrytych przeprowadzono, w pierwszym kroku, z zastosowaniem algorytmu ATS-des (rys. 8.4). Jak można zauważyć, wprowadzanie kolejnych komórek ukrytych powodowało początkowo relatywnie szybkie zmniejszanie wartości błędu  $E_{RMS}$ . Zauważalne spowolnienie zmian nastąpiło po wprowadzeniu 7 komórki ukrytej. Natomiast zasadnicza zmiana wartości błędu maksymalnego  $E_{MAX}$  nastąpiła po wprowadzeniu 9 komórki ukrytej. Wartość błędu  $E_{MAX}$  wskazuje na poprawne sklasyfikowanie wszystkich wektorów trenujących, co sugerować może zastosowanie sieci o 9 komórkach w warstwie ukrytej.

Kolejne etapy szacowania liczby komórek ukrytych z zastosowaniem metody pruningu komórek przedstawiono na rys. 8.5. Redukcję liczby komórek rozpoczęto od sieci zawierającej 20 komórek w warstwie ukrytej (zob. również rys. 8.6). Wykazano w tym przypadku możliwość zmniejszenia liczby komórek do 15. Przeprowadzenie symulacji sieci 13-15-3 pozwoliło na kolejną redukcję liczby komórek. Kontynuując symulacje uzyskano wynik wskazujący na możliwość zastosowania 7 komórek ukrytych.



Rys. 8.4. Szacowanie liczby komórek ukrytych z zastosowaniem algorytmu ATS-des

Fig. 8.4. Hidden node number estimation with use of the ATS-des algorithm



Rys. 8.5. Szacowanie liczby komórek ukrytych z zastosowaniem metody pruningu komórek

Fig. 8.5. Estimation of the hidden node number with use of the node pruning method

Zgodnie z przyjętym w pracy podejściem przeprowadzono ostatecznie próby arbitralnego zmniejszenia liczby komórek. Zaznacza się, że próby te zainspirowane były niektórymi wynikami uzyskiwanymi z zastosowaniem metody SW+GS. Komentując ten fakt pomija się typowe dla tej metody (sygnalizowane w poprzednich rozdziałach), znaczne wahania szacowanej liczby komórek ukrytych i zwraca się uwagę na możliwość uzyskania cennych informacji wskazujących na minimalną liczbę komórek w warstwie ukrytej. Jak wykazały przeprowadzone symulacje, istniała możliwość realizacji treningu sieci neuronowej FFBP o jedynie 5÷6 komórkach ukrytych.

Podjętą dyskusję wykazanego zróżnicowania liczby komórek ukrytych zwraca się szczególnie uwagę na metodę ATS-des. W przypadku tej metody konieczna wydaje się analiza wartości nie tylko błędu maksymalnego  $E_{MAX}$ , ale również błędu skutecznego  $E_{RMS}$ , ponieważ

Struktura sieci neuronowej FFBP		Reprezentacja elementów wektora wejściowego	Sprawność sieci FFBP
Struktura początkowa	13-20-3		95.7%
Struktura podstawowa	13-6-3		94.7%

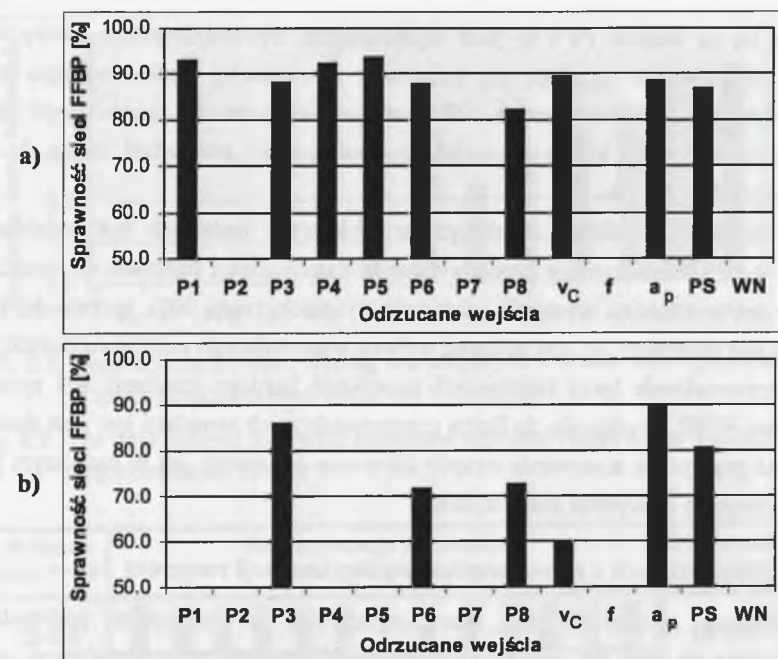
Rys. 8.6. Struktury początkowa i podstawowa oraz sprawności sieci neuronowej FFBP

Fig. 8.6. The initial and basic structures and respective performances of the FFBP neural network

dążenie do uzyskania 100% sprawności treningu (obserwacja tylko i wyłącznie zmian wartości błędu  $E_{MAX}$ ) doprowadzić może do znacznego przewymiarowania struktury sieci FFBP. Sugerowane analizy błędu  $E_{RMS}$  powodują oczywiście konieczność podejmowania przez Użytkownika arbitralnych decyzji o liczbie komórek ukrytych. W konsekwencji konieczne jest niedogodne, wielokrotne powtarzanie symulacji, mające na celu weryfikację możliwości realizacji treningu sieci o przyjętej strukturze.

Za zdecydowanie korzystniejsze uznać należy jednoznaczne wskazanie na 7 komórek ukrytych z zastosowaniem metody pruningu komórek. Sygnalizuje się również możliwość bardziej ogólnej interpretacji uzyskanego w tym przypadku wyniku. Odwołując się do możliwości zmniejszenia liczby komórek ukrytych zaznaczyć należy, że trening sieci o 5 komórkach ukrytych wymagał 2÷3-krotnie większej liczby iteracji w porównaniu z treningiem sieci o 7 komórkach ukrytych. Następnie, w ponad połowie symulacji konieczne było kilkakrotne inicjalizowanie wag (powtarzanie symulacji) ze względu na blokowanie treningu. Obserwowano także zmniejszenie sprawności klasyfikacji do poziomu 92%. Przyjął zatem można, iż zastosowanie metody pruningu komórek umożliwia nie tylko bardziej wiarygodne oszacowanie liczby komórek ukrytych, ale również uzyskanie istotnych informacji dotyczących możliwości realizacji treningu sieci neuronowej FFBP. Oznacza to, że przyjmując liczby komórek mniejsze (lub znacznie mniejsze) od oszacowanych z zastosowaniem metody pruningu, spodziewać się można występowania utrudnień w realizacji treningu sieci czy też zmniejszenia zdolności generalizacji.

Uwzględniając powyższą dyskusję, do dalszych testów przyjęto ostatecznie sieć neuronową o strukturze podstawowej 13-6-3 (rys. 8.6). Sieć ta wymaga zidentyfikowania podczas treningu wartości 112 parametrów, tj. wag i wartości progowych. Podkreślić należy, że w poprzednich pracach autora (np. [Sokołowski i Kosmol, 1996a], [Sokołowski i Kosmol, 1999], [Sokołowski i Kosmol, 1999a]) przyjmowano większe liczby komórek ukrytych, co może w niektórych przypadkach utrudniać porównywanie uzyskanych wyników.



Rys. 8.7. Sprawności sieci FFBP uzyskiwane w przypadkach eliminacji wybranych wejść, analizowany podzbiór 9 (a) oraz 6 wejść (b)

Fig. 8.7. The FFBP neural network performance achieved while neglecting selected inputs, analysed sub-set of 9 (a) and 6 (b) inputs

### 8.2.3. Próba selekcji danych z zastosowaniem metody *leave-one-out*

Selekcję z zastosowaniem metody *leave-one-out* przeprowadzono etapami, eliminując permanentnie w każdym etapie jedno wejście. Charakteryzując zastosowane podejście dogodne jest odwołanie się do wybranych etapów selekcji przedstawionych na rys. 8.7. Interpretując sprawności sieci FFBP z rys. 8.7 podkreśla się, że sprawności te są sprawnościami średnimi, wyznaczonymi po odrzuceniu danego wejścia. Przykładowo (rys. 8.7a), odrzucenie wejścia P5 pozwala na uzyskanie najwyższej ( $S_{FFBP}=93.6\%$ ) sprawność klasyfikacji, co równoznaczne jest z uznaniem najniższej istotności tego wejścia. Konsekwencją jest permanentne odrzucenie wejścia P5 i przejście do kolejnego etapu, w którym ponawiane są próby eliminacji, a tym samym oceny istotności pozostałych 8 wejść.

Odrzucając permanentnie kolejne wejścia uzyskano podzbiór 6 wejść przedstawiony na rys. 8.7b. Porównując etapy selekcji z rys. 8.7a i rys. 8.7b, zwraca się uwagę na zmiany wartości sprawności odpowiadających poszczególnym wejściom. W przypadku rys. 8.7a wskazać można na kilka wejść o zbliżonej, a tym samym kłopotliwej w ocenie istotności, np. wejścia P3, P6, v<sub>C</sub> i a<sub>p</sub>. Analizując natomiast etap selekcji z rys. 8.7b jednoznacznie

wskazuje się na wejścia P6 i  $v_c$  jako najistotniejsze. Stwierdzić zatem należy, iż stosując metodę *leave-one-out* uzyskuje się informacje o istotności wejść znacząco zależne od analizowanego podzbioru danych. W praktyce oznacza to konieczność stopniowej, długotrwałej eliminacji kolejnych wejść, co potencjalnie prowadzić może do uzyskania zadowalających wyników.


Ostatecznym wynikiem uzyskanym w niniejszych badaniach był podzbiór 4 wejść {P6, P8,  $v_c$ , PS}. Jak zostanie przedstawione w dalszej części rozdziału (podrozdział 8.3.1), podzbiór ten pozwala na uzyskanie relatywnie wysokich, rzędu 90%, sprawności sieci FFBP. Znaczące jest natomiast, że, aby dokonać wyboru wspomnianego podzbioru danych, konieczne było przeprowadzanie (przy założeniu 5 powtórzeń każdego treningu) 405 symulacji sieci neuronowej FFBP. Wydaje się, że liczba przeprowadzonych symulacji jest zbyt duża, aby móc sugerować praktyczne stosowanie metody *leave-one-out* nawet, jak w niniejszym przypadku, zbiorów danych o relatywnie małej liczności.

#### 8.2.4. Selekcja danych z zastosowaniem analizy korelacji rangowej

Podstawą selekcji danych charakteryzowanej w niniejszym podrozdziale było przedstawione na rys. 8.8 uporządkowanie wejść zgodnie ze wzrastającymi wartościami bezwzględnymi współczynnika korelacji rangowej  $\tau$ -Kendalla. Dodać można, że w pełni analogiczne uporządkowanie wejść uzyskano w przypadku zastosowania miary korelacji rangowej R Spearmana. Próby integracji podzbiorów danych poprzedzono analizą korelacji danych wejściowych. Wykazano istnienie pary wejść (P7, P8) o wartości współczynnika korelacji ( $R_{P7,P8}=0.811$ ) powyżej przyjętego progu  $R=0.80$ . Stąd też, po uwzględnieniu wartości współczynników korelacji rangowej z rys. 8.8, odrzucono wejście P7 ze zbioru danych wejściowych. Odrzucenie tego wejścia nie spowodowało zniżenia sprawności klasyfikacji, co wykazały próby integracji podzbioru pozostałych 12 wejść przeprowadzone z zastosowaniem sieci neuronowej FFBP (rys. 8.9).

Podjęta w kolejnym kroku eliminacja wejść zgodnie z kolejnością wynikającą z rys. 8.8 prowadziła jednakże do znacznego obniżenia sprawności sieci FFBP (rys. 8.9). Zwraca się uwagę na relatywnie niską, rzędu 85%, sprawność klasyfikacji uzyskaną w przypadku symulacji sieci o 10 wejściach (analogiczne sprawności uzyskiwano w przypadku integracji 9 i 8 danych). Ponadto wskazuje się na obniżenie sprawności poniżej 80% (podzbiór 7 i 6 danych), brak możliwości realizacji treningu sieci FFBP o 5 wejściach oraz kłopotliwe wahania liczby błędów klasyfikacji w poszczególnych symulacjach.

Komentując uzyskane wyniki uwypuklić należy przypisanie niskich istotności parametrom obróbki, co jak wykazano, decydowało o niezadowalającej jakości integracji wyselekcjonowanych danych (por. podrozdział 8.2.3). Potwierdza się w ten sposób



Rys. 8.8. Dane uporządkowane według wzrastających wartości bezwzględnych współczynnika korelacji rangowej  $\tau$ -Kendalla


Fig. 8.8. The data ordered following increasing absolute values of the  $\tau$ -Kendall rang correlation factors

Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego	Sprawność sieci FFBP
12-6-3	P1 P2 P3 P4 P5 P6 P7 P8 $v_c$ f $a_p$ PS WN	95.5%
10-6-3	P1 P2 P3 P4 P5 P6 P7 P8 $v_c$ f $a_p$ PS WN	85.1%
7-7-3	P1 P2 P3 P4 P5 P6 P7 P8 $v_c$ f $a_p$ PS WN	79.7%
6-7-3	P1 P2 P3 P4 P5 P6 P7 P8 $v_c$ f $a_p$ PS WN	76.3%

Rys. 8.9. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem analizy korelacji rangowej  $\tau$ -Kendalla

Fig. 8.9. The results obtained while integrating data selected based on the  $\tau$ -Kendall rang correlation analysis

wnioski i sugestie z rozdziału 6, gdzie wskazywano na konieczność zachowania ostrożności w stosowaniu analizy korelacji rangowej do oceny istotności parametrów obróbki. Przypomina się również, że w badaniach przedstawionych w rozdziale 6 uzyskano wzrost sprawności klasyfikacji stanów narzędzia poprzez arbitralne uznanie istotności parametrów obróbki. Podejście takie wydaje się być mało uzasadnione w przypadku niniejszych badań, ponieważ prowadzi do zawyżenia liczności podzbiorów danych (por. podrozdział 8.2.3).



Rys. 8.10. Istotności wejść wyznaczone z zastosowaniem metod bazujących na sieci neuronowej FFBP

Fig. 8.10. Input importance determined with the FFBP neural network based methods

### 8.3. Integracja danych z zastosowaniem sieci neuronowej FFBP

#### 8.3.1. Integracja danych wyselekcjonowanych z zastosowaniem metod bazujących na sieci neuronowej FFBP

Istotności wejść wyznaczone z zastosowaniem metod bazujących na sieci neuronowej FFBP przedstawiono na rys. 8.10. Oceniając wstępnie uzyskane wyniki wskazuje się na wejścia P5 i P7, charakteryzujące się najniższymi istotnościami. Zwraca się szczególną uwagę na wejście P7, skorelowane z wejściem P8 ( $R_{P7,P8}=0.811$ , zob. podrozdział 8.2.4). Jak można zauważyć, zastosowane metody selekcji umożliwiły wyraźne zróżnicowanie istotności tych wejść, co stanowi kolejną formę weryfikacji wniosków z rozdziału 5. Dodaje się również, że w przypadku niniejszego zadania nie wykazano zawyżania liczności podzbiorów danych przez dane uznane za skorelowane (przyjęto  $R \geq 0.75$ ). Kontynuując przypomina się, iż wejście P5 reprezentuje wartości skuteczne prędkości drgań wyznaczone w paśmie, w którym analizowano wartość składowej widma o częstotliwości  $f \approx 7200$  Hz, uznaną za jeden z podstawowych symptomów zużycia VB<sub>B</sub>. Potwierdzona w poniższych analizach niska istotność wejścia P5 świadczy o pewnej tendencyjności w przypadku arbitralnego wyboru symptomów zużycia ostrza, tzn. poszukiwaniu symptomów o "największych zmianach wartości" lub "zmianach najbardziej widocznych i monotonicznych". Jak można stwierdzić, stosowanie tego typu kryteriów nie zawsze jest słuszne.

Dyskusję wyników przedstawionych na rys. 8.10 można również ukierunkować na próbę wyboru wejść najistotniejszych, co prowadzi do jednoznacznego wskazania na wejścia P6 i P8. Potwierdzeniem wysokiej istotności wejść P6 i P8 jest uzyskana sprawność sieci neuronowej FFBP o strukturze 11-8-3, rys. 8.11. Odrzucenie wejść P6 i P8 spowodowało radykalne obniżenie sprawności klasyfikacji do poziomu 82%.

Powyższe uwagi i komentarze w zdecydowanie mniejszym stopniu odnoszą się do oceny istotności danych dokonanej z zastosowaniem metody A-Karina. Już pobieżna analiza wyznaczonych istotności prowadzi do wniosku o możliwości diagnozowania stanu ostrza z zastosowaniem głównie informacji o parametrach obróbki. Z punktu widzenia potencjalnego Użytkownika wnioski takie należy za mało przekonujące.

Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego													Sprawność sieci FFBP
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS	WN	
11-8-3	■	■	■	■	■	■	■	■	■	■	■	■	■	81.9%

Rys. 8.11. Symulacja sieci neuronowej FFBP zrealizowana z pominięciem wejść P6 i P8

Fig. 8.11. The FFBP neural network simulation conducted while neglecting P6 and P8 inputs


MS( pruning wag )		
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego	Sprawność sieci FFBP
11-5-3		93.1%
7-8-3		92.8%
5-7-3		92.8%
4-8-3		90.4%

Rys. 8.12. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metody pruningu wag

Fig. 8.12. Results obtained while integrating data selected based on the weight pruning method

Wybrane wyniki integracji danych wyselekcjonowanych z zastosowaniem metody pruningu wag przedstawiono na rys. 8.12. Jak można zauważyć, odrzucenie 2 wejść spowodowało nieznaczne zmniejszenie sprawności sieci FFBP do poziomu 93% (por. rys. 8.6). Jednakże wahania sprawności klasyfikacji  $\pm 1$  błąd klasyfikacji (w niniejszych testach  $\pm 1.3\%$ ) uznaje się za dopuszczalne i naturalne dla zastosowań sieci FFBP. Sprawności rzędu 93% uzyskiwane były w przypadku eliminacji kolejnych 4 wejść. Wybór podzbioru 6 wejść wymaga natomiast komentarza wyjaśniającego sposób określenia kolejności eliminacji danych. Problematiczne jest w tym przypadku niewielkie zróżnicowanie wartości istotności wejść P1, f oraz  $a_p$ . (rys. 8.10). Aby uniknąć błędnego wyboru wejścia do odrzucenia, przeprowadzono powtórny ocenę istotności 7 danych uznanych zgodnie z rys. 8.10 za najistotniejsze. Charakterystycznym uzyskane wyniki (rys. 8.13) wskazuje się na zwiększenie zróżnicowania wartości istotności, stanowiące zasadniczy cel zastosowanego podejścia. Potencjalny Użytkownik uzyskuje informacje o niższej istotności wejścia  $a_p$  oraz f, co ułatwia podjęcie decyzji o eliminacji wejść i prowadzi ostatecznie do w pełni zadowolających wyników (rys. 8.12).

Podsumowując dyskusję wyników z rys. 8.12 podkreśla się możliwość znacznego zmniejszenia liczby wejść z zachowaniem sprawności klasyfikacji na poziomie 93% (sieć FFBP 5-7-3). Odrzucenie kolejnego wejścia powodowało obniżenie sprawności do bezwzględnie akceptowalnego poziomu 90% (sieć FFBP 4-6-3). Możliwy był także arbitralny wybór 3 wejść {P6, P8,  $v_c$ }, pozwalających na uzyskanie sprawności rzędu 81%.


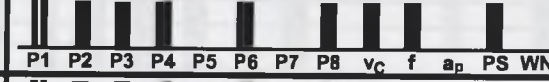
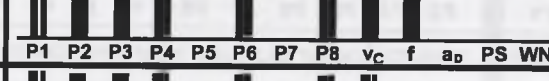
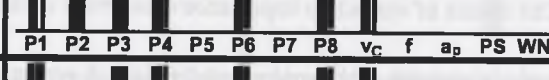
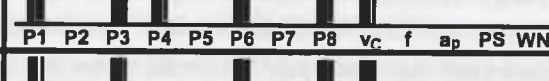
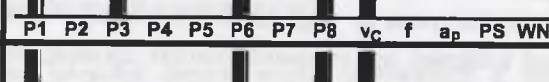
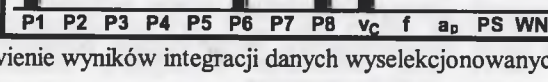


Rys. 8.13. Wyniki powtórnej oceny istotności wybranych danych

Fig. 8.13. The results of secondary importance assessment of the selected data

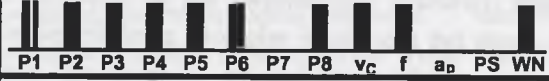
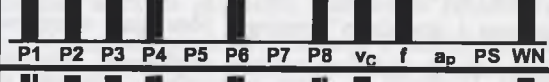
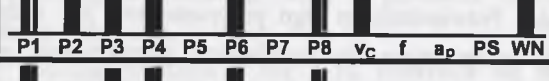
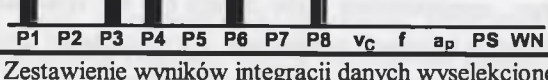
Uwypuklenia wymaga również możliwość eliminacji danych reprezentujących parametry obróbki. Potencjalny Użytkownik może odrzucić informacje reprezentujące wysięg narzędzia (WN), posuwu (f) i głębokości skrawania ( $a_p$ ). Możliwość pominięcia głębokości skrawania uznaje się za szczególnie korzystną ze względu na kłopotliwe, w niektórych przypadkach, określenie wartości tej wielkości, np. przypadek obróbki zgrubnej. Możliwość odrzucenia informacji o wspomnianych parametrach obróbki należy oczywiście rozważać w świetle poprawnego wyboru wejść reprezentujących cechy sygnału pomiarowego, kompensujące informacje wprowadzane przez wejścia odrzucone.

Kontynuując podsumowanie testów metody pruningu wag zwraca się uwagę na występowanie trudnych do realizacji treningów sieci o 8, 7 i 6 wejściach. Obserwowano w tych przypadkach wzrost liczby iteracji koniecznej do uzyskania założonego błędu treningu (przyjęto  $E_{MAX}=0.15$ ), blokowanie treningu oraz zwiększenie zróżnicowania uzyskiwanych sprawności klasyfikacji. Konieczne było również radykalne zmniejszenie wartości współczynnika treningu ( $\eta_F=0.01$ ). Domniemywa się, że przyczyną wystąpienia utrudnień w realizacji treningu mogły być specyficzne zależności pomiędzy poszczególnymi wejściami. Wprowadzenie do sieci dwóch wejść lub ich równoczesne odrzucenie pozwala na przeprowadzenie „łatwego i szybkiego” treningu. Natomiast wprowadzenie tylko jednego z wejść może powodować, iż niektóre wektory wejściowe „przyswajane są” przez sieć zdecydowanie trudniej. Potwierdzeniem tego przypuszczenia jest stabilizacja treningu sieci o 5 i 4 wejściach, przejawiająca się możliwością przywrócenia początkowej wartości współczynnika treningu, zmniejszeniem liczby iteracji czy też zmniejszeniem zróżnicowania sprawności uzyskiwanych w kolejnych symulacjach. Przypuszcza się również, że dyskutowane zależności mogły mieć wpływ na wyznaczone istotności danych (rys. 8.10). Wskazuje się na problematyczną interpretację wyznaczonych istotności w świetle uzyskanych sprawności klasyfikacji. Pomimo przypisania zbliżonych, relatywnie wysokich istotności (rys. 8.10) możliwa była skuteczna eliminacja danych (rys. 8.12).

MS( suma wag )		
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego	Sprawność sieci FFBP
10-5-3		91.7%
9-6-3		89.6%
8-8-3		92.3%
7-6-3		90.4%
6-8-3		84.3%
5-7-3		85.1%
4-7-3		83.7%

Rys. 8.14. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metody sumy wag

Fig. 8.14. Results obtained while integrating data selected based on the weight sum method

MS( analiza wrażliwości )		
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego	Sprawność sieci FFBP
10-8-3		90.7%
9-6-3		88.5%
8-7-3		89.1%
5-9-3		76.8%

Rys. 8.15. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metody analizy wrażliwości

Fig. 8.15. Results obtained while integrating data selected based on the sensitivity analysis method

W kolejnym kroku przeprowadzono integrację danych wyselekcjonowanych metodą sumy wag (rys. 8.14). Zgodnie z rys. 8.10, najniższymi istotnościami charakteryzowały się odrzucone w pierwszej kolejności wejścia  $\{a_p, P7, P5\}$ . Jak można zauważyć, odrzucenie tych wejść spowodowało obniżenie sprawności klasyfikacji. Obniżenie sprawności, podobnie jak w przypadku metody pruningu wag, nie ma charakteru krytycznego. Jednakże uzyskanie niższych sprawności sygnalizować może, iż wejście  $a_p$  reprezentujące głębokość skrawania nie jest wejściem, które powinno być eliminowane jako jedno z pierwszych. Potwierdzeniem tego przypuszczenia jest utrzymywanie się sprawności klasyfikacji na niższym niż w przypadku metody pruningu wag poziomie (symulacje sieci o liczbie wejść od 10 do 7, rys. 8.14). Za znaczące uważa się również występowanie scharakteryzowanych w odniesieniu do metody pruningu wag utrudnień w symulacji sieci FFBP, ujawniających się już w przypadku sieci o 10 wejściach oraz wahania sprawności klasyfikacji wraz ze zmniejszaniem liczby wejść.

Analizując przedstawione na rys. 8.14 kolejne podzbiory wejść oraz odpowiadające im sprawności klasyfikacji zauważa się utrzymywanie sprawności na poziomie 90% wraz z sukcesywną eliminacją wejść reprezentujących parametry obróbki. Wyraźne obniżenie sprawności występuje natomiast po odrzuceniu wejścia P2 (sieć FFBP 6-8-3, rys. 8.14). Podejmując próbę wyjaśnienia przyczyny obniżenia sprawności klasyfikacji można ponownie odwołać się do selekcji danych metodą pruningu wag (rys. 8.12), co prowadzi do stwierdzenia, że wejście P2 nie jest wejściem koniecznym do uzyskania wysokich sprawności sieci FFBP. Istotne natomiast może być w tym przypadku występowanie wejść wprowadzających specyficznie kompensujące się informacje. Przypuszcza się, że informacje wprowadzane przez wejście P2 kompensowały informacje wprowadzane przez kolejno eliminowane wejścia reprezentujące parametry obróbki (głównie wejście PS). W tym świetle uznać można wysoką istotność wejścia P2, a tym samym możliwość obniżenia sprawności klasyfikacji w efekcie odrzucenia tego wejścia.

Kolejną metodą selekcji danych diskutowaną w niniejszym podrozdziale jest metoda analizy wrażliwości (rys. 8.15). W pierwszym kroku wskazuje się na wybór tych samych podzbiorów 6 i 7 danych jak w przypadku metody sumy wag. Stąd też na rys. 8.15 przedstawia się te wyniki, które różnią się od wyników przedstawionych na rys. 8.14. Następnie, porównując symulacje sieci neuronowych o 10, 9 i 8 wejściach, zauważa się uzyskiwanie zbliżonych lub nieznacznie niższych, w przypadku metod analizy wrażliwości, sprawności klasyfikacji. Porównanie takie może mieć bardzo praktyczne znaczenie dla Użytkownika testującego alternatywne kolejności eliminacji wejść. Niemniej jednak zaznaczyć należy, że sprawności podane na rys. 8.15 należy traktować jako przybliżone ze względu na występowanie znacznych wahań liczby błędów klasyfikacji (np.  $\pm 3$  błędy klasyfikacji). Równie znaczące jest stosowanie zbioru testującego do wyznaczenia liczby komórek ukrytych sieci o 10, 9 i 8 wejściach, co oznacza prowadzenie w tym miejscu (rys. 8.15) dyskusji wybranych, najkorzystniejszych z uzyskanych wyników.

MS( met. A-Karina )													
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego											Sprawność sieci FFBP	
9-6-3	█	█				█	█	█	█	█	█	█	93.3%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	
8-6-3	█	█				█	█	█	█	█	█	█	78.4%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	
7-7-3	█	█				█	█	█	█	█	█	█	75.5%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	

Rys. 8.16. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metody A-Karina

Fig. 8.16. Results obtained while integrating data selected based on the A-Karin method

Podjmując ostatecznie dyskusję selekcji danych z zastosowaniem metody A-Karina dogodnie jest przypomnieć, że istotności wejść wyznaczone z zastosowaniem tej metody wskazywały na interesującą, aczkolwiek wątpliwą z punktu widzenia praktycznego zastosowania możliwość eliminacji wejść reprezentujących cechy sygnału pomiarowego. Potwierdzeniem mało wiarygodnej, co sygnalizowano również w komentarzu do rys. 8.10, oceny istotności wejść są uzyskane sprawności klasyfikacji. Eliminując wejścia zgodnie z kolejnością wynikającą z rys. 8.10 wybrano podzbiór 9 danych, pozwalający na uzyskanie wysokiej sprawności klasyfikacji  $S_{FFBP}=93.7\%$ . Krytyczne natomiast było odrzucenie wejścia P8, powodujące radykalne zmniejszenie sprawności sieci FFBP poniżej poziomu 80%. Przypomnieć można, że wejście P8 uznane było za jedno z najistotniejszych zgodnie z istotnościami wyznaczonymi z zastosowaniem pozostałych metod bazujących na sieci FFBP.

### 8.3.2. Integracja danych wyselekcjonowanych z zastosowaniem metod bazujących na macierzy rozproszenia i metody SR+AG

Zestawienie wybranych wyników integracji danych wyselekcjonowanych z zastosowaniem metod bazujących na macierzy rozproszenia przedstawiono na rys. 8.17. Podkreśla się, że w przypadku metody SM+AG przedstawiono tylko wyniki tych symulacji, w których stosowano podzbiory wejść różniące się od podzbiorów wyselekcjonowanych metodą SM+SFS. Charakteryzując przeprowadzone testy wskazuje się na relatywnie małe zróżnicowanie wartości śladu macierzy rozproszenia  $J_{SM}$  wyznaczanego dla podzbiorów danych wybieranych z zastosowaniem algorytmu SFS i algorytmu genetycznego AG. Zwraca się w ten sposób uwagę na brak możliwości prognozowania zróżnicowania jakości integracji wybranych danych. Również zmiany wartości  $J_{SM}$  uniemożliwiały wskazanie podzbioru danych o małej liczności, potencjalnie zapewniającego uzyskanie wysokiej sprawności klasyfikacji.

Powracając do oceny sprawności klasyfikacji wyselekcjonowanych danych jednoznacznie należy wskazać na uzyskanie w pełni zadowalających wyników. Podkreśla się możliwość uzyskania sprawności klasyfikacji zbliżonych do 90% z zastosowaniem podzbiorów 6 wejść. Równie korzystnie należy ocenić możliwość zmniejszenia liczby wejść do 5 bez obniżenia sprawności sieci neuronowej FFBP poniżej 80%.


Dokonując natomiast charakterystyki testów metody SR+AG ograniczono się do uogólniającego komentarza ze względu na wykazanie braku przydatności tej metody do selekcji analizowanych w niniejszym podrozdziale danych. Za zdecydowanie problematyczne uznano wskazanie na podzbiór jedynie 6 wejść stosując  $UP_w=0.0$ . Wynik ten uniemożliwia praktycznie ocenę istotności pozostałych wejść. Jednocześnie uzyskano niską sprawność sieci o strukturze 6-7-3 ( $S_{FFBP}=81.9\%$ ), a próba odrzucenia kolejnego wejścia spowodowała spadek sprawności klasyfikacji do wartości 74.4%.

MS( SM+SFS )													
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego											Sprawność sieci FFBP	
9-7-3	█	█	█	█	█	█	█	█	█	█	█	█	93.6%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	
8-7-3	█	█				█	█	█	█	█	█	█	89.3%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	
6-7-3	█	█				█	█	█	█	█	█	█	89.3%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	
5-9-3		█				█	█	█	█	█	█	█	82.9%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	

MS( SM+AG )													
Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego											Sprawność sieci FFBP	
8-6-3	█	█	█	█	█	█	█	█	█	█	█	█	91.7%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	
6-8-3	█	█				█	█	█	█	█	█	█	88.8%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	
5-8-3	█	█				█	█	█	█	█	█	█	85.1%
	P1	P2	P3	P4	P5	P6	P7	P8	v <sub>c</sub>	f	a <sub>p</sub>	PS WN	

Rys. 8.17. Zestawienie wyników integracji danych wyselekcjonowanych z zastosowaniem metod bazujących na macierzy rozproszenia SM+SFS i SM+AG

Fig. 8.17. Results obtained while integrating data selected with the scatter matrix based methods SM+SFS and SM+AG



Rys. 8.18. Uzyskane sprawności klasyfikacji sieci neuronowej FFBP w funkcji liczby wejść

Fig. 8.18. The obtained FFBP neural network classification performance against input number

### 8.3.3. Podsumowanie zastosowań sieci neuronowej FFBP

W celu dokonania wstępnego podsumowania testów sieci neuronowej FFBP na rys. 8.18 zestawiono uzyskane sprawności klasyfikacji w funkcji liczby wejść. Analiza zestawienia z rys. 8.18 prowadzi do jednoznacznego wskazania na metodę pruningu wag jako metodę umożliwiającą wybór podzbiorów danych o najmniejszej liczności i uzyskiwanie najwyższych sprawności klasyfikacji. Podejmując natomiast próby wstępnej oceny pozostałych metod selekcji dogodnie jest zastosowanie kryteriów pomocniczych. Przyjmując kryterium minimalnej liczby wejść (danych) koniecznej do uzyskania sprawności powyżej 90%, wskazuje się na metody sumy wag i analizy wrażliwości (7 wejść) oraz metodę SM+AG (8 wejść). Następnie, decydując się na ograniczenie liczby wejść hipotetycznego układu diagnostycznego do przykładowo 6 wejść, jednoznacznie wskazać można na metody bazujące na macierzy rozproszenia SM+SFS i SM+AG. Dążąc natomiast do uzyskania sprawności zbliżonych do sprawności sieci o strukturze podstawowej 13-6-3 ( $S_{FFBP}=94.7\%$ , rys. 8.6), konieczne jest wprowadzenie do sieci 9 danych wyselekcjonowanych z zastosowaniem metody A-Karina lub metod bazujących na macierzy rozproszenia.

Odmiernym, aczkolwiek stosowanym już w poprzednich podrozdziałach, podejściem jest skoncentrowanie się na selekcji danych reprezentujących parametry obróbki. Potencjalny Użytkownik za korzystniejsze uznać może te wyniki, które pozwalają na uzyskanie założonej sprawności klasyfikacji z jednoczesnym odrzuceniem jak największej liczby wejść reprezentujących parametry obróbki. Przyjmując poziom sprawności rzędu 90% wskazuje się na metodę sumy wag, w przypadku której wprowadzając do sieci 7 danych wymagane było jedynie podanie informacji o prędkości skrawania  $v_c$ . W pozostałych przypadkach wymagane było wprowadzenie co najmniej 2 danych reprezentujących parametry obróbki.

Liczba wejść	MS( suma wag )					MS( SM+SFS )				
	MKBR	MF <sub>WE</sub>	Liczba reguł		S <sub>FL</sub>	MKBR	MF <sub>WE</sub>	Liczba reguł		S <sub>FL</sub>
			pocz.	końc.				pocz.	końc.	
7	WTA(-)	-----	---	---	---	WTA(-)	-----	---	---	---
	AG-H2	2-2-2-2-2-2-2	128	8	73.3%	AG-H1	2-2-2-2-2-2-2	128	20	78.7%
6	WTA(0.1)	3-3-3-3-3-3	729	78	85.3%	WTA(0.1)	2-2-2-2-2-2	64	14	73.3%
	AG-H2	3-3-3-3-3-2	729	17	82.7%	AG-H1	2-2-2-2-2-2	64	13	80.0%
5	WTA(-)	-----	---	---	---	WTA(-)	-----	---	---	---
	AG-H2	3-3-3-3-3	243	16	66.7%	AG-H2	3-3-3-3-3	243	10	69.3%

Rys. 8.19. Zestawienie wybranych wyników integracji danych przeprowadzonej z zastosowaniem systemu logiki rozmytej


Fig. 8.19. The selected results of data integration performed with the fuzzy logic system

### 8.4. Zastosowanie systemu logiki rozmytej do integracji danych

Podobnie jak w przypadku niektórych z charakteryzowanych powyżej testów, dyskusja systemu logiki rozmytej zastosowanego jako metoda integracji danych jest znacznie zredukowana ze względu na uzyskanie zdecydowanie niezadowolających wyników. Reprezentację wybranych wielkości charakteryzujących skonstruowane systemy FL oraz sprawności klasyfikacji  $S_{FL}$  przedstawiono na rys. 8.19 w postaci analogicznej do opisów badań z rozdziału 6. Podkreślić należy, że przedstawiono te rozwiązania, które umożliwiały uzyskiwanie najwyższych, jakkolwiek nie przekraczających poziomu 86%, sprawności klasyfikacji.

Komentując przeprowadzone próby konstruowania systemu logiki rozmytej potwierdza się cechy systemu FL uwypuklone w poprzednich rozdziałach pracy. Ponownie wykazano mniejszą w porównaniu z siecią neuronową FFBP zdolność uczenia, przejawiającą się występowaniem błędów klasyfikacji po zakończeniu treningu. Przyjęto, że za poprawnie skonstruowany system FL uważa się system osiągający sprawność treningu powyżej 90% (maksymalnie 4 błędy klasyfikacji). Następnie potwierdzono negatywny wpływ liczby wejść na sprawność klasyfikacji. Podejmując próby integracji 8+9 danych uzyskiwano sprawności rzędu 70% lub też stwierdzano brak możliwości skonstruowania systemu FL. Przedstawienie na rys. 8.19 wyników integracji danych wyselekcjonowanych z zastosowaniem metody sumy wag i metody SM+SFS potwierdza także możliwość występowania zależności pomiędzy metodami selekcji i integracji. Ostatecznie odnieść się można do wykazanego zróżnicowania metod konstruowania bazy reguł. Wskazać w tym przypadku należy na metodę AG-H\*, zastosowanie której stanowiło w większości symulacji o powodzeniu w konstruowaniu systemów FL.






Rys. 8.20. Zestawienie sprawności klasyfikacji sieci neuronowej FFBP i systemu logiki rozmytej w funkcji liczby wejść

Fig. 8.20. The classification performance of FFBP neural network and fuzzy logic system against input number

Mając na uwadze powyższe stwierdzenia i komentarze zdecydowano, aby w tym miejscu zakończyć dyskusję systemu logiki rozmytej oraz nie dokonywać porównania systemu FL i sieci neuronowej FFBP w podsumowaniu rozdziału. Przypomina się, że porównanie metod integracji danych sprowadza się zasadniczo do porównania sprawności zastępczych  $S_z$ . Zestawienie na rys. 8.20 uzyskanych sprawności klasyfikacji systemu logiki rozmytej i sieci neuronowej FFBP wskazuje na oczywisty, zdaniem autora, wniosek wynikający z takiego porównania, a tym samym stanowi dodatkowe uzasadnienie podjętej decyzji.

## 8.5. Podsumowanie badań

W celu podsumowania przeprowadzonych badań wyznaczono sprawności zastępcze bazując na sprawnościach klasyfikacji uzyskanych z zastosowaniem podzbiorów o liczebności od 4 do 9 danych (rys. 8.21). Przyjęcie tego zakresu liczby danych wynika z dążenia do uwypuklenia zróżnicowania rozpatrywanych metod selekcji (rys. 8.18). Sprawności zastępcze wyznaczono przyjmując wartości progów sprawności  $S_p=82\%$  i  $S_p=90\%$ . Dodaje się, iż przyjęcie wartości progów sprawności było relatywnie kłopotliwe ze względu na brak możliwości wskazania takich wartości  $S_p$ , które pozwalałyby na jednoznaczne rozgraniczenie uzyskanych wyników. Przykładowo, nieznaczne zwiększenie wartości progu  $S_p=90\%$ , np. o 0,5%, powoduje zmianę kolejności uporządkowania metody sumy wag i metody SM+AG na rys. 8.21b.



Rys. 8.21. Uporządkowanie metod selekcji danych według wzrastającej wartości sprawności zastępczej  $S_z$  wyznaczonej z zastosowaniem progu sprawności  $S_p=82\%$  (a) i  $S_p=90\%$  (b)

Fig. 8.21. The order of the data selection methods following increasing substitute performance values  $S_z$  determined with use of the performance threshold  $S_p=82\%$  (a) and  $S_p=90\%$  (b)

Uporządkowanie metod selekcji danych przedstawione na rys. 8.21 umożliwia potwierdzenie, a zarazem usystematyzowanie wstępnej oceny dokonanej w podrozdziale 8.3.3. Za jednoznacznie najkorzystniejszą metodą selekcji uznaje się metodę bazującą na pruningu wag. Następnie wskazać należy na metodę sumy wag i metodę SM+AG. Wartości wyznaczonych sprawności zastępczych sygnalizują jednakże, iż dokonanie selekcji z zastosowaniem tych metod w zdecydowanie mniejszym stopniu zapewnia uzyskiwanie sprawności klasyfikacji rzędu 90%. Podkreślenia wymaga również wyznaczenie wyższej wartości sprawności zastępczej dla metody SM+AG niż metody SM+SFS, co w porównaniu z oceną dokonaną w rozdziale 6 wskazuje na możliwość uzyskiwania wyników zależnych od rozwiązywanego zadania.

Dokonując uzupełniającej oceny metod selekcji zwraca się przede wszystkim uwagę na kryterium *powtarzalności wyznaczania istotności*. Zaskakująco wysoką powtarzalność wykazano w przypadku metody A-Karina ( $BPI_{MAX}=15.4\%$  oraz  $BPI_{AV}=1.9\%$ ). W badaniach charakteryzowanych w poprzednich rozdziałach niska powtarzalność stanowiła zasadniczą, dyskwalifikującą wadę tej metody. Kontynuując, za akceptowalną uznano powtarzalność wyznaczania istotności metodą pruningu wag ( $BPI_{MAX}=3$  oraz  $BPI_{AV}=0.6$ ). Uznanie akceptowalnej powtarzalności pomimo wysokiej wartości błędu  $BPI_{MAX}$  związane jest z wystąpieniem tej wartości błędu jedynie w przypadku wejścia WN. W pozostałych przypadkach uzyskiwano  $BPI_{MAX}^{(j)}=1+2$ .

Tabela 8.3

Zestawienie uzupełniających kryteriów oceny metod selekcji danych

Kryteria		Metody selekcji danych						
		MS(pruning wag)	MS(suma wag)	MS(met. A-Karina)	MS(anal. wrażliwość)	MS(SM+SFS)	MS(SM+AG)	MS(SR+AG)
1	duża powtarzalność wyznaczania istotności	1	0	2	0	2	1	-
2	możliwość nie tylko jakościowej ale również ilościowej oceny istotności danych	1	2	2	2	0	0	--
3	możliwość wskazania parametru metody selekcji pozwalającego na wybór quasi-optimalnego podzbioru danych	1	1	0	0	0	0	--
4	niski koszt obliczeniowy metody	1	1	1	1	2	0	-
Suma (max. 8 pkt) :		4	4	5	3	4	1	--

Wyraźne zmniejszenie powtarzalności wyznaczania istotności danych obserwowano analizując wyniki uzyskane z zastosowaniem metody sumy wag ( $BPI_{MAX}=31.2\%$ ,  $BPI_{AV}=5.2\%$ ) i analizy wrażliwości ( $BPI_{MAX}=42.8\%$ ,  $BPI_{AV}=5.6\%$ ). Zaznacza się, że wysokie wartości błędów, szczególnie w przypadku analizy wrażliwości, ujawniały się dla większej liczby wejść, tj. oprócz  $BPI_{MAX}^{(P1)}=42.8\%$  wyznaczono także  $BPI_{MAX}^{(P3)}=37.4\%$  i  $BPI_{MAX}^{(VC)}=23.8\%$ . Wydaje się, że niska powtarzalność wskazywać mogłaby na uznanie małej przydatności tej metody w rozpatrywanym zadaniu. Niemniej jednak, wyraźne obniżenie powtarzalności obserwuje się także w przypadku pozostałych metod, co spowodowane może być nie tyle cechami danej metody, co komentowanym w dalszej części podsumowania, specyficznym charakterem rozwiązywanego w niniejszym rozdziale zadania.

Odnosząc się do kolejnych kryteriów (tab. 8.3) wskazuje się na metodę pruningu wag i obniżenie punktacji wyrażającej stopień spełnienia kryterium *możliwości ilościowej oceny istotności danych*. Obniżenie punktacji związane jest z małym zróżnicowaniem wyznaczonych istotności utrudniającym jednoznaczną ocenę ilościową. Następnie, za jedynie częściowo spełnione lub niespełnione uznaje się *kryterium 3*. W przypadku metody sumy wag uzyskanie sprawności klasyfikacji powyżej 90% wymaga obniżenia progu istotności do wartości  $ID_p=40\%$ . Podobnie jak w rozdziale 6 próg istotności rzędu 50% uznać należy za zbyt niski w przypadku metody pruningu wag. Możliwe jest zastosowanie  $ID_p=80\%$ , prowadzące do wyboru podzbioru 7 danych i sprawności  $S_{FFBP}=92.8\%$ . Stosując  $ID_p=50\%$  wybrano podzbiór 11 danych i uzyskano sprawność klasyfikacji  $S_{FFBP}=93.1\%$ . W przypadku metody analizy wrażliwości i metody A-Karina zachowanie sprawności klasyfikacji na poziomie 90% wymaga przyjęcia wartości progu sprawności odpowiednio  $ID_p=30\%$  i  $ID_p=20\%$ .

Podsumowując uzupełniającą ocenę metod selekcji podkreśla się małe zróżnicowanie sumarycznej punktacji z tab. 8.3. W przeciwieństwie do oceny bazującej na sprawności zastępczej kłopotliwe jest zatem jednoznaczne wskazanie metody najkorzystniejszej. Niemniej jednak, uwzględniając wyznaczone sprawności zastępcze, Użytkownik uzyskuje istotne informacje o przeciwstawnych aspektach praktycznego zastosowania metod selekcji danych. Na przykładzie metody pruningu wag za korzystne uznać należy uzyskiwanie wysokich sprawności klasyfikacji. Natomiast sposób uzyskania tych wyników, wyrażający się stopniem spełnienia kryteriów uzupełniających, nie może być uznany za równie zadowalający. Analogicznie interpretuje się wyniki uzyskane z zastosowaniem najniższej ocenionej w tab. 8.3 metody SM+AG, która jest jedną z korzystniejszych metod selekcji w świetle wyznaczonych sprawności zastępczych (rys. 8.21).

Dokonując ogólnego podsumowania badań zwraca się uwagę na charakter rozpatrywanego w niniejszym rozdziale zadania. Przede wszystkim, definiując zadanie przyjęto rozpatrywać dogodny dla potencjalnego Użytkownika jednoczynnikowy układ pomiarowy. Podejście takie mogło jednak powodować ograniczenie zróżnicowania analizowanych w kolejnym kroku informacji. Równie znacząca może być liczba zdeterminowanych danych reprezentujących parametry obróbki zbliżona do liczby obciążonych szumem cech sygnału pomiarowego. Ponadto do rozwiązania zadania wymagana jest zdolność interpolacji (ogólnie zdolność generalizacji) metod integracji danych. Przypomnieć również należy o koniecznym z punktu widzenia klasyfikacji grupowaniu wartości zużycia  $VB_B$  do 3 klas. Domniemywa się, że takie zdefiniowanie zadania mogło mieć wpływ na ogólnie rozumiane wyniki testów i analiz. Wskazuje się na niższe, w porównaniu z wartościami analizowanymi w rozdziale 6, sprawności klasyfikacji. Następnie wypuklić można występowanie przypadków małego zróżnicowania istotności danych oraz zmniejszenie powtarzalności wyznaczania istotności. Obserwowano także blokowanie treningu sieci neuronowej FFBP spowodowane, jak założono, specyficznymi relacjami pomiędzy rozpatrywanymi danymi. Istotne jest również odrzucenie jako niezadowalających wyników selekcji metodą SR+AG oraz brak możliwości skutecznej integracji danych z zastosowaniem systemu logiki rozmytej.

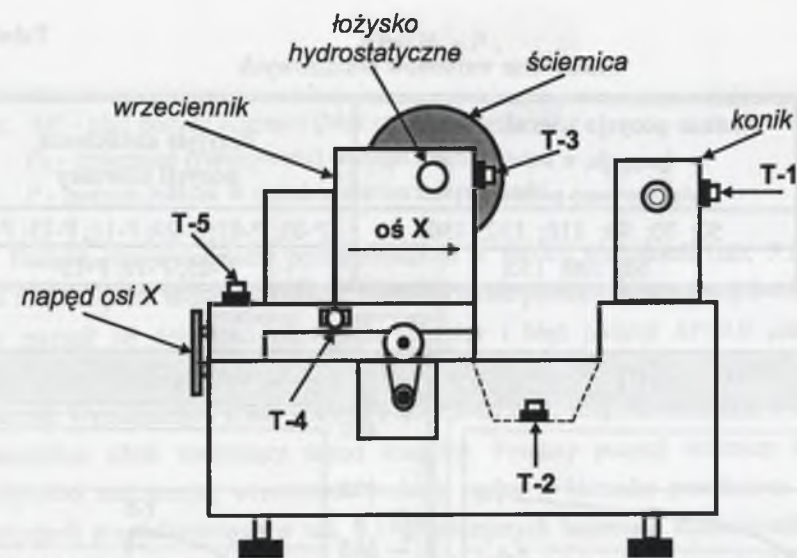
Uogólniając, zadanie rozwiązywane w niniejszym rozdziale jest, według autora, zadaniem relatywnie trudnym, co pozwala na uznanie uzyskanych wyników za jedne z najbardziej znaczących w świetle prób weryfikacji przydatności metod selekcji i integracji danych. Znaczące jest w tym przypadku wykazanie możliwości realizacji zbliżonej do efektywnej selekcji danych z zastosowaniem metody pruningu wag, a także metody sumy wag i metody SM+AG, oraz możliwości integracji wyselekcjonowanych danych z zastosowaniem sieci neuronowej FFBP. Podkreśla się, iż wspomniane metody selekcji stanowią jedne z metod opracowanych przez autora niniejszej pracy.

## 9. DIAGNOSTYKA ODKSZTAŁCEŃ TERMICZNYCH SZLIFIERKI

Odkształcenia termiczne obrabiarek do obróbki wykańczającej, a szczególnie szlifierek, uznaje się za jeden z głównych czynników wpływających na dokładność wymiarową przedmiotu obrabianego. Przytaczając przykładowo za [Campos et al., 1994] i [Campos et al., 1995], wskazać można na dwa rodzaje przyczyn zmian pola temperatur obrabiarki powodujących zmiany odkształceń termicznych, tj. przyczyny zewnętrzne i wewnętrzne. Przyczyny zewnętrzne związane są ze zmianami temperatury w otoczeniu maszyny. Przyczyny wewnętrzne odnoszą się do zmian temperatury wywoływanych generującymi ciepło elementami obrabiarki, np. silnikami, łożyskami, przewodnicami czy układami hydraulicznymi, oraz do zmian temperatury wywoływanych procesem obróbki. Podkreślić należy, że zmiany pola temperatur są nierozłącznie związane z pracą obrabiarki, co jednoznacznie stanowi o konieczności uwzględnienia problemu odkształceń termicznych w diagnostyce OPN-PS.

W praktyce przemysłowej stosuje się zróżnicowane podejścia do kompensacji wpływu odkształceń termicznych. Koncentrując się na szlifierkach i obróbce szlifowaniem wskazać można na stosowanie częstego obciążania ściernicy. To podejście, choć efektywne, powoduje wysokie zużycie ściernicy i wzrost nieproduktywnego czasu obróbki. Stosowany jest także pomiar *on-line*. Jednakże pomiar taki może być znacznie utrudniony ze względu na ograniczony dostęp do przestrzeni obróbkowej lub ze względu na kształt przedmiotu obrabianego. Podobnie problematyczna jest kompensacja liniowa nie uwzględniająca stochastycznego charakteru procesu szlifowania. Kompensację odkształceń termicznych realizować również można z zastosowaniem analitycznych modeli rozkładu temperatur w szlifierce. Do rozwiązania pozostaje w tym przypadku problem modelu nieustalonego rozptywu ciepła i złożonych oddziaływań termicznych pomiędzy poszczególnymi elementami szlifierki.

Celem niniejszych badań jest próba wyznaczenia empirycznego modelu odkształceń termicznych szlifierki, który pozwalałby na korekcję położenia ściernicy względem przedmiotu obrabianego. W badaniach skoncentrowano się na odkształceniach termicznych szlifierki w oderwaniu od realizowanego na tej obrabiarence procesu technologicznego. Podejmowana próba jest zatem „pierwszym podejściem”, odnoszącym się do zmian odkształceń termicznych szlifierki powodowanych zmianami temperatury otoczenia i ciepłem generowanym przez elementy szlifierki. Podejście takie można uznać za relatywnie uproszczone w stosunku do badań opisywanych w literaturze. Niemniej jednak podkreślić należy możliwość przeprowadzenia testów zorientowanych na weryfikację zdolności generalizacji metod integracji danych, co odzwierciedla również znaczący cel badań. Dodaje się, że charakter badań zbliżony jest do prób wykazania zdolności interpolacji, opisanych w rozdziale 8.



Rys. 9.1. Rozmieszczenie punktów pomiarowych T-1+T-5 (rozmieszczenie termopar)

Fig. 9.1. Arrangement of the measuring points T-1+T-5 (arrangement of the thermocouples)

### 9.1. Stanowisko pomiarowe i charakterystyka sygnałów pomiarowych

Badania eksperymentalne przeprowadzono na sterowanej numerycznie (CNC), wyposażonej w obrotowy układ pomiarowy, szlifierce do wałków ([Campos et al., 1994] [Campos et al., 1995]). Pomiary przeprowadzono w laboratorium University of Sao Paulo, Brazil, a zarejestrowane sygnały pomiarowe wraz z opisem badań przekazano autorowi pocztą elektroniczną w celu przeprowadzenia analiz.


W badaniach zastosowano pięć miedziowo-konstantanowych termopar, których rozmieszczenie przedstawiono na rys. 9.1. Dodatkowo mierzono temperaturę otoczenia (punkt pomiarowy T-0 nie uwzględniony na rys. 9.1). Termopary umieszczono w uznanych za istotne punktach szlifierki. Pomiaru temperatury dokonywano na koniku (punkt pomiarowy T-1), w dolnej części łoża szlifierki (T-2), w pobliżu hydrostatycznego łożyska ściernicy (T-3) oraz w końcowej części przewodnic hydrostatycznych wrzecionki (T-5). Dokonywano także pomiaru temperatury oleju w układzie hydraulicznym (T-4).

Pomiaru względnego położenia konika, reprezentującego przedmiot obrabiany, i reprezentującego ściernicę wrzecionki szlifierki dokonywano interferometrem laserowym. Dokonywano zatem pomiaru w kierunku osi X (rys. 9.1), co pozwalało na określenie różnicy zadanej w układzie sterowania pozycji ściernicy w stosunku do pozycji rzeczywistej. Wartość zadanej pozycji ściernicy odpowiada wartości promienia szlifowanego wałka. Różnica pomiędzy pozycją zadaną i zmierzoną (rzeczywistą) nazywana jest błędem pozycji (9.1) i konsekwentnie interpretowana jako błąd promienia przedmiotu obrabianego.

Zestawienie wariantów pomiarowych

Tabela 9.1

Wariant	Zadane pozycje ściernicy P [mm] (pozycje, w których dokonywano pomiarów)	Przyjęte oznaczenia pozycji ściernicy
W-I	50; 70; 90; 110; 130; 150	P-05; P-07; P-09; P-11; P-13; P-15
W-II	50; 100; 150;	P-05; P-10; P-15

Rys. 9.2. Temperatury zarejestrowane w pozycji P-05 oraz błędy pozycji  $\Delta P$ Fig. 9.2. The recorded temperatures at the P-05 position and the position errors  $\Delta P$ 

$$\Delta P = P_R - P, \quad (9.1)$$


gdzie:  $\Delta P$  - błąd pozycji ściernicy (błąd rzeczywisty);  
 $P_R$  - zmierzona (rzeczywista) pozycja ściernicy;  
 $P$  - pozycja zadana w układzie sterowania szlifierki.

Badania eksperymentalne przeprowadzono w dwóch wariantach (tab. 9.1 i rys. 9.2). Przed rozpoczęciem badań „zerowano” laserowy układ pomiarowy w pozycji P-05 przyjmując, że w pozycji tej dokonano obciążania ściernicy i błąd pozycji  $\Delta P = 0.0 \mu\text{m}$ . Następnie uruchamiano napęd wrzeciennika w osi X i realizowano cykliczny ruch wrzeciennika w zakresie wyznaczonym przez pozycje P-05 i P-15 (tab. 9.1). W Wariacie I uruchamiano równocześnie silnik realizujący napęd ściernicy. Pomiary pozycji ściernicy i temperatur dokonywano zatrzymując wrzeciennik podczas ruchu w kierunku przedmiotu obrabianego w pozycjach przedstawionych w tab. 9.1. W niniejszych badaniach analizowane są pomiary dokonywane co 3 minuty. W Wariacie II pomiary rozpoczęto z wyłączonym silnikiem napędu ściernicy. Silnik uruchomiono po 40 minutach i ponownie wyłączono po upływie 120 minut od chwili rozpoczęcia pomiarów. W tym przypadku analizowane są pomiary dokonywane co 2 minuty. Łącznie przeprowadzono 705 pomiarów.

Temperatury zarejestrowane w pozycji P-05 oraz błędy pozycji ściernicy przedstawiono na rys. 9.2. Zaznaczyć należy, że różnice temperatur rejestrowanych w chwili dokonywania pomiarów w wybranych pozycjach nie przekraczały  $0.25 \text{ }^\circ\text{C}$ , co pozwala na uznanie zmian temperatur w P-05 za reprezentatywne dla pozostałych pozycji ściernicy (rys. 9.2). Analizując wartości błędu pozycji  $\Delta P$  zauważa się, że na błąd pozycji mają wpływ nie tylko zmiany temperatur, ale także, zależny również od temperatury, błąd skoku śruby kulkowej stosowanej w napędzie wrzeciennika szlifierki. Następnie, w przypadku Wariantu I (tab. 9.1) zauważa się początkowe zmniejszanie błędu pozycji ściernicy, co odpowiada zmniejszeniu średnicy przedmiotu obrabianego. Dominujący wpływ ma w tym przypadku szybkie nagrzewanie się łożyska hydrostatycznego ściernicy, a tym samym oleju w układzie hydraulicznym. Domniemywać można, że zmniejsza się napięcie śruby kulkowej powodując zmniejszenie błędu pozycji. Po pewnym czasie dominujące stają się, jak można przyjąć, zmiany kształtu korpusu szlifierki („otwieranie się kształtu U”), powodujące zwiększanie błędu pozycji.

Podobnie interpretować można błędy pozycji ściernicy wyznaczone w pomiarach przeprowadzonych według Wariantu II (tab. 9.1). W tym przypadku nie zauważa się początkowego zmniejszenia błędu pozycji. Błąd pozycji rośnie wraz ze wzrostem temperatury. Typową zmianę przyrostów błędu pozycji zaobserwować natomiast można po uruchomieniu silnika napędu ściernicy. Szybki wzrost temperatury w punkcie T-3 powoduje zmniejszenie błędu pozycji. Równie typową zmianę zaobserwować można w chwili wyłączenia silnika napędu ściernicy.


ZESTAW DANYCH : ZD - 1



Rys. 9.3. Reprezentacja zbioru trenującego i testującego (zestaw ZD-1)


Fig. 9.3. Representation of the training and testing sets (batch ZD-1)

ZESTAW DANYCH : ZD - 2



Rys. 9.4. Reprezentacja zbioru trenującego i testującego (zestaw ZD-2)

Fig. 9.4. Representation of the training and testing sets (batch ZD-2)



Rys. 9.5. Reprezentacja zbioru trenującego i testującego (zestaw ZD-3)

Fig. 9.5. Representation of the training and testing sets (batch ZD-3)

## 9.2. Testy zdolności interpolacji sieci neuronowej FFBP

Jak zaznaczono we wprowadzeniu do niniejszego rozdziału, badania ukierunkowano na próbę weryfikacji zdolności interpolacji metod integracji danych (tym przypadku sieci neuronowej FFBP). Testy przeprowadzono z zastosowaniem zbiorów trenujących o różnej liczności. Zastosowano 3 zestawy danych zobrazowane na rys. 9.3, rys. 9.4 i rys. 9.5. Jak można zauważyć, sukcesywnie zmniejszono licznosc zbioru trenującego. W zestawie danych ZD-1 zastosowano 405 wektorów trenujących (sieć FFBP o strukturze 7-9-1), w zestawie ZD-2 340 wektorów trenujących (7-9-1) i w zestawie ZD-3 235 wektorów (7-7-1). Trening sieci prowadzono z zastosowaniem algorytmu inkrementalnego ATS-inc i  $\eta_F=0.2$ . Warunek zakończenia treningu ustalono dążąc do minimalizacji błędu  $E_{MAX}$  z jednoczesnym uwzględnieniem nieznacznych zmian (wahań) wartości błędu pozycji ściernicy w kolejnych pomiarach. Zmiany wartości błędu pozycji związane mogą być ze wzajemnym przemieszczaniem się elementów szlifierki i laserowego układu pomiarowego, powodowanym zarówno nie ujawniającymi się jednoznacznie wpływami termicznymi, jak i ruchami (drganiami) podłoża. Trening sieci neuronowej FFBP przyjęto realizować do uzyskania błędu  $E_{MAX}=0.0153$ , co odpowiadało  $\Delta P=2.0 \mu m$ .

$$B_{NN}^{(i)} = \Delta P^{(i)} - \Delta P_{NN}^{(i)} \quad (9.2)$$

$$B_{NN,j}^{MIN} = \min_{i=1,\dots,N} \{ B_{NN}^{(i)} \} \quad \text{oraz} \quad B_{NN,j}^{MAX} = \max_{i=1,\dots,N} \{ B_{NN}^{(i)} \} \quad (9.3)$$

$$B_{NN,j} = \max \{ ABS(B_{NN,j}^{MAX}), ABS(B_{NN,j}^{MIN}) \} \quad (9.4)$$

$$BS_{NN} = \frac{1}{5} \cdot \sum_{j=1}^5 B_{NN,j}, \quad (9.5)$$

gdzie:  $i$  - indeks pomiaru;

$j$  - indeks symulacji sieci neuronowej;


$B_{NN}^{(i)}$  - błąd sieci neuronowej FFBP;

$\Delta P^{(i)}$  - rzeczywisty błąd pozycji (por. (9.1));

$\Delta P_{NN}^{(i)}$  - błąd pozycji obliczony z zastosowaniem sieci neuronowej FFBP;

$BS_{NN}$  - średni, bezwzględny błąd sieci neuronowej FFBP.

Jakość wyznaczanych modeli o postaci sieci neuronowej oceniano na podstawie błędu sieci  $B_{NN}$ , opisanego zależnością (9.2). Typowo dla prowadzonych w pracy badań, symulacje sieci powtarzano 5-krotnie i w celu ujednoczenia opisów tych symulacji wyznaczano średni, bezwzględny błąd sieci neuronowej FFBP, zależność (9.5) (zob. również (9.3) i (9.4)). Podkreśla się, że błąd  $BS_{NN}$  służy głównie porównywaniu uzyskiwanych na tym etapie rozwiązań. Szczegółowa analiza wyników prowadzona jest natomiast w podsumowaniu badań.




Rys. 9.6. Przykład rzeczywistych i obliczonych z zastosowaniem sieci neuronowej FFBP błędów pozycji (zestaw ZD-2)

Fig. 9.6. An example of actual and calculated with FFBP neural network position errors (batch ZD-2)


Uzyskane wyniki skomentować można na przykładzie rzeczywistych i obliczonych z zastosowaniem sieci neuronowej FFBP błędów pozycji (rys. 9.6, rys. 9.7 oraz rys. 9.8). Pomija się w tym przypadku zestaw ZD-1, dla którego uzyskane wyniki uznaje się za w pełni zadowalające. Błąd sieci neuronowej wyznaczony z zastosowaniem zbioru testującego nie przekraczał  $3\mu\text{m}$  ( $BS_{NN}=3.0\mu\text{m}$ ). Rozpatrywany błąd wzrósł do w pełni akceptowalnej wartości  $BS_{NN}=4.3\mu\text{m}$  w przypadku zestawu ZD-2 (rys. 9.6, rys. 9.8). Przypomnieć należy, że trening sieci prowadzono do uzyskania błędu, który wyrazić można jako  $BS_{NN}=2.0\mu\text{m}$ . Zwraca się także uwagę na znaczne ograniczenie ilości informacji prezentowanych sieci podczas treningu. Sieci neuronowej FFBP prezentowano jedynie dane rejestrowane w skrajnych położeniach ściernicy.

Uzyskanie zadowalających wartości błędu stanowi o potwierdzeniu zdolności generalizacji sieci neuronowej FFBP, ujawniającej się w tym przypadku zdolnością interpolacji rozwiązań ze względu na położenie ściernicy. Stwierdzenie to ma dwa istotne aspekty. Podejmując próby zastosowania sieci FFBP do wyznaczenia modelu odkształceń termicznych szlifierki można w znacznym stopniu ograniczyć zakres pomiarów prowadzonych w celu



Rys. 9.7. Przykład rzeczywistych i obliczonych z zastosowaniem sieci neuronowej FFBP błędów pozycji (zestaw ZD-3)

Fig. 9.7. An example of actual and calculated with FFBP neural network position errors (batch ZD-3)



Rys. 9.8. Średnie, bezwzględne błędy sieci neuronowej FFBP ( $BS_{NN}$ )

Fig. 9.8. The average, absolute errors of the FFBP neural network ( $BS_{NN}$ )

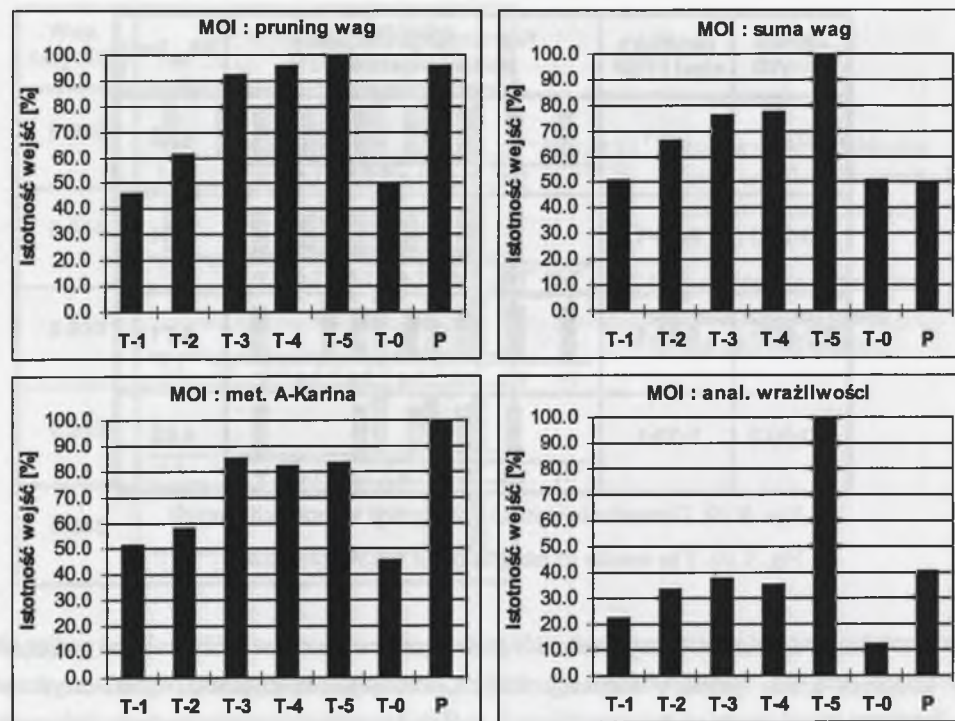
zgromadzenia danych koniecznych do skonstruowania sieci. Jednocześnie założyć można dużą dokładność obliczeń  $\Delta P$  w przypadku praktycznego zastosowania sieci neuronowej FFBP do określenia błędu pozycji, która nie była reprezentowana w danych zastosowanych do konstruowania sieci.

Kolejna próba ograniczenia liczności zbioru trenującego (zestaw ZD-3) spowodowała jednakże znaczny wzrost błędu  $B_{NN}$  (a tym samym  $BS_{NN}$ , rys. 9.7 i rys. 9.8). W fazie symulacji sieci neuronowej FFBP obserwowano przypadki wydłużonego treningu lub wymagające powtórzeń blokowania treningu. Charakteryzując przykładowe wyniki przedstawione na rys. 9.7, uznać należy, że sieć FFBP „uchwyciła” wpływ zmian temperatur na błąd pozycji. Niemniej jednak zastosowanie danych reprezentujących tylko pomiar w pozycji P-10 (Wariant II, tab. 9.1) spowodowało, iż obliczone wartości błędu pozycji są „niewłaściwie skalowane”. Analogiczne wyniki uzyskano z zastosowaniem zbioru trenującego zawierającego dane reprezentujące jedynie Wariant I, tj. wprowadzając do sieci dane zgodnie z zestawem ZD-1 (rys. 9.3), pomijając w tym zestawie dane z Wariantu II. Obliczone z zastosowaniem sieci FFBP błędy pozycji odzwierciedlały wpływ zmian temperatury w punkcie pomiarowym T-3 i T-4. Błąd sieci wzrósł jednakże do nieakceptowalnej wartości  $BS_{NN} \approx 30 \mu m$ .

### 9.3. Próba selekcji danych

W podjętych próbach selekcji danych zastosowano zestaw danych ZD-2 (rys. 9.4). Istotności danych wyznaczone z zastosowaniem metod bazujących na sieci neuronowej FFBP (sieć o strukturze 7-9-1) przedstawiono na rys. 9.9. Charakteryzując ogólnie wyznaczone istotności zauważyć można znaczną zbieżność uzyskanych wyników. Za najmniej istotne uznaje się wejścia reprezentujące temperaturę mierzoną w punkcie pomiarowym T-1 (punkt pomiarowy na koniku) oraz temperaturę otoczenia T-0. Wydaje się, że taką ocenę istotności danych potwierdzić może interpretacja fizykalna. Temperatura mierzona w punkcie T-1 wpływa w mniejszym stopniu na zmiany „U” kształtu korpusu szlifierki. Natomiast temperatura otoczenia zmieniała się nieznacznie w czasie realizacji pomiarów i stąd też miała mniejszy wpływ na błędy pozycji ściernicy.

Porównując wyznaczone istotności danych uwypuklić także należy występujące różnice. W pierwszym kroku zwraca się uwagę na istotność wejścia reprezentującego zadana pozycję ściernicy (wejście P). Istotność tego wejścia wynika bezpośrednio z charakterystyki sygnałów pomiarowych dokonanej w podrozdziale 9.1, gdzie wskazano na niewielkie zmiany temperatur występujące w chwili dokonywania pomiarów w poszczególnych pozycjach ściernicy. Zatem, aby wyznaczyć błąd pozycji ściernicy, za konieczne uznaje się uwzględnienie informacji o pozycji ściernicy. Wyniki zgodne z tak rozumianą wysoką oceną istotności wejścia P, zweryfikowaną również w dodatkowych testach, uzyskano jedynie w przypadku metody pruningu wag i metody A-Karina. Następnie, akceptowalne, aczkolwiek kłopotliwe w interpretacji, wyniki uzyskano z zastosowaniem metody analizy wrażliwości. Jak można zauważyć, metoda ta pozwala na uporządkowanie danych zgodne z powyższymi uwagami i wnioskami. Kłopotliwe jest jednakże przypisanie zdecydowanie wyższej istotności wejściu P-5 i niskich, zbliżonych istotności pozostałym wejściom.



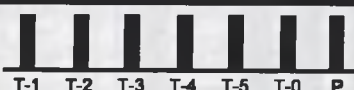

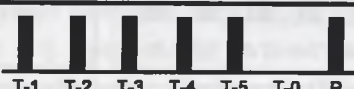

Rys. 9.9. Istotności wejść wyznaczone z zastosowaniem metod bazujących na sieci neuronowej FFBP

Fig. 9.9. Input importance determined with the FFBP neural network based methods

Natomiast ocena istotności danych w oparciu o istotności wyznaczone z zastosowaniem metody sumy wag prowadzi do krytycznego wyeliminowania danej reprezentującej zadana pozycję ściernicy. Niemniej jednak podkreślić można korzystną, tylko i wyłącznie w tym przypadku, zbliżoną istotność wejść {T-1, T-0, P}. W efekcie wyznaczenia zbliżonych istotności wejść {T-1, T-0, P} Użytkownik ma zdecydowanie ograniczoną możliwość jednoznacznego wyboru wejścia do odrzucenia i zmuszony jest do prowadzenia symulacji z arbitralnie wybieranymi podzbiórami danych. Podejście takie, weryfikowane błędami treningu sieci neuronowej FFBP, prowadzi do uznania wysokiej istotności wejścia P.

Kontynuując dyskusję oceny istotności wejścia P uwypukla się korzyści wynikające z wyznaczania istotności danych kilkoma metodami. Mając na uwadze, iż trzy spośród czterech metod wskazały na wejście P jako wejście istotne, założyć można rzeczywistą istotność tego wejścia. Oczywiście nie można odrzucić przypadku, w którym jedynie metoda sumy wag pozwoliła na poprawne wyznaczenie istotności danych. Jednakże uwzględniając wyniki dotychczas przedstawionych badań przypadek taki wydaje się być mniej prawdopodobny.



Zestaw danych	Struktura sieci FFBP	Reprezentacja elementów wektora wejściowego	$BS_{NN}$ [ $\mu m$ ]
ZD-2	7-9-1		4.30
ZD-2(A)	6-10-1		4.51
ZD-2(B)	6-10-1		4.71
ZD-2(C)	5-10-1		4.85

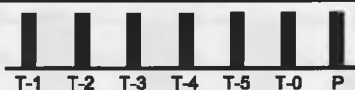
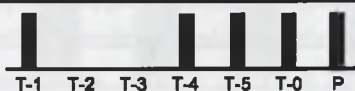
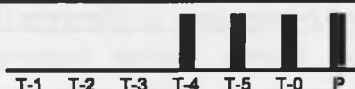
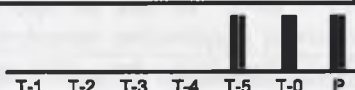
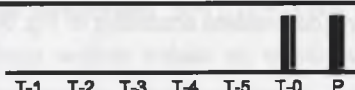
Rys. 9.10. Zestawienie wyników integracji wybranych danych

Fig. 9.10. The results of integration of the selected data

Dyskusja dokonanej oceny istotności danych ma swoje odzwierciedlenie w podjętych w kolejnym kroku próbach eliminacji danych. Pomijając specyficzne wyniki uzyskane z zastosowaniem metody analizy wrażliwości, ogólnie kłopotliwe jest jednoznaczne wskazanie wejść do odrzucenia. Oczywiście, łatwo jest wskazać wejścia o najniższych istotnościach. Niemniej jednak wejścia te opisane są istotnościami o wartościach zbliżonych do przyjętego w pracy progu istotności  $ID_p \approx 50\%$ .

Wyniki integracji wybranych danych przedstawiono na rys. 9.10. Dokonując selekcji eliminowano pojedyncze wejścia oraz jednocześnie odrzucono 2 wejścia o najniższych istotnościach. Odrzucenie kolejnego wejścia, tj. wejścia T-2, uniemożliwiało realizację treningu do przyjętej wartości błędu. Eliminacja wybranych danych powodowała nieznaczny, jakkolwiek zauważalny, wzrost wartości błędu  $BS_{NN}$ . Zwraca się szczególną uwagę na symulacje sieci 5-10-1, w których obserwowano blokowanie treningu oraz specyficzne wydłużenie czasu treningu. Analiza przeprowadzonych symulacji ujawniła występowanie dwóch przypadków. Symulacje, w których realizowano około 25+35 tys. iteracji, pozwalały na uzyskiwanie zadowalających wyników, tj. błędów wyrażonych wartością  $BS_{NN}=4.85 \mu m$  (rys. 9.10). Natomiast w symulacjach sieci, w których konieczne było zrealizowanie 100+130 tys. iteracji, uzyskiwano znacznie wyższe błędy.

Komentując symulacje sieci 5-10-1 odnieść się należy do dwóch zagadnień. W pierwszym kroku zwraca się uwagę na rolę potencjalnego Użytkownika, który prowadząc badania i wykazując zaistnienie takiego problemu odrzucać może symulacje, w których uzyskiwane są mniej korzystne wyniki. Konieczna jest jednak szczegółowa analiza, zwiększająca nakłady na realizację selekcji danych. W drugim przypadku ponownie podkreślić

Wsp. kary $UP_W$	Reprezentacja podzbiorów danych
0.000	
0.014	
0.030	
0.040	
0.050	

Rys. 9.11. Reprezentacja podzbiorów danych wyselekcjonowanych z zastosowaniem metody SR+AG

Fig. 9.11. Representation of the data sub-sets selected based on the SR+AG method


można konieczność ostrożnej oceny danych charakteryzujących się istotnościami o wartościach zbliżonych do  $ID_p \approx 50\%$ . Eliminacja takich danych nie ma charakteru krytycznego, ale powodować może utrudnienia w realizowanej w kolejnym kroku integracji.

Próby wyboru podzbiorów istotnych danych dokonano także z zastosowaniem metody SR+AG. Podzbiory potencjalnie istotnych danych przedstawiono na rys. 9.11. Odrzucenie wejścia T-2 pozwalało na realizację treningu sieci neuronowej FFBP, nie zapewniającego jednakże uzyskiwania zadowalających wyników ( $BS_{NN} = 10.5 \mu m$ ). Krytyczne natomiast było odrzucenie wejścia T-3 uniemożliwiające realizację treningu do zadanej wartości błędu  $E_{MAX}$ . Znaczące dla ogólnej oceny selekcji z zastosowaniem metody SR+AG jest wskazanie na dane reprezentowane przez wejścia T-0 i P jako najistotniejsze w rozważanym zbiorze. Ocena taką nie można uznać za zadowalającą.

W uzupełnieniu opisów selekcji danych wskazuje się na przeprowadzoną także ocenę istotności danych bazującą na analizie korelacji. Współczynniki korelacji wartości danych wejściowych i wyjściowych prowadziły do analogicznego, nie uznanego za poprawne, uporządkowania danych jak w przypadku metody SR+AG. Również próba eliminacji jednego z wejść T-4 i T-5 o najwyższej wartości współczynnika korelacji ( $R_{T-4,T-5}=0.952$ ) prowadziła do braku możliwości realizacji treningu sieci neuronowej FFBP.

#### 9.4. Podsumowanie badań

Dokonując podsumowania przeprowadzonych badań odnieść się należy w pierwszym kroku do prób zastosowania systemu logiki rozmytej do integracji danych. Rozwiązywane w niniejszym rozdziale zadanie ponownie uwydatniło zdecydowanie niższą zdolność uczenia



Rys. 9.12. Zestawienie błędów średnicy przedmiotu obrabianego (PO), (ozn. wg rys. 9.10)

Fig. 9.12. The workpiece (PO) diameter errors (denotations according to Fig. 9.10)

$$B_{NN}^{MIN} = \min_{j=1...5} \{ B_{NN,j}^{MIN} \} \quad \text{oraz} \quad B_{NN}^{MAX} = \max_{j=1...5} \{ B_{NN,j}^{MAX} \}, \quad (9.6)$$

gdzie:  $B_{NN,j}^{MIN}$ ,  $B_{NN,j}^{MAX}$  - błędy wyznaczone zgodnie z zależnością (9.3).

systemu FL. Pomimo zastosowania wszystkich rozważanych w pracy metod i algorytmów konstruowania systemów FL, nie wykazano możliwości realizacji treningu do osiągnięcia założonej wartości błędu. Typowe było osiąganie błędu treningu o wartości kilkakrotnie większej od wartości założonej, co ewidentnie uwidacznia brak przydatności systemu FL do integracji danych w rozważanym zadaniu.

Odwołując się w kolejnym kroku do zastosowań sieci neuronowej FFBP podjęto próbę wskazania na utylitarny charakter uzyskanych wyników. Przyjęto aby rozważyć hipotetyczne zastosowanie sieci FFBP w układzie korekcji pozycji ściernicy. W tym celu wyznaczono maksymalny i minimalny błąd sieci neuronowej obliczany w odniesieniu do 5-krotnie powtarzanych symulacji, zależność (9.6). Przyjęto zatem, że w hipotetycznym układzie korekcji stosowana jest sieć neuronowa FFBP, charakteryzująca się ekstremalnymi wartościami błędów, tj.  $B_{NN}^{MIN}$  i  $B_{NN}^{MAX}$ . Następnie, wyznaczone błędy sieci przeskalowano tak, aby wyrażały zakres wartości błędu średnicy przedmiotu obrabianego. Wyznaczone błędy oraz zakresy wartości wybranych pól tolerancji wymiarowej zestawiono na rys. 9.12. Przyjęto równomierny podział pola tolerancji względem średnicy nominalnej przedmiotu obrabianego (przyjęto zakres średnic 120÷180 mm).

Komentując zestawienie z rys. 9.12 wskazać należy na przyjęcie najniższego zakresu średnic przedmiotu obrabianego, odpowiadającego pozycji ściernicy P-07. Jak łatwo zauważyć, pomimo przyjęcia do rozważań najmniej „korzystnego” modelu o postaci sieci

neuronowej FFBP, możliwe jest uzyskanie wartości średnic przedmiotu obrabianego w 6 klasie dokładności (IT6). W tym przypadku, konstruując sieć FFBP, zastosowano dane rejestrowane w 5 punktach szlifierki i jedynie w skrajnych pozycjach przyjętego zakresu ruchu ściernicy. Decydując się na zastosowanie 7 czujników pomiarowych i przeprowadzenie pomiarów w większej liczbie pozycji ściernicy (zestaw danych ZD-1, rys. 9.12), potencjalnie możliwe jest uzyskanie wartości średnic przedmiotu obrabianego w 5 klasie dokładności (IT5). Dodać należy, że nie stosując korekcji położenia ściernicy błąd średnicy przedmiotu obrabianego (pozycja P-07) zawierałby się w zakresie [-6.0 µm, 74.4 µm].

Podsumowując niniejszy rozdział zestawienie stopni spełnienia uzupełniających kryteriów oceny metod selekcji danych przedstawiono w tab. 9.2. W przeprowadzonych symulacjach wykazano zadowalającą powtarzalność wyznaczania istotności danych metodą pruningu wag  $BPI_{MAX}=2$  ( $BPI_{AV}=0.77$ ). Za akceptowalną uznać można powtarzalność metody analizy wrażliwości  $BPI_{MAX}=23.0\%$  ( $BPI_{AV}=3.7\%$ ), w przypadku której jedynie istotność jednego wejścia wahała się w zakresie większym niż  $BPI_{MAX}^{(j)}=20.0\%$ . Natomiast niską powtarzalnością charakteryzowała się metoda sumy wag ( $BPI_{MAX}=28.6\%$ ,  $BPI_{AV}=6.1\%$ ) oraz metoda A-Karina ( $BPI_{MAX}=30.0\%$ ,  $BPI_{AV}=6.7\%$ ). Następnie, stwierdzono brak możliwości zastosowania progu istotności danych w odniesieniu do metody analizy wrażliwości (zob. rys. 9.9). Ostatecznie, większych nakładów obliczeniowych wymagały metody bazujące na sieci neuronowej FFBP ze względu na relatywnie długi czas treningu. Trening sieci o strukturze 7-9-1 z zastosowaniem zestawu danych ZD-2 wymagał czasu rzędu 20÷30 minut.

Tabela 9.2

Zestawienie uzupełniających kryteriów oceny metod selekcji danych

Kryteria		Metody selekcji danych						
		MS(pruning wag)	MS(suma wag)	MS(met. A-Karina)	MS(anal. wrażliwości)	MS(SM+SFS)	MS(SM+AG)	MS(SR+AG)
1	duża powtarzalność wyznaczania istotności	2	0	0	1	--	--	2
2	możliwość nie tylko jakościowej ale również ilościowej oceny istotności danych	2	2	2	2	--	--	0
3	możliwość wskazania parametru metody selekcji pozwalającego na wybór quasi-optimalnego podzbioru danych	2	2	2	0	--	--	0
4	niski koszt obliczeniowy metody	0	1	1	1	--	--	2
Suma (max. 8 pkt) :		6	5	5	4	--	--	4

## 10. PODSUMOWANIE PRACY

Dokonując podsumowania przeprowadzonych badań odwołano się do stanowiącego przedmiot niniejszej pracy zagadnienia wspomaganie projektowania układów diagnostycznych obrabiarki i procesu skrawania. Dyskusja przeprowadzona w początkowej części pracy uzasadniła potrzebę (konieczność) wspomaganie projektowania układów diagnostycznych, co stanowiło o celowości i ukierunkowaniu podjętych badań. Przewodnią ideę badań odzwierciedla oryginalna koncepcja Inteligentnego Układu Diagnostycznego (IUD). Analizując koncepcję takiego układu zaproponowano implementację IUD w Inteligentnym Projektancie Układów Diagnostycznych (IPUD). Równocześnie podkreślono znaczenie ogólnie rozumianego przetwarzania danych, co było przesłanką dokonania wstępnego wyboru możliwych podejść i określenia celu i tezy niniejszej pracy.

Podjmując dyskusję celu pracy dogodne jest uwypuklenie dwóch orientacji podjętych badań. Pierwsza z orientacji związana była z *wyborem i usystematyzowaniem, a także opracowaniem lub zmodyfikowaniem metod selekcji i integracji danych*. Dokonując wyboru metod starano się uwzględnić specyficzne wymagania stawiane IUD/IPUD oraz dążono do zróżnicowania metod, pozwalającego potencjalnie na uogólnienia wniosków z przeprowadzonych badań. W przypadku metod selekcji danych analizowano metody proponowane w literaturze (wybrano metodę analizy wrażliwości), metody dostępne w komercyjnych pakietach oprogramowania (wybrano metodę SR+AG) oraz metody stosowane w dziedzinie diagnostyki OPN-PS (wybrano metodę SM+SFS). Następnie, do testów przyjęto oryginalne, opracowane przez autora rozwiązania:

- metodę pruning wag,
- metodę sumy wag,
- metodę bazującą na macierzy rozproszenia i algorytmie genetycznym (metoda SM+AG)

oraz:

- adaptowano metodę optymalizacji struktury sieci neuronowej FFBP (metoda A-Karina).

Na etapie integracji danych zastosowano sieć neuronową FFBP oraz system logiki rozmytej. W tym przypadku autor opracował:

- metody konstruowania bazy reguł systemu logiki rozmytej opierające się na algorytmie genetycznym (metody AG, AG-H1 i AG-H2)

oraz zmodyfikował:

- metodę pruningu komórek stosowaną do oszacowania liczby komórek ukrytych sieci neuronowej FFBP,

- metodę KFM inicjalizacji funkcji przynależności systemu logiki rozmytej,
- metodę konstruowania bazy reguł systemu logiki rozmytej z zastosowaniem treningu z rywalizacją (metoda WTA(\*)).

Dokonanie wyboru metod selekcji i integracji danych stanowiło o możliwości realizacji kolejnej części badań, której celem było *przeprowadzenie testów i porównań zorientowanych na weryfikację przydatności rozpatrywanych metod i wskazanie wytycznych oraz zasad ich jak najbardziej skutecznego zastosowania*. Przed przystąpieniem do realizacji tej części badań przyjęto zasady realizacji testów. Rozważano także zasadnicze i uzupełniające kryteria oraz sposoby oceny metod selekcji i integracji danych (podrozdział 4.7), a w szczególności autor zaproponował:

- sposób oceny stopnia spełnienia kryteriów zasadniczych bazujący na zastępczej jakości integracji danych,
- sposób oceny stopnia spełnienia kryterium powtarzalności wyznaczania istotności danych bazujący na zdefiniowanych w pracy błędach powtarzalności wyznaczania istotności,
- sposób wyboru quasi-optymalnego podzbioru istotnych danych.

Dodać należy, że dokonanie wyboru metod, podział metod, przyjęte zasady realizacji testów oraz zaproponowane kryteria i sposoby oceny metod odzwierciedlają uwzględnione w celu pracy próby usystematyzowania metod selekcji i integracji danych.

Testy metod selekcji i integracji danych przeprowadzono z zastosowaniem zadań testowych, tj. zadania parzystości i zadania graficznego, oraz podjęto próby rozwiązania reprezentatywnych, zdaniem autora, problemów diagnostyki obrabiarki i procesu skrawania. Rozpatrywano problem zużycia narzędzia podczas toczenia i wiercenia wielowrzecionowego, problem diagnostyki przedmiotu obrabianego w świetle tworzenia się zadziorów poobróbkowych oraz problem diagnostyki obrabiarki ze względu na odkształcenia termiczne. Charakteryzując przeprowadzone testy zwraca się uwagę na:

- szczegółową analizę wpływu skorelowania danych wejściowych na wyznaczone istotności wejść (rozdział 5, w tym podrozdział 5.3),
- wykazanie i analizę efektu rozplywu istotności danych oraz propozycję testu podobieństwa wag (rozdział 5, w tym podrozdział 5.1),
- proponowanie metod wstępnego przetwarzania sygnałów pomiarowych oraz metod ekstrakcji cech sygnałów pomiarowych w analizach każdego z rozpatrywanych problemów diagnostycznych,
- próby fizykalnych interpretacji analizowanych zjawisk, podkreślające technologiczne aspekty rozważanych problemów,
- analizy badań eksperymentalnych, w których stosowano zarówno jednoczynnikowe, jak i wieloczynnikowe układy pomiarowe (por. rozdziały 6 i 8),

- podjęcie analiz zarówno zadań klasyfikacji (rozdziały 6 i 8) jak i aproksymacji (rozdziały 7 i 9),
- dyskusje metod i algorytmów stosowanych zarówno do konstruowania sieci neuronowej FFBP, jak i systemu logiki rozmytej,
- analizy problemu utraty zdolności generalizacji sieci neuronowych i systemów logiki rozmytej, wskazujące przyczyny utraty zdolności generalizacji (np. rozdziały 6 i 7),
- analizy zdolności generalizacji w świetle zdolności interpolacji metod integracji danych (rozdziały 8 i 9),
- uwypuklenie utylitarnego aspektu zastosowanych metod wyrażanego nakładami obliczeniowym związanymi z selekcją i integracją danych.

Przeprowadzenie wielokierunkowych badań z zastosowaniem zasadniczo zróżnicowanych zadań oraz porównanie uzyskanych wyników pozwoliło na *weryfikację przydatności rozpatrywanych metod i wskazanie wytycznych oraz zasad ich jak najbardziej skutecznego zastosowania*. W tym przypadku zwraca się uwagę na możliwość dwojakiego podejścia do charakterystyki przeprowadzonych badań. W pierwszym kroku wskazuje się na podejmowane w każdym rozdziale pracy szczegółowe dyskusje spełnienia zasadniczych i uzupełniających kryteriów oceny zastosowanych metod. Przeprowadzone dyskusje odnoszą się zarówno do *weryfikacji przydatności* zastosowanych metod, jak i umożliwiają określenie *wytycznych skutecznego zastosowania* metod. Przykładowo, stosując pewne metody selekcji i integracji danych wybierać można małymi nakładami obliczeniowymi i z dużą powtarzalnością podzbiory istotnych danych, nie zapewniające jednakże uzyskiwania najwyższych jakości integracji. Nie mniej znaczące są również ponownie przytaczane zasady realizacji testów. Przyjmując zasady realizacji testów, wskazano zasadniczo na *wytyczne i zasady* zastosowania metod selekcji i integracji danych.

W drugim kroku odnieść się można do porównań metod selekcji i integracji danych przeprowadzonych na podstawie wyznaczonych wartości zastępczej jakości integracji. Porównania pozwalają na *weryfikację przydatności* i jednocześnie uściślenie *zasad i wytycznych skutecznego zastosowania* testowanych metod. Uogólniając przeprowadzone porównania wskazuje się na mniejszą przydatność metody SR+AG. Mało efektywne może być także dokonanie selekcji danych z zastosowaniem metody A-Karina. Zwraca się uwagę na kłopotliwy do jednoznacznego ujęcia wpływ charakteru rozwiązywanego zadania oraz występowanie, krytycznego w niektórych przypadkach, braku powtarzalności wyznaczania istotności danych (por. rozdziały 6 i 8). Zdecydowanie korzystniej ocenić należy metodę analizy wrażliwości i metodę sumy wag. Niemniej jednak również w przypadku tych metod uwidaczniała się zależność uzyskiwanych wyników od charakteru rozwiązywanego zadania. W świetle przeprowadzonych testów uznaje się, że metoda analizy wrażliwości stosowana powinna być głównie do rozwiązywania zadań aproksymacji. Znacznie bardziej uniwersalna

jest metoda sumy wag, ze wskazaniem na większą przydatność w rozwiązywaniu zadań klasyfikacji. Korzystnie ocenia się także metody bazujące na macierzy rozproszenia (SM+SFS i SM+AG). Korzystna ocena nie jest jednakże szerzej komentowana, ponieważ metody te stosowane są wyłącznie w przypadku zadań klasyfikacji. Dodaje się jedynie, że raczej kłopotliwe jest wskazanie na korzystniejszy algorytm wyboru podzbioru danych (algorytm SFS lub algorytm genetyczny AG, por. rozdziały 6 i 8). Podsumowując tę część rozważań stwierdza się, iż w większości przeprowadzonych testów jednoznacznie korzystne wyniki uzyskiwano z zastosowaniem metody pruningu wag. Stwierdzając przydatność metody pruningu wag pomija się problem powtarzalności czy też rozdzielczości tej metody.

Przyjmując, że najkorzystniejsze wyniki uzyskiwano stosując metody pruningu wag i sumy wag oraz metodę analizy wrażliwości konieczne jest uwzględnienie sposobu uzyskania tych wyników. Autor odwołuje się w tym przypadku do możliwości wyboru quasi-optimalnego podzbioru danych, co pozwala na kolejne zróżnicowanie metod selekcji. Stosując próg istotności o wartości  $ID_p \approx 50\%$ , zadowalające wyniki uzyskiwano jedynie w przypadku metody pruningu wag i sumy wag. Zastosowanie metody analizy wrażliwości wymaga zazwyczaj żmudnego testowania kolejnych podzbiorów danych. W tym miejscu zweryfikować można także przyjętą wartość progu istotności. W świetle uzyskanych wyników wskazane jest podniesienie wartości progu istotności w przypadku metody pruningu wag ( $ID_p \approx 60\%+70\%$ ), pozwalające na zmniejszenie liczności podzbiorów wyselekcjonowanych danych oraz obniżenie wartości progu ( $ID_p \approx 40\%+50\%$ ) w przypadku metody sumy wag, co potencjalnie zabezpiecza przed odrzuceniem istotnych danych (np. rozdział 8).

Zdecydowanie mniej rozbudowane jest porównanie metod integracji danych. Wyraźnie uwypuklić można większą przydatność sieci neuronowej FFBP. Systemy logiki rozmytej pomimo atrakcyjnej możliwości odzyskiwania wiedzy, charakteryzują się mniejszą zdolnością uczenia i generalizacji (np. rozdział 8). Mniejsza zdolność uczenia i generalizacji stanowi może zarówno specyficzną, niekorzystną cechę systemów logiki rozmytej, jak i związana może być z niedoskonałością zastosowanych metod konstruowania systemów FL.

Podsumowując powyższą charakterystykę wskazuje się ponownie na metody, które wykazały mniejszą przydatność i nie w pełni i nie zawsze spełniały przyjęte kryteria (w tym również rozwiązania proponowane przez autora). Wydaje się, że wyniki uzyskiwane z zastosowaniem tych metod traktować można jako ostrzeżenie przed próbami proponowania rozwiązań o trudnym do uogólnienia zakresie zastosowań lub rozwiązań, które pomimo podbudowy teoretycznej nie sprawdzają się w praktycznych zastosowaniach.

Przeprowadzona dyskusja stanowi jednoznacznie, zdaniem autora, o realizacji celu pracy. Dyskusja pozwala także na udowodnienie tezy pracy, w której zakładano możliwość *efektywnej realizacji selekcji i integracji danych z zastosowaniem wybranych metod sztucznej inteligencji*. Uznaje się, iż w ramach badań zaproponowano rozwiązania, które pozwoliły na *efektywne* wykorzystanie (praktyczne zastosowanie) cech wybranych metod sztucznej

inteligencji. W rozpatrywanych zadaniach możliwe było znaczne zmniejszenie liczności podzbiorów danych stosowanych do rozwiązania tych zadań. Przeprowadzenie redukcji liczby danych uznaje się za jak najbardziej efektywne, co potwierdziły porównania nakładów ponoszonych w przypadku analizowanych szczegółowo metod i nakładów związanych z innymi, stosowanymi w badaniach podejściami. Oczywiście, nakłady obliczeniowe nie mogą być oceniane w oderwaniu od wyników uzyskiwanych w etapie integracji danych, co powtórnie uwypukla efektywność rozważanych metod. Odwołać się można w tym przypadku do:

- prób wyboru istotnych danych z zastosowaniem klasycznej analizy statystycznej (rozdziały 6, 7 i 9),
- prób wyboru istotnych danych z zastosowaniem analizy korelacji rangowej  $\tau$ -Kendalla (rozdział 6 i 8),
- prób wyboru istotnych danych z zastosowaniem metody *leave-one-out* (rozdział 8).

Ogólnie, uznana za *efektywną* selekcja i integracja danych pozwalała na dokonanie wyboru optymalnego, w świetle przyjętego kryterium, podzbioru danych i poddanie tych danych integracji prowadzącej do wyznaczenia generalizującego opis danego zjawiska modelu współzależności o wysokiej jakości.

Dokonując końcowych uogólnień przeprowadzonych badań wskazuje się na ich zakres. Badania przeprowadzono w odniesieniu do wybranych problemów diagnostyki obrabiarki i procesu skrawania. Rozważania teoretyczne, uwagi i sugestie odnoszono także do ogólnego zagadnienia diagnostyki OPN-PS, rozpatrywanego z punktu widzenia projektowania układów diagnostycznych. Podejście takie związane było z dziedziną, w której autor prowadził swoje dotychczasowe prace. Podkreślić również należy przyjęcie założenia o zasadności ostrożnego podejścia do stosowania daleko idących uogólnień odnoszących się do innych dziedzin, np. innych maszyn i procesów technologicznych. Niemniej jednak, przewodnia idea badań, odzwierciedlana w koncepcji Inteligentnego Układu Diagnostycznego, nie narzuca takich ograniczeń. Dlatego też w tym miejscu zaproponować można podjęcie prób weryfikacji zastosowanych metod i algorytmów w innych dziedzinach. Propozycja ta uzasadniana jest oczywiście zadowalającymi wynikami przeprowadzonych badań. Jednocześnie propozycja ta, wraz z próbami opracowania lub wyboru kolejnych metod selekcji i integracji danych, których znaczenie wielokrotnie podkreślano, wyznacza kierunki przyszłych badań autora niniejszej pracy.

## LITERATURA

1. [Ali i Zhang, 1999] Ali Y.M., Zhang L.C. : Surface roughness prediction of ground components using a fuzzy logic approach. *Journal of Materials Processing Technology* 89-90, 1999
2. [Antic, et al., 2001] Antic A., Hodolic J., Gatalo R., Stevic M. : Contribution to development of multisensor system for tool monitoring. *Proceedings of the 12th International DAAAM Symposium, Jena 2001*
3. [Arabas, 2000] Arabas J. : Algorytmy ewolucyjne : przegląd tematyki. *Conference Proceedings „Methods of Artificial Intelligence in Mechanics and Mechanical Engineering”, AIMECH'2000, Gliwice 2000*
4. [Azouzi i Guillot, 1996] Azouzi R., Guillot M. : Control and optimisation of the turning process using a new hybrid neural network. *Proceedings of the 1996 Japan - USA Symposium on Flexible Automation, Vol. 2, Boston 1996*
5. [Bahre et al., 1992] Bahre D., Rosenberger U., Warnecke G. : Monitoring of cutting processes by vibration analysis : Exemplary applications in grinding and turning processes. *Sensors and Signal Processing for Manufacturing, ASME, PED, Vol. 55, 1992*
6. [Bajtyngier i Jemielniak, 1988] Bajtyngier T., Jemielniak K. : Diagnostyka stanu noża tokarskiego oparta na bezpośrednich pomiarach sił skrawania. *I Naukowa Szkoła Nadzorowania i Diagnostyki Systemów Obróbkowych, Prace Naukowe Instytut Technologii Budowy Maszyn Politechniki Wrocławskiej nr 38, seria : Konferencje nr 14, Wrocław 1988*
7. [Balazinski i Jemielniak, 1998] Balazinski M., Jemielniak K. : Tool condition monitoring using fuzzy decision support system. *Proceedings of the V International Conference on Monitoring and Automatic Supervision in Manufacturing, Warszawa 1998*
8. [Barschdorff i Monostori, 1991] Barschdorff D., Monostori L. : Seminar on learning in LMS. *The first CIRP workshop on the Intelligent Manufacturing Systems, Budapest 1991*
9. [Barton i Thangaraj, 1991] Barton R.P., Thangaraj A.R. : A neural network approach to drilled hole quality monitoring based on machine spindle vibrations. *Trans. of NAMRI/SME, Vol. 19, 1991*
10. [Basil, 1994] Basil S.A. : Modelling and monitoring drill bit transverse motion. *First S.M. Wu Symposium on Manufacturing Science, SME, Chicago 1994*
11. [Bavarian, 1992] Bavarian B. : Tutorial on artificial neural networks for intelligent manufacturing and robotics systems. *Proceedings of the 1992 Japan - USA Symposium on Flexible Automation, San Francisco 1992*
12. [Berger et al., 2001] Berger B., Belai C., Anand D. : Toeplitz matrices and cutting state identification. *Proceedings of the Eighth International Congress on Sound and Vibration, vol. 2, Hong Kong (China) 2001*

13. [Bhar et al., 1994] Bhar B., Motavalli S., Arfi T., Srinivas G. : Integrating vibration and vision system for monitoring cutting process. First S.M. Wu Symposium on Manufacturing Science, SME, Chicago 1994
14. [Bolikowski, 1997] Bolikowski J. : Inteligentne przetworniki pomiarowe w diagnostyce procesów przemysłowych. II Krajowa Konferencja Naukowo – Techniczna Diagnostyka Procesów Przemysłowych, Łagów 1997
15. [Burczyński, 2000] Burczyński T. : Evolutionary algorithms : applications in mechanics. Conference Proceedings „Methods of Artificial Intelligence in Mechanics and Mechanical Engineering”, AIMECH'2000, Gliwice 2000
16. [Burke, 1989] Burke L.I. : Automated identification of tool wear states in machining processes : an application of self-organising neural networks. Ph.D. Dissertation, Department of Mechanical Engineering, University of California at Berkeley, 1989
17. [Byrne et al., 1995] Byrne G., Dornfeld D., Inasaki I., Ketteler G., Konig W., Teti R. : Tool Condition Monitoring (TCM) – The status of research and industrial application. Annals of the CIRP, Vol. 44/2/ 1995
18. [Campos et al., 1994] Campos Bicudo L.A.M., Sokołowski A., Gomes de Oliveira J.F., Dornfeld D.A. : Compensation of thermal deformation on cylindrical grinding machines using neural networks. Proceedings of The 1994 Japan-U.S.A. Symposium on Flexible Automation, Kobe 1994
19. [Campos et al., 1995] Campos Bicudo L.A.M., Sokołowski A., Gomes de Oliveira J.F., Dornfeld D.A. : Thermal compensation of grinding machines using neural networks. Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing, Miedzyszyn/Warszawa 1995
20. [Carpenter et al., 1991] Carpenter G. A., Grossberg S., Rosen D. : ART 2-A : An adaptive resonance algorithm for rapid category learning and recognition. Neural Networks, Vol. 4, 1991
21. [Carpenter i Grossberg, 1987] Carpenter G.A., Grossberg S. : ART 2 : Self-organisation of stable category recognition codes for analogue input patterns. Applied Optics 26, 1987
22. [Cempel, 1980] Cempel C. : Redukcja zbioru danych w diagnostyce maszyn. Zagadnienia Eksploatacji Maszyn, Zeszyt 4/44/1980
23. [Chern, 1993] Chern G.L. : Analysis of burr formation and breakout in metal cutting. Ph.D. Dissertation, Department of Mechanical Engineering, University of California at Berkeley, 1993
24. [Choi et al., 1990] Choi G. S., Wang Z. X., Dornfeld D. A., Tsujino K. : Development of an intelligent on-line tool wear monitoring system for turning operations. Proceedings of the 1990 Japan - USA Symposium on Flexible Automation, Kyoto 1990
25. [Cholewa et al., 1988] – Cholewa W. i inni : Programowany analizator sygnałów diagnostycznych PAS6. Instytut Mechaniki i Podstaw konstrukcji Maszyn, Politechnika Śląska, Zeszyt 109, Gliwice 1988
26. [Cholewa i Kiciński, 1995] Cholewa W., Kiciński J. : Metody identyfikacji reguł dla diagnostycznych systemów doradczych. XXXV Sympozjon „Modelowanie w Mechanice”, Gliwice 1995
27. [Cholewa i Solipiwo, 1985] Cholewa W., Solipiwo A. : Optymalizacja przestrzeni cech w wibroakustycznych badaniach diagnostycznych. VII Szkoła Diagnostyki, Politechnika Poznańska, Poznań – Rydzyna 1985
28. [Cholewa, 2000] Cholewa W. : Dynamiczne systemy doradcze. Conference Proceedings „Methods of Artificial Intelligence in Mechanics and Mechanical Engineering”, AIMECH'2000, Gliwice 2000
29. [Ciupke, 2001] Ciupke K. : Metoda selekcji i redukcji informacji w diagnostyce maszyn. Zeszyt Naukowy KPKM nr 118, Gliwice 2001
30. [Clabian et al., 1997] Clabian M., Pftzner H., Paky F., Rauscher H. : Determination of decisive inputs of a neural network for sleep apnea classification. Proceedings of the 1997 International Conference on Engineering Applications of Neural Networks, Stockholm 1997
31. [CODEF] Consortium on Deburring and Edge Finishing (CODEF), The University of California at Berkeley, <http://lma.berkeley.edu/codef/>
32. [Colgan et al., 1992] Colgan J., Chin H., Danai K., Hayashi S.R. : On-line tool breakage detection in turning : A multi-sensor method. Sensors and Signal Processing for Manufacturing, ASME, PED, Vol. 55, November 1992
33. [Constantinides i Bennett, 1987] Constantinides N., Bennett S. : An investigation of methods for on-line estimation of tool wear. Int. J. Mach. Tools Manufact., Vol. 27, No. 2, 1987
34. [Czech et al., 1997] Czech M., Wodecki J., Klarecki K., Śliwka J., Dyrbuś G. : Optymalizacja wiertel do obróbki stali austenitycznej. Prace Naukowe Katedry Budowy Maszyn Nr 2/97, Politechnika Śląska w Gliwicach, Gliwice 1997
35. [Davis, 1991] Davis L. : Handbook of Genetic Algorithms. Van Nostrand Reinhold, New York 1991
36. [DeVor et al., 1996] DeVor R.E., Kapoor S.G., Hibner M., Kim D., Reutzel K. : A process model-based approach for machine tool and cutting process diagnostics. Proceedings of the 1996 Japan - USA Symposium on Flexible Automation, Vol. 2, Boston 1996
37. [Diagnostyka techniczna, 1997] Diagnostyka techniczna. Odwrotne modele diagnostyczne. Cholewa W., Kiciński J. (red.), Wydawnictwo Politechniki Śląskiej, Gliwice 1997
38. [Diagnostyka techniczna, 2001] Diagnostyka techniczna. Metody odwracania nieliniowych modeli obiektów. Cholewa W., Kiciński J. (red.), Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, Zeszyt 120, Gliwice 2001
39. [Diei i Dornfeld, 1987] Diei E.N., Dornfeld D.A. : Acoustic emission sensing of tool wear in face milling. J. Eng. Industry, Vol. 109, August 1987

40. [Dimla et al., 1997] Dimla D.E., Lister P.M., Leighton N.J. : Application of back-propagation neural network to tool condition monitoring in a metal turning process. MATADOR CONFERENCE, Manchester, 1997
41. [Diniz et al., 1992] Diniz A.E., Liu J.J., Dornfeld D.A. : Correlating tool life, tool wear and surface roughness by monitoring acoustic emission in finish turning. Proceedings of the 1992 Japan - USA Symposium on Flexible Automation, San Francisco 1992
42. [Dmochowski, 1981] Dmochowski J. : Podstawy obróbki skrawaniem. PWN, Warszawa 1981
43. [Domański et al., 1995] Domański P.D., Tadej W., Arabas J. : A comparison of the genetic and neural approaches to the fuzzy logic based modelling. Proceeding of the Second International Symposium on Methods and Models in Automation and Robotics, Międzyzdroje, 1995
44. [Dornfeld, 1992] Dornfeld D. : Intelligent deburring of precision components. Proceedings of the International Conference on Industrial, Electronics, Control, Instrumentation and Automation, Vol. 2., 1992
45. [Du et al., 1992] Du R. X., Elbestawi M.A., Li S. : Tool condition monitoring in turning using fuzzy set theory. Int. J. Mach. Tools Manufact. Vol. 32, No. 6, 1992
46. [Elanayar i Shin, 1992] Elanayar S., Shin Y.C. : Robust tool wear estimation via radial basis function neural networks. Neural Networks in Manufacturing and Robotics, ASME, PED, Vol. 57, November 1992
47. [Emel i Kannatey-Asibu, 1991] Emel. E., Kannatey-Asibu Jr E. : Acoustic emission monitoring of the cutting process - negating the influence of varying condition. Journal of Engineering Materials and Technology, ASME, Vol. 113, October 1991
48. [Fan i Wu, 1992] Fan H.T., Wu S.M. : Case studies on modelling manufacturing processes using artificial neural networks. Neural Networks in Manufacturing and Robotics, ASME, PED, Vol. 57, 1992
49. [Gawlik i Karbowski, 1997] Gawlik J., Karbowski K. : Prognozowanie stanu ostrza skrawającego z zastosowaniem sieci neuronowych. Mechanik Nr 4/1997
50. [Gawlik i Zębala, 1995] Gawlik J., Zębala W. : New concept of edge wear prediction in the precision cutting. Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing, Miedzyszyn/Warszawa 1995
51. [Gibiec, 2000] Gibiec M. : Artificial intelligence in diagnostic systems. Conference Proceedings „Methods of Artificial Intelligence in Mechanics and Mechanical Engineering”, AIMECH'2000, Gliwice 2000
52. [Gillespie i Blotter, 1976] Gillespie L.K., Blotter P.T. : The formation and properties of machining burr. Journal of Engineering for Industry, Vol. 98, No. 1, 1976
53. [Gindy i Al-Habaibeh, 1997] Gindy N., Al-Habaibeh A. : Condition monitoring of cutting tools using artificial neural networks. MATADOR CONFERENCE, Manchester, 1997
54. [Giusti et al., 1987] Giusti F., Santochi M., Tantussi G. : On - line sensing of flank and crater wear of cutting tools. Annals of the CIRP, Vol. 36/1/ 1987
55. [Goldberg, 1989] Goldberg D.E. : Genetic Algorithms in Search, Optimization and Machine Learning. Addison - Wesley Co., Redwood City, USA, 1989
56. [Govekar i Grabec, 1998] Govekar E., Grabec I. : Classification of cutting tool wear by chaotic characteristics. Proceedings of the V International Conference on Monitoring and Automatic Supervision in Manufacturing, Warsaw 1998
57. [Guo i Dornfeld, 1998] Guo Y., Dornfeld D.A., : Finite element analysis of drilling burr minimization with a backup material. Trans. of NAMRI/SME, Vol. 26, 1998
58. [Gupta i Rao, 1994] Gupta M.M., Rao D.H. : On the principles of fuzzy neural networks. Fuzzy Sets and Systems, Vol. 61, 1994
59. [Hamrol i Twardowski, 1995] Hamrol A., Twardowski, P. : Diagnosis of ceramic tool point during turning of hardened steel. Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing, Miedzyszyn/Warszawa 1995
60. [Hamrol i Twardowski, 1998] Hamrol, A., Twardowski, P. : Shape error control for turning hardened steel based on neural network model. Proceedings of the V International Conference on Monitoring and Automatic Supervision in Manufacturing, Warsaw, 1998
61. [Hamrol, 1998] Hamrol A. : Sterowanie jakością procesu obróbki na podstawie sygnałów diagnostycznych. Technologia Maszyn, IV Naukowe Warsztaty Profesorskie TM'98 i III Forum Prac Badawczych, Wyd. Pol. Koszalińskiej, Koszalin 1998
62. [Hertz et al., 1991] Hertz J., Krogh A., Palmer R.G. : Introduction to the Theory of Neural Computation. Addison - Wesley Co., Redwood City, USA, 1991
63. [Heyden, 1996] Heyden van der M.J. : Neural network and statistics : a brief overview. Proceedings of the International Workshop on Neural Networks HELNET'94 - '95, Vol. I/II, VU University Press, Amsterdam 1996
64. [Holland, 1975] Holland J. H. : Adaptation in Natural and Artificial Systems. Ann Arbor : The University of Michigan Press, 1975
65. [Hong at al., 1992] Hong S.Y., Ni J., Wu S.M. : Analysis of drill failure modes by multi-sensors on a robotic end effector. Proceedings of the 1992 Japan - USA Symposium on Flexible Automation, San Francisco 1992
66. [Hornik, 1991] Hornik K. : Approximation capabilities of multilayer feedforward networks. Neural Networks, Vol. 4, 1991
67. [Inasaki, 1995] Inasaki I. : Intelligent monitoring and supervision in grinding. Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing, Miedzyszyn/Warszawa 1995
68. [Inasaki, 1998] Inasaki I. : Sensor fusion for monitoring and controlling grinding processes. Proceedings of the V International Conference on Monitoring and Automatic Supervision in Manufacturing, Warsaw 1998
69. [Jacob i Ball, 1997] Jacob P.J., Ball A.D. : Structuring a RBF classifier using genetic algorithm or a forward selection heuristic. Proceedings of the 1997 International Conference on Engineering Applications of Neural Networks, Stokholm 1997

70. [Jammu et al., 1993] Jammu V.B., Danai K., Malkin S. : Unsupervised neural network for tool breakage detection in turning. *Annals of the CIRP*, Vol. 42/1/ 1993
71. [Jawahir i Fei, 1993] Jawahir I.S., Fei J. : A comprehensive evaluation of tool inserts for chip control using fuzzy modelling of machinability parameters. *Trans. of NAMRI/SME*, Vol. 21, 1993
72. [Jemielniak i Kosmol, 1995] Jemielniak K., Kosmol J. : Tool and process monitoring – State of art and future prospects. *Proceedings of VI Workshop on Diagnostics and Supervision in Flexible Manufacturing*, Prace Naukowe Instytutu Technologii Maszyn i Automatyzacji Politechniki Wrocławskiej nr 61, Seria : Konferencje 26, Wrocław 1995
73. [Jemielniak, 1995] Jemielniak K. : Catastrophic tool failure detection based on signals from feed force sensors. *Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing*, Miedzyszyn/Warszawa 1995
74. [Jemielniak, 1998] Jemielniak K. : Commercial tool condition monitoring systems. *Proceedings of the V International Conference on Monitoring and Automatic Supervision in Manufacturing*, Warsaw 1998
75. [Jemielniak, 2001] Jemielniak K. : Automatyczna diagnostyka stanu narzędzia i procesu skrawania. *Oficyna Wydawnicza Politechniki Warszawskiej*, Warszawa 2001
76. [Jędrzejewski, 1997] Jędrzejewski J. : Trends in development of intelligent manufacturing systems. *MANUFACTURING CONTROL OPTIMIZATION*, *Proceedings of the VIII Workshop on Supervising and Diagnostics of Machining Systems*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 1997
77. [Jin i Murakawa, 2001] Jin M., Murakawa M. : Development of practical ultrasonic vibration cutting tool system. *Journal of Materials Processing Technology*, vol. 113/1-3 (2001), Special Issue, Korea 2001
78. [John et al., 1994] John G., Kohavi R., Pflieger K. : Irrelevant features and the subset selection problem. *11th International Conference on Machine Learning*, New Brunswick, Morgan Kaufman 1994
79. [Kacalak i Wawryn, 1995] Kacalak W., Wawryn K. : A fuzzy compensation of disturbances in automated manufacturing. *Intelligent Engineering Systems Through Artificial Neural Networks*, Vol. 5, Fuzzy Logic And Evolutionary Programming, ASME Press, 1995
80. [Kacalak, 1995] Kacalak W. : Metodyka tworzenia algorytmów wnioskowania rozmytego do optymalizacji i sterowania w procesach szlifowania. *Prace Naukowe Instytutu Technologii Maszyn i Automatyzacji Politechniki Wrocławskiej - XVIII Naukowa Szkoła Obróbki Ściernej*, Wrocław 1995
81. [Kacalak, 1995a] Kacalak W. : Optymalizacja cykli współrzędnościowego szlifowania otworów z zastosowaniem sieci neuronowych . *Prace Naukowe Instytutu Technologii Maszyn i Automatyzacji Politechniki Wrocławskiej – XVIII Naukowa Szkoła Obróbki Ściernej*, Wrocław 1995
82. [Kacalak, 1996] Kacalak W. : Metody i zastosowania sztucznej inteligencji do diagnostyki, optymalizacji i sterowania w procesach szlifowania. *Materiały XIX Naukowej Szkoły Obróbki Ściernej*, Łódź 1996
83. [Kang et al., 2001] Kang M.C., Kim J.S., Kim H.J. : A monitoring technique using a multi-sensor in high speed machining. *Journal of Materials Processing Technology*, vol. 113/1-3 (2001), Special Issue, Korea 2001
84. [Karin, 1991] Karin E.D. : A simple procedure for pruning back propagation trained neural networks. *IEEE Transactions on Neural Networks* 1 (2), 1991
85. [Ketteler, 1999] Ketteler G. : Analysis of requirements for manufacturing systems. *Proceedings of the Second International Workshop on Intelligent Manufacturing Systems*, Leuven, Belgium 1999
86. [Khan, 1993] Khan E. : NeuFuz : The integration of fuzzy logic and neural nets offers designers tremendous application advantage – Today. *WESCON'93, Conference Record*, Moscone Convention Center, San Francisco 1993
87. [Kim i Dornfeld, 1999] Kim J., Dornfeld D.A. : Experimental study of burr formation in drilling of intersecting holes with gun drill and twist drills. *Technical Papers of the NAMRC, SME*, 1999
88. [Kim i Klamecki, 1990] Kim S., Klamecki B.E. : Milling cutter wear monitoring using spindle shaft vibration. *Monitoring and Control for Manufacturing Processes*, ASME, PED, Vol. 44, 1990
89. [Kim, 2000] Kim J. : Development of a drilling burr control chart. *Research Reports 1999/2000, Laboratory for Manufacturing Automation, University of California at Berkeley*, Berkeley 2000
90. [Kishawy i Elbestawi, 1997] Kishawy H.A., Elbestawi M.A. : On mechanics and properties of chip formation during machining of hardened steel. *MATADOR CONFERENCE*, Manchester, 1997
91. [Ko i Cho, 1994] Ko T.J., Cho D.W. : Adaptive optimization of face milling operations using neural networks. *First S.M. Wu Symposium on Manufacturing Science*, SME, Chicago 1994
92. [Kohonen, 1988] Kohonen T. : *Self-Organisation and Associative Memory*. Springer-Verlag, Berlin 1988
93. [König et al., 1992] König W., Kutzner K., Schehl U. : Tool monitoring of small drills with acoustic emission. *Int. J. Mach. Tools Manuf.*, Vol. 32, No. 4, 1992
94. [König et al., 1995] König W., Dornfeld D.A., Rehse M., Sokołowski A. : On designing of a tool wear monitoring system for multispindle drilling machine. *Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing*, Miedzyszyn/Warszawa 1995
95. [Kopac i Sali, 2001] S Kopac J., Sali S. : Tool wear monitoring during turning process. *Journal of Materials Processing Technology*, vol. 113/1-3 (2001), Special Issue, Korea 2001
96. [Korbicz et al., 1994] Korbicz J., Obuchowicz A., Uciński D. : *Sztuczne sieci neuronowe. Podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994



97. [Korbicz, 2000] Korbicz, J. : Optymalizacja modelowania neuronowego w diagnostyce procesów. II Międzynarodowy Kongres Diagnostyki Technicznej "Diagnostyka 2000", vol. 1, Warszawa, 2000
98. [Kosko, 1992] Kosko B. : Neural Networks and Fuzzy Systems - A Dynamical Systems Approach to Machine Intelligence. Prentice-Hall International Editions, 1992
99. [Kosmol (red), 1996] Adamczyk Z., Jemielniak K., Kosmol J., Sokołowski A. : Automatyzacja wytwarzania. Monitorowanie ostrza skrawającego. Metody konwencjonalne i sieci neuronowe. Pod redakcją J. Kosmola, Wydawnictwo Naukowo-Techniczne, Warszawa 1996
100. [Kosmol et al., 2002] Kosmol J., Sokołowski A., Niedbała M. : Machine tool as mechatronic system. 1st Intern. Congress on Mechatronics Incorporating ICANOV 2002 MECH2K2 (wydano na CD), Austria / Linz 2002
101. [Kosmol i Sokołowski, 1991] Kosmol J., Sokołowski A. : Adaptive control in wheel sets machining. Proceedings of International Conference "Modelling & Simulation", ASME, Vol.1, New Orleans 1991
102. [Kosmol i Sokołowski, 2000a] Kosmol J., Sokołowski A. : Machine tool as mechatronic system. Materiały Międzynarodowej Konferencji "Mechatronika 2000", vol. 1, Warszawa 2000
103. [Kosmol, 1995] Kosmol J. : Automatyzacja obrabiarek i obróbki skrawaniem. Wydawnictwa Naukowo – Techniczne, Warszawa 1995
104. [Kostka, 1998] Kostka P. : Badanie wrażliwości cech sygnałów diagnostycznych. III Krajowa Konferencja Naukowo – Techniczna : „Diagnostyka Procesów Przemysłowych”, Jurata 1998
105. [Krimmel et al., 2000] Krimmel O., Tonnessen K., Wen Li Z. : Potentials and limitations of tool condition monitoring for MoS<sub>2</sub> and TiN-coated drills with acoustic emission in dry machining. Proceedings of the XI Workshop on Supervising and Diagnostics of Machining Systems, Design and Optimization of Intelligent Machine Tools, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2000
106. [Kubowicz i Sokołowski, 1997] Kubowicz K., Sokołowski A. : Modelowanie zadziorów poobróbkowych w procesie wiercenia. Prace Naukowe Katedry Budowy Maszyn Nr 2/97, Politechnika Śląska w Gliwicach, Gliwice 1997
107. [Kumuluca et al., 1997] Kumuluca A., Tulunay E., Altinay O., Tulunay Y. : Relative significance of inputs to a neural network. Proceedings of the 1997 International Conference on Engineering Applications of Neural Networks, Stockholm 1997
108. [Leem i Dreyfus, 1992] Leem C.S., Dreyfus S. : A neural network with automatic feature selection for on-line monitoring of tool wear in metal-cutting. Proceedings of the 2nd Pacific Rim International Conference on Artificial Intelligence, Seoul 1992
109. [Leżański, 1998] Leżański P. : A neuro-fuzzy system for diagnostics of cylindrical grinding process. Proceedings of the V International Conference on Monitoring and Automatic Supervision in Manufacturing, Warsaw 1998
110. [Li et al., 1992] Li S., Elbestawi M.A., Du R. X. : A fuzzy logic approach for multi-sensor process monitoring in machining. Sensors and Signal Processing for Manufacturing, ASME, PED, Vol. 55, 1992
111. [Li i Kim, 1992] Li C.J., Kim T. : A new feedforward neural network structural and weight learning algorithm. Neural Networks in Manufacturing and Robotics, ASME, PED, Vol. 57, 1992
112. [Liang i Dornfeld, 1989] Liang S.Y., Dornfeld D.A. : Tool wear detection using time series analysis of acoustic emission. J. Eng. Industry, Vol. 111, 1989
113. [Lierath et al., 1988] Lierath F., Popke H., Goldau H. : Sensorsystem fur die Werkzeuguberwachung auf der basis des Körperschalls. Prace Naukowe Instytutu Technologii Budowy Maszyn Politechniki Wrocławskiej, Seria : Konferencje nr 13, Wrocław 1988
114. [Lin i Lee, 1991] Lin C. T., Lee G. C. S. : Neural-network-based fuzzy logic control and decision system, IEEE Transaction on Computers, Vol. 40, No 12, 1991
115. [Mahdi i Zhang, 2001] Mahdi M., Zhang L. : A finite element model for the orthogonal cutting of fibre-reinforced composite materials. Journal of Materials Processing Technology, vol. 113/1-3 (2001), Special Issue, Korea 2001
116. [Mańczak, 1976] Mańczak K. : Technika planowania eksperymentu. WNT, Warszawa 1976
117. [Marsumura et al., 1993] Marsumura T., Obikawa T., Shirakashi T., Usui E. : Autonomous turning operation planning with predicting tool wear and surface roughness. Trans. of NAMRI/SME, Vol. 21, 1993
118. [Mechanik, 1989] Diagnostowanie stanu narzędzi w autonomicznych stacjach obróbkowych. Oprac. na podst. VDI-Z 12/1988, Mechanik 6/1989
119. [Mehrotra et al., 1991] Mehrotra K.G., Mohan C.K., Ranka S. : Bounds on the number of samples needed for neural learning. IEEE Transactions on Neural Networks, Vol. 2, No. 6, 1991
120. [Mehta et al., 1983] Mehta N.K., Pandey P.C., Chakravarti G. : An investigation of tool wear and the vibration spectrum in milling. Wear, Vol. 91, 1983
121. [Michalewicz, 1992] Michalewicz Z. : Genetic Algorithms + Data Structure = Evolutionary Programs. Springer-Verlag, AI Series, New York 1992
122. [Min et al., 2001] Min S., Kim J., Dornfeld D.A. : Development of a drill burr control chart for low alloy steel AISI 4118. Journal of Materials Processing Technology, vol. 113/1-3 (2001), Special Issue, Korea 2001
123. [Moczulski, 1997] Moczulski W. : Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn. Zeszyty Naukowe Politechniki Śląskiej, seria : MECHANIKA, z. 130, Gliwice 1997
124. [Monostori, 1992] Monostori L. : Artificial neural networks in intelligent manufacturing. Robotics & Computer-Integrated Manufacturing, Vol. 9, No. 6, 1992

125. [Monostori, 1993] Monostori L. : Intelligent manufacturing through neural networks. Proceedings of the International Conference on Intelligent Autonomous Systems, Pittsburgh 1993
126. [Monostori, 1995] Monostori L. : Hybrid AI approaches to supervision and control of manufacturing processes. Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing, Miedzyszyn/Warszawa 1995
127. [Mori et al., 1992] Mori K., Kasashima N., Yamane T., Nakai T. : An intelligent vibration diagnostic system for cylindrical grinding. Proceedings of the 1992 Japan - USA Symposium on Flexible Automation, San Francisco 1992
128. [Morrison, 1990] Morrison D.F. : Wielowymiarowa analiza statystyczna. Państwowe Wydawnictwa Naukowe, Warszawa 1990
129. [Nakayama i Arai, 1987] Nakayama K., Arai M. : Burr Formation in Metal Cutting. Annals of the CIRP, Vol. 36/1/ 1987
130. [Narayanaswami i Dornfeld, 1994] Narayanaswami R., Dornfeld D.A. : Design and process planing strategies for burr minimization and deburring. Trans. of NAMRI/SME, Vol. 22, 1994
131. [Narayanaswami i Sokołowski, 1994] Narayanaswami R., Sokołowski A. : Minimizing burr length in face milling using genetic algorithm. Research Reports 1993/1994, Laboratory for Manufacturing Automation, University of California at Berkeley, Berkeley 1994
132. [Oishi i Yasuda, 1997] Oishi K., Yasuda T. : Machinability of reisen impregnated sintered iron. MATADOR CONFERENCE, Manchester, 1997
133. [Orantek i Burczyński, 2000] Orantek P., Burczyński T. : Hybrid evolutionary algorithms aided by sensitivity information in identification and structural optimisation. Conference Proceedings „Methods of Artificial Intelligence in Mechanics and Mechanical Engineering”, AIMECH'2000, Gliwice 2000
134. [Osowski, 1996] Osowski S. : Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa 1996
135. [Pao, 1989] Pao Yoh-Han : Adaptive Pattern Recognition and Neural Networks. Addison - Wesley Co., Redwood City, USA, 1989
136. [Parlos et al., 1992] Parlos A.G., Muthusami J., Fernandez B., Atiya A.F., Tsai W.K. : An adaptive Backpropagation learning algorithm for multilayer neural networks. Proceedings of the Artificial Neural Networks in Engineering Conference, St. Louis 1992
137. [Peterson i Ladage, 1992] Peterson G.E., Ladage R.N. : On using sensitivity analysis to prune the inputs to a neural network. Proceedings of the Artificial Neural Networks in Engineering Conference, St. Louis 1992
138. [Pettersson et al., 2001] Pettersson L., Hakansson L., Cleasson I., Olsson S. : Active control of machine-tool vibration in a CNC lathe based on an active tool holder shank with embedded piezo ceramic actuators. Proceedings of the Eighth International Congress on Sound and Vibration, vol. 2, Hong Kong (China) 2001
139. [Piramuthu, 1996] Piramuthu S. : The effect of feature selection on backpropagation in Feed-Forward Neural Networks. Proceedings of the International Workshop on Neural Networks HELNET'94 – '95, Vol. I/II, VU University Press, Amsterdam 1996
140. [Praca zbiorowa, 2000] Praca zbiorowa : Biocybernetyka i inżynieria biomedyczna 2000, tom 6 : Sieci neuronowe. Red. Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R., Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000
141. [Projekt Badawczy, 1993] Projekt badawczy KBN nr 707319101 „Badania nad wykorzystaniem sygnałów wibroakustycznych do nadzorowania zużycia ostrza skrawającego”. Projekt zrealizowany pod kierunkiem prof. J.Kosmola, Politechnika Śląska w Gliwicach, Gliwice 1993 – 1995
142. [Projekt Badawczy KBN, 1997] Projekt badawczy KBN nr 7 T07 D 010 08 „Inteligentny system wspomaganie projektowania układów nadzorujących stan procesu skrawania”. Projekt zrealizowany pod kierunkiem dra inż. A. Sokołowskiego, Politechnika Śląska w Gliwicach, Gliwice 1995-1997
143. [Projekt Badawczy KBN, 1999] Projekt badawczy KBN nr 7 TO7 D 005 17 „Inteligentne narzędzia w diagnostyce procesu skrawania”. Projekt realizowany pod kierunkiem dra inż. A. Sokołowskiego, Politechnika Śląska w Gliwicach, 1999 (projekt w trakcie realizacji)
144. [Projekt PSA/RENAULT] Projekt badawczy “Drill state diagnostics”. Projekt zlecony przez Renault, France oraz PSA Peugeot Citroen, France, projekt zrealizowany w The University of California at Berkely pod kierunkiem Prof. D.A. Dornfelda, Berkely 1992-1993
145. [Rangwala i Dornfeld, 1990] Rangwala S., Dornfeld D.A. : Sensor integration using neural networks for intelligent tool condition monitoring. Journal of Engineering for Industry, Vol. 112, August 1990
146. [Rao, 1986] Rao S.B. : Tool wear monitoring through the dynamics of stable turning. J. Eng. Industry, Vol. 108, August 1986
147. [Richter i Spiewak, 1990] Richter F., Spiewak S.A. : A system for on-line detection and prediction of catastrophic tool failure in milling. Trans. of NAMRI/SME, Vol. 17, 1990
148. [Rumelhardt et al., 1986] Rumelhart D.E., Hinton G.E., Williams R.J. : Learning internal representation by error propagation. Parallel Distributing Processing, The MIT Press, 1986
149. [Rutkowska et al., 1997] Rutkowska D., Piliński M., Rutkowski M. : Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Wydawnictwa Naukowe PWN, Warszawa 1997
150. [Sakakura i Inasaki, 1992] Sakakura M., Inasaki I. : A neural network approach to the decision-making process for grinding operations. Annals of the CIRP, Vol. 36/1/ 1992
151. [Sarwal i Srinath, 1992] Sarwal P., Srinath M.D. : A conjugate gradient algorithm for learning in multilayer perceptrons. Proceedings of the Artificial Neural Networks in Engineering Conference, St. Louis 1992

152. [Shiraishi, 1988] Shiraishi M. : Scope of in-process measurement, monitoring and control techniques in machining processes - Part 1 :In-process techniques for tools. Precision Engineering, Butterworth & Co Ltd, November 1988
153. [Sietsma i Dow, 1991] Sietsma J., Dow R.J.F. : Creating artificial neural networks that generalize. Neural Networks, Vol. 4, No. 1, 1991
154. [Sobczak i Malina, 1985] Sobczak W., Malina W. : Metody selekcji i redukcji informacji. WNT, Warszawa 1985
155. [Sokołowski et al., 1992] Sokołowski A., Liu J.J., Kosmol J. : On the correlation between the vibration measurement and tool wear in turning. Proceedings of the 1992 Japan - USA Symposium on Flexible Automation, San Francisco 1992
156. [Sokołowski et al., 1994] Sokołowski A., Vincent P., Dornfeld D.A. : Drill state monitoring during multispindle machining. Trans. of NAMRI/SME, Vol. 22, 1994
157. [Sokołowski et al., 1994a] Sokołowski A., Narayanaswami R., Dornfeld D.A. : Prediction of burr size using neural networks and fuzzy logic. The Japan-U.S.A. Symposium on Flexible Automation, Kobe 1994
158. [Sokołowski et al., 1995] Sokołowski A., Kosmol J., Dornfeld D.A. : Vibration measurement as a means for tool wear monitoring; Part 2 : Neural network application. Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing, Miedzyszyn/Warszawa 1995
159. [Sokołowski et al., 1996] Sokołowski A., Wodecki J., Czech M. : Burr formation modelling in metal cutting. International Conference on "Development of Metal Cutting DMC 96", Kosice 1996
160. [Sokołowski et al., 1996a] Sokołowski A., Kolka A., Kosmol J. : Projekt badawczy: Inteligentny system wspomaganie projektowania układów nadzorujących stan procesu skrawania. Prace Naukowe Katedry Budowy Maszyn Nr 1/96, Politechnika Śląska w Gliwicach, Gliwice 1996
161. [Sokołowski et al., 1997] Sokołowski A., Kolka A., Kosmol J. : An approach to support designing of monitoring systems. MANUFACTURING CONTROL OPTIMIZATION, Proceedings of the VIII Workshop on Supervising and Diagnostics of Machining Systems, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 1997
162. [Sokołowski et al., 1997a] Sokołowski A., Kolka A., Kosmol J. : A new approach to aid designing of monitoring systems. MATADOR CONFERENCE, Manchester, 1997
163. [Sokołowski et al., 1997b] Sokołowski A., Kolka A., Kosmol J. : Wspomaganie projektowania układów diagnostycznych. Rozdział w pozycji książkowej „Optymalizacja sterowania wytwarzaniem”, Seria : Inżynieria Maszyn, pod redakcją J. Jędrzejewskiego, vol. 2, Nr 2/3, 1997
164. [Sokołowski i Dornfeld, 1994] Sokołowski A., Dornfeld, D.A. : Intelligent system for cutting parameter optimization and design of cutting process monitoring systems. First S.M. Wu Symposium on Manufacturing Science, SME, Chicago 1994

165. [Sokołowski i Dornfeld, 1994a] Sokołowski A., Dornfeld D.A. : On designing tool wear monitoring systems using supervised and unsupervised neural networks. Mechatronics; The Basis for New Industrial Development, Computational Mechanics Publications, Southampton, Boston 1994
166. [Sokołowski i Gude, 1999] Sokołowski A., Gude M. : Optimisation of curvature of laminate plates with genetic algorithm. Prace Naukowe Katedry Budowy Maszyn Nr 2/99, Politechnika Śląska w Gliwicach, Gliwice 1999
167. [Sokołowski i Kosmol, 1991] Sokołowski A., Kosmol J. : Utilization of vibration measurements of machine tool elements in the monitoring of the cutting tool condition. Proceedings of 4th World Meeting on Acoustic Emission and 1st International Conference on Acoustic Emission in Manufacturing, Boston 1991
168. [Sokołowski i Kosmol, 1994] Sokołowski A., Kosmol J. : On application of neural networks, fuzzy logic and genetic algorithm for design of tool wear monitoring systems. Proceedings of the III-rd International Conference „Achievements in the Mechanical and Material Science”, Gliwice 1994
169. [Sokołowski i Kosmol, 1995] Sokołowski A., Kosmol J. : Cutting process supervision : review of artificial intelligence application. Proceedings of VI Workshop on Diagnostics and Supervision in Flexible Manufacturing, Prace Naukowe Instytutu Technologii Maszyn i Automatykacji Politechniki Wrocławskiej nr 61, Seria : Konferencje 26, Wrocław 1995
170. [Sokołowski i Kosmol, 1995a] Sokołowski A., Kosmol J. : Diagnostyka narzędzia za pomocą sieci neuronowej. IV Naukowa Szkoła Nadzoru i Diagnostyki Systemów Obróbkowych, Sztuczna Inteligencja w Diagnostyce i Nadzorowaniu, Prace Naukowe Instytutu Technologii Maszyn i Automatykacji Politechniki Wrocławskiej 57, seria: Konferencje 23, Wrocław 1995
171. [Sokołowski i Kosmol, 1995b] Sokołowski A., Kosmol J. : Sieć neuronowa typu Feed Forward Back Propagation jako narzędzie do selekcji i integracji cech sygnałów pomiarowych. XXXIV Sympozjon „Modelowanie w Mechanice”, Zeszyty Naukowe Politechniki Śląskiej, seria: Mechanika , z. 121, Gliwice 1995
172. [Sokołowski i Kosmol, 1995c] Sokołowski A., Kosmol J. : Vibration measurement as a means for tool wear monitoring; Part 1 : Conventional method application. Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing, Miedzyszyn/Warszawa 1995
173. [Sokołowski i Kosmol, 1995d] Sokołowski A., Kosmol J. : Koncepcja inteligentnego czujnika w zastosowaniu do identyfikacji zużycia ostrza skrawającego. VIII Krajowa Konferencja Metrologii, Warszawa 1995
174. [Sokołowski i Kosmol, 1995e] Sokołowski A., Kosmol J. : An example of Feed Forward Back Propagation and ART-2A neural networks application for tool wear monitoring. Proceeding of the Second International Symposium on Methods and Models in Automation and Robotics, Międzyzdroje, 1995
175. [Sokołowski i Kosmol, 1996] Sokołowski A., Kosmol J. : Designing intelligent diagnostic systems. Proceedings of the International Conference on "Computer Integrated Manufacturing - CIM 96", vol. I, Zakopane 1996

176. [Sokołowski i Kosmol, 1996a] Sokołowski A., Kosmol J. : Intelligent Monitoring System Designer. Proceedings of the 1996 Japan - USA Symposium on Flexible Automation, Vol. 2, Boston 1996
177. [Sokołowski i Kosmol, 1996b] Sokołowski A., Kosmol J. : Przykłady zastosowań wybranych metod sztucznej inteligencji w diagnostyce procesu obróbki skrawaniem. Materiały Kongresu Diagnostyki Technicznej KDT'96, Gdańsk 1996
178. [Sokołowski i Kosmol, 1997] Sokołowski A., Kosmol J.: Koncepcja i realizacja inteligentnego systemu wspomagania projektowania układów diagnostycznych. Zeszyty Naukowe Katedry Mechaniki Stosowanej, z. 3, Gliwice 1997
179. [Sokołowski i Kosmol, 1998] Sokołowski A., Kosmol J. : Feature selection for burr height estimation. Proceedings of the V International Conference on Monitoring and Automatic Supervision in Manufacturing, Warsaw 1998
180. [Sokołowski i Kosmol, 1998a] Sokołowski A., Kosmol J.: Wybrane testy metod selekcji i integracji cech sygnałów pomiarowych. Technologia Maszyn, IV Naukowe Warsztaty Profesorskie TM'98 i III Forum Prac Badawczych, Wyd. Pol. Koszalińskiej, Koszalin 1998
181. [Sokołowski i Kosmol, 1999] Sokołowski A., Kosmol J. : On some aspects of productivity and quality improvement in machining. Refereed papers presented at the 8th International Conference on "Productivity & Quality Research", Vaasa, Finland 1999
182. [Sokołowski i Kosmol, 1999a] Sokołowski A., Kosmol J. : Artificial intelligence in cutting process monitoring. Advances in Technology of Machines and Mechanical Equipment, Poland, vol. 23, No 3, 1999
183. [Sokołowski i Kosmol, 2000] Sokołowski A., Kosmol J. : Selected aspects of practical implementation of Intelligent Diagnostic System. II Międzynarodowy Kongres Diagnostyki Technicznej "Diagnostyka 2000", vol. 2, Warszawa 2000
184. [Sokołowski i Kosmol, 2001] Sokołowski A., Kosmol J. : Complex approach to vibration based cutting tool diagnostics. Proceedings of the Eighth International Congress on Sound and Vibration, vol. 2, Hong Kong (China) 2001
185. [Sokołowski i Kosmol, 2001a] Sokołowski A., Kosmol J. : On a specific approach to application of artificial neural networks for machine tool monitoring. Proceedings of the 4th International Conference "Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques", Paryż 2001
186. [Sokołowski i Kosmol, 2001b] Sokołowski A., Kosmol J. : Selected examples of cutting process monitoring and diagnostics. Journal of Materials Processing Technology, vol. 113/1-3 (2001), Special Issue, Korea 2001
187. [Sokołowski i Rehse, 1994] Sokołowski A., Rehse M. : Feature selection task in tool wear monitoring – genetic algorithm approach. Research Reports 1993/1994, Laboratory for Manufacturing Automation, University of California at Berkeley, Berkeley 1994
188. [Sokołowski, 1993] Sokołowski A. : Comparison between neural networks and fuzzy logic for tool wear detection. Research Reports 1992/1993, Laboratory for Manufacturing Automation, University of California at Berkeley, Berkeley 1993
189. [Sokołowski, 1995] Sokołowski A. : Nadzorowanie stanu ostrza skrawającego z zastosowaniem sieci neuronowych. Rozprawa doktorska, Katedra Budowy Maszyn, Politechnika Śląska w Gliwicach, Gliwice 1995
190. [Sokołowski, 1996] Sokołowski A. : Teoretyczne i praktyczne aspekty zastosowań sieci neuronowej Feed Forward Back Propagation. Prace Naukowe Katedry Budowy Maszyn Nr 1/96, Politechnika Śląska w Gliwicach, Gliwice 1996
191. [Sokołowski, 2000] Sokołowski A. : Konstruowanie sztucznych sieci neuronowych. Conference Proceedings „Methods of Artificial Intelligence in Mechanics and Mechanical Engineering”, AIMECH'2000, Gliwice 2000
192. [Sokołowski, 2001] Sokołowski A. : Application of neural networks and neuro-fuzzy logic for burr modelling. Proceedings of the 12th International DAAAM Symposium, Jena 2001
193. [STATISTICA] STATISTICA for Windows, Computer program manual, ver. 5.1 D, StatSoft, Inc., 1996
194. [STATISTICA-NN] STATISTICA – Neural Networks, User Guide and Descriptions, ver. 3.0 B, Trajan Software Ltd., StatSoft, Inc., 1998
195. [Stein et al., 1993] Stein J., Narayanaswami R., Ho S., Lam A., Babu M., Park I., Afzal A., Dornfeld D. : Intelligent deburring of precision components. Proceedings of the Symposium on Deburring and Surface Finishing, SME, 1993
196. [Stein i Dornfeld, 1997] Stein J., Dornfeld D. : An architecture for integrated design and manufacturing of precision mechanical components, Trans. of NAMRI/SME, Vol. 25, 1997
197. [Such et al., 1999] Suh J.H., Kumara S.R.T., Mysore S. P. : Machinery fault diagnosis and prognosis : Application of advanced signal processing techniques. Annals of the CIRP, Vol. 48/1/ 1999
198. [Sung i Kuo, 1992] Sung M.H., Kuo L.E. : The use of Back-Propagation neural networks to construct the membership functions. Proceedings of the 2nd Pacific Rim International Conference on Artificial Intelligence, Seoul 1992
199. [Sunil et al., 1990] Sunil Elanayar V.T., Shin Y. C., Kumara S. : Machining condition monitoring for automation using neural networks. Monitoring and Control for Manufacturing Processes, ASME, PED, Vol. 44, 1990
200. [Susmaga et al., 1999] Susmaga R., Słowiński R., Greco S., Matarazzo B. : Computation of reducts for multi-attribute and multi – criteria classification. Intelligent Information Systems, IPI PAN, Ustroń 1999
201. [Szabo et al., 1989] Szabo B., Du R., Wu S.M. : Tool wear monitoring for milling processes using DDS methodology. Trans. of NAMRI/SME, Vol. 17, 1989
202. [Tadeusiewicz, 1993] Tadeusiewicz R. : Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa 1993

203. [Tadeusiewicz, 2000] Tadeusiewicz R. : Sieci neuronowe jako wciąż jeszcze nie w pełni wykorzystane narzędzie diagnostyki. II Międzynarodowy Kongres Diagnostyki Technicznej "Diagnostyka 2000", vol. 1, Warszawa, 2000
204. [Takagi i Hayashi, 1991] Takagi H., Hayashi I. : NN-driven fuzzy reasoning. *International Journal of Approximate Reasoning*, Vol. 5, No. 3, 1991
205. [Takagi i Sugeno, 1985] Takagi T., Sugeno M. : Fuzzy identification of systems and its applications to modelling and control. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 15, 1985
206. [Takahashi et al., 1993] Takahashi H., Tomita E., Kawabata T. : Separability of internal representation in multilayer perceptrons with application to learning. *Neural Networks*, Vol. 6, 1993
207. [Takata et al., 1986] Takata S., Ahn J.H., Miki M., Miyao Y., Sata T. : A sound monitoring system for fault detection of machine and machining states. *Annals of the CIRP*, Vol. 35/1/ 1986
208. [Takata et al., 1987] Takata S., Nakajima T., Ahn J.H., Sata T. : Tool breakage monitoring by means of fluctuation in spindle rotational speed. *Annals of the CIRP*, Vol. 36/1/ 1987
209. [Takeshita i Inasaki, 1991] Takeshita H., Inasaki I. : Monitoring of endmill cutter with an AE-sensor. *Proceedings of 4th World Meeting on Acoustic Emission and 1st International Conference on Acoustic Emission in Manufacturing*, Boston, 1991
210. [Tang et al., 2001] Tang Y., Sun Q., Lu W. : Tool wear detection for microdrilling process with discrete wavelet transform. *Proceedings of the Eighth International Congress on Sound and Vibration*, vol. 2, Hong Kong (China) 2001
211. [Tansel i Mc Laughlin, 1991] Tansel I. N., Mc Laughlin C. : On-line monitoring of tool breakage with unsupervised neural networks. *Trans. of NAMRI/SME*, Vol. 20, 1991
212. [Tarng et al., 1994] Tarng Y.S., Li T.C., Chen M.C. : On-line drilling chatter recognition and avoidance using an ART-2A neural network. *International Journal of Machine Tools & Manufacture, Design, Research and Application*, vol. 34, no 7, 1994
213. [TCM Workshop, 1993] *Proceedings : Workshop on Tool Condition Monitoring (TCM). Second Meeting of the CIRP Working Group on TCM*, edited by W. Weis and D. Dornfeld, Edinburgh 1993
214. [Teshima et al., 1993] Teshima T., Shibasaka T., Takuma M., Yamamoto A., Iwata K. : Estimation of cutting tool life by processing tool image data with neural network. *Annals of the CIRP*, Vol. 42/1/ 1993
215. [Teti i Dornfeld, 1989] Teti R., Dornfeld D. : Modelling and experimental analysis of acoustic emission from metal cutting. *J. Eng. Industry*, Vol. 111, August 1989
216. [Tyrlik et al., 1989] Tyrlik T., Kosmol J., Sokołowski A. : Komputerowa obróbka dyskretnych sygnałów pomiarowych - pakiet DATA-DYN. *Materiały VII Konferencji MiSPWK*, Warszawa 1989
217. [Ueda i Manabe, 1993] Ueda K., Manabe K. : Rigid – plastic FEM analysis of three – dimensional deformation field in chip formation process. *Annals of the CIRP*, Vol. 42/1/ 1993
218. [Urbaniak, 2001] Urbaniak M. : Neural network approach to analyse of grinding wheel cutting surface. *Proceedings of the 12th International DAAAM Symposium*, Jena 2001
219. [Virck i Thusty, 1992] Virck K.C., Thusty J. : Adaptive thresholding for cutter breakage in milling. *Sensors and Signal Processing for Manufacturing*, ASME, PED, Vol. 55, 1992
220. [Wang i Dornfeld, 1992] Wang X., Dornfeld D.A. : In-process tool wear monitoring using neural networks. *Proceedings of the 1992 Japan – USA Symposium on Flexible Automation*, San Francisco 1992
221. [Wang i Mendel, 1992] Wang L.X., Mendel J.M. : Generating fuzzy rules by learning from examples. *IEEE Transactions on Systems, Man and Cybernetics*, Vol. 22, No. 6, 1992
222. [Westkamper et al., 1995] Westkamper E., Lange D., Hoffmeister H.W. : Safe abrasive process through adaptive control under highly chaotic conditions. *Proceedings of the IV International Conference on Monitoring and Automatic Supervision in Manufacturing*, Miedzyszyn/Warszawa 1995
223. [Westkamper et al., 1996] Westkamper E., Lange D., Schmidt T. : Modelling the grinding process with regression models and artificial neural networks. *Production Engineering, Research and Development in Germany*, Vol. III/1, 1996
224. [Yager, 1994] Yager R.R. : Modelling and formulating fuzzy knowledge bases using neural networks. *Neural Networks*, Vol. 7 No. 8, 1994
225. [Yamasaki, 1996] Yamasaki H. (editor) : *Intelligent Sensors, Handbook of Sensors and Actuators*. ELSEVIER, Amsterdam, 1996
226. [Yao i Fang, 1993] Yao Y.L., Fang X.D. : Assessment of chip forming patterns with tool wear progression in machining via neural networks. *Int. J. Mach. Tools Manufact.*, Vol. 33, No. 1, 1993
227. [Yerramareddy et al., 1993] Yerramareddy S., Lu S.C.-Y., Arnold K.F. : Developing empirical models from observational data using artificial neural networks. *Journal of Intelligent Manufacturing*, Vol. 4, No. 1, February 1993
228. [Zackshouse, 2001] Zackshouse, M. : How blind can neural networks based diagnostic be ?. *Proceedings of the 4th International Conference "Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques"*, Paryż 2001
229. [Zadeh, 1983] Zadeh L. A. : A Computational Approach to Fuzzy Quantifiers in Natural Languages. *Comp & Maths with Appls*, Vol. 9, No 1, 1983
230. [Żurada et al., 1994] Żurada J.M., Malinowski A., Cloete I. : Sensitivity analysis for minimisation of input data dimension for feedforward neural network. *IEEE Symposium CAS*, London 1994
231. [Żurada, 1992] Żurada J.M. : *Introduction to Artificial Neural Systems*. West Publishing Company, 1992

## Wybrane zagadnienia projektowania układów diagnostycznych obrabiarki i procesu skrawania

### Streszczenie

Przedmiotem pracy jest zagadnienie wspomaganie projektowania układów diagnostycznych obrabiarki i procesu skrawania. Dyskusja przeprowadzona w początkowej części pracy uzasadniła konieczność wspomaganie projektowania układów diagnostycznych, co stanowiło o celowości i ukierunkowaniu podjętych badań. Przewodnią ideę badań odzwierciedla oryginalna koncepcja Inteligentnego Układu Diagnostycznego (IUD). Analizując koncepcję takiego układu zaproponowano implementację IUD w Inteligentnym Projektancie Układów Diagnostycznych (IPUD). Równocześnie uwypuklono znaczenie selekcji i integracji danych, co było przesłanką dokonania wyboru metod możliwych do zastosowania na tych etapach projektowania układów diagnostycznych.

Dokonując wyboru metod uwzględniono specyficzne wymagania stawiane IUD/IPUD. Dążono również do zróżnicowania metod, potencjalnie pozwalającego na uogólnienia wniosków z przeprowadzonych badań. Analizowano metody proponowane w literaturze, metody dostępne w komercyjnych pakietach oprogramowania oraz metody dotychczas stosowane w diagnostyce obrabiarki i procesu skrawania. Zastosowano także oryginalne, opracowane lub zmodyfikowane przez autora rozwiązania. Przed przystąpieniem do realizacji badań przyjęto zasady prowadzenia testów i zaproponowano kryteria oraz sposoby oceny metod selekcji i integracji danych.

W zasadniczej części badań podjęto próby rozwiązania wybranych zadań (problemów) diagnostycznych. Rozpatrując każdy z problemów dokonywano opisu stanowiska pomiarowego oraz charakteryzowano przeprowadzone pomiary. Prowadzono również wybiórcze analizy aspektów technologicznych w celu uwypuklenia specyfiki lub stopnia złożoności rozwiązywanych zadań. W ramach pracy rozpatrywano problem klasyfikacji zużycia narzędzia podczas wiercenia wielowrzecionowego i podczas toczenia. Problem ten analizowano w odniesieniu do zróżnicowanych układów pomiarowych, tj. rozważano typowy układ wieloczuJNIKOWY oraz układ jednoczuJNIKOWY. Dyskutowano także zastosowanie metod selekcji i integracji w zadaniach aproksymacji, tj. rozważano problem diagnostyki przedmiotu obrabianego (problem tworzenia się zadziórów poobróbkowych) oraz problem diagnostyki odkształceń termicznych szlifierki.

Zaproponowane w pracy kryteria i sposoby oceny oraz przyjęte zasady realizacji testów pozwoliły na usystematyzowanie metod selekcji i integracji danych. Natomiast przeprowadzenie wielokierunkowych badań z zastosowaniem zasadniczo zróżnicowanych zadań oraz porównanie uzyskanych wyników umożliwiło weryfikację przydatności rozpatrywanych metod i wskazanie wytycznych oraz zasad ich jak najbardziej efektywnego zastosowania.

## Selected problems of designing of the machine tool and cutting process diagnostic systems

### Abstract

The subject of this work is related to aiding of machine tool and cutting process diagnostic system design. The discussion conducted in the first part of the dissertation justified necessity for aiding design of such systems. This justification depicted the aim and direction of the research to conduct, as well. The main idea of the research has been reflected by a concept of Intelligent Diagnostic System (IUD). Analysis of the above mentioned concept led to suggestion of implementing the IUD in the Intelligent Diagnostic System Designer (IPUD). Simultaneously, importance of data selection and integration was emphasised and methods that can be possibly applied at these stages of diagnostic system design have been selected.

The selection of the methods has been done focusing on the specific requirements of the IUD / IPUD. Moreover, it has been decided to select possibly divers solutions that potentially allow generalising the conclusions of the tests conducted. The selection was performed based on the literature review, commercially available software and the methods, which have been applied in the field of machine tool and cutting process diagnostics. Methods and algorithms developed by the Author of the dissertation have been considered, as well. Before conducting the tests, a set of rules for running such tests was assumed and criteria and means for data selection and integration method assessment were decided.

In the main part of the dissertation several diagnostic tasks (problems) were analysed. In each case, short characteristics of measuring set-up and recorded signals was presented. Then, technological aspects specific to each problem were emphasised in order to point at complexity of task to be solved. First, classification of cutting tool wear during multispindle drilling and turning was discussed. It can be underlined that not only different types of machining were analysed but different types of measuring set-ups, i.e. multi-sensor and single-sensor, were considered, as well. Also, application of the data selection and integration methods for solving an approximation task was discussed. In this case, a problem of workpiece diagnostics (i.e. a problem of burr formation) and a problem of thermal deformation of grinding machine tool were analysed.

The proposed in the dissertation rules for running the tests and proposed criteria and means of assessment allowed systematising the data selection and integration methods. Whereas, the widely oriented research conducted based on the variety of diagnostic tasks together with careful comparison of the achieved results permitted verifying suitability of the considered methods and pointing at rules and settings for their the most effective application.

Wydano za zgodą

Rektora Politechniki Śląskiej

Wydawnictwo Politechniki Śląskiej  
ul. Akademicka 5, 44-100 Gliwice  
tel./fax (032) 237-13-81

[www.polsl.gliwice.pl/alma.mater/wps.html](http://www.polsl.gliwice.pl/alma.mater/wps.html)  
[wydawnictwo@polsl.gliwice.pl](mailto:wydawnictwo@polsl.gliwice.pl)

Nakład 100+50	Ark. wyd. 16	Ark. druk. 14	Papier offset. 70x100, 80 g
Oddano do druku 5.05.2003 r.	Podpis. do druku 5.05.2003 r.		Data ukończ. maj 2003 r.
Zam. 154/03			

Fotokopie, druk i oprawę  
wykonano w Zakładzie Graficznym Politechniki Śląskiej w Gliwicach, ul. Kujawska 1

BIBLIOTEKA GŁÓWNA  
Politechniki Śląskiej

P.3361/03/142

DRUK: Drukarnia Gliwice, ul. Zarytektwa 27, tel. 230 49 50