


Marek FIDALI

METODYKA
TERMOGRAFICZNEJ DIAGNOSTYKI
OBIEKTÓW TECHNICZNYCH



METODYKA TERMOGRAFICZNEJ DIAGNOSTYKI OBIEKTÓW TECHNICZNYCH



**METODYKA
TERMOGRAFICZNEJ DIAGNOSTYKI
OBIEKTÓW TECHNICZNYCH**

Marek FIDALI

**METODYKA
TERMOGRAFICZNEJ DIAGNOSTYKI
OBIEKTÓW TECHNICZNYCH**

Gliwice 2013

Marek FIDALI

**METODYKA TERMOGRAFICZNEJ DIAGNOSTYKI
OBIEKTÓW TECHNICZNYCH**

Recenzenci: **prof. dr hab. inż. Bogusław WIĘCEK**
dr hab. inż. Jacek DYBAŁA

Monograficzna seria wydawnicza Biblioteka Problemów Eksploatacji – Studia i Rozprawy
Redaktor naukowy: **prof. dr hab. inż. Adam MAZURKIEWICZ**

© Copyright by Marek Fidali;
Politechnika Śląska, Gliwice 2013

ISBN 978-83-7789-194-0

Praca naukowa finansowana ze środków Narodowego Centrum Nauki w ramach projektu badawczego
N N504 508340 realizowanego w latach 2011–2013.

Wydanie monografii częściowo sfinansowane z funduszy statutowych.

Współpraca wydawnicza: Instytut Technologii Eksploatacji – Państwowy Instytut Badawczy, Radom
Projekt okładki: Marek Fidali



Wydawnictwo Naukowe Instytutu Technologii Eksploatacji – PIB
26-600 Radom, ul. K. Pułaskiego 6/10, tel. centr. (48) 364-42-41, fax (48) 364-47-65
e-mail: instytut@itee.radom.pl, <http://www.itee.radom.pl>

Spis treści

Od autora	9
1. Wstęp	11
1.1. Diagnostyka termiczna	11
1.2. Termografia w podczerwieni	11
1.3. Analiza obrazów termograficznych w diagnozowaniu maszyn i urządzeń	13
1.4. Geneza pracy	13
1.5. Cel pracy	14
1.6. Zakres pracy	14
2. Wybrane zagadnienia termografii i przetwarzania obrazów	17
2.1. Zjawiska ciepłe zachodzące w obiektach technicznych	17
2.1.1. Przepływ ciepła przez przewodzenie (kondukcję)	18
2.1.2. Przepływ ciepła przez konwekcję	18
2.1.3. Przepływ ciepła przez radiację (promieniowanie)	18
2.2. Termografia w podczerwieni	20
2.3. Obrazowanie podczerwieni	21
2.3.1. Parametry urządzeń obrazowania w podczerwieni	23
2.3.2. Obraz termograficzny i jego reprezentacja	25
2.4. Sygnał diagnostyczny	28
2.4.1. Wielowymiarowy sygnał diagnostyczny	29
2.4.2. Sygnał termograficzny	30
2.5. Przetwarzanie obrazów	30
2.5.1. Przekształcenia bezkontekstowe	31
2.5.2. Metody przetwarzania bazujące na dwóch obrazach	34
2.5.3. Metody przetwarzania obrazów w dziedzinie czasu	35
2.5.4. Przekształcenia kontekstowe	36
2.5.5. Segmentacja obrazu	37
2.5.6. Metody transformacyjne	37
2.6. Komputerowa analiza obrazów	40
2.7. Rozpoznawanie obrazów	42
2.7.1. Dopasowywanie wzorca	43
2.7.2. Podejście syntaktyczne	43
2.7.3. Podejście statystyczne	43
2.7.4. Rozpoznawanie z zastosowaniem sztucznych sieci neuronowych	44
2.7.5. Redukcja wymiarowości zbioru cech	45
2.8. Fuzja danych	46
2.8.1. Fuzja obrazów	46
2.8.2. Fuzja klasyfikatorów	48
3. Termograficzne metody diagnozowania	51
3.1. Metody termografii pasywnej	51
3.1.1. Jednorazowe inspekcje termograficzne	52
3.1.2. Cykliczne inspekcje termograficzne	52
3.1.3. Ciągła obserwacja w podczerwieni	59
3.1.4. Ogólne zasady prowadzenia inspekcji termograficznych	62

3.2.	Metody termografii aktywnej	63
3.2.1.	Termografia impulsowa	65
3.2.2.	Termografia impulsowo-fazowa	65
3.2.3.	Termografia synchroniczna	66
3.3.	Dokładność pomiarów termograficznych	66
4.	Metodyka diagnostyki termograficznej	69
4.1.	Diagnozowanie obiektów z zastosowaniem termografii	69
4.2.	Strategie obserwacji termograficznych	71
4.2.1.	Cykliczne obserwacje termograficzne	71
4.2.2.	Cykliczno-sekwencyjne obserwacje termograficzne	71
4.2.3.	Acykliczne obserwacje termograficzne	72
4.2.4.	Acykliczno-sekwencyjne obserwacje termograficzne	72
4.2.5.	Mieszane obserwacje termograficzne	73
4.3.	Procedura inspekcji termograficznej	73
4.4.	System termograficznego monitorowania i diagnostyki obiektów technicznych	76
4.4.1.	Struktura sprzętowa systemu	77
4.4.2.	Struktura programowa	82
4.5.	Koncepcja diagnozowania z wykorzystaniem analizy obrazów termograficznych	84
4.5.1.	Strategie analizy obrazów termograficznych i sygnałów diagnostycznych	86
5.	Przykłady zastosowania metodyki	93
5.1.	Przykład systemu termograficznego monitorowania obiektów i procesów	93
5.2.	Przykład termograficznego diagnozowania laboratoryjnego modelu maszyny	98
5.2.1.	Eksperymenty diagnostyczne	99
5.2.2.	Przykład oceny stanu obiektu na podstawie statystycznej analizy obrazów termograficznych	101
5.2.3.	Ocena stanu technicznego z zastosowaniem jednowymiarowej transformaty Fouriera	121
5.2.4.	Ocena stanu technicznego z zastosowaniem dwuwymiarowej transformaty Fouriera	127
5.2.5.	Przykład zastosowania transformaty falkowej obrazów termograficznych w detekcji zmian stanu technicznego	142
5.2.6.	Zastosowanie analizy składowych głównych (PCA) w analizie sekwencji obrazów termowizyjnych	147
5.3.	Przykład oceny stanu na podstawie geometrycznych cech kształtu	150
5.3.1.	Binaryzacja obrazów termograficznych	150
5.3.2.	Wyznaczanie sygnałów diagnostycznych	151
5.3.3.	Klasyfikacja stanu technicznego maszyny na podstawie geometrycznych cech kształtu	153
5.4.	Przykład termograficznego monitorowania i diagnozowania obiektu rzeczywistego	155
5.5.	Przykład termograficznego monitorowania i diagnozowania procesu przemysłowego	163
5.5.1.	Przetwarzanie i analiza obrazów podczerwieni rejestrowanych w trakcie procesu spawania	166
5.5.2.	Identyfikacja stanu procesu spawania na podstawie wartości cech profilu poziomego	171
5.5.3.	Przykład wykorzystania fuzji obrazów do oceny stanu procesu przemysłowego	172
6.	Uwagi końcowe	177
6.1.	Podsumowanie	177
6.2.	Wnioski	178

6.3. Oryginalne elementy pracy	180
6.4. Kierunki dalszych badań	180
Dodatek A. Przegląd cech statystycznych obrazów teksturowych	181
A.1. Cechy wyznaczone na podstawie histogramu	182
A.2. Cechy wyznaczone na podstawie macierzy gradientu	183
A.3. Cechy wyznaczone na podstawie macierzy zdarzeń	183
A.4. Cechy wyznaczone na podstawie macierzy długości pasm	186
A.5. Cechy wyznaczone na podstawie modelu autoregresyjnego	187
Dodatek B. Przegląd geometrycznych cech kształtów obiektów	189
Dodatek C. Cechy liczbowe sygnałów diagnostycznych	197
Bibliografia	199
Streszczenie	207
Abstract	208

Monografię dedykuję mojej żonie Agnieszce i córce Barbarze

Od autora

Niniejsza monografia została opracowana w trakcie realizacji grantu habilitacyjnego N N504 508340 pt.: *Metodologia analizy obrazów termowizyjnych dla potrzeb diagnostyki maszyn i urządzeń* i zawiera podsumowanie prowadzonych przeze mnie badań w zakresie termograficznej diagnostyki obiektów technicznych i procesów przemysłowych. Omówiona w książce metodyka stanowi propozycję interdyscyplinarnego podejścia do diagnozowania obiektów z zastosowaniem termografii oraz metod przetwarzania, analizy i rozpoznawania obrazów. Moim celem jest, aby proponowane w książce rozwiązania znalazły zastosowanie w systemach monitorowania i diagnozowania działających w trybie on-line, szczególnie że dzięki wykorzystaniu obrazów termograficznych możliwe jest diagnozowanie jednocześnie wielu obiektów lub ich podzespołów, co przedstawiono w niniejszej monografii. Mam również nadzieję, że treści ogólne przedstawione w monografii staną się przydatnym źródłem wiedzy dla studentów i pracowników naukowych.

Składam serdeczne podziękowania recenzentom książki, prof. dr. hab. inż. Bogusławowi WIĘCKOWI i dr. hab. inż. Jackowi DYBALE za bardzo cenne uwagi pomocne w opracowaniu ostatecznej wersji monografii. Bardzo dziękuję mojej żonie Agnieszce za wyrozumiałość i wsparcie oraz Koleżankom i Kolegom z Instytutu Podstaw Konstrukcji Maszyn Politechniki Śląskiej za okazaną mi pomoc i życzliwość w trakcie prowadzenia badań. Szczególnie dziękuję dr. inż. Wojciechowi JAMROZIKOWI za wsparcie techniczne w trakcie opracowywania monografii oraz bardzo dobrą współpracę na polu wspólnie realizowanych badań. Szczególną wdzięczność chciałbym wyrazić prof. dr. hab. Wojciechowi CHOLEWIE za inspirację, dobrą radę, cenne uwagi i umożliwienie mi podjęcia i realizacji samodzielnych badań.

Bielsko-Biała, lipiec 2013

Marek Fidali

1. Wstęp

Strategia eksploatacji systemów technicznych bazująca na ocenie stanu technicznego stanowi jeden z podstawowych elementów polityki zarządzania utrzymaniem ruchu w wielu przedsiębiorstwach produkcyjnych. Określanie stanu (klasy stanu) obiektu nazywa się diagnozowaniem i obejmuje takie fazy jak detekcja uszkodzenia, jego lokalizacja i identyfikacja [75, 141]. Obiektem diagnozowania może być system mechaniczny i/lub proces przemysłowy. Diagnozowanie realizowane jest poprzez wnioskowanie na podstawie informacji pozyskiwanych w wyniku obserwacji obiektu a dziedziną wiedzy grupującą metody diagnozowania jest diagnostyka techniczna. Stosowanie metod diagnostyki technicznej pozwala odpowiednio wcześniej wykrywać niesprawności obiektów, jednocześnie zapobiegając dużym stratom finansowym wynikającym z przestojów produkcyjnych wywołanych nagłymi awariami oraz racjonalnie prowadzić politykę remontową [75, 141]. Spośród różnych sposobów oceny stanu technicznego maszyn, urządzeń i procesów przemysłowych [29, 20] powszechnie stosowane są metody diagnostyki termicznej. [2].

1.1. Diagnostyka termiczna

Diagnostyka termiczna stosowana jest wszędzie tam, gdzie na podstawie symptomów temperaturowych możliwe jest zidentyfikowanie stanu badanego obiektu. Diagnozowanie na podstawie temperatury jest jednym z najstarszych, prostych i bardzo skutecznych sposobów wykrywania nieprawidłowości w funkcjonowaniu obiektów technicznych [14, 2]. Metody diagnostyki termicznej to z jednej strony działania mające na celu obserwację zjawisk cieplnych a z drugiej strony wnioskowanie diagnostyczne na podstawie zarejestrowanych wartości temperatur. Podstawowym czynnikiem determinującym metodykę wnioskowania diagnostycznego na podstawie danych temperaturowych jest sposób ich pozyskania. Istnieje wiele sposobów pomiaru temperatury i obserwacji zjawisk cieplnych zachodzących w obiektach technicznych [111, 125]. Ogólnie można je sklasyfikować ze względu na umiejscowienie punktów pomiarowych jako jedno- i wielopunktowe oraz ze względu na sposób pomiaru jako stykowe i bezstykowe. Metody wielopunktowe pozwalają identyfikować rozkład wartości temperatur, niosący więcej informacji diagnostycznych niż wartość temperatury zmierzonej w jednym punkcie. Pomiar bezstykowy umożliwia natomiast szybkie wyznaczenie wartości temperatury w różnych, często niedostępnych dla pomiarów stykowych, punktach. Nowoczesną techniką pomiarową integrującą jednocześnie zalety wielopunktowych i bezkontaktowych pomiarów temperatury jest termografia w podczerwieni, która otwiera możliwości rozwoju nowych metod diagnostyki termicznej obiektów technicznych i procesów.

1.2. Termografia w podczerwieni

Termografia w podczerwieni jest bezkontaktową techniką pomiaru temperatury i obrazowania rozkładu pola temperatur, bazującą na detekcji promieniowania podczerwonego emitowanego przez każdy obiekt mający temperaturę większą od zera bezwzględnego. Zastosowanie termografii w podczerwieni do badań diagnostycznych znane jest od lat 50. XX

wieku. W początkowej fazie rozwoju termografii istotnym ograniczeniem w jej efektywnym stosowaniu w diagnostyce termicznej były ceny, rozmiary i parametry urządzeń obrazowania w podczerwieni. Stopniowy rozwój technologii detektorów podczerwieni wpłynął na znaczące obniżenie cen kamer termowizyjnych, czyniąc termografię jedną z kluczowych technik współczesnej eksploatacyjnej diagnostyki termicznej obiektów technicznych i procesów przemysłowych.

Przegląd publikacji zamieszczanych w czasopismach i materiałach największych międzynarodowych konferencji termograficznych jak *Qirt*, *Thermosence*, *TTP* pokazuje, że termografia stosowana jest w diagnostyce obiektów technicznych i/lub procesów praktycznie we wszystkich dziedzinach gospodarki i przemysłu. Przykłady zastosowań można znaleźć w przemyśle energetycznym [38, 119, 135], wydobywczym [45], chemicznym, rafineryjnym [82], hutniczym [79, 150], szklarskim [105], motoryzacyjnym [18, 94, 104, 114], lotniczym, papierniczym [21], budownictwie [149, 151], rolnictwie [13], badaniach nieniszczących [84] i innych [82, 91, 137].

Badane są obiekty mikroskopijne i obiekty o gigantycznych rozmiarach, badane są procesy wolno- oraz szybkozmienne. Najczęściej przedmiotem badań są wszelkiego rodzaju urządzenia elektroenergetyczne i elektroniczne, maszyny i/lub ich wybrane podzespoły mechaniczne, procesy produkcji i przesyłu różnego rodzaju mediów, procesy wytwarzania itp. Badania termograficzne zwykle mają na celu kontrolę prawidłowości działania obiektu lub przebiegu procesu, kontrolę prawidłowego przeprowadzenia remontów lub napraw, a także wspomaganie w podjęciu decyzji diagnostycznych, gdy inne metody nie pozwalają na jednoznaczną klasyfikację stanu. Termografia w podczerwieni w niektórych przypadkach stanowi jedyne źródło informacji diagnostycznych lub stosowana jest równolegle z innymi metodami diagnostycznymi, co podnosi skuteczność stosowanej strategii diagnozowania.

Dominującą formą diagnostycznych badań termograficznych są inspekcje termograficzne wykonywane w regularnych lub nieregularnych odstępach czasu. Na wyniki inspekcji a zatem i jakość diagnozowania mają wpływ różne czynniki, w tym: wykształcenie osoby prowadzącej inspekcję, procedura badawcza, zastosowany sprzęt, warunki otoczenia, własności i właściwości badanego obiektu lub procesu i znajomość relacji diagnostycznych stan–symptom. Duża różnorodność i zmienność czynników badawczych czyni diagnostykę termograficzną, bardzo skuteczną pod warunkiem stosowania się do odpowiednich zasad prowadzenia badań i wnioskowania diagnostycznego. Zagadnienia prawidłowego wykonywania pomiarów i ich interpretacji dyskutowane są od lat na różnych konferencjach i forach termograficznych [131], czego efektem są różnorodne wytyczne, normy i regulacje prawne oraz systemy szkoleniowe wspomagające i przygotowujące badaczy do prawidłowego przygotowania i przeprowadzenia inspekcji oraz wyciągnięcia odpowiednich wniosków. Ze względu na szerokie pole zastosowań termografii i różnorodność badanych obiektów wiele wytycznych odnosi się do konkretnych klas obiektów, np. urządzeń elektrycznych i mechanicznych [8]. Należy wspomnieć, że istnienie różnorodnych wytycznych nie jest jednoznaczne z ich jednakowym stosowaniem w różnych krajach, z uwagi na obowiązujące przepisy. W kraju nadal nie określono praktycznie żadnych przepisów wprowadzających odpowiednie procedury dotyczące metodyki badań, certyfikacji i akceptacji wyników badań termograficznych. Jest to tylko jeden z wielu przykładów uzasadniający konieczność rozwoju metodyki diagnozowania obiektów z zastosowaniem termografii w podczerwieni. Jednym z ważnych obszarów diagnostyki termicznej, w obrębie którego termografia w podczerwieni nie jest w pełni wykorzystywana, jest ciągłe monitorowanie i diagnozowanie obiektów i procesów. Pojęcie ciągłe monitorowanie

należy rozumieć jako cykliczne obserwacje termograficzne w trybie off-line lub on-line prowadzące do pozyskania sekwencji obrazów termograficznych, na podstawie której możliwe jest wnioskowanie o zmianach stanu obiektu oraz identyfikacja relacji diagnostycznych stan–symptom. Obszar ciągłej termograficznej diagnostyki obiektów i procesów determinuje kolejne zagadnienia, które wymagają rozwoju i usystematyzowania, dotyczące przetwarzania i analizy obrazów termograficznych a co za tym idzie generowania i analizy sygnałów diagnostycznych opisujących trendy zmian danych termograficznych rejestrowanych w trakcie badań prowadzonych w długim czasie z zastosowaniem zarówno systemów on-line, jak i off-line. Tematyka ta niejednokrotnie jest poruszana w kontekście skuteczności programów eksploatacyjnej diagnostyki obiektów i procesów [76, 7].

1.3. Analiza obrazów termograficznych w diagnozowaniu maszyn i urządzeń

W trakcie prowadzenia badań termograficznych obiektów technicznych i procesów do przetwarzania i analizy zarejestrowanych termogramów stosowane są zwykle proste metody (histogram, izotermy, wartości alarmowe itp.) zaimplementowane w komercyjnym oprogramowaniu sprzedawanym razem z kamerą termowizyjną. Tylko w nielicznych znanych i opisanych przypadkach obrazy termograficzne analizowano w bardziej zaawansowany sposób [4, 33, 148, 157, 158, 116]. W przypadku badań nieniszczących z zastosowaniem termografii dynamicznej zaawansowane metody przetwarzania i analizy obrazów znajdują szersze zastosowanie [55, 84], dzięki temu możliwe jest skuteczne pozyskiwanie informacji o uszkodzeniach struktur na podstawie sekwencji obrazów termowizyjnych. Metodyka analizy obrazów stosowana w tej dziedzinie termografii wydaje się bardzo ciekawa i może zostać wykorzystana w ciągłej diagnostyce termograficznej obiektów i procesów przemysłowych. Do analizy obrazów termograficznych mogą być stosowane metody przetwarzania i analizy, które pierwotnie opracowano na potrzeby analizy obrazów światła widzialnego [100, 123]. Potwierdzeniem takiego podejścia są przykłady ich wykorzystania w diagnostyce medycznej [102] oraz szeroko pojętej diagnostyce technicznej [33, 148, 157, 158, 116, 76, 86].

1.4. Geneza pracy

Pomimo dużego potencjału metody przetwarzania i analizy obrazów termograficznych nie znajdują szerokiego zastosowania podczas analizy obrazów termograficznych pozyskanych podczas badań obiektów technicznych i procesów. Ponadto pomimo szerokiego pola zastosowań badań termograficznych w ocenie stanu obiektów technicznych autorowi nie są znane przykłady usystematyzowanego i sformalizowanego opisu zagadnień przetwarzania i analizy obrazów termowizyjnych oraz wnioskowania diagnostycznego na podstawie wyników ich analizy. Zaobserwowano również nikłe zainteresowanie możliwościami, jakie oferuje integracja nowoczesnych metod analizy obrazów z zaletami ciągłej diagnostyki termograficznej.

1.5. Cel pracy

Celem pracy jest usystematyzowanie i sformułowanie ogólnych reguł postępowania niezbędnych do przygotowania i prowadzenia inspekcji termograficznych obiektów technicznych i procesów w celu ich diagnozowania. W pracy szczególną uwagę zwraca się na metodykę ciągłego termograficznego monitorowania i diagnozowania obiektów technicznych oraz procesów przemysłowych z uwzględnieniem zastosowania nowoczesnych metod przetwarzania, analizy i rozpoznawania obrazów termograficznych. Głównym problemem, jaki starano się rozwiązać, było opracowanie spójnej metodyki ciągłego diagnozowania stanu obiektów technicznych i procesów przemysłowych, bazując na danych pochodzących z systemów monitorowania pracujących w trybie on-line i off-line. Jednolita metodyka jest podstawą do budowy systemów diagnostycznych umożliwiających wczesną detekcję, lokalizację i rozpoznanie uszkodzenia oraz wcześniejsze zaplanowanie remontu na podstawie wyników prognozowania stanu obiektu.

W ramach badań skupiono się na opracowaniu sposobów postępowania przy przetwarzaniu i analizie obrazów termograficznych pozyskiwanych w trakcie ciągłego monitorowania termograficznego wybranych obiektów technicznych i procesu przemysłowego. Odpowiednio dobrane metody są podstawą wyznaczenia zbioru relewantnych cech obrazów, na podstawie których możliwe jest skuteczne diagnozowanie. Problemem, na który zwrócono uwagę, jest poszukiwanie relacji diagnostycznych między cechami obrazów termograficznych a stanami eksploatacyjnymi i technicznymi wybranych obiektów technicznych w celu zastosowania ich w automatycznych układach wnioskowania diagnostycznego. Poszukiwane relacje diagnostyczne powinny w jednoznaczny sposób pozwolić na rozpoznanie i klasyfikację stanu obserwowanego obiektu, dając tym samym służbom utrzymania ruchu wiarygodną przesłankę do podjęcia odpowiedniej decyzji o sposobie dalszej eksploatacji obiektu. Duża różnorodność metod analizy obrazów termowizyjnych ma wpływ na liczebność zbioru cech mogących nieść informacje o stanie obiektu lub procesu. Dodatkowym problemem, jaki jest podejmowany w pracy, jest poszukiwanie cech relewantnych z punktu widzenia możliwości ich zastosowania do rozpoznawania konkretnej klasy stanów obiektu lub procesu. Biorąc pod uwagę różne obiekty techniczne i procesy oraz różne klasy stanów, rozwiązanie postawionego problemu związane jest z kombinowaniem różnych technik i metod przetwarzania i analizy obrazów, a także z poszukiwaniem nowych oryginalnych metod analizy obrazów termograficznych.

1.6. Zakres pracy

Treść pracy ujęto w sześciu rozdziałach. Poza rozdziałem 1 zawierającym wprowadzenie do omawianej tematyki, w rozdziale 2 scharakteryzowano wybrane i podstawowe zagadnienia dotyczące termografii w podczerwieni, metod diagnostyki technicznej i przetwarzania, analizy oraz rozpoznawania obrazów. Opisane zagadnienia są podstawą zrozumienia zaproponowanej metodyki. W rozdziale 3 przedstawiono aktualne metody i wybrane zalecenia dotyczące diagnozowania obiektów technicznych i procesów przemysłowych z zastosowaniem termografii. Rozdział 4 zawiera podstawowe założenia i dokładny opis opracowanej metodyki diagnozowania obiektów technicznych i procesów przemysłowych. Zaproponowano w nim również sformalizowany algorytm postępowania w celu odpowiedniego doboru metod przetwarzania, analizy i rozpoznawania obrazów na potrzeby ciągłego termograficznego diagnozowania obiektów. Przykłady zastosowania zaproponowanej metodyki przedstawiono

w rozdziale 5. Przykłady dotyczą obiektu laboratoryjnego, obiektu przemysłowego oraz procesu przemysłowego realizowanego w warunkach laboratoryjnych. W rozdziale 6 zamieszczono podsumowanie i wnioski płynące z badań. W końcowej części pracy umieszczono dodatki uzupełniające treść pracy i zawierające definicje cech obrazów stosowane w trakcie przeprowadzonych badań.

2. Wybrane zagadnienia termografii i przetwarzania obrazów

W rozdziale przedstawiono zagadnienia leżące u podstaw zaprezentowanych w monografii rozważań dotyczących metodyki diagnozowania maszyn, urządzeń i procesów przemysłowych z wykorzystaniem termografii w podczerwieni.

2.1. Zjawiska cieplne zachodzące w obiektach technicznych

Ciepło jest nieodłącznym zjawiskiem towarzyszącym maszynom i urządzeniom podczas ich działania. U podstaw powstawania energii cieplnej w maszynach i urządzeniach leżą zjawiska powodujące rozpraszanie różnych rodzajów energii lub ilościową zmianę energii w układzie przez jej dodanie albo odebranie. Każda działająca maszyna i urządzenie posiada określony stan cieplny, który prawie zawsze zmienia się w trakcie eksploatacji obiektu. Na zmiany stanu cieplnego obiektów w maszynie mogą mieć wpływ różne czynniki, m.in.:

- naturalne procesy zużycia,
- kontrolowane zmiany w sterowaniu maszyny dokonane celowo przez operatora,
- niekontrolowane zmiany w sterowaniu maszyny wynikające z uszkodzeń napędu i urządzeń sterujących,
- pojawienie się niesprawności elementów maszyny i zakłócenia w ich wzajemnym współdziałaniu,
- zaburzenia w przepływie mediów roboczych,
- lokalne i globalne zmiany oporu cieplnego elementów i mediów roboczych.

Zmiany stanu cieplnego obiektu najczęściej objawiają się zmianą rozkładu wartości temperatur w przestrzeni wewnętrznej, co zwykle skutkuje zmianami temperatury na powierzchni zewnętrznej maszyny. Dynamika tych zmian może być różna. Wolne zmiany stanu cieplnego mogą świadczyć o postępującym procesie zużycia lub degradacji materiału, natomiast szybkie zmiany będą wskazywały na anomalie w przepływie energii cieplnej wynikające z własności maszyny, wystąpienia stanów przedawaryjnych lub poważnych uszkodzeń. Należy zaznaczyć, że w przypadku zjawisk cieplnych pojęcie „szybkie zmiany” jest względne i zależy od wielkości obiektu, pojemności cieplnej podzespołów i korpusów, zjawisk fizycznych generowanych podczas działania obiektu zarówno w normalnych warunkach, jak i podczas występowania niesprawności. Przykładem może być np. komutatorowy silnik elektryczny, w którym zjawiska cieplne szybkozmiennne mogą wynikać zarówno z wystąpienia zwarcia w uzwojeniu, jak również z efektu komutacji, podczas którego iskrzące szczotki powodują wydzielanie się dużej ilości promieniowania cieplnego w relatywnie krótkim czasie.

Zjawisku powstawania ciepła zawsze towarzyszy proces cieplnego przepływu energii lub inaczej wymiany ciepła. Wymiana ciepła może dokonywać się na trzy sposoby, przez:

- przewodzenie,
- konwekcję,
- promieniowanie.

Całkowitą ilość ciepła Q_C przepływającą między obiektem a otoczeniem można zdefiniować jako następującą sumę [2]:

$$Q_C = Q_P + Q_K + Q_R \quad (2.1)$$

gdzie:

- Q_P – ilość ciepła przekazywana przez przewodzenie,
- Q_K – ilość ciepła przekazywana przez konwekcję,
- Q_R – ilość ciepła przekazywana przez promieniowanie.

2.1.1. Przepływ ciepła przez przewodzenie (kondukcję)

Przewodzenie ciepła zachodzi w ciałach stałych, w cieczach, a także w gazach. Polega na wymianie energii pomiędzy cząstkami obszarów ciał(a) o różnej temperaturze. W ciałach stałych wymiana ta zachodzi dzięki drgającemu ruchowi atomów oraz ruchowi swobodnemu elektronów. Warunkiem zaistnienia przepływu są występujące w danym ciele różnice temperatur. Przepływ ciepła wyłącznie przez przewodzenie odbywa się w ciałach stałych nieprzenikliwych dla promieniowania temperaturowego [134].

2.1.2. Przepływ ciepła przez konwekcję

Konwekcja (unoszenie ciepła) polega na przekazywaniu energii w wyniku makroskopowego ruchu substancji. Cząsteczki medium są w tym procesie nośnikami energii, toteż kierunek ruchu strumienia cząsteczek jest kierunkiem przekazywania ciepła. w różnych obiektach technicznych najważniejszym konwekcyjnym ruchem ciepła jest ruch zachodzący pomiędzy poruszającą się substancją a nieruchomą powierzchnią ciała stałego. Taki konwekcyjny ruch ciepła nazywa się konwekcyjnym przejmowaniem (wnikaniem) ciepła. Rozróżnia się konwekcję swobodną i konwekcję wymuszoną. W przypadku konwekcji swobodnej ruch cząsteczek przenoszących ciepło jest spowodowany tylko istniejącymi różnicami temperatury środowiska i danego ciała stałego (istotne znaczenie ma siła pola grawitacyjnego). W przypadku konwekcji wymuszonej ruch cząsteczek środowiska jest wywołany środkami technicznymi (np.: pompy, wentylatory, dmuchawy) [134].

2.1.3. Przepływ ciepła przez radiację (promieniowanie)

Radiacja (promieniowanie ciepła) polega na przekazywaniu energii pomiędzy ciałami lub częściami tego samego ciała za pośrednictwem temperaturowego promieniowania elektromagnetycznego. Wszystkie ciała, których temperatura jest wyższa od zera bezwzględnego w skali Kelwina ($-273, 150^{\circ}\text{C}$) emitują promieniowanie cieplne (termiczne). Promieniowanie termiczne może występować przy dowolnych długościach fal zawartych między 0 a ∞ . Ze względu na wymianę ciepła najbardziej istotne jest promieniowanie w zakresie długości fal 0,4–1000 μm , czyli obejmujące zakres fal świetlnych (promieniowania widzialnego) oraz bliskiej i dalekiej podczerwieni.

Pasmo podczerwieni można umownie podzielić na cztery węższe pasma obejmujące:

- bliską podczerwień 0,78–3 μm
- pośrednią podczerwień 3–6 μm ,
- daleką podczerwień 6–15 μm ,
- bardzo daleką podczerwień $> 15 \mu\text{m}$.

Istnieje bezpośredni związek między rodzajem powierzchni ciała, jego temperaturą a widmowym natężeniem emitowanego przez nie promieniowania. W danej temperaturze różne

ciała emitują promieniowanie o różnym rozkładzie widmowym. W celu ujednoczenia sposobu teoretycznej analizy promieniowania cieplnego wprowadzono wyidealizowany model ciała zwanego ciałem doskonale czarnym. Ciało czarne to obiekt, który pochłania całe padające na niego promieniowanie niezależnie od długości fali. Koncepcja ciała czarnego może być również zastosowana w stosunku do obiektu emitującego promieniowanie, co wyjaśnia prawo Kirchhoffa. Mówi ono, że ciało zdolne do absorpcji całego promieniowania o dowolnej długości fali jest również zdolne do emitowania tego promieniowania. Promieniowanie ciała doskonale czarnego można scharakteryzować za pomocą podstawowych praw fizycznych [82, 146], do których należą:

1. Prawo Plancka, opisujące rozkład widmowy promieniowania ciała doskonale czarnego, czyli gęstość widmową egzytancji energetycznej (mocy promieniowania) jako funkcję zarówno długości fali, jak i temperatury [82]:

$$M_B(\lambda, T) = \frac{2\pi hc^2}{\lambda^5 \left(e^{\frac{hc}{\lambda kT}} - 1 \right)}, \quad \frac{\text{W}}{\text{m}^2 \cdot \mu\text{m}} \quad (2.2)$$

gdzie:

λ – długość fali μm ,

T – temperatura bezwzględna ciała czarnego K,

$h = 6,626 \cdot 10^{-34}$, J·s – stała Plancka,

$k = 1,381 \cdot 10^{-23}$, J/K – stała Boltzmanna,

$c = 2,997 \cdot 10^8$, m/s – prędkość rozchodzenia się fal w próżni.

2. Prawo Stefana–Boltzmanna, określające całkowitą egzytancję (moc) promieniowania wysyłanego przez ciało doskonale czarne w danej temperaturze. Całkowita moc wyznaczona jest poprzez scałkowanie wzoru Plancka 2.2 [82]:

$$M_B(T) = \int_{\lambda=0}^{\lambda=\infty} M_B(\lambda, T) d\lambda = \sigma T^4, \quad \frac{\text{W}}{\text{m}^2} \quad (2.3)$$

gdzie:

$\sigma = 5,67 \cdot 10^{-8}$, $\text{W}/\text{m}^2 \cdot \text{K}^4$ – stała Stefana–Boltzmanna.

3. Prawo przesunięć Wiena określające długość fali, dla której gęstość widmowa egzytancji energetycznej (mocy promieniowania) $M_B(\lambda, T)$, dla danej temperatury osiąga wartość maksymalną.

$$\lambda_{max} = \frac{2897,8}{T}, \quad \text{mm} \quad (2.4)$$

Powyższy wzór jest efektem różniczkowania wzoru Plancka względem długości fali λ i wyznaczenia maksimum pochodnej.

Wymienione prawa są podstawą termografii w podczerwieni, gdyż pozwalają na wyznaczenie temperatury ciała na podstawie zmierzonego w sposób bezkontaktowy strumienia mocy promieniowania podczerwonego. W praktyce większość materiałów i powierzchni to „ciała szare”, które częściowo pochłaniają, częściowo odbijają i częściowo przepuszczają promieniowanie. Właściwości promienne takich ciał można scharakteryzować za pomocą emisyjności (widmowej) ε , będącą stosunkiem gęstości widmowej egzytancji ciała do gęstości widmowej egzytancji ciała doskonale czarnego w tej samej temperaturze i dla tej samej długości fali [82]:

$$\varepsilon = \frac{M(\lambda, T)}{M_B(\lambda, T)} \quad (2.5)$$

Wartość emisyjności dla ciał rzeczywistych jest zawsze mniejsza od jedności $\varepsilon < 1$ (dla ciała doskonale czarnego $\varepsilon = 1$) i zależy od parametrów fizykochemicznych materiału. Uwzględniając emisyjność obiektu oraz wprowadzając uproszczenia w postaci stałych, wzór Plancka przyjmuje następującą postać:

$$M(\lambda, T) = \frac{\varepsilon(\lambda, T) \cdot c_1}{\lambda^5 \left(e^{\frac{c_2}{\lambda T}} - 1 \right)}, \quad \frac{\text{W}}{\text{m}^2 \cdot \mu\text{m}} \quad (2.6)$$

gdzie:

λ – długość fali μm ,

T – temperatura bezwzględna K,

$C_1 = 3,7415 \cdot 10^{-16}$, $\text{W} \cdot \text{m}^2$ – pierwsza stała promieniowania,

$C_2 = 14388$, $\mu\text{m} \cdot \text{K}$ – druga stała promieniowania.

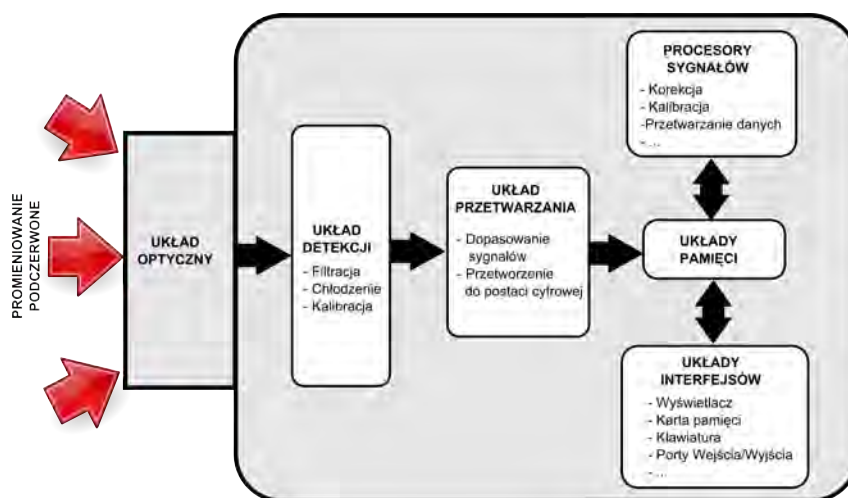
Obszerne szczegóły dotyczące podstaw promieniowania cieplnego zawarto w licznych publikacjach krajowych i zagranicznych [82, 84, 93, 146].

2.2. Termografia w podczerwieni

Słownik języka polskiego definiuje termografię jako technikę obserwacji i rejestracji rozkładu temperatur na powierzchni obiektów, wykorzystującą emitowane przez nie promieniowanie podczerwone. W języku polskim chętnie stosuje się pojęcie termowizja, które jest traktowane jako synonim termografii. W rzeczywistości pojęcia te należy rozróżniać. Dyskusje na ten temat prowadzono w latach siedemdziesiątych ubiegłego wieku podczas sympozjów naukowych dotyczących termografii. Uznano wówczas, że termografia dotyczy starszej techniki polegającej na rejestracji obrazu na papierze światłoczułym z zastosowaniem przyrządu o nazwie termograf. Termowizję odniesiono natomiast do nowoczesnej techniki stosującej kamery termowizyjne, z których obraz można było wyświetlić na ekranie monitora (często telewizora z lampą kineskopową), a następnie w razie potrzeby zarejestrować [91, 122]. Proponowane podejście rozróżniania terminów termografia i termowizja należy zmodyfikować ze względu na aktualny stan technologii w zakresie obrazowania podczerwieni i braku odzwierciedlenia terminologicznego słowa termowizja w literaturze anglojęzycznej, w której jedynym aktualnie stosowanym terminem jest *infrared thermography* lub ogólniej *thermography*. W opracowaniu autor proponuje rozróżnianie pojęć termografia i termowizja ze względu na własności urządzenia do obrazowania w podczerwieni. Pojęcie termografia dotyczy obrazowania podczerwieni z zastosowaniem kamer pomiarowych, w wyniku stosowania których możliwe jest pozyskanie obrazu niosącego informacje metrologiczne o rozkładzie temperatury z określoną niepewnością. Termowizja natomiast dotyczy obrazowania podczerwieni z wykorzystaniem kamer obserwacyjnych umożliwiających pozyskanie obrazów o charakterze jakościowym niosących informacje o względnych zmianach wartości promieniowania cieplnego generowanego przez obiekt. Cechą wspólną termografii i termowizji jest efekt ich stosowania, czyli zobrazowanie w podczerwieni odwzorowujące rozkład temperatury na powierzchni obserwowanego obiektu nazywane termogramem i stanowiące podstawowe źródło informacji o obserwowanym obiekcie i jego stanie. Uwzględniając zakres rozważań, który ukierunkowany jest na analizę obrazów termograficznych, podobnie jak w licznych publikacjach krajowych [146], w opracowaniu wykorzystywany będzie termin termografia.

2.3. Obrazowanie podczerwieni

Obrazowanie podczerwieni jest procesem wizualizacji wartości wielkości fizycznej (np. napięcia), proporcjonalnych do zmierzonego strumienia mocy promieniowania podczerwonego emitowanego z powierzchni obserwowanego obiektu. Efektem pomiaru jest obraz nazywany termogramem. Współczesnym narzędziem realizującym proces obrazowania podczerwieni jest urządzenie zwane kamerą termograficzną lub termowizyjną. Podstawową funkcją urządzenia do obrazowania w podczerwieni jest detekcja i pomiar mocy promieniowania podczerwonego docierającego do urządzenia, co pozwala na uformowanie, rejestrację i/lub wyświetlenie termogramu. Schemat blokowy pokazujący w sposób ogólny budowę i działanie urządzenia do obrazowania w podczerwieni przedstawiono na rysunku 2.1.



Rys. 2.1. Schemat blokowy kamery termowizyjnej (opracowanie własne na podstawie [84, 143, 146])¹

Do kamery termowizyjnej dociera sumaryczny strumień promieniowania podczerwonego pochodzącego ze wszystkich elementów obserwowanej sceny, w tym z obiektu będącego przedmiotem zainteresowania, otoczenia i przypadkowych źródeł zewnętrznych istniejących w tle. Niektóre ze strumieni promieniowania podlegają odbiciu i rozproszeniu. Część promieniowania jest tłumiona przez atmosferę znajdującą się na drodze obserwacji. Sama kamera, a w szczególności jej układ optyczny, również ma wpływ na wypadkowy strumień promieniowania docierającego do układu detekcji kamery. Całkowite natężenie promieniowania docierającego do detektora kamery można przedstawić w postaci następującego modelu [84, 93, 146]:

$$E_c = \tau_{atm} \varepsilon M_{obj} + \tau_{atm} (1 - \varepsilon) M_{env} + (1 - \tau_{atm}) M_{atm} \quad (2.7)$$

gdzie:

E_c – natężenie promieniowania podczerwonego docierającego do kamery W/m^2 ,

M_{obj} – gęstość strumienia energii promieniowania (egzytancja) emitowana przez obiekt o temperaturze T_{obj} ,

M_{env} – zastępcza gęstość strumienia energii promieniowania (egzytancja) obiektów w otoczeniu przy zastępczej temperaturze otoczenia T_{env} ,

¹ Rysunki i tabele, dla których nie podano źródła są opracowaniami własnymi.

M_{env} – gęstość strumienia energii promieniowania (egzytancja) atmosfery przy temperaturze atmosfery T_{atm} ,

τ_{atm} – transmisyjność (współczynnik przepuszczania) atmosfery,

ε – emisyjność obiektu.

Strumień mocy promieniowania zamieniany jest w detektorze na radiometryczny sygnał elektryczny $U = cE_c$ proporcjonalny do natężenia promieniowania E_c (2.7) i określonego współczynnika proporcjonalności (stałej) c , którego wartość zależy m.in. od stopnia tłumienia atmosfery, absorpcji elementów optycznych i filtrów, właściwości detektora itp. [93, 146]. W zależności od rodzaju urządzenia obrazującego układ detekcji odpowiedzialny jest za dyskretyzację przestrzenną wartości ciągłej funkcji $f(x, y, t, \lambda)$, promieniowania podczerwonego o długości fali λ w dowolnym punkcie pola widzenia kamery o współrzędnych x, y występującego w chwili czasu t . Sygnały elektryczne z układu detekcji przesyłane są do układu przetwarzania analogowo-cyfrowego, gdzie w wyniku operacji dyskretyzacji czasowej (próbkiowania) i kwantyzacji zamieniane są na sygnały cyfrowe. Radiometryczne sygnały cyfrowe mogą być przetwarzane, rejestrowane i wyświetlane w postaci termograficznego obrazu jakościowego lub ilościowego. Interfejsy komunikacyjne pozwalają użytkownikowi w sposób bezpośredni i pośredni kontrolować parametry i sposób działania kamery.

W zależności od szczegółów konstrukcyjnych urządzenia obrazowania podczerwieni można podzielić na:

obserwacyjne i pomiarowe – kamery obserwacyjne są urządzeniami wizualizującymi rozkład mocy promieniowania podczerwonego. Kamery pomiarowe pozwalają szacować wartości temperatur na podstawie wartości mocy promieniowania podczerwonego, co pozwala wizualizować rozkład wartości temperatur w obrębie obserwowanej przez kamerę sceny. Zapewnienie odpowiedniej dokładności pomiaru temperatury wymaga implementowania w kamerze procedur metrologicznych polegających na m.in. kalibracji kamery z zastosowaniem wcześniej wyznaczonych charakterystyk, korekcji niejednorodności detektorów (w przypadku kamer matrycowych), stosowaniu modeli obliczeniowych uwzględniających emisyjności obiektu, transmisyjność atmosfery czy też wpływ otoczenia;

skanujące i matrycowe – podział związany jest ze sposobem formowania obrazu termograficznego. Urządzenia skanujące wyposażone są w mechaniczno-optyczny układ przeszukiwania obserwowanej sceny i kierowania wiązki promieniowania na pojedynczy detektor lub linię detektorów podczerwieni. Kamery matrycowe, złożone z matrycy detektorów o rozdzielczościach od 320×240 do 1024×1024 , pozwalają na obserwację całej sceny w jednej chwili czasowej. Zaletą kamer matrycowych jest m.in. duża szybkość działania i mniejsza odporność na wibracje, co spowodowało, że zdominowały one rynek urządzeń do obrazowania w podczerwieni;

długo i krótkofalowe – podczas detekcji emisji promieniowania podczerwonego zwykle pomiędzy promieniującym obiektem, a kamerą znajduje się powietrze atmosferyczne o charakterystycznych własnościach transmisyjnych dla podczerwieni. Do obserwacji w podczerwieni wykorzystywane są dwa pasma transmisyjne: krótkofalowe (SW) w zakresie od $2 \mu\text{m}$ do $5 \mu\text{m}$ i długofalowe (LW) od $8 \mu\text{m}$ do $14 \mu\text{m}$. Najczęściej stosowane są kamery długofalowe, jednak na potrzeby obserwacji specyficznych zjawisk fizykochemicznych (np. wycieków gazów) lepsze rezultaty metrologiczne uzyskuje się, stosując kamery krótkofalowe;

chłodzone i niechłodzone – podział jest konsekwencją stosowania w kamerach dwóch rodzajów detektorów: termicznych (bolometrycznych) i fotonowych, których działanie

w celu zapewnienia odpowiednich własności detekcyjnych (czułość) i metrologicznych wymaga stabilizacji temperaturowej. W przypadku niektórych detektorów fotonowych konieczne jest ich chłodzenie nawet do temperatury 77 K (temperatury ciekłego azotu).

Szczegóły dotyczące budowy i działania urządzeń obrazujących w podczerwieni opisywane są szeroko w licznych publikacjach [82, 93, 143, 146].

Jak pokazują przykłady praktyczne, każdy rodzaj urządzenia obrazowania w podczerwieni znajduje zastosowanie w diagnozowaniu obiektów technicznych i procesów przemysłowych. Ze względu m.in. na kompaktową budowę i cenę, najczęściej do inspekcji termograficznych stosowane są długofalowe kamery z matrycami detektorów bolometrycznych. W przypadku monitorowania procesów przemysłowych chętnie stosowane są skanery z linijkami detektorów bolometrycznych. Wielu producentów oferuje urządzenia dedykowane do potrzeb monitorowania i diagnozowania maszyn, urządzeń i procesów przemysłowych. W większości przypadków są to urządzenia pomiarowe, aczkolwiek odpowiedniej klasy urządzenia obserwacyjne również mogą być stosowane w diagnozowaniu, o ile rozpatrywane są względne zmiany w wartościach rozkładu mocy promieniowania emitowanego przez obiekt.

2.3.1. Parametry urządzeń obrazowania w podczerwieni

Możliwości urządzeń do obrazowania w podczerwieni zdeterminowane są ich parametrami technicznymi, które można podzielić na kilka grup:


- Parametry odnoszące się do jakości zobrazowania, w tym parametry układów optycznych, np.: rozdzielczość przestrzenna, pole widzenia, ogniskowa, czułość termiczna lub rozdzielczość termiczna (NETD), częstotliwość akwizycji obrazu, zakres widmowy itp.
- Parametry metrologiczne, np.: zakres temperaturowy, dokładność, zakres korekty emisyjności itp.
- Parametry dotyczące sposobu zapisu, transmisji obrazu oraz sterowania kamerą jak np.: format obrazu, interfejsy wyjściowe i wejściowe, rozmiar pamięci zewnętrznej itp.
- Parametry środowiskowe i fizyczne, np.: zakres temperatury pracy, klasa szczelności obudowy, odporność na wibracje i udary, masa, wymiary itp.
- Inne, np.: parametry zasilania, akcesoria dodatkowe itp.

Parametry i konfiguracja kamery termograficznej oraz warunki jej stosowania mają wpływ na jakość zobrazowania, którą można scharakteryzować w kontekście zdolności kamery do ujawniania niewielkich różnic w rozkładzie temperatury obiektów o małych rozmiarach. Decydujący wpływ na jakość obrazowania mają:

- rozdzielczość matrycy,
- parametry zastosowanego układu optycznego,
- czułość,
- sposób korekcji niejednorodności matrycy.

Dwa pierwsze parametry decydują o obszarze widzenia pojedynczego piksela (IFOV), który określa dolną granicę minimalnego rozmiaru obserwowanego obiektu. Wynika z tego, że odwzorowanie szczegółów na obrazie zależeć będzie od zastosowanego obiektywu. Na rysunku 2.2 pokazano, jak zmienia się jakość zobrazowania i rozróżnialność szczegółów obrazu w zależności od rozdzielczości matrycy, przy tym samym obiektywie.


O jakości obrazu decydują również zniekształcenia wprowadzane przez obiektywy. Mogą nimi być aberracja sferyczna, chromatyczna i komatyczna, astygmatyzm, krzywizna pola, dystorsja i winietowanie. Intensywność występowania zniekształcenia uzależniona jest od jakości układu optycznego oraz sposobu jego zastosowania.



Rys. 2.2. Przykład odwzorowania tego samego szczegółu obrazu przez kamery termograficzne o różnych rozdzielczościach matrycy [37]

Kolejnym parametrem decydującym o jakości zobrazowania jest czułość kamery. Decyduje ona o rozróżnialności niewielkich zmian temperatury. Kamera o dużej wartości czułości około 100 mK będzie miała problem z wygenerowaniem obrazu o dużym kontraście dla różnic temperaturowych na obiekcie mniejszych niż $0,25^\circ\text{C}$. Obraz w takim przypadku cechować się będzie dużym poziomem szumów. Kamery o małej czułości, np. 50 mK , potrafią wygenerować dobry jakościowo obraz dla obiektów, dla których różnice temperatur nie są mniejsze niż $0,05^\circ\text{C}$.

Z punktu widzenia zastosowania kamer w diagnozowaniu obiektów technicznych i procesów nie należy również zapominać o równie istotnych, a często pomijanych w specyfikacjach, cechach dotyczących stabilności działania kamery w czasie. Kamery matrycowe posiadają wiele niezależnych detektorów, z których każdy ma inną charakterystykę opisującą odpowiedź na pobudzenie cieplne, co skutkuje istnieniem ustalonego szumu zakłócającego obraz. Poziom szumu zmienia się w czasie, co jest wywołane dryftem temperaturowym. Dryft temperaturowy wynika np. w przypadku detektora bolometrycznego z akumulacji ciepła pochodzącego z promieniowania padającego na matrycę detektorów i ciepła generowanego przez układy elektroniczne. Dodatkowymi czynnikami są zjawiska wymiany ciepła między obudową i optyką kamery, a samym detektorem. Praktycznie każda z kamer termograficznych posiada dryft temperaturowy. W przypadku kamer z detektorami fotonowymi jest on mniejszy niż w przypadku kamer z detektorami bolometrycznymi. Problem dryftu temperaturowego i niejednorodności matrycy rozwiązuje się, stosując np. ruchomą przesłonę o jednorodnej emisyjności i temperaturze, która w mechaniczny sposób cyklicznie przesłania powierzchnię matrycy detektorów, stanowiąc dla każdego z detektorów jednorodne źródło promieniowania odniesienia. W chwili gdy przesłona jest zamknięta, dokonywana jest korekta dryftu temperaturowego matrycy detektorów i mierzonej temperatury, a zatem korygowana jest aktualnie mierzona wartość temperatury w przypadku kamer pomiarowych. Parametry korekcyjne określone są przez producenta i zapisywane w pamięci kamery. Niektóre kamery badawcze mają możliwość zmiany tych parametrów. Na rysunku 2.3 przedstawiono przykładowy przebieg temperatury mierzonej kamerą termowizyjną, w której okres między kolejnymi korektami niejednorodności wynosił 16 min. Dostrzegalna jest bardzo wyraźna zmiana temperatury o $\Delta T = 2,5^\circ\text{C}$ wywołana dryftem temperaturowym zastosowanej kamery termograficznej.



Rys. 2.3. Przykład zmian temperatury wywołanej dryftem i działaniem układu korekcji

2.3.2. Obraz termograficzny i jego reprezentacja

Efektom działania urządzeń obrazowania podczerwieni są najczęściej obrazy cyfrowe – termogramy, odwzorowujące promieniowanie podczerwone pochodzące z przestrzeni trójwymiarowej (3D) na płaszczyznę dwuwymiarową (2D). Obraz cyfrowy powstaje w wyniku operacji dyskretyzacji i kwantyzacji ciągłej funkcji rozkładu promieniowania podczerwonego rzutowanej przez układ optyczny na powierzchnię detektora [143].

Zatem cyfrowy obraz podczerwieni można zapisać za pomocą dwuwymiarowej funkcji $g(m,n)$, gdzie $m = 1,2,\dots,M$ i $n = 1,2,\dots,N$ są dyskretnymi współrzędnymi punktów obrazu (pikseli obrazu), w których funkcja przyjmuje wartości należące do zbioru liczb rzeczywistych i proporcjonalne do natężenia promieniowania podczerwonego docierającego do detektora. Wartości pikseli mogą być wartościami napięcia sygnału z detektora, wartościami sygnału wyrażonymi w jednostkach izotermicznych wyliczonymi na podstawie odpowiedniego modelu pomiarowego, wartościami mocy promieniowania podczerwonego wyliczonymi na podstawie odpowiedniego modelu, wartościami temperatury lub wartościami identyfikującymi barwę. Rozmiar obrazu cyfrowego i liczba poziomów intensywności pikseli obrazu (liczba) uzależniona jest od własności urządzenia obrazującego. Współczesne matrycowe urządzenia obrazowania podczerwieni posiadają przetworniki 12-, 14- i 16-bitowe i pozwalają na uzyskanie obrazów o rozdzielczościach 1280×1024 pikseli i większych [143]. Można uznać, że jeśli dla procesu przetwarzania i analizy termogramów bezwzględne wartości pikseli obrazu podczerwieni nie stanowią źródła istotnych informacji, taki obraz można nazwać termogramem jakościowym [70]. Wartości pikseli termogramu jakościowego są proporcjonalne do natężenia promieniowania podczerwonego i niosą informację o względnych różnicach w wartościach natężenia promieniowania (kontrast) zależnych od temperatury obserwowanych obiektów. Termogramy jakościowe są bezpośrednim efektem działania obserwacyjnych kamer termowizyjnych. W przypadku pomiarowych kamer termograficznych możliwe jest uzyskanie obrazu, przedstawiającego rozkład bezwzględnych i rzeczywistych wartości temperatur obiektów występujących w obrębie obserwowanej sceny. Wartości te są pozornymi wartościami temperatur $T(m,n)$ w odpowiedniej skali temperatur, obliczonymi na podstawie odpowiedniego

modelu pomiarowego, wartości cyfrowego sygnału pochodzącego z detektora oraz modelu kalibracyjnego (np. RBF) [93, 146].

Dyskretna funkcja rozkładu wartości temperatur $T(m, n)$ może być nazwana termogramem ilościowym [70] lub obrazem termometrycznym. Łatwo zauważyć, że jeśli parametry modelu pomiarowego kamery będą błędne, uzyskany obraz może stać się termogramem jakościowym, o ile wartości temperatur odczytywane z obrazu będą przekraczały dopuszczalny błąd pomiaru. Z punktu widzenia ciągłej diagnostyki termograficznej i zagadnień przetwarzania oraz analizy obrazów rozpatrywanie termogramów ilościowych wydaje się być korzystniejsze ze względu na możliwość identyfikacji prostych relacji między zmierzonymi wartościami temperatur, a fizycznymi własnościami (np. temperatura topnienia) i/lub właściwościami obserwowanych obiektów (np. temperatura, przy której występuje luz graniczny między dwoma podzespołami).

Cyfrowy obraz termograficzny zwykle reprezentowany jest w formie graficznej lub numerycznej. Postać graficzna utworzona na nośniku analogowym (papier, folia) lub elektronicznym (ekran monitora, wyświetlacza) jest reprezentacją obrazu termograficznego przeznaczoną bezpośrednio na potrzeby człowieka, który dzięki zdolnościom percepcyjnym wzroku i analitycznym mózgu może dokonać jakościowej interpretacji i analizy oraz przeprowadzić wnioskowanie o stanie obiektów utrwalonych na obrazie w określonej chwili czasu eksploatacji t . Graficzna reprezentacja cyfrowego obrazu termograficznego może przybierać różne formy. Podstawową formą jest płaski (dwuwymiarowy) wykres, na którym piksele reprezentowane są przez sąsiadujące ze sobą obszary (najczęściej o kształcie kwadratowym) i tworzą mapę rozkładu wartości pikseli w przyjętej skali barw (rys. 2.4(a)). Podstawowym zestawem barw stosowanym w graficznej prezentacji termogramów jest skala odcieni szarości utworzona na bazie kolorów czarnego i białego.


Liczba odcieni szarości może odpowiadać liczbie poziomów kwantyzacji, które wykorzystano do zapisu wartości pikseli obrazu. Najczęściej jednak ze względu na cechy ludzkiego wzroku, który może rozróżnić maksymalnie 90 odcieni szarości, wystarczającą liczbą jest 256 odcieni szarości, co odpowiada 8-bitowej głębi koloru. Należy zaznaczyć, że w przypadku komputerowych systemów przetwarzania i analizy obrazów liczba poziomów szarości może mieć wpływ na wyniki analizy. Pochodną czarno-białej formą reprezentacji graficznej obrazu termograficznego jest obraz „pseudokolorowy” powstały w wyniku przypisania do wartości każdego piksela obrazu odpowiedniej barwy zakodowanej w palecie barw.

Na potrzeby termografii opracowano szereg standardowych palet barw (np. fire, iron, blue/red, menthol, rainbow, sephia itp.) pozwalających na przedstawianie zjawisk cieplnych w zgodzie z ich naturą i ludzką intuicją. Na przykład barwy będące pochodnymi koloru czarnego, granatowego i niebieskiego przypisywane są wartościom pikseli korespondującym z niskimi temperaturami, natomiast odcienie koloru czerwonego, żółtego i pomarańczowego czy białego przypisywane są wysokim temperaturom.

Producenci systemów termowizyjnych udostępniają użytkownikom również oryginalne palety barw dedykowane do wizualizacji specyficznych zjawisk oraz narzędzia do samodzielnego tworzenia tablic kolorowania. Prawidłowy dobór odpowiedniej palety barw lub umiejętne manipulowanie tablicami kolorowania pozwala na uwypuklenie takich cech obrazu, które mogą być trudne w identyfikacji, np. w skali odcieni szarości, a także przedstawienie zjawisk cieplnych objawiających się promieniowaniem w specyficznych zakresach długości fali.

Wybór palety barw najczęściej uzależniony jest od indywidualnych preferencji operatora systemu termowizyjnego, jak również rodzaju i intensywności zjawisk cieplnych zachodzących w obserwowanym obiekcie. Autorowi nie są znane ogólne zalecenia i reguły odnoszące się do wyboru odpowiedniej palety barw.

Innym sposobem graficznej reprezentacji wartości obrazu termograficznego jest trójwymiarowy wykres przedstawiający dyskretną funkcję rozkładu mocy promieniowania podczerwonego (lub temperatury) (rys. 2.4(b)). Wartość piksela w takiej formie termogramu, przedstawiana jest w postaci słupka nazywanego wokselem (ang. *volume element* — *voxel*). Reprezentacja trójwymiarowa pozwala na skuteczniejszą analizę jakościową jak i ilościową rozkładu wartości pikseli obrazu termograficznego [127].



Rys. 2.4. Przykład reprezentacji obrazu termograficznego $T(m, n)$ w postaci wykresu dwu- (a) i trójwymiarowego (b)

Numeryczna reprezentacja cyfrowego obrazu termograficznego najczęściej dotyczy wartości liczbowych poszczególnych pikseli uszeregowanych w jedno- lub wielowymiarowej tablicy utworzonej w pamięci komputera i/lub zapisanych na nośniku danych. Taka forma reprezentacji obrazu cyfrowego jest niezbędna w praktycznej realizacji metod cyfrowego przetwarzania, analizy i rozpoznawania obrazów. Z punktu widzenia analitycznego najczęściej spotykaną formą numerycznej reprezentacji cyfrowego obrazu termograficznego $g(m, n)$ jest dwuwymiarowa tablica traktowana jako macierz, w której liczba wierszy M i kolumn N odpowiada rozdzielczości przestrzennej obrazu.

$$g(m, n) = \begin{bmatrix} g(0,0) & g(0,1) & \cdots & g(0,N-1) \\ g(1,0) & g(1,1) & \cdots & g(1,N-1) \\ \cdots & \cdots & \cdots & \cdots \\ g(M-1,0) & g(M-1,1) & \cdots & g(M-1,N-1) \end{bmatrix} \quad (2.8)$$

W praktycznych aplikacjach metod komputerowego przetwarzania i analizy obrazów do zapisu wartości pikseli stosowane są jednowymiarowe tablice ze względu na optymalizację szybkości działania algorytmów.

Większość urządzeń obrazowania podczerwieni umożliwia zapis obrazów termograficznych do pliku w celu ich dalszej analizy. Dostępne są dwie klasy formatów plików, do których może zostać zapisany obraz termowizyjny. Są to niestandardowe formaty radiometryczne i standardowe formaty grafiki rastrowej (JPG, TIFF, GIF, BMP). Formaty plików radiometrycznych, podobnie jak w przypadku formatu RAW stosowanego w klasycznej fotografii, posiadają charakterystyczną strukturę uwzględniającą zapis wartości sygnałów z detektora podczerwieni oraz metadane służące do ich opisu. Metadane poza podstawowymi

informacjami technicznymi jak data rejestracji, własności kamery i optyki zawierają również wartości podstawowych parametrów metrologicznych niezbędnych do wyliczenia wartości temperatur (w przypadku kamer pomiarowych).

Rastrowa reprezentacja obrazu pozwala na zapis wartości pikseli obrazu dla ustalonych w chwili rejestracji parametrów kamery jak poziom, zakres, paleta barw, emisyjność itp. Oznacza to, że w przeciwieństwie do formatu radiometrycznego, nie jest możliwa modyfikacja tych parametrów i zmiana treści obrazu po jego rejestracji. W przypadku gdy rejestrowana jest sekwencja obrazów w trakcie obserwacji obiektu nagrzewającego się w dużym zakresie temperatur, może dojść do sytuacji utraty informacji w wyniku przekroczenia ustawionych zakresów i poziomów temperatur. Ponadto zapis w plikach grafiki rastrowej w formacie skompresowanym (np. jpg) może doprowadzić do utraty części użytecznej informacji przydatnej np. do diagnostyki obserwowanego obiektu lub procesu.

2.4. Sygnał diagnostyczny

W diagnostyce technicznej na potrzeby uwzględnienia różnych metod diagnozowania, wprowadzono pojęcie sygnału diagnostycznego, które stanowi uogólnienie powszechnie przyjętego pojęcia sygnału traktowanego jako przebieg dowolnej wielkości fizycznej w czasie. Definicja sygnału diagnostycznego [75] zakłada, że wielkością opisującą stan obiektu może być przebieg dowolnej wielkości wynikającej z obserwacji oddziaływań między badanym obiektem, a otoczeniem. Uogólnienie takie pozwala na rozszerzenie dziedziny sygnału diagnostycznego i uporządkowanie jego wartości nie tylko w czasie, lecz również względem parametrów pochodnych np. kąтового położenia wału, opóźnienia czasowego, częstotliwości itp. Dzięki takim założeniom sygnałem diagnostycznym mogą być zarówno przebiegi mierzalnych wielkości fizycznych, jak i parametrów wyliczonych m.in na podstawie wartości wielkości mierzonych jako nośników informacji o stanie obiektów diagnozowania. Przykładem takiego sygnału diagnostycznego może być roczny przebieg wartości współczynnika korelacji wzajemnej wyznaczany na podstawie dziennych przebiegów wartości temperatur mierzonych przez dwa czujniki temperatury zainstalowane w różnych punktach diagnozowanego obiektu.

Przyjęcie definicji sygnału diagnostycznego, jako przebiegu dowolnej wielkości, uzasadnia uwzględnienie w dalszych rozważaniach stosowanego w diagnostyce wibroakustycznej maszyn, umownego rozróżnienia dziedziny czasu zegarowego [19, 23] na:

- czas „makro” t_M nazywany również czasem „życia” obiektu lub czasem „eksploatacyjnym” opisujący historię zmian stanu technicznego obiektu w dziedzinie wartości odnoszących się do liczby godzin, dni, miesięcy lub lat;
- czas „mikro” t_m nazywany czasem „dynamicznym” pozwala opisać szybkozmiennie zjawiska w dziedzinie wartości przedstawianych np. w mikrosekundach, milisekundach lub w sekundach.

Podział czasu rzeczywistego t na czas „mikro” t_m i czas „makro” t_M pozwala na rozpatrywanie „szybko zmieniających się” wartości chwilowych sygnałów, zależnych od „wolno zmieniających się” stanów technicznych obiektu.

Przyjęcie odpowiedniej interpretacji pojęć czasu „mikro” i czasu „makro” może wynikać z założenia, że czas rzeczywisty t

$$t = t_m + t_M \quad (2.9)$$

Wartości chwilowe sygnałów diagnostycznych rozpatrywane są na dostatecznie krótkich odcinkach czasu „mikro” pozwalających na przyjęcie stałej wartości czasu „makro”, tzn.:

$$x(t) = x(t_m + t_M) = x(t_m)|_{t_M} \quad (2.10)$$

Założenie o „wolno zachodzących zmianach” stanu obiektu pozwala na uznanie, że stan nie zależy od czasu „mikro” t_m . Jest on jedynie funkcją czasu „makro” t_M .

$$s(t_m + t_M) = s(t_M) \quad (2.11)$$

Obserwacja obiektu w kolejnych ustalonych chwilach czasu „makro” $\dots, t_{M_j}, t_{M_{j+1}}, \dots$ umożliwiła pozyskanie informacji o historii zmian wartości cech termogramów, a zatem również historii zmian stanu technicznego. Podział dziedziny (2.9) czasu rzeczywistego t na dziedzinę czasu „mikro” t_m i „makro” t_M jest oczywiście niejednoznaczny i umowny. Dziedziny czasu „mikro” i czasu „makro” dotyczą tego samego czasu rzeczywistego t , lecz pozwalają zróżnicować długości obserwacji diagnozowanego obiektu oraz zdefiniować sygnały diagnostyczne opisujące zjawiska cieplne o różnej dynamice zmian w czasie.

Koncepcja czasu „mikro” i „makro” może znaleźć zastosowanie w diagnostyce termograficznej. Przykładem może być klasyczna strategia nadzoru termograficznego, w której inspekcje termograficzne wykonywane są cyklicznie w stałych odstępach czasu liczonych np. w tygodniach. Przy czym w trakcie każdej inspekcji rejestrowana jest sekwencja obrazów termograficznych w czasie kilku sekund. Jeśli zdefiniujemy punkt (piksel) $g_i(x, y)$ o współrzędnych wspólnych dla wszystkich obrazów sekwencji, możliwe jest przedstawienie przebiegu wartości tego punktu w czasie rejestracji sekwencji. Przebieg taki można traktować jako sygnał diagnostyczny w czasie „mikro”. Na podstawie wartości sygnału diagnostycznego w czasie „mikro” można wyznaczyć wartość cechy v_i (np. wartość średnią sygnału), która będzie reprezentowała informację diagnostyczną związaną z konkretną inspekcją termograficzną. Posiadając wartości cechy wyznaczone w trakcie historycznych inspekcji termograficznych tego samego obiektu, możliwe jest zdefiniowanie sygnału diagnostycznego w dziedzinie czasu „makro” reprezentowanego w tym przypadku przez tygodnie, w których przeprowadzano inspekcje termograficzne. Należy zwrócić uwagę, że w takim przypadku wartość cechy nie będzie zależała już od czasu „mikro”, ale będzie funkcją czasu „makro” związanego z eksploatacją obiektu $v_i(t_{M_j})$. W wyniku analizy sygnału diagnostycznego w czasie „makro” może być wyznaczona wartość cechy stanu $s(t_{M_j})$.

Uwzględniając koncepcję czasu „mikro” i „makro”, sygnał diagnostyczny można zapisać w następujący sposób:

$$d : (t_m, t_M) \rightarrow s \in \mathbf{R} \quad (2.12)$$

Z uwagi na powszechne stosowanie cyfrowych metod akwizycji i przetwarzania danych zakłada się, że sygnały diagnostyczne są sygnałami cyfrowymi określonymi w dyskretnych chwilach czasu i przyjmującymi wartości z pewnego określonego zbioru.

2.4.1. Wielowymiarowy sygnał diagnostyczny

Domyślnie pojęcie sygnału kojarzone jest z funkcją jednej zmiennej niezależnej, co jest jednoznaczne z jednowymiarową przestrzenią wartości. Sygnały diagnostyczne mogą być jednak reprezentowane w wielu wymiarach, co związane jest z opisem ich wartości za pomocą funkcji wielu zmiennych niezależnych

$$d(z_1, z_2, \dots, z_n, t_m, t_M) \quad (2.13)$$

Niejednokrotnie podczas obserwacji termograficznej rejestrowana jest sekwencja obrazów termograficznych w czasie t . Uwzględniając czas jako czynnik porządkujący obrazy, zarejestrowaną sekwencję można traktować jako wielowymiarowy sygnał diagnostyczny i zdefiniować w następujący sposób:

$$d(m, n, t) = (g(m, n), t) \quad (2.14)$$

gdzie:

$g(m, n)$ — obraz termograficzny,

$t = t_1, t_2, \dots, t_K$ — zbiór dyskretnych chwil czasu opisujący czas obserwacji eksploatowanego obiektu technicznego.

Uwzględniając istotę działania urządzeń obrazujących w podczerwieni, przestrzeń wartości sygnału wielowymiarowego można rozszerzyć do większej liczby zmiennych niezależnych, uwzględniając np. długość fali λ , emisyjność ε , składową koloru (na przykład czerwonego r) itp. Pozwala to zapisać wielowymiarowy sygnał diagnostyczny np. w następujący sposób $d(m, n, \lambda, \varepsilon, t)$; $d(m, n, r, t)$ itp.

Na tym etapie rozważań nie rozgraniczono dziedziny czasu t na chwile czasu „mikro” i „makro”, aczkolwiek, uwzględniając np. istotę powstawania obrazu termograficznego, znaczenie dziedziny czasu „mikro” i „makro” w opisie sygnału wielowymiarowego nie pozostaje obojętne i powinno być wyraźnie dostrzegalne.

2.4.2. Sygnał termograficzny

Wartości sygnału diagnostycznego uzyskanego na podstawie obrazów termograficznych są bezpośrednim efektem występowania zjawisk cieplnych skutkujących zmianami temperatury w czasie. Aby umożliwić jednoznaczne rozróżnianie zarówno jednowymiarowych, jak i wielowymiarowych sygnałów diagnostycznych powstałych na podstawie obrazów podczerwieni, zaproponowano wprowadzenie pojęcia sygnał termograficzny. Sygnały termograficzne należy rozumieć jako klasę sygnałów diagnostycznych, które mogą powstać na podstawie bezpośrednich lub pośrednich obserwacji zjawisk cieplnych zachodzących w obiekcie z zastosowaniem urządzeń obrazowania w podczerwieni i umożliwiające ocenę stanu technicznego obiektu. Zaproponowane pojęcie jest na tyle ogólne, że pozwala traktować jako sygnał termograficzny zarówno sekwencje wartości pikseli obrazów radiometrycznych, jak również sekwencje wartości pikseli pseudokolorowych obrazów rastrowych wygenerowanych przez urządzenie obrazujące podczerwień.

2.5. Przetwarzanie obrazów

Przetwarzanie obrazów to szereg przekształceń zmieniających i poprawiających jakość całości lub wybranej ich części oraz wypuklających wybrane cechy obrazów w celu podniesienia skuteczności ich analizy i rozpoznawania. Proces poprawy jakości obrazów nie ma wpływu na ich treść, lecz ma wpływ na zakres dynamiczny wybranych cech, co ułatwia ich detekcję [85]. Najogólniej operację przetwarzania obrazu można zdefiniować jako przekształcenie P obrazu zarejestrowanego $g(m, n)$ do obrazu wynikowego $h(m, m)$. Przetwarzanie obrazów termograficznych jest zagadnieniem bardzo ważnym zarówno z punktu widzenia człowieka-operatora kamery, jak i systemu komputerowej analizy obrazu. W obu przypadkach skuteczność analizy i interpretacji obrazów zależy od ich jakości. Należy

jednak pamiętać, że operacje przetwarzania mogą mieć wpływ na informację ilościową zawartą w termogramie, gdyż w wyniku odpowiednich przekształceń zmianie ulegną wartości temperatur. Ponadto niektóre przekształcenia są nieodwracalne, czyli nie można znaleźć przekształcenia odwrotnego pozwalającego odtworzyć obraz wejściowy na podstawie obrazu wyjściowego. Proces przetwarzania obrazu można podzielić na dwa niezależne od siebie etapy: etap przetwarzania wstępnego (tzw. *preprocessing*) i etap przetwarzania końcowego (tzw. *postprocessing*). Na każdym etapie mogą być stosowane różne rodzaje przekształceń obrazu, które ogólnie można podzielić na dwie podstawowe grupy: przekształcenia bezkontekstowe i przekształcenia kontekstowe [152]. W dalszej części monografii, w encyklopedycznym skrócie przedstawiono najważniejsze rodzaje przekształceń. Szczegółowa charakterystyka zagadnień związanych z przetwarzaniem obrazów wizyjnych i termograficznych jest zawarta w licznych publikacjach krajowych i zagranicznych np. [1, 47, 76, 85, 91, 113, 152].

2.5.1. Przekształcenia bezkontekstowe

Przekształcenia bezkontekstowe nazywane są również przekształceniami punktowymi i pozwalają, poprzez stosowanie odpowiednich operacji algebraicznych, manipulować wartościami poszczególnych punktów pojedynczego obrazu lub pary obrazów. Przekształcenia punktowe można podzielić m.in. na [152]:

- przekształcenia geometryczne,
- przekształcenia arytmetyczne,
- operacje binaryzacji obrazu,
- przekształcenia regionalne
- przekształcenia logiczne.

2.5.1.1. Przekształcenia arytmetyczne obrazu

W przypadku przekształceń tej klasy operator przekształcenia $P[.]$ jest funkcją jednej zmiennej, której argumentem jest wartość (jasność) punktu obrazu. Wynik tego przekształcenia nie zależy od współrzędnej (m, n) tego punktu. Działanie operatora $P[.]$ polega na przekształceniu skali wartości $g \in \langle 0, G - 1 \rangle$ obrazu źródłowego do wynikowej skali wartości $h \in \langle 0, H - 1 \rangle$ obrazu wynikowego, gdzie G jest liczbą poziomów jasności obrazu źródłowego, a H liczbą poziomów jasności obrazu wynikowego. W zależności od rodzaju funkcji transformującej wartości punktów obrazu, operacje można podzielić na [152]:

- przekształcenia liniowe – funkcja transformująca jest funkcją liniową; przykłady operacji liniowych to np. dodawanie, odejmowanie, mnożenie lub dzielenie obrazu przez liczbę k . Szczególnym przypadkiem operacji liniowych jest negacja obrazu należąca również do grupy operacji logicznych;
- przekształcenia nieliniowe – funkcja transformująca jest funkcją nieliniową (np. łamaną, gładką wypukłą lub wklęsłą); klasycznymi funkcjami stosowanymi w przekształceniach nieliniowych to funkcje eksponencjalna, logarytmiczna i kwadratowa;
- przekształcenia złożone – funkcja transformująca jest kombinacją funkcji liniowych i nielinowych.

Aby przekształcenie było wzajemnie jednoznaczne, funkcja P musi być ściśle monotoniczna (rosnąca lub malejąca). W innym przypadku przekształcenie odwrotne (odzyskanie obrazu źródłowego) nie będzie możliwe [88]. Jednym z podstawowych zastosowań klasy przekształceń punktowych obrazu jest korekcja kontrastu i średniej jasności obrazu.

2.5.1.2. *Przekształcenia stosujące histogram obrazu*

Obraz można interpretować jako wynik rejestracji pewnego procesu losowego, w którym kolejne punkty obrazu są obserwowanymi zdarzeniami losowymi [88]. Rejestrowane wartości punktów obrazu (temperatur lub jasności) o wartościach dyskretnych z określonego zakresu wartości przyjmują pewien rozkład gęstości prawdopodobieństwa, który można estymować na podstawie histogramu.

Podstawowe operacje bazujące na histogramie to jego normalizacja i wyrównywanie. Normalizacja histogramu lub inaczej rozciąganie histogramu jest przekształceniem bazującym na funkcji liniowej i polega na zwiększeniu wartości obrazu o małym kontraście (zakresie wartości) do określonego (zwykle pełnego) zakresu dostępnych poziomów wartości elementów obrazu. Nie jest to przekształcenie wzajemnie jednoznaczne i należy starannie dobierać zakres przekształcanych wartości obrazu źródłowego [88]. Wyrównanie histogramu, zwane inaczej linearyzacją lub spłaszczeniem histogramu, polega na takim przekształceniu wartości poszczególnych punktów obrazu, aby liczba punktów o wartościach leżących w każdym z równych przedziałów histogramu była w przybliżeniu taka sama. Przy wyrównywaniu histogramu zwiększa się różnicę między wartościami tych punktów obrazu, których wartości występują najczęściej. Z kolei te wartości pikseli, które na obrazie rzadko występują, są ze sobą utożsamiane. Oznacza to, że część informacji jest tracona, a zatem nie jest to przekształcenie odwracalne [85]. Operacja ta poprawia wyrazistość i czytelność obrazu.

2.5.1.3. *Przekształcenia geometryczne obrazu*

Przekształcenia geometryczne należą do klasy operacji globalnych na obrazie. Podstawowymi operacjami geometrycznymi stosowanymi wobec obrazów termograficznych są:

- zmniejszenie i powiększenie obrazu,
- obrót obrazu,
- przesunięcie obrazu,
- korekta zniekształceń geometrycznych obrazu.

Operacje te przydatne są w procesie usuwania zniekształceń geometrycznych wprowadzanych przez układy optyczne urządzeń obrazowania, stosuje się je również w procesie tworzenia zobrażeń panoramicznych składających się z kilku obrazów. Przesunięcie, obrót i powiększenie obrazu są nieodzownymi operacjami na etapie dopasowania obrazu w procesie fuzji obrazów. Powszechnie stosowaną operacją jest powiększenie obrazu w celu wydobywania lepszego zobrażenia jego szczegółów. Przekształcenia geometryczne cyfrowych obrazów termograficznych wiążą się z problemami reprezentacji obrazu wynikowego. Podstawowy z nich to zmiana wartości punktów obrazu, co w przypadku termogramów ilościowych wiąże się z zafałszowaniem pomiarów mierzonych wartości takich jak np. wartość średnia czy maksymalna temperatury w danym obszarze. Efekt ten spowodowany jest, w przypadku operacji powiększania obrazu, wzrostem liczby dyskretnych punktów obrazu, w których należy wyświetlić nową, większą wersję tego samego obrazu. Innym powodem zmiany wartości pikseli jest uzyskanie niecałkowitej wartości współrzędnych w wyniku wykonania takich transformacji geometrycznych jak np. obrót obrazu lub zmiany jego skali o niecałkowitą wielkość współrzędnych. Problemy te rozwiązuje się poprzez stosowanie metod interpolacji funkcji dwuwymiarowej.

Alternatywą dla metod interpolacyjnych, szczególnie w operacjach powiększania obrazów, jest stosowanie metod nadrozdzielczościowych [66, 83].

2.5.1.4. Operacje progowania obrazu

Operacja progowania polega na wydzieleniu z obrazu obszarów poprzez porównywanie wartości każdego punktu obrazu z zadaną wartością progową. Szczególnym przypadkiem progowania jest proces binaryzacji, który polega na przekształceniu obrazów monochromatycznych i kolorowych w obrazy binarne (czarno-białe). Informacja obszarowa niesiona przez obraz po progowaniu wykorzystywana jest w operacjach segmentacji obrazów, zadaniach pomiarowych (zliczanie obiektów, wyznaczanie cech topologicznych), definiowaniu przekształceń regionalnych obrazu itp. Istnieją różne metody progowania [85]. Można podzielić je na metody globalne i lokalne. Najprostsze metody wykorzystują jeden próg (dolny lub górny). Istnieją metody z podwójnym ograniczeniem pozwalające wyodrębnić obszary na podstawie określonego zakresu wartości punktów obrazu. Można stosować metody wielokryterialne bazujące na kilku progach, których efektem nie jest obraz binarny, lecz obraz składający się z segmentów grupujących elementy obrazu o różnych wartościach poziomów szarości. W operacjach progowania najistotniejsze jest dobranie odpowiedniego ograniczenia (ograniczeń), co nie jest zadaniem trywialnym. Istnieją metody, w których próg wyznaczany jest na podstawie histogramu, adaptacyjnie, na podstawie wyników analizy statystycznej obrazu, na bazie analizy dyskryminacyjnej itd. Operacje progowania mają istotne znaczenie w przetwarzaniu obrazów termograficznych ze względu na możliwość wyodrębniania izoterm oraz analizy ich kształtów i położenia.

2.5.1.5. Obszar zainteresowania

Obrazy generowane przez urządzenia obrazujące w podczerwieni przedstawiają scenę, na której poza obiektami istotnymi mogą pojawiać się obiekty niepożądane, mogące zakłócać proces przetwarzania i analizy obrazu. Taka sytuacja jest wypadkową usytuowania kamery i zastosowanego układu optycznego. Aby ocena obserwowanego obiektu mogła być dokonywana szybko i skutecznie, bardzo często w procesie przetwarzania, analizy i rozpoznawania obrazów rozpatruje się tylko fragment(y) obrazu, tzw. obszar(y) zainteresowania, (ang. *Region Of Interest ROI*). W obrębie wyselekcjonowanego obszaru(ów) można przeprowadzać wszelkie istniejące operacje na punktach obrazu. Podstawową zaletą rozpatrywania wybranego obszaru zainteresowania (ROI) zamiast całego obrazu jest redukcja rozmiaru przetwarzanego obrazu oraz zmniejszenie czasu jego analizy, co jest szczególnie istotne w układach diagnozujących działających on-line. Za podstawowe parametry obszaru zainteresowania można uznać jego: kształt, rozmiar i lokalizację. Kształt obszaru zainteresowania może być dowolny i wynikać np. z kształtu obserwowanego obiektu. W takim przypadku rozpatrywany jest fragment obrazu o kształcie wielokątą. Najczęściej jednak definiuje się obszary zainteresowania o kształcie prostokątnym (tzw. bloki obrazu [152]) z uwagi na tablicową reprezentację wartości obrazu i sposób ich przetwarzania przez maszynę cyfrową. Definiowanie obszaru zainteresowania wymaga maskowania zadanego fragmentu obrazu i kopiowania wartości punktów obrazu w wybranym fragmencie. Definiowanie maski może odbywać się w sposób ręczny, przez wskazanie przez operatora fragmentu obrazu, lub w sposób automatyczny przez zastosowanie odpowiednich algorytmów bazujących np. na metodach segmentacji obrazu. W przypadku automatycznego definiowania maski obszaru zainteresowania efektem końcowym jest obraz binarny [152].

2.5.2. Metody przetwarzania bazujące na dwóch obrazach

W praktyce komputerowego przetwarzania obrazów, również termograficznych, niejednokrotnie zachodzi potrzeba porównania lub złożenia dwóch obrazów. W takim przypadku można posługiwać się operatorami arytmetycznymi i operatorami logicznymi wykonywanymi na odpowiadających sobie punktach rozpatrywanych obrazów źródłowych. Podczas przetwarzania dwóch obrazów przyjmuje się dwa podstawowe założenia [27]:

- obrazy mają ten sam rozmiar,
- wartości punktów obrazu należą do tego samego zakresu.

Założenia te są oczywiste, a drugie z nich szczególnie istotne w przypadku obrazów termograficznych, reprezentowanych w postaci tablicy wartości temperatur i tablicy stopni odcieni szarości lub kolorów. Rozpatrywanymi obrazami mogą być dwa dowolne obrazy, przy czym w przypadku obrazów termograficznych zwykle są to obrazy tej samej sceny, gdzie jeden z nich może pełnić funkcję obrazu odniesienia (np. obraz w świetle widzialnym w zadaniach nakładania lub fuzji obrazów), funkcję maski (np. obraz binarny będący modyfikacją obrazu pierwotnego) lub funkcję wzorca (np. termogram zarejestrowany w nominalnych warunkach działania obiektu).

Do operacji arytmetycznych obrazów należy zaliczyć: dodawanie, odejmowanie, dzielenie i mnożenie dwóch obrazów. Operacje te mogą być rozpatrywane niezależnie lub w formie kombinacji.

Podczas operacji dodawania konieczne jest narzucenie odpowiednich ograniczeń w celu uniknięcia przekroczenia maksymalnej wartości punktu obrazu korespondującej z tablicą kolorowania.

Odejmowanie w przypadku obrazów termograficznych jest bardzo często stosowane w termografii dynamicznej np. do porównywania obrazów rejestrowanych w różnych chwilach czasowych z obrazem wzorcowym w celu detekcji zmian wartości temperatur, tłumienia wpływu odbić promieniowania oraz do obniżania poziomu zakłóceń, co jest efektywne w przypadku addytywnego szumu, który w równej mierze występuje w obu zobrazowaniach. Operacje mnożenia i dzielenia są stosowane głównie do polepszania jakości obrazu. Mnożenie jest prostą operacją stosowaną w celu wycięcia fragmentu obrazu z zastosowaniem maski będącej obrazem binarnym, na którym punkty obrazu obszaru zainteresowania są reprezentowane w postaci wartości 1 a tło w postaci wartości 0. Inne przykłady operacji arytmetycznych stosowanymi wobec dwóch obrazów to np. operacja wyznaczania ekstremów (minimum lub maksimum) z dwóch obrazów. W efekcie powstaje obraz będący złożeniem np. wartości maksymalnych.

Operacje logiczne są stosowane najczęściej do obrazów binarnych, gdzie 1 symbolizuje prawdę a 0 fałsz. Przy takiej interpretacji obrazów istnieje możliwość przeprowadzenia operacji logicznych na poszczególnych punktach obrazu, stosując algebrę Boole'a. Do najczęściej stosowanych tego typu operacji można zaliczyć:

- OR – sumę logiczną,
- XOR – sumę rozłączną,
- NOT – zaprzeczenie,
- AND – iloczyn logiczny,
- SUB – różnicę logiczną.

W przypadku obrazów o większej liczbie poziomów wartości punktów obrazu możliwe jest stosowanie operacji bazujących na logice wielowartościowej.

2.5.3. Metody przetwarzania obrazów w dziedzinie czasu

Większość współczesnych urządzeń zobrazowania podczerwieni pozwala na akwizycję sekwencji obrazów w czasie. Czas w takim przypadku stanowi zmienną niezależną, która może być zastosowana w procesie przetwarzania obrazów. Sekwencje obrazów wykorzystywane są do poprawy jakości obrazów oraz tworzenia nowych obrazów podkreślających określone cechy zmieniające się w czasie.

Najprostszym i najbardziej popularnym sposobem poprawy jakości obrazu jest uśrednianie obrazów w czasie. Efektem końcowym jest pojedynczy obraz, w którym występuje najczęściej poprawa stosunku sygnału do szumu. Redukcja szumów przez uśrednianie obrazów jest użyteczna tylko wtedy, gdy obrazowane obiekty nie zmieniają swojego położenia w trakcie akwizycji. Jeśli warunek ten nie jest spełniony, krawędzie i szczegóły obrazu staną się nieostre (zostaną „rozmyte”). W przypadku obrazów termograficznych uśrednienie wartości punktów obrazów w czasie prowadzi z jednej strony do podwyższenia rozdzielczości temperaturowej w wyniku obniżenia nieskorelowanych szumów, ale z drugiej strony pogarsza rozdzielczość w czasie [147].

Inną grupą metod wykorzystujących sekwencje obrazów do poprawy jakości zobrazowania są metody nadrozdzielczościowe (ang. *super resolution*) [66, 83]. Są to metody złożone i można je pogrupować na metody działające w dziedzinie częstotliwości i dziedzinie przestrzennej [83]. Ogólnie pozwalają one zwiększać rozdzielczość obrazu na podstawie sekwencji obrazów o niskiej jakości przedstawiających tę samą scenę w różnych ujęciach czasowych i przestrzennych. Ich stosowanie pozwala na redukcję szumów i poprawę ostrości zobrazowania [66].

Dysponując sekwencją obrazów, możliwe jest przekształcenie ich w dziedzinie czasu do jednego syntetycznego obrazu. Elementy nowego obrazu są liniową lub nieliniową kombinacją elementów obrazów składowych sekwencji. W zależności od potrzeb wykorzystywane są różne sposoby generowania obrazów syntetycznych. Najczęściej przetwarzanie obrazów w dziedzinie temporalnej stosowane jest w termografii dynamicznej. Jednym z przykładów klasy obrazów syntetycznych, które otrzymywane są na podstawie sekwencji obrazów, są maksigramy i czasogramy [147]. Maksigram jest „sztucznym” zobrazowaniem, powstałym z sekwencji zarejestrowanych termogramów i stosowanym na potrzeby detekcji i identyfikacji niejednorodności strukturalnych w nieniszczących badaniach materiałów metodami termografii aktywnej. Do tworzenia maksigramu wykorzystuje się wzorec, którym jest najczęściej wybrany piksel z obszaru wolnego od wad. Wartość elementów nowego obrazu zależy od chwil czasowych, w których występuje maksymalna różnica między wartościami bieżącego piksela i piksela odniesienia, co można przedstawić następującym równaniem [147]:

$$\Delta T_m(i, j, \tau_m) = \max(T(i, j, \tau) - T_{ref}(i_{ref}, j_{ref}, \tau)) \quad (2.15)$$

W porównaniu z pojedynczymi termogramami, wybranymi z zarejestrowanej sekwencji, maksigram zawiera o wiele więcej informacji dotyczących podpowierzchniowych defektów w materiale oraz charakteryzuje się maksymalnym stosunkiem sygnał/szum.

Czasogram jest obrazem syntetycznym, który podobnie do maksigramu, powstaje na podstawie sekwencji termogramów i odzwierciedla rozkład charakterystycznych czasów wymiany ciepła w obiekcie w stosunku do wzorca [147].

2.5.4. Przekształcenia kontekstowe

Przekształcenia kontekstowe (nazywane również lokalne [88]) należą do ważnych metod przetwarzania obrazów stosowanych na etapie przetwarzania wstępnego i przetwarzania końcowego. Przekształcenia kontekstowe polegają na utworzeniu obrazu wynikowego, którego wartości punktów są funkcją zarówno wartości poszczególnych punktów obrazu źródłowego, jak i wartości punktów z nimi sąsiadujących lub wartości punktów innego obrazu [152]. Operacje kontekstowego przetwarzania obrazów można podzielić na dwie podstawowe grupy: filtrację przestrzenną obrazu i przekształcenia morfologiczne.

2.5.4.1. Filtracja przestrzenna

Filtracja cyfrowa jest operacją przekształcającą jeden obraz w drugi metodą „punkt po punkcie” z uwzględnieniem tablicy o niewielkich rozmiarach będącej ograniczeniem wymiaru odpowiedzi impulsowej filtru i nazywanej maską przekształcenia lub szablonem strukturalnym. Szablon strukturalny określa lokalne otoczenie o bieżącego punktu m_0, n_0 obrazu źródłowego. Filtracja polega na przesuwaniu maski przekształcenia w polu obrazu $g(m, n)$ (z wyłączeniem punktów brzegowych, dla których nie można zdefiniować pełnego otoczenia o) oraz wykonaniu przekształcenia P dla każdego położenia okna. Jeżeli bieżącym położeniem okna filtracji jest punkt (m_0, n_0) , to wynik filtracji należy zapisać w punkcie obrazu wynikowego $h(m_0, n_0)$. Stosowanie masek znacznie skraca czas wykonania filtracji przez przyspieszenie operacji dwuwymiarowego splotu. Filtry można podzielić na dwie podstawowe grupy: liniowe i nieliniowe. Różnice między filtrami liniowymi i nieliniowymi wynikają z własności wieloargumentowej funkcji P przekształcającej jeden obraz w drugi. Filtry najczęściej wykorzystuje się na etapie przetwarzania wstępnego obrazów do:

- usuwania niepożądanych szumów,
- poprawy jakości technicznej zobrazowania – np. usunięcie artefaktów wynikających z obecności zanieczyszczeń na powierzchni układu optycznego lub w przestrzeni ścieżki pomiarowej, poprawę ostrości zobrazowania itp.,
- uwydatnienia obiektów o niskim kontraście,
- wydzielania granic obszarów,
- rekonstrukcji uszkodzonego obszaru obrazu.

Pomimo dużych możliwości, jakie dają filtry cyfrowe w kształtowaniu jakości termogramów, w praktyce przetwarzania obrazów termograficznych filtracja często bywa pomijana. Głównymi przyczynami są: brak wiedzy operatora na temat procesów filtracji, obawa przed zmianą czy zafałszowaniem rozkładu temperatury i brak odpowiednich narzędzi programowych [74].

2.5.4.2. Filtracja morfologiczna

Filtracja morfologiczna jest to szereg przekształceń logicznych, stosowanych najczęściej wobec obrazów po operacji progowania. Operacje morfologiczne można zaliczyć do grupy zadań przetwarzania końcowego obrazów (tzw. postprocessingu). Istota przekształceń morfologicznych polega na weryfikacji lokalnej konfiguracji punktów obrazu z konfiguracją zapisaną w elemencie strukturalnym oraz wykonaniu, w przypadku zgodności konfiguracji punktu centralnego maski i punktów obrazu objętych maską, operacji określonej dla danego przekształcenia. Zwykle jest to po prostu zmiana wartości danego punktu obrazu [85]. Ważną cechą przekształceń morfologicznych jest to, że są one przekształceniami iteracyjnymi. Do klasycznych przekształceń morfologicznych zaliczamy [152]:

- erozję oraz dylatację,
- otwarcie i zamknięcie,
- pogrubianie i ścienianie,
- szkieletyzację.

Operacje morfologiczne stosowane wobec obrazów wcześniej poddanych operacji progowania stosuje się w procesie segmentacji.

2.5.5. Segmentacja obrazu

Segmentacja obrazu polega na identyfikacji i wydzieleniu nienachodzących na siebie obszarów (regionów) cechujących się jednorodnością w sensie przyjętego kryterium. Własnościami, które są często wybierane jako kryteria jednorodności obszarów, są: poziom szarości, barwa, tekstura. Zadania segmentacji polegają na przejściu od ilościowej do jakościowej informacji (reprezentacja obrazu). Segmentacji towarzyszy zwykle indeksacja obiektów polegająca na przypisaniu do wszystkich pikseli zidentyfikowanych obiektów identyfikatorów wskazujących, do którego obiektu który piksel należy. Segmentacja jest bardzo często silnie zależna od zastosowania, ponieważ implikuje to konieczność uwzględniania wiedzy dziedzinowej. Istnieją różnorodne algorytmy segmentacji [48, 52, 163], spośród których można wyróżnić np.:

- metody punktowe – bazujące na progowaniu i klasteryzacji,
- metody krawędziowe — wymagają zastosowania któregoś z algorytmów wykrywania krawędzi,
- metody obszarowe:
 - rozrost obszarów,
 - łączenie obszarów,
 - podział obszarów,
 - metoda podziału i łączenia,
 - segmentacja wododziałowa,
- metody hybrydowe — wykorzystujące dwie lub więcej z powyższych metod, np. rozrost obszarów z wykorzystaniem informacji o przebiegu krawędzi.

2.5.6. Metody transformacyjne

Metody transformacyjne pozwalają przekształcać obraz do alternatywnej reprezentacji zdefiniowanej w innej dziedzinie jego wartości. Przekształcenia obrazów są z reguły odwracalne i bezstratne. Transformacje obrazu pozwalają uwypuklać cechy obrazu istotne z punktu widzenia celu analizy obrazu. Metody transformacyjne wykorzystuje się w realizacji takich zadań przetwarzania i analizy obrazów jak np.: kompresja, filtracja, ekstrakcja cech, rozpoznawanie obrazów itp. Istnieje wiele różnych przekształceń obrazów, spośród których najbardziej popularne to:

- dwuwymiarowa transformata Fouriera,
- transformata kosinusowa,
- transformata falkowa,
- transformata Hougha,
- transformata Radona,
- transformata Karhunen-Loevego.

2.5.6.1. Dwuwymiarowe dyskretne przekształcenie Fouriera

Dwuwymiarowe dyskretne przekształcenie Fouriera ma największe znaczenie w przetwarzaniu obrazów cyfrowych. Stosowane jest w: detekcji cech obrazów lepiej rozróżnialnych w dziedzinie częstotliwości; szybkim obliczaniu splotu, wzmacnianiu lub usuwaniu składowych obrazu itp. Dyskretne przekształcenie Fouriera można zdefiniować w następujący sposób:

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} g(m, n) e^{-j2\pi(\frac{vn}{N} + \frac{um}{M})} \quad (2.16)$$

gdzie:


$g(m, n)$ jest obrazem reprezentowanym w postaci uporządkowanego zbioru liczb o wartościach rzeczywistych zapisanych w tablicy o rozmiarach $M \times N$.

$F(u, v)$ – widmo Fouriera zapisane w postaci zbioru liczb zespolonych uporządkowanych w tablicy o rozmiarze $M \times N$.

Przekształcenie Fouriera obrazu jest przekształceniem globalnym i każda z wyznaczanych wartości widma $F(u, v)$ jest zależna od wszystkich punktów obrazu [88]. Dwuwymiarowa transformata Fouriera jest operacją odwracalną i przekształcenie odwrotne można zdefiniować w następujący sposób:


$$g(m, n) = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{j2\pi(\frac{vn}{N} + \frac{um}{M})} \quad (2.17)$$

Zespolone widmo Fouriera $F(u, v)$ można przedstawić za pomocą uporządkowanych w tablicy dwuwymiarowej wartości części rzeczywistej i urojonej lub modułu amplitudy, lub fazy (widmo fazowe). Tablice takie można interpretować jako specyficzne obrazy cyfrowe nazywane również F-obrazami (rys. 2.5) [136].



Rys. 2.5. Przykład obrazu termograficznego (a) i jego F-obraz widma amplitudowego (b) i fazowego (c) otrzymane w wyniku zastosowania dwuwymiarowej transformaty Fouriera

W praktyce przetwarzania obrazów najczęściej stosuje się widmo amplitudowe $|F(u, v)|$. Specyficzną własnością F-obrazów jest symetria ich wartości. Komponenty niskoczęstotliwościowe położone są w narożnikach obrazów, jednak z praktycznego punktu widzenia dokonuje się przestawienia ćwiartek F-obrazów, umieszczając składowe o niskich częstotliwościach w środku obrazu. Takie postępowanie poprawia czytelność obrazu i pomaga w interpretacji obrazu (rys. 2.6). W dwuwymiarowym widmie Fouriera szczególną interpretację ma prążek widma dla częstotliwości zerowych. Jest on wartością rzeczywistą i popularnie określa się go mianem składowej stałej widma.



Rys. 2.6. Przykładowe F-obrazy widma amplitudowego przed (a) i po (b) przestawieniu ćwiartek

F-obrazy powstałe w wyniku transformacji obrazów rzeczywistych charakteryzują się bardziej złożoną strukturą i są trudne w interpretacji ze względu na brak bezpośredniego związku z cechami fizycznymi widocznymi na obrazie. Stanowią one jednak odrębną reprezentację obrazu rzeczywistego i mogą nieść ważne informacje, trudne do zidentyfikowania na podstawie obrazu rzeczywistego. Istotną własnością transformaty Fouriera jest niezmiennosc względem przesunięcia, pozwalająca analizować sekwencje obrazów, na których obiekty uległy przemieszczeniu w wyniku zmiany położenia urządzenia obrazującego lub przemieszczenia obiektu obserwowanego.

2.5.6.2. Przekształcenie falkowe

Transformacja falkowa (analiza falkowa) dzięki możliwości analizy zmiany częstotliwości sygnału w funkcji czasu stała się popularnym narzędziem przetwarzania i analizy sygnałów niestacjonarnych, przejściowych oraz różnego typu złożonych obrazów. W odróżnieniu od transformacji Fouriera, transformacja falkowa nie powoduje utraty informacji o czasie, lecz umożliwia jednoczesne przedstawienie sygnałów w dziedzinie czasu i częstotliwości oraz prowadzi do aproksymacji sygnałów przez wyodrębnienie ich charakterystycznych elementów strukturalnych [9, 12]. Transformata falkowa jest przekształceniem podobnym do transformaty Fouriera pod tym względem, iż oba należą do przekształceń całkowitych. W odróżnieniu od transformacji Fouriera, gdzie jako jądro wykorzystuje się funkcje sinusoidalne, w przypadku transformaty falkowej jądrem jest falka. Falki to rodziny funkcji, z których każda jest wyprowadzona z funkcji podstawowej za pomocą przesunięcia i skalowania. Falki umożliwiają przedstawienie z określoną dokładnością dowolnej funkcji ciągłej poprzez sumę ważoną. Falkowe równanie aproksymujące funkcję $f(x)$ ma postać [12]:


$$f(x) = \sum_k \sum_j c_{j,k} \psi_{j,k}(x) \quad (2.18)$$

gdzie:

$\psi_{j,k}(x)$ – falka o skali j i przesunięciu k w stosunku do falki podstawowej,
 $c_{j,k}$ – współczynniki falkowe wyznaczone w procesie aproksymacji.


Falka podstawowa może przybierać różne postacie. W trakcie analizy falkowej poszukiwane jest podobieństwo do wybranego typu falki, które opisywane jest przez współczynniki falkowe. Wybór falki dokonywany jest na podstawie wstępnej analizy rozpatrywanych danych, a rodzaj wybranej falki decyduje o cechach, jakie zostaną wydobyte z analizowanych danych. Reprezentacja falkowa sygnału może być uogólniona na dowolny wymiar. Znaczenie praktyczne w zastosowaniu falek do przetwarzania obrazów ma przypadek dwuwymiarowy

bazujący na teorii analizy wielorozdzielczej [12]. Istotą analizy wielorozdzielczej obrazu (wg algorytmu Mallata) jest dekompozycja obrazu na cztery obrazy składowe, przy czym każda składowa ma rozmiar równy jednej czwartej obrazu pierwotnego (czyli ma rozdzielczość liniowo dwa razy mniejszą niż dekomponowany obraz). Każda składowa może być następnie dekomponowana w ten sam sposób, przez co powstaje reprezentacja na wielu poziomach rozdzielczości. Realizacja dekompozycji polega na sekwencyjnym filtrowaniu górno- i dolnoprzepustowym, osobno wzdłuż wierszy i osobno wzdłuż kolumn obrazu, przy jednoczesnym zmniejszaniu rozdzielczości (decymacji) z interwałem dwa (rys. 2.7).



Rys. 2.7. Przykład dekompozycji falkowej obrazu wg algorytmu Mallata

W zależności od rodzaju i kolejności filtrów powstają następujące reprezentacje obrazu: zgrubna (aproksymacja) (LL – filtr dolnoprzepustowy dla wierszy i kolumn), pozioma (LH – dla wierszy filtr dolnoprzepustowy a górnoprzepustowy dla kolumn), pionowa (HL – odwrotnie niż LH) i diagonalna (HH – dwa razy filtr górnoprzepustowy). Dekompozycja może być kontynuowana; jedna ze strategii przyjmuje, że kolejna dekompozycja dotyczy komponentu zgrubnego z poprzedniej. Proces ten został przedstawiony schematycznie na rysunku 2.8.



Rys. 2.8. Przykładowe wyniki dwupoziomowej dekompozycji falkowej obrazu

Powstająca w wyniku zastosowania takiego algorytmu wielorozdzielcza reprezentacja obrazu pozwala na pozyskanie obrazów o nowych i niedostępnych dla obrazu pierwotnego cechach. Ta zaleta transformaty falkowej pozwoliła na jej liczne zastosowania, m.in. w analizie obrazów termograficznych rejestrowanych w czasie badań nieniszczących z zastosowaniem metod termografii impulsowej [161] lub termograficznych zobrazowań medycznych [145].

2.6. Komputerowa analiza obrazów

Komputerowa analiza obrazów ma na celu wyodrębnienie z całkowitej informacji zawartej w obrazie tylko najistotniejszej jego części z punktu widzenia użytkownika lub systemu wizyjnego [136]. W trakcie analizy obrazów zwykle wyznacza się własności obiektów zidentyfikowanych na obrazie oraz przeprowadza selekcję najistotniejszych z nich. Zadania te

nazywane są powszechnie ekstrakcją i selekcją cech obrazu na podstawie przyjętego kryterium. Proces analizy poprzedzony jest przetwarzaniem obrazów.

Metodyka analizy obrazów jest ściśle powiązana z klasą rozpatrywanych obrazów i uwarunkowana celem badań, co czyni, że ogólnych metod analizy jest niewiele. Na potrzeby analizy obrazów można przyjąć, że każdy obraz odznacza się określoną wieloszczeblową organizacją utworzoną z kolejno następujących po sobie poziomów [77]:

- poziom zerowy – na którym obraz rozpatrywany jest jako całość i może odznaczać się np. średnim poziomem jasności (lub temperatury w przypadku obrazów termograficznych), dominującą barwą itp.;
- poziom pierwszy – na którym można wyróżnić tło i dominujące obiekty lub podobszary różniące się pewnymi integralnymi cechami;
- poziom drugi – na którym w ramach poszczególnych obiektów można wyodrębnić ich główne części składowe stanowiące podobszary charakteryzujące się różnymi cechami;
- poziom trzeci (a także następne) – na których można wyodrębnić elementy składowe poziomu niższego lub mikroobszary o określonych cechach.

Na każdym z zaproponowanych poziomów struktury obrazu możliwe jest określenie różnorodnych cech, które można podzielić na kilka podstawowych grup:

- cechy statystyczne – pozwalające opisać ilościowo parametry rozkładu wartości elementów obrazu;
- cechy geometryczne – określające wzajemne położenie obiektów, odległości między nimi, relatywne rozmiary itp.;
- cechy topologiczne – określające wzajemne przyleganie do siebie obiektów lub zawieranie się jednych obiektów w innych;
- cechy mereologiczne – świadczące o przynależności danych obiektów do tego samego obiektu nadrzędnego;
- cechy densytometryczne – pozwalające określać stopnie jasności obiektów;
- cechy kolorometryczne – charakteryzujące w sposób ilościowy barwy obiektów na obrazie;
- cechy heurystyczne – ilościowe parametry opisujące obraz utworzone indywidualnie dla rozpatrywanego przypadku na podstawie doświadczenia i intuicji projektanta systemu komputerowej analizy obrazów.

Ilościowa ocena obrazów na podstawie odpowiednio dobranych cech nie jest jedyną strategią stosowaną w analizie obrazów. Obraz może być również analizowany z zastosowaniem odpowiednio dopasowanego modelu [88]. Model obrazu należy traktować jako funkcję jednej lub wielu zmiennych, która opisuje rozkład wartości elementów obrazu w obszarze zainteresowania. Modelem można posługiwać się co najmniej na dwa sposoby. Pierwszy polega na określeniu wzorcowych parametrów funkcji, na podstawie danych wzorcowych i porównywaniu modelu z aktualnie analizowanym obrazem. Wynikiem analizy jest w tym przypadku różnica między wartościami modelu i aktualnymi wartościami obrazu w analizowanym obszarze. Drugie podejście polega na każdorazowym dopasowywaniu modelu do analizowanych wartości obrazu w obszarze zainteresowania. Miarą jakości dopasowania jest najczęściej średnia energia błędu (suma kwadratów różnic między wartościami punktów obrazu a wartością funkcji dla każdego piksela obszaru podzieloną przez liczbę pikseli w obszarze — błąd średniokwadratowy). Wartości parametrów, którym odpowiada minimalna wartość błędu, są wynikiem analizy obrazu.

2.7. Rozpoznawanie obrazów

Rozpoznawanie obrazów jest procesem przetwarzania informacji, podczas którego przeprowadzany jest proces klasyfikacji mający na celu przyporządkowania obiektów do określonej klasy w sytuacji braku informacji co do reguł przynależności. Klasa jest reprezentowana przez wzorzec, którym może być obraz reprezentowany przez dwuwymiarową macierz wartości obrazu lub wektor cech obrazu. Obiektem rozpoznawanym jest zbiór danych o strukturze i reprezentacji zgodnej ze wzorcem. Pojęcie rozpoznawania obrazów można rozumieć bardzo szeroko i odnosić zarówno do zagadnień klasyfikacji obiektów na obrazie, jak również klasyfikacji informacji zawartej w obrazie. Drugie podejście jest stosowane w diagnostyce technicznej na etapie detekcji i lokalizacji uszkodzeń lub ogólniej klasyfikacji stanu obiektu technicznego. Traktowanie zagadnień rozpoznawania obrazów w kontekście określania relacji między informacjami zakodowanymi w obrazie bardzo często reprezentowanymi przez określone cechy obrazu a wiedzą dziedzinową spowodowało, że w literaturze polskiej [23] można spotkać się z przykładami traktowania wektora cech jako pewnego obrazu (np. obrazu stanu obiektu w przypadku wektora cech stanu), co w procesie klasyfikacji pozwala traktować pojęcie wzorca i obrazu równorzędnie. W przypadku obrazów termograficznych zarówno bezpośrednio jego wartości, jak i cechy wyznaczone na podstawie jego wartości mogą nieść informację diagnostyczną, zatem mogą być zastosowane do klasyfikacji stanu technicznego. Rezultaty uzyskane w wyniku procesu rozpoznawania obrazów umożliwiają m.in. wspomaganie podejmowania decyzji eksploatacyjnych, ocenę stanu obiektu, identyfikację uszkodzeń itp. Proces rozpoznawania obrazów wymaga przeprowadzania wcześniej opisanych zadań dotyczących rejestracji, przetwarzania i analizy obrazów obejmującą również etap ekstrakcji cech. Dodatkowo do nieodłącznych operacji związanych z procesem rozpoznawania obrazów można zaliczyć selekcję cech. Istnieje duża liczba różnych algorytmów klasyfikacji stosowanych w rozpoznawaniu obrazów. Najogólniej można podzielić je na dwie podstawowe grupy:

1. Metody klasyfikacji nienadzorowanej, zwane inaczej metodami grupowania, polegającymi na podziale danych o nieznannej strukturze na grupy, gdzie każda z utworzonych grup zawiera elementy, które posiadają określone własności charakterystyczne dla tej grupy. Grupowanie jest dokonywane na podstawie określonego kryterium.
2. Metody klasyfikacji nadzorowanej, nazywane inaczej metodami bazującymi na analizie dyskryminacyjnej, których zadaniem jest przypisanie identyfikowanego obiektu do jednej z wcześniej choćby częściowo scharakteryzowanej klasy, z których pochodzą obiekty. Istota działania algorytmów nadzorowanych polega na uczeniu się w oparciu o zbiór uczący. Nauczony klasyfikator dokonuje klasyfikacji nowych danych na podstawie wiedzy zdobytej w procesie uczenia.

Spośród stosowanych podejść w rozpoznawaniu obrazów za najlepsze można uznać:

- podejście bazujące na dopasowywaniu do obrazu wzorcowego (szablonu),
- podejście statystyczne,
- podejście syntaktyczne lub strukturalne,
- podejście bazujące na sztucznych sieciach neuronowych.

2.7.1. Dopasowywanie wzorca

Dopasowywanie wzorca jest najstarszym i najprostszym podejściem stosowanym w rozpoznawaniu obrazów. W podejściu tym poszukuje się najlepszego dopasowania rozpatrywanego obrazu do znanego i istniejącego wzorca (szablonu). Kryterium dopasowania określone jest przez ekstremum miary podobieństwa wzorca i rozpatrywanego obrazu. Miarą podobieństwa może być np. wartość funkcji korelacji wzajemnej. Wzorec (szablon) określany jest często na podstawie zbioru trenującego. Podejście to w niektórych zastosowaniach należy uznać za bardzo efektywne, jednak należy pamiętać również o jego wadach wynikających z dużej wariancji międzyklasowej występującej w rozpoznawanych obrazach lub zniekształceniach obrazów wynikających ze sposobu ich rejestracji.

2.7.2. Podejście syntaktyczne

W wielu problemach rozpoznawania obrazów zawierających złożone wzorce bardziej odpowiednie jest przyjęcie reprezentacji hierarchicznej obrazu składającej się z prostych wzorców, które również mogą być zbudowane z jeszcze prostszych obiektów pierwotnych. Dzięki przyjęciu analogii do języka polegającej na tym, że skończony zbiór obiektów pierwotnych (liter) uznaje się za specyficzną formę alfabetu, za pomocą którego możliwe jest budowanie zdań według przyjętych zasad gramatycznych, możliwe jest przedstawienie bardziej złożonej struktury obrazu za pomocą wzajemnych relacji między obiektami pierwotnymi. Takie podejście pozwala na zapis dużej ilości różnych złożonych wzorców za pomocą małego zbioru obiektów pierwotnych z uwzględnieniem reguł gramatycznych. Reguły gramatyczne dla każdej klasy wzorców powstają na podstawie określonego zbioru danych trenujących. Syntaktyczne rozpoznawanie obrazów jest podejściem bardzo intuicyjnym, ponieważ poza możliwościami klasyfikacji wzorców możliwa jest również analiza relacji między obiektami pierwotnymi we wzorcach. Na potrzeby syntaktycznego opisu obrazu można posłużyć się metodami bazującymi na zastosowaniu języków ciągowych, grafowych i drzewowych. Implementacja metod syntaktycznego rozpoznawania obrazów może wiązać się z trudnościami w prawidłowej segmentacji obrazów zaszumionych w celu identyfikacji obiektów pierwotnych, a także z dedukcją zasad gramatycznych ze zbioru trenującego. Kolejnymi problemami mogącymi się pojawić podczas stosowania metod syntaktycznych jest gwałtowny wzrost kombinacji elementów pierwotnych, potrzeba stosowania bardzo rozbudowanych zbiorów trenujących i duże wymagania obliczeniowe [77, 138].

2.7.3. Podejście statystyczne

W podejściu statystycznym każdy obraz reprezentowany jest w postaci zbioru V wartości cech tworzącego punkt w v wymiarowej przestrzeni wartości cech. Celem rozpoznawania jest wybór i klasyfikacja takich wartości cech obrazów, które tworzą w przestrzeni wartości cech zwarte i rozłączne obszary. Efektywność rozpoznawania jest uzależniona od stopnia separacji międzyklasowej wartości przestrzeni cech. Na podstawie zbioru wzorców trenujących reprezentujących różne klasy tworzone są granice decyzyjne w przestrzeni wartości cech rozdzielające zbiory wartości cech należące do różnych klas. Według podejścia opartego na statystycznej teorii decyzji granice decyzyjne są określane na podstawie znanych lub wyuczonych rozkładów prawdopodobieństw cech należących do każdej klasy. Klasyfikację można również przeprowadzić na podstawie analizy dyskryminacyjnej, w której granice decyzyjne reprezentowane są w postaci parametrycznej i określane na podstawie

danych trenujących. Klasyczny system rozpoznawania bazujący na metodach statystycznych wymaga przeprowadzenia operacji trenowania i testowania klasyfikatora. Operacje trenowania i testowania zwykle bywają poprzedzone wstępnym przetwarzaniem danych polegającym m.in. na segmentacji wzorców, usuwaniu szumów, normalizacji wartości cech itp. Odpowiednio przygotowane wzorce poddawane są procesowi rozpoznawania (klasyfikacji). Klasyfikacja wzorców wymaga zaprojektowania lub wyboru odpowiedniego klasyfikatora. Można wskazać trzy różne podejścia w projektowaniu klasyfikatorów. Najprostszy sposób wyboru klasyfikatora polega na przyjęciu zasady, że wzorce podobne do siebie powinny należeć do tej samej klasy. Determinuje to zastosowanie metod bazujących m.in. na miarach podobieństwa, np. miarach minimalno-odległościowych stosowanych w algorytmie k najbliższych sąsiadów. Drugim podejściem stosowanym na potrzeby rozpoznawania wzorców jest zastosowanie optymalnej reguły decyzyjnej Bayesa przypisującej wzorzec do klasy z maksymalnym prawdopodobieństwem posteriori. Trzecie możliwe podejście przy projektowaniu klasyfikatora może polegać na przyjęciu granic decyzyjnych bezpośrednio na podstawie optymalizacji określonego kryterium błędu. W statystycznym rozpoznawaniu wzorców stosowane są m.in. takie klasyfikatory jak [62]:

- klasyfikator najbliższej średniej (*Nearest Mean Classifier*),
- metoda podprzestrzeni (*Subspace Method*),
- klasyfikatory 1 najbliższego sąsiada i k - najbliższych sąsiadów,
- klasyfikator Bayesa,
- klasyfikator logistyczny,
- klasyfikator Parzena,
- klasyfikator dyskryminacyjny Fishera,
- drzewa decyzyjne,
- klasyfikator bazujący na wektorach wspierających.

2.7.4. Rozpoznawanie z zastosowaniem sztucznych sieci neuronowych

Sztuczne sieci neuronowe są systemami obliczeniowymi odwzorowującymi istotę działania ludzkiego mózgu oraz procesów w nim zachodzących. Umożliwiają one równoległe przetwarzanie informacji dzięki istnieniu dużej liczby wzajemnie powiązanych, prostych jednostek obliczeniowych zwanych sztucznymi neuronami. Podstawowymi zaletami sztucznych sieci neuronowych jest umiejętność dochodzenia do rozwiązania bez znajomości algorytmu, zdolność do uogólniania przy wykorzystaniu niepełnej wiedzy, zdolność uczenia się i adaptacji do zmieniających się warunków. Stosowanie sieci neuronalnej wymaga określenia jej topologii, przygotowania danych uczących oraz przeprowadzenia procesu uczenia. Istotną wadą sieci neuronalnych jest to, że użytkownik nie zna sposobu, w jaki sieć neuronalna doszła do konkluzji. Do rozpoznawania wzorców najczęściej stosuje się [62] jednokierunkowe perceptronowe sieci wielowarstwowe realizujące proces uczenia metodą wstecznej propagacji błędów i sieci oparte na radialnych funkcjach bazowych (ang. *Radial Basis Function (RBF)*). Na potrzeby grupowania i przekształceń przestrzeni cech bardzo często stosuje się samoorganizujące się mapy zwane również sieciami Kohonena. W sieciach tych sztuczne neurony tworzą układ powiązany ze współrzędnymi prostej, płaszczyzny lub w dowolnej n -wymiarowej przestrzeni. Dzięki temu uczenie polega na zmianach współrzędnych neuronów tak, aby ich struktura dopasowała się do struktury przetwarzanych danych. Większość właściwości modeli bazujących na sztucznych sieciach neuronowych stosowanych

Tab. 2.1. Związki między metodami rozpoznawania obrazów bazującymi na sztucznych sieciach neuronowych i metodami statystycznymi [62]

Metody statystyczne	Sztuczne sieci neuronowe
Dyskryminacja z zastosowaniem funkcji liniowej	Perceptron
Analiza składowych głównych	Sieci autoasocjacyjne i różne sieci PCA
Ocena prawdopodobieństwa a posteriori	Perceptron wielowarstwowy
Nieliniowa analiza dyskryminacyjna	Perceptron wielowarstwowy
Klasyfikator bazujący na oknie Parzena	Sieci bazujące na funkcjach radialnych
Reguła k-najbliższych sąsiadów	Kohonena LVQ

w rozpoznawaniu obrazów jest ekwiwalentna lub podobna do klasycznych statystycznych metod rozpoznawania obrazów (tabela 2.1).

2.7.5. Redukcja wymiarowości zbioru cech

Bardzo często spotykanym problemem jest duża liczebność rozpatrywanych cech wpływająca na wzrost szumów informacyjnych i ograniczenie sprawności klasyfikacji. Jak pokazują badania, sprawność klasyfikatora zależy od wzajemnej relacji między liczebnością zbioru trenującego, liczbą cech i złożonością klasyfikatora. Dobrą praktyką jest, aby liczba przykładów uczących z każdej klasy była przynajmniej 10 razy większa od liczby cech [132, 62].

W celu przeprowadzenia redukcji wymiarowości wektora cech stosuje się dwie podstawowe operacje:

Ekstrakcję cech – polegającą na transformacji przestrzeni wartości cech do przestrzeni o mniejszej wymiarowości poprzez stosowanie liniowych lub nieliniowych przekształceń lub kombinacji wartości cech. Najbardziej znanymi metodami stosowanymi w redukcji wymiarowości są przekształcenia liniowe takie jak analiza składowych głównych (PCA) zwana również przekształceniem Karhunenena-Loeve’go, analiza czynnikowa, liniowa analiza dyskryminacyjna Fishera i rzutowania. Wśród nieliniowych metod można wymienić skalowanie wielowymiarowe (MDS), sieci neuronowe wraz z samoorganizującymi się mapami cech istotnych Kohonena.

Selekcję cech – polegającą na poszukiwaniu podzbioru cech spośród zbioru wejściowego cech zgodnie z przyjętym kryterium optymalizacji funkcji celu. Kryterium optymalizacji powinno umożliwić jak najwyższą sprawność klasyfikacji przy jednoczesnym zapewnieniu takiego rozkładu klas, aby był on możliwie najbliższy rozkładowi oryginalnemu. W selekcji cech istotnym jest przyjęcie odpowiedniej funkcji kryterialnej i strategii poszukiwań. Funkcje kryterialne mogą bazować na miarach informacyjnych lub klasyfikatorach. Opracowano wiele metod selekcji cech [69]. Wśród strategii poszukiwań rozróżnia się trzy grupy algorytmów: algorytmy wykładnicze (np. przeszukiwanie wyczerpujące, branch&bound), sekwencyjne (np. *Sequential Forward Selection* (SFS), *Sequential Backward Floating Search* (SBFS)) i stochastyczne (np. algorytmy genetyczne, symulowane wyżarzanie). Podczas projektowania algorytmów selekcji cech konieczne jest uwzględnienie czterech podstawowych kwestii:

- 1) wyboru punktu startowego w przestrzeni przeszukiwań, który determinuje kierunek przeszukiwania oraz dostarcza różnice pomiędzy przeszukiwaniem typu przeszukiwanie w przód (*forward selection*) i przeszukiwanie w tył (*backward selection*);
- 2) określenie sposobu organizacji procesu przeszukiwania wiążącego się z zastosowaniem algorytmu należącego do jednej z trzech grup [34]:
 - algorytmy wykładnicze (optymalne);
 - algorytmy sekwencyjne (suboptymalne),
 - algorytmy stochastyczne;
- 3) określenia strategii oceniania wybranych podzbiorów, które można sklasyfikować jako [73]:
 - metody powłoki (*wrapper approaches*),
 - metody filtrujące (*filters approaches*),
 - metody zagnieżdżające (*embedded approaches*);
- 4) określenia kryterium zatrzymującego proces przeszukiwania często określanego za pomocą heurystyki realizowanej przez odcinającą wartość funkcji kryterialnej bądź przez wymuszenie ilości cech potrzebnych do dalszego przetwarzania.

2.8. Fuzja danych

2.8.1. Fuzja obrazów

Szczególnym przypadkiem połączenia metod przetwarzania i analizy obrazów jest ich fuzja [67]. Komputerowa fuzja obrazów jest algorytmiczną techniką synergicznej kombinacji informacji zakodowanej w dwóch lub więcej obrazach cyfrowych, czego efektem jest nowy syntetyczny obraz charakteryzujący się cechami relewantnymi obrazów źródłowych i ograniczoną ilością cech redundantnych. Realizacja fuzji obrazów wymaga przyjęcia następujących założeń:

- proces fuzji powinien pozwalać na zachowanie (na ile to tylko możliwe) wszystkich wyraźnych cech obrazów wejściowych,
- proces fuzji nie może wprowadzać do obrazu wynikowego żadnych niespójności ani artefaktów,
- niepożądane cechy obrazów wejściowych (np. szumy) powinny być stłumione w obrazie syntetycznym.

Fuzja obrazów znana jest od wielu lat i najczęściej polega na sekwencyjnej realizacji dwóch podstawowych operacji: dopasowania obrazów i agregacji obrazów. Dopasowanie obrazów jest operacją polegającą na przemieszczeniu współrzędnych pikseli jednego obrazu względem drugiego, wykorzystując odpowiedni model transformacji pozwalający w efektywny sposób minimalizować stopień niedopasowania obrazów. Niedopasowanie obrazów jest efektem różnic we własnościach i właściwościach urządzeń obrazujących takich jak np. różnych kątów obserwacji i obszarów widzenia układów optycznych, różnych chwil obserwacji i detektorów działających w różnym zakresie promieniowania elektromagnetycznego. W praktyce stosowane są przekształcenia translacyjne, afiniczne elastyczne lub dowolne. W literaturze można znaleźć charakterystykę różnych metod dopasowania obrazów [162], co pozwala je podzielić na metody operujące na znacznikach umieszczonych na obrazie oraz metody bazujące na intensywności pikseli dopasowywanych obrazów. W metodach tych dopasowanie może odbywać się na poziomie obszarów lub cech wyznaczonych na etapie analizy obrazów.

Prawidłowe dopasowanie obrazów ma kluczowe znaczenie dla jakości obrazu wynikowego powstałego w wyniku agregacji informacji zawartej w obrazach wejściowych. Agregacja obrazów jest operacją łączącą uprzednio dopasowane obrazy wejściowe w jeden obraz wyjściowy. Opracowano szereg różnych algorytmów agregacji, które można podzielić na trzy podstawowe grupy [49]:

- algorytmy działające na poziomie pikseli,
- algorytmy działające na poziomie cech,
- algorytmy działające na poziomie symbolicznym.

Spośród wymienionych wyżej grup najszerze zastosowanie znalazły algorytmy bazujące bezpośrednio na pikselach i reprezentowane przez cztery klasy metod [156]:

- metody bazujące na modelu przestrzeni barw,
- metody statystyczne/numeryczne,
- metody wykorzystujące dekompozycję wieloskalową,
- metody radiometryczno-spektralne.

Znaczący udział w metodach agregacji ma dekompozycja wieloskalowa, której efektem jest struktura hierarchiczna obrazu. Strukturę hierarchiczną można uzyskać, stosując m.in.:

1) Transformacje piramidalne, w których wyznaczany jest zbiór obrazów, gdzie każdy z obrazów w piramidzie jest dwukrotnie mniejszy od obrazu na niższym stopniu piramidy. Spośród opracowanych przekształceń piramidalnych można wyróżnić:

- piramidę Gaussa [103],
- piramidę Laplace'a (lap) [15],
- piramidę stosunku współczynników dolnoprzepustowych (rat) [139],
- piramidę kontrastu (con) [140],
- piramidę fsd [6] (ang. *filter-subtract-decimate*),
- piramidę gradientu (gra)[16],
- piramidę różnic morfologicznych (mor) [118].

2) Transformacje falkowe, które działają podobnie jak w metodach piramidowych, jednak prowadzą do nieredundantnej reprezentacji obrazu. W algorytmach agregacji obrazów najczęściej stosuje się dwie transformaty:

- dwuwymiarową dyskretną transformatę falkową (dwb) [80],
- transformatę falkową niezmienną względem przesunięcia (sih) [120].

Duża różnorodność zarówno algorytmów dopasowania, jak i agregacji obrazów umożliwia ich kombinowanie, co pozwala na budowę metod fuzji obrazów dostosowanych do specyficznych potrzeb różnych dziedzin nauki i techniki. Proste metody fuzji obrazów termograficznych i wizyjnych znalazły zastosowanie w oprogramowaniu współczesnych kamer termograficznych z zainstalowaną kamerą światła widzialnego. Takie rozwiązanie ułatwia operatorowi interpretację obserwowanych obrazów termograficznych. Fuzja obrazów światła widzialnego i podczerwonego znajduje również zastosowania w systemach wojskowych i cywilnych do poszukiwania, identyfikacji i śledzenia celów. Fuzja obrazów znajduje szerokie zastosowanie w diagnostyce medycznej, gdzie dopasowywane i łączone są obrazy pochodzące z różnych źródeł obrazowania, np. obrazy rentgenowskie i obrazy rezonansu magnetycznego [99]. W diagnostyce technicznej fuzja obrazów radiograficznych i ultradźwiękowych pozwala na identyfikację defektów strukturalnych materiałów, a obrazy wizyjne i termowizyjne procesu spawania po operacji fuzji są źródłem cennych informacji o stanie procesu spawania i jakości wykonanego złącza spawanego [39]. Przegląd licznych publikacji [67], a także wyniki badań, w których autor uczestniczył [65], pokazują, że fuzja obrazów termograficznych i wizyjnych

powinna być prowadzona z zastosowaniem metod hybrydowych, operujących zarówno na obszarach obrazów, jak również na ich cechach.

2.8.2. Fuzja klasyfikatorów

W systemach wieloklasyfikatorowych odpowiedź grupy klasyfikatorów wyznaczana jest w większości przypadków z użyciem metod, które można podzielić na dwie podstawowe grupy [51]: selekcja klasyfikatorów i fuzja klasyfikatorów. Selekcja klasyfikatorów polega na wyborze z całego zbioru klasyfikatorów jednego lub kilku klasyfikatorów będących tzw. „lokalnymi ekspertami” [5, 61] podejmującymi decyzje. W przypadku fuzji klasyfikatorów zakłada się, że wszystkie klasyfikatory są trenowane na całym zbiorze wartości cech lub pewnych powiązanych ze sobą jego podzbiorach. Oznacza to istnienie klasyfikatorów potrafiących podejmować decyzje na podstawie pewnej przestrzeni wartości cech, jeśli współzawodniczą w podejmowaniu decyzji, uzupełniają się wzajemnie i proces ich uczenia przeprowadzono z zastosowaniem niejednorodnej przestrzeni wartości cech [51, 97, 153]. W przypadku praktycznego zastosowania fuzji klasyfikatorów kluczowe stają się dwa zagadnienia: zapewnienie różnorodności w zespole klasyfikatorów (co jest trudne ze względu na brak obiektywnych miar różnorodności) oraz wybór odpowiedniego sposobu łączenia odpowiedzi poszczególnych klasyfikatorów wchodzących w skład zespołu. Wiele prac skupia się na drugim zagadnieniu, wskazując na możliwość zastosowania zarówno prostych metod, jak na przykład głosowanie [124], a także bardziej skomplikowanych metod bazujących na teorii Bayesa [54], całkach rozmytych [81], sztucznych sieciach neuronowych [46] czy teorii funkcji przekonania Dempstera-Shafera [10, 107, 154]. Ostatnia grupa metod stała się niezwykle popularna, gdyż w wielu przypadkach pozwala na łączenie informacji niepewnej pochodzącej z wielu źródeł.

Centralnym elementem przy zastosowaniu teorii funkcji przekonania do agregowania odpowiedzi wielu klasyfikatorów jest reguła kombinacji Dempstera. Mimo wielu niepodważalnych zalet ma ona również pewne ograniczenia, a zasadność jej stosowania była dyskutowana przez wielu autorów [159, 36, 144, 129, 30]. Szczególnie niebezpieczne jest jej stosowanie, kiedy odpowiedzi klasyfikatorów cechują się znacznym poziomem sprzeczności [159]. Aby uniknąć tych zagrożeń, opracowano teorię będącą rozwinięciem, a także uogólnieniem klasycznej teorii Dempstera-Shafera. Uogólniona teoria funkcji przekonania opracowana przez J. Dezerta i F. Smarandache [30, 31] pozwala na zerwanie z obostrzeniem dotyczącym rozdzielności podzbiorów D^Θ , gdzie Θ jest ramą rozdzielającą zawierającą wyczerpujący zbiór stanów elementarnych, $\Theta = (\theta_1, \dots, \theta_n)$, a D^Θ (*hyper-power set*), stanowi zbiór podzbiorów utworzonych z elementów Θ , taki, że $\emptyset, \theta_1, \dots, \theta_n \in D^\Theta$ oraz jeśli podzbiory $A, B \in D^\Theta$, to $A \cup B \in D^\Theta$ oraz $A \cap B \in D^\Theta$ [31]. Dla każdego elementu ze zbioru D^Θ możliwe jest określenie funkcji $m : D^\Theta \rightarrow [0, 1]$ będącej podstawowym przyporządkowaniem przekonania, spełniającym następujące warunki: $m(\emptyset) = 0$, $\sum_{A \in D^\Theta} m(A) = 1$.

Aby w pełni wykorzystać nowe narzędzie teoretyczne, opracowano szereg reguł agregacji pozwalających na proporcjonalną redystrybucję konfliktów (*Proportional Conflict Redistribution*, PCR) pomiędzy odpowiedziami poszczególnych klasyfikatorów. Spośród tych reguł najbardziej zaawansowana jest reguła PCR6 [87], która dla M klasyfikatorów przy $A \in D^\Theta$, $A \neq \emptyset$ ma następującą postać:

$$m_{PCR6}(A) = m_c(A) + \sum_{\substack{\bigcap_{k=1}^{M-1} B_{\sigma_i(k)} \cap A = \emptyset \\ (B_{\sigma_i(1)}, \dots, B_{\sigma_i(M-1)}) \in (D^\ominus)^{M-1}}} \left(\frac{\prod_{j=1}^{M-1} m_{\sigma_i(j)}(B_{\sigma_i(j)})}{m_i(A) + \sum_{j=1}^{M-1} m_{\sigma_i(j)}(B_{\sigma_i(j)})} \right) \quad (2.19)$$

gdzie m_c jest regułą koniunktywną $\forall A \in D^\ominus$:

$$m_c(A) = \sum_{B_1 \cap \dots \cap B_M} \prod_{j=1}^M m_j(B_j) \quad (2.20)$$

Jeśli jest konflikt pomiędzy odpowiedziami klasyfikatorów, to reguła PCR6 zostaje zredukowana do reguły koniunktywnej.

Podejmowanie decyzji odbywa się w oparciu o maksymalną wartość funkcji przekonania, wyznaczaną dla poszczególnych elementów D^\ominus . Uogólniona funkcja przekonania Bel zdefiniowana jest następująco [32]:

$$Bel(A) = \sum_{B \in D^\ominus, B \subseteq A, B \neq \emptyset} m(B) \quad (2.21)$$

3. Termograficzne metody diagnozowania

Zastosowanie termografii w podczerwieni do diagnozowania stanu obiektów technicznych jest zagadnieniem obszernym i odnosi się do różnych obszarów szeroko rozumianej diagnostyki termicznej. Ocena stanu technicznego obiektów z zastosowaniem termografii w podczerwieni może być realizowana z wykorzystaniem metod należących do dwóch podstawowych grup [2]:

- Metody termografii pasywnej – wykorzystujące promieniowanie podczerwone generowane samoczynnie przez zjawiska cieplne powstające w sposób naturalny w trakcie eksploatacji obiektu.
- Metody termografii aktywnej – bazujące na obserwacji w podczerwieni reakcji badanego obiektu na kontrolowane lub niekontrolowane pobudzenie cieplne.

3.1. Metody termografii pasywnej

Metody termografii pasywnej dobrze wpasowują się w obszar diagnostyki technicznej ze względu na możliwość obserwacji emisji promieniowania podczerwonego generowanego przez zjawiska cieplne powstające na różnych etapach istnienia obiektu technicznego. Termografia pozwala realizować zadania diagnostyki emisyjnej na etapie konstruowania środka technicznego a szczególnie na etapie testów prototypów. W trakcie tego typu testów identyfikowane są niepożądane zjawiska cieplne. Na etapie wytwarzania termografia znajduje zastosowanie w diagnostyce kontrolnej pozwalającej weryfikować poprawność procesów technologicznych i montażu podzespołów wytworu. Najczęściej jednak pasywne metody termograficzne stosowane są w diagnostyce eksploatacyjnej obiektów technicznych, w której dzięki obrazowaniu promieniowania podczerwonego emitowanego przez eksploatowany obiekt możliwe jest identyfikowanie i ocenianie jego stanu technicznego. Podstawowym i najczęściej uwzględnianym temperaturowym symptomem diagnostycznym jest wartość temperatury zmierzona w wybranym punkcie/obszarze obiektu odniesiona do poziomu kontrolnego. Wartość temperatury może być traktowana w sposób bezwzględny i odniesiona do ustalonych w normach lub dokumentacji eksploatacyjnej wartości granicznych. Ze względu na liczne czynniki wpływające na dokładność wyznaczanej przez kamerę termograficzną temperatury, najczęściej uwzględnia się względne wartości temperatur wyznaczone jako różnice np. między obiektami o tych samych cechach konstrukcyjnych działające w tej samej maszynie (np. różnica temperatur opraw łożyskowych), różnica między temperaturą otoczenia a temperaturą badanego obiektu lub różnica wyznaczona na podstawie dwóch pomiarów w tym samym punkcie lub obszarze w różnych chwilach czasu eksploatacji. W takim przypadku symptomem jest względna zmiana wartości temperatury w czasie. Uwzględniając ogromną różnorodność obiektów technicznych i procesów, w których diagnozowaniu może być wykorzystana termografia w podczerwieni, oczywistym staje się fakt, że możliwe jest zdefiniowanie ogromnej liczby różnorodnych symptomów temperaturowych uzależnionych od własności i właściwości badanych obiektów.

Na podstawie symptomów temperaturowych możliwa jest identyfikacja różnych niesprawności mogących się pojawić w obiektach technicznych. Przykładem może być obserwacja temperatury korpusów łożysk maszyn wirnikowych. Względne zmiany wartości temperatur

pozwalają np. na wykrycie nieprawidłowości w rozkładzie obciążeń łożysk, a co za tym idzie pozwalają diagnozować główne niesprawności maszyn wirnikowych, jakimi są rozosiowanie i/lub niewyrównoważenie wałów. Badanie węzłów łożyskowych pozwala również identyfikować uszkodzenie łożysk.

Aktualnie stosowane sposoby diagnozowania obiektów technicznych z zastosowaniem termografii pasywnej można podzielić na trzy grupy:

- Jednorazowe inspekcje termograficzne.
- Cykliczne inspekcje termograficzne.
- Ciągłe monitorowanie.

3.1.1. Jednorazowe inspekcje termograficzne

Jednorazowe inspekcje termograficzne mają na celu lokalizację i/lub identyfikację wcześniej wykrytej niesprawności obiektu technicznego. Tego typu inspekcje stosowane są również w diagnostyce odbiorczej obiektów przed wprowadzeniem nowego obiektu do eksploatacji i diagnostyce kontrolnej, np. po wykonanym remoncie. Rezultatem inspekcji jest najczęściej raport z badań informujący o stanie obiektu. W raporcie zawarte są zarejestrowane obrazy termograficzne i wyniki ich analizy, na podstawie których przeprowadzono wnioskowanie diagnostyczne. Inspekcja prowadzona jest zwykle na zlecenie przez wyspecjalizowaną w tego typu badaniach firmę zatrudniającą do wykonania inspekcji doświadczonego i certyfikowanego diagnostę/operatora. Inspekcja najczęściej prowadzona jest według ogólnych zasad postępowania (por. 3.1.4) oraz z wykorzystaniem wiedzy nabytej operatora. Do wnioskowania diagnostycznego i sporządzenia raportu wykorzystywane są narzędzia do przetwarzania i analizy termogramów oferowane przez producentów kamer termograficznych lub narzędzia samodzielnie opracowane przez diagnostę. Wyniki jednorazowych inspekcji termograficznych bardzo często po wykorzystaniu ich do rozwiązania problemu związanego z badanym obiektem nie są udostępniane publicznie, a wiedza pozyskana w trakcie badań przez diagnostę nie jest rozpowszechniana na szerszą skalę. Hermetyzacja wiedzy diagnostycznej pozyskiwanej w trakcie cyklicznych inspekcji termograficznych ogranicza możliwości sformalizowania metodyki badań diagnostycznych odnoszących się do różnych klas obiektów technicznych i zweryfikowania ogólnych zasad sformułowanych w różnych poradnikach i podręcznikach dotyczących inspekcji z zastosowaniem termografii w podczerwieni.

3.1.2. Cykliczne inspekcje termograficzne

Cykliczne inspekcje termograficzne prowadzone są w celu detekcji uszkodzeń na wczesnym etapie ich rozwoju, a także na potrzeby ich lokalizacji i identyfikacji. Cykliczne inspekcje termograficzne są bardzo często wpisane w program eksploatacji obiektów bazujący na stanie technicznym w wielu dużych przedsiębiorstwach, w których zapewnienie bezawaryjnego działania maszyn i urządzeń jest kluczowe ze względu na czynniki ekonomiczne i społeczne. Można tutaj wymienić elektrownie i elektrociepłownie, zakłady chemiczne, rafinerie. W dużych koncernach istnieją bardzo efektywnie działające zespoły diagnostów termograficznych współpracujące ze sobą oraz wymieniające doświadczenia. Zespoły te również prezentują swoje dokonania na różnorodnych branżowych konferencjach i seminariach. Ten sposób postępowania pozwala rozwijać metodykę badawczą i propagować ważną dla środowiska diagnostycznego i termograficznego wiedzę. Należy zaznaczyć,

że cykliczne inspekcje termograficzne nie mogą stanowić substytutu dla innych metod eksploatacyjnej diagnostyki obiektów technicznych. Prowadzenie inspekcji termograficznych wpisane w politykę eksploatacji bazującej na stanie technicznym wymaga ustanowienia odpowiedniego programu badań. Program taki powinien uwzględniać:

- Częstotliwość prowadzenia inspekcji – dla systemów elektrycznych zaleca się coroczne inspekcje dotyczące obiektów działających w sieci w celu identyfikacji nieprawidłowości.
- Procedury bezpieczeństwa – inspekcje termograficzne obiektów elektrycznych czy mechanicznych wiążą się niejednokrotnie z koniecznością demontażu osłon ochronnych. Wszelkie niebezpieczeństwa z tym związane muszą zostać uwzględnione na etapie inspekcji, a także szkolenia personelu.
- Gromadzenia, udostępniania i przetwarzania wyników inspekcji – jest to istotny etap ze względu na możliwość opracowywania reguł diagnostycznych i wnioskowania diagnostycznego.
- Kryteriów oceny – wspólnych i wyszczególnianych w licznych normach i zaleceniach organizacji branżowych, a także dobieranych indywidualnie ze względu na specyfikę badanych obiektów i ich otoczenie. Przykłady kryteriów dotyczących urządzeń elektrycznych i maszyn wirnikowych zamieszczono poniżej.

Cykliczne inspekcje stosowane są powszechnie do detekcji nieprawidłowości różnych maszyn wirnikowych w tym ich podzespołów oraz wszelkiego rodzaju urządzeń elektro-energetycznych co pozwoliło różnym organizacjom i zespołom badawczo-pomiarowym w pewnym stopniu sformalizować metodykę inspekcji, przy czym w niektórych przypadkach istnieją różnice między ustalonymi wartościami granicznymi. Ogólnie rozpatruje się dwa podejścia do oceny stanu obiektów technicznych. Bazują one na ocenie jakościowej i ilościowej rozkładów temperatur na powierzchni badanego obiektu.

3.1.2.1. Metody diagnozowania urządzeń elektroenergetycznych

Obserwacje termograficzne systemów elektroenergetycznych są bardzo efektywnym sposobem wykrywania nieprawidłowości ich działania. Przepływ prądu przez obwody i urządzenia elektryczne, napotykając opór generuje energię cieplną. Dzięki temu możliwe jest wykrywanie wszelkich anomalii związanych z nierównomiernym obciążeniem, przerwami obwodów elektrycznych lub luźnymi połączeniami, co w energetyce stanowi około 25% wszystkich uszkodzeń. Podczas inspekcji urządzeń elektrycznych doświadczony diagnosta wraz z asystentem mogą ich przejrzeć od 50 do 100 w ciągu godziny [38]. Poza ogólnymi zasadami prowadzenia inspekcji termograficznych (por. 3.1.4) na potrzeby diagnostyki urządzeń elektrycznych opracowano różne kryteria stanu technicznego. Uwzględniają one pomiary różnicowe (względne) i bezwzględne wartości temperatur. Kryteria te zawarte są w różnych normach i opracowaniach własnych firm. Jednym z przykładów wykorzystujących pomiary różnicy temperatur może być standard opracowany wspólnie przez NETA i ANSI [8], w którym sformułowano wartości graniczne i zalecane działania podczas termograficznych inspekcji urządzeń elektrycznych (tab. 3.1).

Inny przykład kryteriów oceny stanu zawarto w podręczniku stosowanym w szkoleniach diagnostów termograficznych przez Infraspection Institute [57]. W opracowaniu zawarto wartości graniczne i zalecenia bazujące na wiedzy i doświadczeniu diagnostów termograficznych przydatne w inspekcji urządzeń elektrycznych i/lub mechanicznych (tab. 3.2).

Kolejnym przykładem wartości granicznych, którymi można się posłużyć przy ocenie urządzeń elektrycznych, jest specyfikacja firmy Allan–Bradley (tab. 3.3) [3].

Tab. 3.1. Wartości graniczne i zalecane działania podczas termograficznych inspekcji urządzeń elektrycznych według specyfikacji NETA (*InterNational Electrical Testing Association*) [8]

Ważność	Różnica temperatur ΔT , °C między podobnymi komponentami elektrycznymi działającymi przy podobnym obciążeniu		Wzrost temperatury ΔT , °C powyżej temperatury powietrza		Zalecane działania
	od	do	od	do	
4	1	3	1	10	Istnieje prawdopodobieństwo uszkodzenia; przeprowadzić badania
3	4	5	11	20	Prawdopodobne uszkodzenie; przeprowadzić naprawę przy najbliższej możliwej okazji
2	-	-	21	40	Monitorować do chwili zakończenia badań weryfikujących stan obiektu
1	>15		>40		poważne uszkodzenie; przeprowadzić natychmiastową naprawę

Tab. 3.2. Wartości graniczne i zalecane działania podczas termograficznych inspekcji urządzeń elektrycznych i/lub mechanicznych bazujące na wiedzy i doświadczeniu diagnostów termograficznych [57]

Ważność działań	Różnica temperatur ΔT , °C		Zalecane działania
	od	do	
4	1	10	Istnieje prawdopodobieństwo uszkodzenia; przeprowadzić badania
3	11	20	Prawdopodobne uszkodzenie; przeprowadzić naprawę przy najbliższej możliwej okazji
2	21	40	Monitorować do chwili zakończenia badań weryfikujących stan obiektu
1	> 40		Poważne uszkodzenie; przeprowadzić natychmiastową naprawę

Kolejny przykład pochodzi z firmy DUNAFERR Steelworks [106], która opracowała własny, kompleksowy system diagnostyki maszyn i urządzeń wykorzystywanych przy produkcji stali i jej przetworów. Jednym z elementów systemu są cykliczne tygodniowe inspekcje termograficzne urządzeń mechanicznych i elektrycznych, podczas których mierzona jest temperatura z zastosowaniem kamer termograficznych. Ocena stanu urządzeń elektroenergetycznych i mechanicznych dokonywana jest na podstawie trendów zmian mierzonych wartości temperatur i kryteriów bazujących na wartościach granicznych zaprezentowanych

Tab. 3.3. Wartości graniczne i zalecane działania podczas termograficznych inspekcji silników elektrycznych według specyfikacji firmy Allen-Bradley [3]

Różnica temperatur (1), °C		Wzrost temperatury (2), °C		Naprawa/Przegląd; Okres między przeglądami	Działanie
od	do	od	do		
<	10	<	70	Nie jest wymagany przegląd/naprawa	A
10	25	70	100	Przegląd/Naprawa przy najbliższej okazji (Nie później niż 6 miesięcy) Prowadzić profilaktycznie ciągły monitoring	B
25	50	100	115	Przegląd/Naprawa w ciągu dwóch tygodni; monitoring do następnego przeglądu/naprawy	B
>50		>115		Wyłączenie i naprawa. Zweryfikować czy temperatura spadła po załączeniu	B

(1) Różnica temperatur pomiędzy elementami dla sąsiednich faz. Odchylenie standardowe obciążenia między fazami nie może przekraczać 7 %.

(2) Zmierzona temperatura pomniejszona o wartość temperatury otoczenia. Z powodu trudności w pomiarach temperatury powierzchni o małej emisyjności zaleca się stosować pomiary różnicowe

A – oznacza inspekcję obiektu pod kątem oznak przegrzania. Jeśli nie ma śladów przegrzania i badanie termograficzne wskazuje, że przegląd jest niepotrzebny, należy uznać stan obiektu za akceptowalny.

B – oznacza inspekcję obiektu pod kątem oznak przegrzania. Jeśli nie ma śladów przegrzania i badanie termograficzne wskazuje, że przegląd jest potrzebny, należy dokręcić i sprawdzić moment dokręcenia różnych połączeń elektrycznych.

odpowiednio w tabelach 3.4 i 3.7. Do oceny urządzeń elektrycznych wykorzystywane są względne różnice temperatur.

Tab. 3.4. Temperaturowe kryteria oceny urządzeń elektrycznych wg firmy Dunafer Steelworks [106]

Kategoria uszkodzenia	Różnica temperatur, °C		Klasa stanu	Sugerowane działanie
	od	do		
1		<1	Dobry	Eksploatować
2	1	5	Satysfakcjonujący	Kontrolować stan części
3	5	35	Niesatysfakcjonujący	Naprawić jak tylko to będzie możliwe
4		>35	Nieakceptowalny	Wyłączyć i/lub natychmiast naprawić

W krajach Europy Zachodniej wykorzystuje się wytyczne opracowane przez Duński Instytut Technologiczny [109]. W Polsce stworzono m.in. kryteria [119] stosowane na potrzeby diagnozowania obiektów technicznych w energetyce, które pozwalają oceniać stan techniczny na podstawie 3 kategorii stanów awaryjnych: Pierwsza kategoria (kat. C) to te stany, w których przyrost temperatury (mierzony względem średniej temperatury badanego pola) jest mniejszy od 5°C; zaleca się naprawę podczas najbliższego przeglądu. Drugi stan (kat. B) dotyczy przedziału temperatur od 5°C do 35°C; zaleca się szybką naprawę z uwzględnieniem możliwości dokonania stosownych wyłączeń. W przypadku przyrostów temperatury większych

niż 35°C (kat. A) zalecana jest niezwłoczna naprawa [119]. Przyjmowane są również przedziały do 10°C, 10 – 30°C i powyżej 30°C. Zakłada się, że badania muszą być prowadzone przy obciążeniu większym od 30% obciążenia znamionowego [119].

Innym przykładem diagnozowania z zastosowaniem termografii w podczerwieni może być opracowana w ZBE „Energopomiar” metoda oceny i klasyfikacji wad połączeń prądowych rozdzielnic energetycznych [82, 135]. Bazuje ona na obserwacji przyrostu temperatury zacisku ponad temperaturę przyłączonych przewodów z uwzględnieniem warunków pomiarowych takich jak temperatura otoczenia, prędkość wiatru czy wartość obciążenia. Zakłada się, że prędkość wiatru nie może przekraczać 4 m/s, a prąd obciążenia nie powinien być mniejszy od 30% prądu znamionowego dla danego pola rozdzielnic lub linii przesyłowej. Szczegółowe kryteria zestawiono w tabeli 3.5.

Tab. 3.5. Kryteria oceny stanu zacisków prądowych [82]

Parametry	Zmierzony przyrost temperatury, °C			
	Prędkość wiatru < 2 m/s	3 – 10	11 – 30	31 – 50
Prędkość wiatru > 2 m/s	3 – 10	11 – 20	21 – 35	> 35
	Ocena stanu zacisku			
Prąd obciążenia 30 – 60% I_n	dostateczny	zły	bardzo zły	bardzo zły
Prąd obciążenia > 60% I_n	dostateczny	zły	zły	bardzo zły

Istnieją liczne normy i kryteria określające nominalne (znamionowe) wartości temperatur dla różnorodnych urządzeń elektrycznych. Zwykle normy podają trzy podstawowe wartości: nominalną temperaturę otoczenia dla działania urządzenia, dopuszczalny wzrost temperatury i maksymalną dopuszczalną temperaturę, która jest sumą temperatur otoczenia i dopuszczalnego przyrostu. Wartości te odnoszą się do urządzeń działających przy pełnym znamionowym obciążeniu i określonej temperaturze otoczenia. Nie zawsze jednak podczas inspekcji termograficznych urządzenia działają przy 100% obciążenia znamionowego. Aby uwzględnić niższe wartości obciążenia przy określaniu maksymalnej dopuszczalnej temperatury można skorzystać z następującej formuły [56]:

$$T_{max_{corr}} = \left(\frac{I_m}{I_z} \right)^2 T_{zw} + T_{om} \quad (3.1)$$

gdzie:

$T_{max_{corr}}$ – przeliczona maksymalna dopuszczalna temperatura,

I_m – zmierzona wartość prądu obciążenia, A,

I_z – znamionowa wartość prądu obciążenia, A,

T_{zw} – nominalny wzrost temperatury wg zaleceń (norm),

T_{om} – zmierzona temperatura otoczenia.

3.1.2.2. Metody diagnozowania urządzeń mechanicznych

Podobnie jak w przypadku urządzeń elektroenergetycznych również urządzenia mechaniczne i mechaniczno-elektryczne poddawane są cyklicznym inspekcjom termograficznym. Badane są urządzenia, w których uszkodzenia lub nieprawidłowości w eksploatacji mogą objawiać się wzrostem temperatur. Można wymienić tutaj silniki elektryczne, sprzęgła, pompy, przekładnie zębate, sprężarki, węzły łożyskowe itp. Przy ocenie stanu urządzeń mechanicznych podobnie jak w przypadku urządzeń elektrycznych można posługiwać się kryteriami bazującymi na wartościach różnicy temperatur zmierzonej i temperatury odniesienia. W tabeli 3.2 zamieszczono przykład wartości granicznych i wymaganych działań. W przypadku dużej liczby maszyn i urządzeń mechanicznych należących do tej samej klasy i działających w podobnych warunkach zalecane jest określenie granic stanów na podstawie analiz statystycznych wielu pomiarów w różnych chwilach eksploatacji. Ten sposób postępowania uzasadnia konieczność gromadzenia i udostępniania wyników pomiarów prowadzonych przy okazji inspekcji termograficznych w celu sprecyzowania kryteriów klasyfikacji stanu technicznego różnych obiektów mechanicznych. Ocena stanu systemów mechanicznych na podstawie pomiarów termograficznych możliwa jest również na podstawie kryteriów bazujących na bezwzględnych wartościach temperatur publikowanych w różnych normach i dokumentacjach techniczno-ruchowych odnoszących się do maszyn jak i ich podzespołów. Zaleca się, aby podczas badania określonego obszaru obiektu mechanicznego, w którym istnieje kilka sąsiadujących elementów (np. łożysko, uszczelnienie, smar), przy ocenie stanu brać pod uwagę element o najniższej temperaturze. W wielu specyfikacjach środki smarne mają niższe dopuszczalne temperatury pracy niż np. łożyska. W przypadku gdy nie jest możliwe znalezienie dopuszczalnej wartości temperatury dla konkretnego podzespołu, przyjmuje się najniższą znaną dopuszczalną temperaturę dla dowolnego podzespołu tej samej klasy. Większość maksymalnych dopuszczalnych wartości temperatur podawanych w normach i dokumentacjach maszyn wyznaczona jest dla pełnego obciążenia znamionowego maszyny. Przykładowe maksymalne dopuszczalne wartości temperatur dla różnych podzespołów stosowanych w urządzeniach mechanicznych zebrano w tabeli 3.6. Bezwzględne wartości temperatur dla systemów mechanicznych mogą być również określone w sposób ogólny na podstawie wyników analizy statystycznej pomiarów historycznych. W tabeli 3.7 zaprezentowano zakresy wartości granicznych stosowanych przy ocenie maszyn w firmie Dunafer Steelworks. Przykładem metody rozszerzającej sposób termograficznej oceny stanu urządzeń elektrycznych przedstawiony w różnych normach jest uwzględnienie wielu czynników mających wpływ na jakość detekcji a uwzględnionych w macierzy ocen ważonych (tab. 3.8) [130]. Macierz buduje się, uwzględniając specyficzne dla prowadzonej inspekcji wymagania i kryteria. W macierzy dokonuje się oceny zgodności danego kryterium, dla którego przypisana jest w sposób arbitralny waga mówiąca o jego ważności i wpływie prawidłowości oceny stanu badanego urządzenia. Na podstawie wszystkich ocen wyznaczana jest ocena ważona.

Tab. 3.6. Przykładowe wartości temperatur dopuszczalnych dla różnych podzespołów systemów mechanicznych (wg [58])

Podzespół	Temperatura dopuszczalna, °C
Pierścienie łożysk tocznych	125
Koszyk łożyskowy (metalowy)	300
Koszyk łożyskowy (plastikowy)	120
Stalowa osłona łożyska	300
Kauczukowy pierścień uszczelniający	100
Silikonowy pierścień uszczelniający	180
Pierścień uszczelniający wykonany z PTFE	180
Elementy łożysk ślizgowych wykonane ze stopów cyny lub ołowiu	149
Elementy łożysk ślizgowych wykonane z kadmu lub brązu cynowego	260
Elementy łożysk ślizgowych wykonane z aluminium	121
Oleje maszynowe lub hydrauliczne	120
Smar litowy	110
Uszczelki gumowe	107
Uszczelki poliuretanowe	93
Uszczelki silikonowe	232

Tab. 3.7. Temperaturowe kryteria oceny urządzeń mechanicznych wg firmy Dunaferr Steelworks [106]

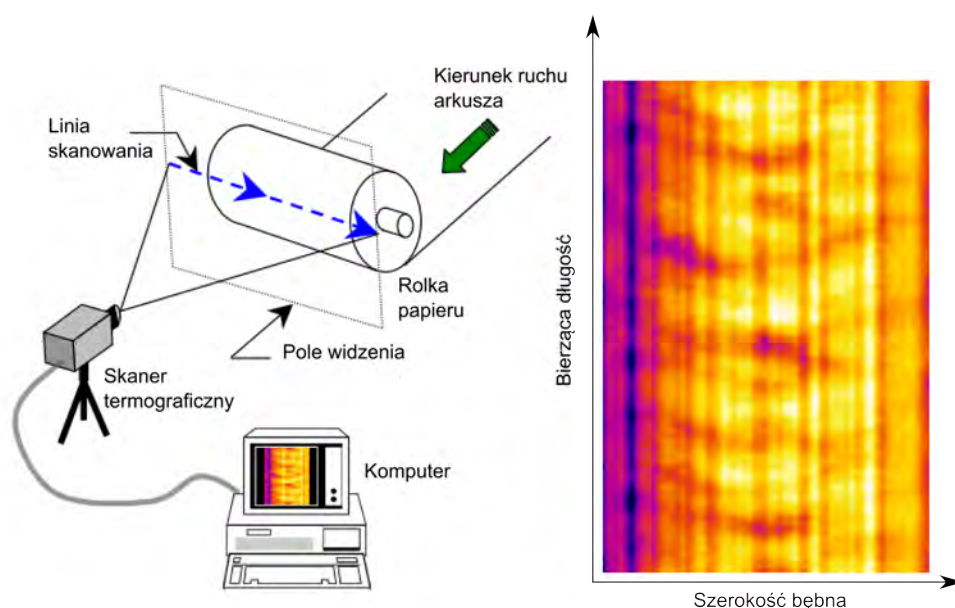
Kategoria uszkodzenia	Różnica temperatur, °C		Klasa stanu	Sugerowane działanie
	od	do		
1	0	40	Dobry	Ekspluatować
2	40	50	Satysfakcjonujący	Kontrolować stan części
3	50	65	Niesatysfakcjonujący	Naprawić jak tylko to będzie możliwe
4	>65		Nieakceptowalny	Wyłączyć i/lub natychmiast naprawić

Tab. 3.8. Przykład macierzy ocen ważonych stosowanej w ocenie urządzeń elektrycznych metodami termograficznymi (wg [130])

Kryterium	Ocena cząstkowa					Waga	Ocena końcowa
	2	4	6	8	10		
Czy badany obiekt jest krytyczny?		✓			**	2.5	10
Czy wymagany jest wysoki poziom bezpieczeństwa?			✓		**	3.0	18
Czy emisyjność jest niska?		✓				1.5	6
Czy parametr kamery IFOV jest zgodny z wymaganiami?			✓			1.0	6
Czy obciążenie wzrosło?		✓				2.0	8
Czy temperatura otoczenia wzrosła?				✓		1.5	12
Czy poziom konwekcyjnej wymiany ciepła jest wysoki (wiatr, przeciągi)?		✓				2.0	8
Czy historia eksploatacji wskazuje na wcześniejsze problemy?		✓				2.5	10
Czy źródło ciepła jest osłonięte?	✓					1.5	3
Czy trend temperatury ma tendencję wzrostową?			✓			2.5	15
Ocena całkowita							96
Działania zależne od oceny całkowitej: >180 – natychmiast zatrzymać i naprawić 120–179 – zaplanować naprawę 75–119 – naprawić przy najbliższej okazji <75 – monitorować					** – naprawić natychmiast bez względu na ocenę całkowitą		

3.1.3. Ciągła obserwacja w podczerwieni

Termografia w podczerwieni znajduje coraz częściej zastosowanie w ciągłej obserwacji obiektów i procesów. Stało się to możliwe dzięki coraz szerszemu rozprzestrzenieniu się przystępnych cenowo przemysłowych wersji urządzeń do obrazowania podczerwieni. Ciągła obserwacja podczerwieni stosowana jest głównie w kontroli procesów przemysłowych, obejmując swoim zakresem zarówno monitorowanie parametrów procesowych, sterowanie procesem produkcji, jak i kontrolę jakości wyrobów. Ciągła obserwacja wykorzystywana jest m.in. w kontroli i sterowaniu procesem produkcji wyrobów stalowych (np. na linii walcowania na gorąco [84]) i szkła [70], kontroli jakości elementów w przemyśle motoryzacyjnym [114] produkcji laminowanych płyt wiórowych [89], w kontroli jakości powłok lakierniczych [104], kontroli sterowaniu i diagnostyce procesów spawania czy też w kontroli jakości podzespołów i układów elektronicznych [70]. W porównaniu z diagnostyką procesów, zastosowanie ciągłej obserwacji w podczerwieni do diagnostyki maszyn i urządzeń mechanicznych jest mniej rozpowszechnione i w większości przypadków stosowane na etapie badań eksperymentalnych. Przykładem, gdzie ciągle monitorowanie urządzeń mechanicznych znalazło zastosowanie jest np. przemysł papierniczy [21], gdzie kamera z matrycą liniową pozwoliła diagnozować maszyny papiernicze oraz proces produkcji papieru. Innym ciekawym przykładem jest zastosowanie urządzenia obrazującego w podczerwieni o małej rozdzielczości do diagnozowania stanu wybranych podzespołów maszyn sortującej listy [26]. Analizując



Rys. 3.1. Istota ciągłego monitorowania procesu z zastosowaniem kamery termograficznej z matrycą liniową [21]

aktualnie stosowane rozwiązania w ciągłej diagnostyce procesów przemysłowych i obiektów technicznych, można zauważyć, że w zależności od charakteru i własności procesu stosowane są pojedyncze detektory podczerwieni, kamery z detektorami liniowymi oraz matrycowe urządzenia obrazowania w podczerwieni. W większości przypadków urządzenia są montowane w jednym nieruchomym punkcie, chociaż zdarzają się zastosowania, w których kamery są ruchome [70]. Można wyróżnić trzy sposoby realizacji diagnostyki procesów przemysłowych:

monitorowanie procesu – w trakcie monitorowania generowane są sygnały diagnostyczne informujące o prawidłowym lub nieprawidłowym przebiegu procesu. Na podstawie sygnałów diagnostycznych obsługa podejmuje decyzję o zatrzymaniu i korekcji parametrów procesu. To rozwiązanie jest najczęściej stosowane w praktyce przemysłowej;

monitorowanie ze sterowaniem w pętli otwartej – to podejście poza zadaniami monitorowania, pozwala wypracować informacje pozwalające obsłudze korygować na bieżąco parametry procesu bez konieczności jego zatrzymania;

monitorowanie ze sterowaniem w pętli zamkniętej – jest to rozwiązanie, w którym parametry procesu korygowane są w sposób ciągły przez automatyczny programowalny układ sterowania wykorzystujący informacje z układu monitorowania bazującego na urządzeniu obrazującym w podczerwieni. Ten etap jest zadaniem trudnym w realizacji i najrzadziej stosowanym w praktyce.

W przypadkach gdzie przebieg procesu przemysłowego polega na przemieszczaniu produktów ze stałą prędkością, celowo stosuje się kamery liniowe. Mają one większą prędkość działania i pozwalają formować charakterystyczne obrazy podczerwieni, w których jeden z wymiarów obrazu jest funkcją parametru procesowego, np. przemieszczenia produktu w polu widzenia kamery liniowej (rys. 3.1) [21].

Obrazy uformowane w wyniku obserwacji za pomocą kamery liniowej poruszającego się ze stałą prędkością obiektu mają dobrą jakość i nie wymagają stosowania takich operacji wstępnego przetwarzania jak np. wybór obszaru zainteresowania. Detekcja nieprawidłowości procesu może odbywać się na bieżąco w trybie automatycznym lub przez operatora,

który obserwując podgląd uformowanego obrazu może w prosty sposób zlokalizować nieprawidłowość i podjąć decyzję o dalszym sposobie realizacji procesu i/lub akcje korygujące. Automatyczna detekcja nieprawidłowości wymaga zastosowania odpowiedniej procedury analizy linii.

W przypadku gdy do diagnozowania obiektów lub procesów wykorzystuje się dwuwymiarowe obrazy pochodzące z urządzeń obrazowania podczerwieni posiadające detektory matrycowe, zwykle stosowana jest metoda detekcji uszkodzeń stosująca informację różnicową wynikającą ze stosowania obrazów wzorcowych. Metoda ta również może być zastosowana wobec danych pozyskiwanych ze skanerów liniowych. W [70] przedstawiono metodę kontroli procesu przemysłowego bazującą na następujących krokach:

Utworzenie obrazu kryterialnego – dla procesu wzorcowego rejestrowana jest sekwencja obrazów, na podstawie której tworzony jest obraz kryterialny (ang. *criterion image*). Obraz taki zwykle tworzony jest przez uśrednianie wartości pikseli obrazów zarejestrowanej sekwencji. Obraz jest zapisywany w pamięci.

Utworzenie macierzy tolerancji – dla każdego z pikseli lub wskazanych obszarów obrazu kryterialnego określana jest tolerancja dopuszczalnych zmian wartości pikseli lub innych parametrów np. statystycznych. W zakresie tych parametrów proces można uznać za prawidłowy. Wartości zapisywane są w macierzach tolerancji.

Monitorowanie procesu – operacja polegająca na porównywaniu na bieżąco rejestrowanych obrazów z obrazem kryterialnym. Porównywanie obrazu może być realizowane przez odejmowanie wartości pikseli lub analizę statystyczną. Odejmowanie pikseli może być prowadzone, gdy możliwe jest sterownie procesem dopasowania obrazu i kontroli dryftu temperaturowego.

Sterowanie procesem – zadanie polegające na wypracowaniu sygnałów sterowania i modyfikacji zmiennych procesowych w celu uzyskania akceptowalnych wyników porównania obrazu kryterialnego z aktualnie pozyskiwanymi obrazami procesowymi.

W zakresie ciągłej diagnostyki maszyn i urządzeń mechanicznych opracowano kilka metod bazujących na analizie sekwencji obrazów termograficznych rejestrowanych w trakcie ciągłej obserwacji obiektów. W [78, 111, 112] przedstawiono metodykę badań diagnostycznych obrabiarek, która może znaleźć zastosowanie w systemach monitorowania i diagnostyki działających w sposób ciągły. W ramach opisywanych badań opracowano stanowisko do diagnostyki termograficznej maszyn, które pozwala na podstawie obrazów termograficznych analizować stany cieplne maszyn i ich podzespołów oraz ustalać związki między stanami badanej maszyny a jej obrazami termalnymi. W opracowaniach [148, 157, 158] przedstawiono metodę diagnostyki maszyn wirnikowych bazującą na klasycznym podejściu znanym m.in. z wibroakustycznej diagnostyki maszyn. Metodyka polega na tym, że każdy obraz rejestrowany w trakcie ciągłej obserwacji maszyny podlega ocenie, w trakcie której wyznaczany jest zbiór cech. Zbiór wyznaczonych cech obrazów termograficznych poddawany jest ekstrakcji i/lub selekcji, a następnie poprzez zastosowanie klasyfikatora stanu dokonywana jest ocena stanu technicznego.

Zaprezentowane metody znalazły potwierdzenie swojej skuteczności w wynikach badań laboratoryjnych. Niestety autorowi nie są znane podobne metody, które znalazły bezpośrednie zastosowanie w warunkach przemysłowych i pozwoliły w sposób ciągły diagnozować stan maszyn. Główną przeszkodą szerokiego stosowania opisywanych podejść są koszty wdrożenia i obsługi. Aktualnie najbardziej opłacalnym sposobem diagnozowania obiektów technicznych z zastosowaniem termografii w podczerwieni są cykliczne inspekcje termograficzne.

3.1.4. Ogólne zasady prowadzenia inspekcji termograficznych

Przeprowadzanie jakościowych i ilościowych inspekcji termograficznych wiąże się z koniecznością zachowania kilku podstawowych zasad. Zasady te są zarówno istotne, gdy celem inspekcji termograficznej są ilościowe pomiary wartości temperatur, jak również gdy obiekt będzie obserwowany w sposób ciągły a przy ocenie jego stanu będą brane pod uwagę względne zmiany temperatur w czasie i przestrzeni. Prawidłowe przeprowadzenie inspekcji termograficznej wymaga od operatora znajomości konstrukcji obiektu, zastosowanych materiałów i ich parametrów fizykochemicznych. Istotną rolę odgrywają warunki środowiskowe, otoczenie obiektu oraz warunki eksploatacyjne. Prawidłowe wyznaczenie rozkładu wartości temperatury wymaga oszacowania lub wyznaczenia współczynnika emisyjności obiektu, pomiaru temperatury otoczenia oraz innych czynników środowiskowych, których wartości wprowadzane są do kamery termowizyjnej przed wykonaniem pomiarów. Warunki eksploatacyjne dotyczą przede wszystkim stabilności głównych parametrów pracy obiektu, gdyż wpływa to na stabilność rozkładu temperatury powierzchni. O rozkładzie temperatur decydują również wszelkie urządzenia pomocnicze współpracujące oraz otaczające badany obiekt. Mogą one mieć wpływ konwekcyjny lub promienisty na obiekt badań [82, 91].

Aby przystąpić do pomiarów kamerą termowizyjną, należy się najpierw upewnić, czy:

- możliwe jest pozyskanie dokumentacji techniczno-ruchowej lub informacji o obiekcie od osoby znającej obiekt, jego historię, uwarunkowania techniczne, regulacyjne, eksploatacyjne;
- możliwe jest zapewnienie podczas inspekcji asysty specjalisty znającego budowę i specyfikę działania obiektu oraz jego obsługę;
- konieczny będzie demontaż osłon lub barier ochronnych w celu zapewnienia dostępu do obiektu;
- mogą występować zagrożenia życia lub zdrowia dla badacza w trakcie prowadzenia inspekcji, jeśli tak to czy można je zminimalizować lub całkowicie wyeliminować;
- obiekt będzie gotowy do przeprowadzenia badania we właściwym czasie i miejscu;
- obiekt będzie widoczny dla urządzenia obrazującego pod odpowiednim kątem i z odpowiedniej odległości;
- obiekt pracuje przy odpowiednim obciążeniu roboczym;
- możliwe jest oszacowanie emisyjności powierzchni obiektu lub przygotowanie odpowiednich powierzchni kalibracyjnych.

Wykonywanie badań termograficznych powinno być zgodne z następującymi zasadami [58, 82]:

- wykonawcą badań powinien być pracownik o odpowiednim przygotowaniu ogólnym, odpowiednim przeszkoleniu (najlepiej posiadający certyfikat poświadczający jego umiejętności prawidłowego prowadzenia badań termograficznych) i doświadczeniu oraz wiedzy o obiekcie;
- badanie powinno odbyć się za pomocą sprawnego i skalibrowanego sprzętu;
- obiekt badań powinien być odpowiednio przygotowany i obciążony (najkorzystniejsze jest działanie obiektu przy obciążeniu nominalnym);
- badania powinny odbywać się wyłącznie w odpowiednich warunkach środowiskowych (tzn. nie powinny być wykonywane podczas ekstremalnych zjawisk meteorologicznych);
- wykonawca badań powinien natychmiast reagować na stwierdzone znaczne anomalie w rozkładzie i wartości temperatury, powiadamiając o tym użytkownika obiektu;
- wszystkie obrazy termograficzne należy rejestrować w pamięci urządzenia obrazującego;

- wraz z obrazami termograficznymi należy rejestrować również obrazy wizyjne obiektu;
- w trakcie inspekcji należy prowadzić notatki (pisemne lub głosowe) dotyczące warunków pracy obiektu, jego otoczenia oraz wszelkich czynników mogących wpływać niekorzystnie na rejestrowane obrazy podczerwieni;
- w przypadku dużych obiektów lub sytuacji niejednoznacznych należy wykonać kilka obrazów tego samego obszaru z różnych pozycji.

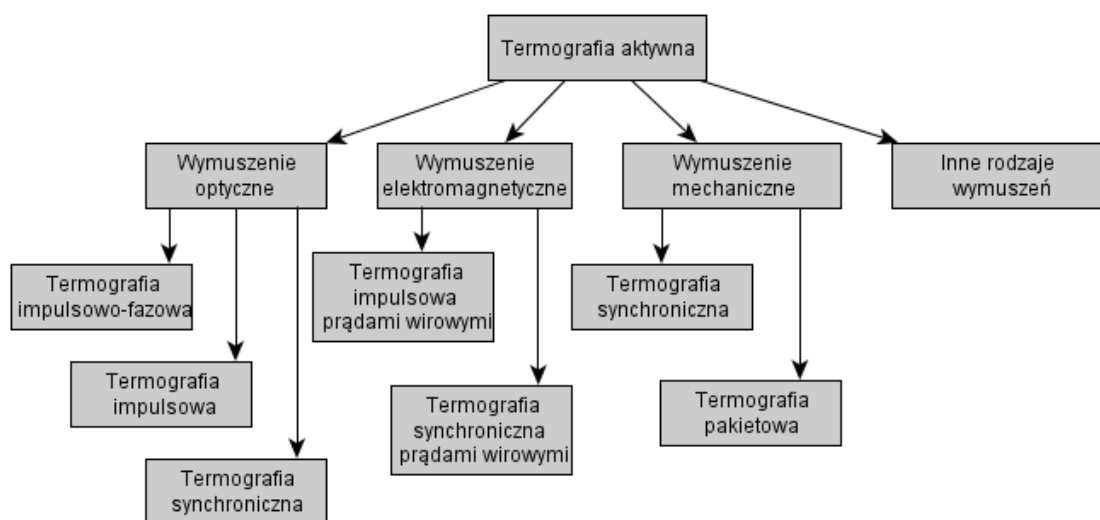
Uzyskane wyniki z pomiarów przedstawia się w postaci sprawozdań, które powinny zawierać [58]:

- dane i uprawnienia osoby prowadzącej inspekcję;
- dane zleceniodawcy;
- dane osoby asystującej w trakcie inspekcji;
- dane techniczne stosowanych urządzeń do obrazowania i pomiarów w podczerwieni oraz wyposażenia dodatkowego;
- czas badania (data, pora dnia);
- charakterystykę miejsc rejestracji termogramów;
- charakterystykę warunków meteorologicznych mogących mieć wpływ na wartość i rozkład temperatury (odległość od obiektu, temperatura otoczenia itp.);
- wykaz obiektów i/lub elementów poddanych inspekcji oraz obiektów niezbadanych wraz z podaniem przyczyn niewykonania inspekcji (np. zasłonięcie obiektu, wyłączenie z eksploatacji itp.);
- dane o warunkach pracy obiektu, obciążeniu (jeśli warunki pracy obiektu nie były stabilne, wówczas przebieg obciążenia w ostatnim czasie);
- obrazy termograficzne badanych obiektów ze wskazaniem anomalii i dokładnej ich lokalizacji (w przypadku obrazów jakościowych), a także podaniu wartości zmierzonych temperatur (w przypadku obrazów ilościowych);
- obrazy wizyjne z zaznaczonymi i scharakteryzowanymi miejscami, w których wystąpiły anomalie;
- charakterystyka warunków pracy i przyczyn mogących powodować wystąpienie anomalii;
- subiektywną lub obiektywną ocenę stanu technicznego obiektu.

3.2. Metody termografii aktywnej

Metody termografii aktywnej stanowią jedną z dziedzin szeroko rozumianych metod nieniszczących stosowanych głównie w celu detekcji i identyfikacji uszkodzeń strukturalnych. Metody termografii aktywnej znajdują szerokie zastosowanie w badaniach struktur kompozytowych. Idea termografii aktywnej znajduje również zastosowanie w ciągłej diagnostyce procesów przemysłowych, a głównie w kontroli jakości wyrobów kompozytowych. Istotą termografii aktywnej jest stymulacja cieplna badanego obiektu i termograficzna obserwacja odpowiedzi obiektu na zadaną stymulację. Odpowiedzią obiektu na wymuszenie cieplne są lokalne zmiany w rozkładzie temperatur wywołane różnicami w propagacji fali cieplnej napotykającej niejednorodności w strukturze wewnętrznej badanego obiektu. Wszelkie niejednorodności strukturalne, np. pęknięcia, delaminacje, pęcherze itp. charakteryzują się odmiennymi warunkami dyfuzji ciepła, co można łatwo wykryć, stosując jedną z metod termografii aktywnej. Metody termografii aktywnej można podzielić ze względu sposób stymulacji cieplnej obiektu na:

- metody optyczne – najczęściej stosowane; wykorzystują one zewnętrzne źródła wymuszenia cieplnego w postaci lamp (halogenowych, błyskowych), promienników podczerwieni, laserów itp.;
- metody elektromagnetyczne – bazujące na wymuszeniach wewnętrznych wywoływanych przez prądy wirowe;
- metody mechaniczne – w których struktura pobudzana jest falą ultradźwiękową o częstotliwości 0–25 kHz. Pobudzenie obiektu wibracjami powoduje w miejscach istnienia wad tarcia i zamiany energii mechanicznej na energię cieplną, co pozwala zidentyfikować uszkodzenie w bardzo precyzyjny sposób [84, 110];
- inne metody – w których do wymuszenia cieplnego stosowany jest strumień cieczy, powietrza lub inne medium.



Rys. 3.2. Podział metod termografii aktywnej ze względu na rodzaj wymuszenia cieplnego (opracowanie własne na podstawie [84, 110])

Metody aktywnej termografii dynamicznej można podzielić również ze względu na sposób umiejscowienia źródła stymulacji względem urządzenia obrazującego w podczerwieni. Rozróżnia się metodę transmisyjną zwaną również projekcją tylną, w której źródło stymulacji cieplnej oraz urządzenie do rejestracji temperatury znajdują się po przeciwnych stronach badanego obiektu i metodę refleksyjną, czyli inaczej projekcję przednią, polegającą na umieszczeniu źródła stymulacji cieplnej i urządzenia do rejestracji temperatury po tej samej stronie badanego obiektu.

Bez względu na metodę stymulacji cieplnej badania termografii aktywnej wymagają odpowiedniego ukształtowania sygnału pobudzenia cieplnego. W praktyce badawczej najczęściej stosowane jest pobudzenie impulsowe i modulacyjne, stąd termografia dynamiczna dzieli się na termografię impulsową (ang. *pulsed thermography*) i termografię synchroniczną (modulacyjną) (ang. *Lock-in thermography*). Inne znane metody termografii dynamicznej są kombinacjami wyżej wymienionych jak np. termografia impulsowo-fazowa (ang. *pulsed-phase thermography*).

3.2.1. Termografia impulsowa

Termografia impulsowa jest aktywną techniką badań nieniszczących, polegającą na wyznaczeniu i analizie rozkładu temperatury na badanej powierzchni w czasie jej stygnięcia po uprzednim pobudzeniu impulsem cieplnym o określonym czasie trwania. Wymuszenie może stanowić również seria impulsów. Impuls wymuszenia cieplnego może trwać kilka milisekund dla materiałów o wysokiej przewodności cieplnej (np. metale) lub kilku sekund w przypadku materiałów o niskiej przewodności cieplnej. W czasie trwania impulsu cieplnego temperatura badanej powierzchni rośnie, zaś po wygaśnięciu zaczyna spadać z powodu dyfuzji ciepła w głąb materiału. Obecność defektu zmienia szybkość dyfuzji. Głównymi celem badania jest wykrycie w obiekcie różnego rodzaju defektów, tj.: wtrącenia, pęknięcia, ubytki materiału, jamy itp.

Termografia impulsowa może być realizowana zarówno metodą transmisyjną, jak i refleksyjną. W czasie pomiaru rejestrowana jest sekwencja obrazów termograficznych, na podstawie której wyznaczane są charakterystyki fazy stygnięcia lub fazy nagrzewania i stygnięcia dla różnych obszarów badanego obiektu. Defekt strukturalny lokalizowany jest dzięki istnieniu różnych wartości stałych czasowych nagrzewania (chłodzenia) dla materiału rodzimego i defektu [91].

Na potrzeby identyfikacji defektów na zarejestrowanych obrazach często stosowane są dodatkowe procedury przetwarzania obrazów polegające na wyznaczeniu parametrów wiążących wartości temperatury w miejscu defektu i w miejscu wolnym od defektu. Parametrami tymi są m.in. [84, 101]:

- współczynnik kontrastu cieplnego (WKC);
- znormalizowany różnicowy współczynnik termografii impulsowej (ZRWTI);
- odwrotny znormalizowany różnicowy współczynnik termografii impulsowej (OZRWTI).

Głównym ograniczeniem termografii impulsowej jest trudność w określeniu rozmiaru i głębokości defektu. Pozwala ona wykrywać jedynie wady przypowierzchniowe. Kolejnym ograniczeniem jest konieczność zapewnienia jednorodnej emisyjności badanej powierzchni.

3.2.2. Termografia impulsowo-fazowa

Metoda impulsowo-fazowa jest modyfikacją termografii impulsowej. Stosuje się identyczne warunki przeprowadzenia pomiarów. Różnica występuje podczas obróbki zarejestrowanej sekwencji termogramów, na potrzeby której stosuje się szybką transformatę Fouriera przebiegów cieplnych w każdym z punktów zarejestrowanego obrazu. Metoda ta bazuje na własnościach impulsu cieplnego, który w dziedzinie częstotliwości składa się z szeregu harmonicznym fal cieplnych. Odpowiedni dobór długości impulsu pozwala sterować głębokością, na jakiej fali cieplne będą penetrować materiał. Częstotliwościowa analiza odpowiedzi obiektu na wymuszenie cieplne z zastosowaniem szybkiej transformaty Fouriera pozwala na wyznaczenie szeregu nowych obrazów parametrycznych przedstawiających wartości modułu i fazy dla różnych częstotliwości harmonicznym. Obrazy modułu nazywane są amplitudogramami, a obrazy fazy – fazogramami (obrazy fazowe). W metodzie tej szczególnie przydane przy wykrywaniu defektu są obrazy fazowe ze względu na fakt, że faza fali o danej częstotliwości w obszarze powierzchni, pod którym znajduje się wada, będzie różna od fazy fali w obszarze, pod którym wady nie ma. Zatem, sporządzając obraz przedstawiający różnicę między fazą fali cieplnej, o danej częstotliwości, w kolejnych punktach powierzchni a fazą fali w punkcie powierzchni materiału wolnego od wady, można wykryć położenie defektu. Przewagą metody impulsowo-fazowej nad metodą impulsową jest

możliwość detekcji wad materiałowych znajdujących się na różnych głębokościach, dzięki analizie fazy kilku fal o różnych częstotliwościach. Dodatkowo metoda ta jest mniej czuła na niejednorodność badanej powierzchni i nierównomierność jej nagrzewania w trakcie wymuszenia cieplnego. Analiza obrazów fazy nie pozwala pozyskać w pełni interesujących wyników dotyczących głębokości defektu [91]. Wynika to z właściwości przekształcenia Fouriera, które tłumi całkowicie informację czasową. Niedogodność tę można ominąć, stosując przekształcenie falkowe. Przekształcenie to zastosowane w termografii impulsowo-fazowej zachowuje informację czasową i dlatego pozwala w miarę dokładnie określić głębokość defektu pod powierzchnią. Jedyną niedogodnością wynikającą ze stosowania przekształcenia falkowego jest konieczność doboru falki pierwotnej. W literaturze [91] wykazano, iż spośród wielu falek najlepszą jest falka Morleta.

3.2.3. Termografia synchroniczna

Termografia synchroniczna polega na pobudzeniu obiektu periodycznym (najczęściej harmonicznym) wymuszeniem cieplnym i jednoczesnej rejestracji sekwencji obrazów termograficznych. W technice tej wykorzystywana jest teoria fal termicznych. W trakcie badania tą metodą zaleca się, aby urządzenie obrazujące było zsynchronizowane ze źródłem wymuszenia. Przy znanej częstotliwości sygnału stymulującego wyznacza się amplitudę i kąt przesunięcia fazowego odpowiedzi stymulowanego materiału względem sygnału wymuszającego. Pozwala to na określenie miejsca i rodzaju anomalii występującej w badanym obiekcie [91].

Na potrzeby analizy sekwencji obrazów termograficznych zostało opracowanych kilka algorytmów obliczeniowych pozwalających na wyznaczenie z termogramów obrazów parametrycznych pozwalających na identyfikację defektów strukturalnych. Klasyczne metody stosowane w termografii synchronicznej to m.in. [101]: podejście klasyczne, metoda czterech obrazów, metoda wariacyjna, metoda średniokwadratowa i inne [84].

Stosowanie metody synchronicznej wymaga właściwego doboru częstotliwości sygnału stymulującego, co może stanowić pewną niedogodność z uwagi na konieczność przeprowadzenia wstępnych testów dla wielu częstotliwości. Zaletą metody termografii synchronicznej jest mniejsza wrażliwość na niejednorodność badanej powierzchni i niejednorodność jej nagrzewania.

3.3. Dokładność pomiarów termograficznych

Dokładność pomiarów termograficznych jest podstawowym parametrem decydującym o skuteczności i jakości oceny stanu technicznego obiektów w oparciu o wartości bezwzględne temperatur. Ponieważ pomiar temperatury z zastosowaniem kamery termowizyjnej jest pomiarem pośrednim, bazującym na ilości promieniowania elektromagnetycznego docierającego do kamery, dokładność pomiaru jest wypadkową wielu czynników, w tym m.in. dokładności kamery, warunków zewnętrznych, emisyjności powierzchni obiektu itp. Dokładność pomiaru można scharakteryzować, korzystając z rachunku błędów, jednak jest to podejście idealistyczne bazujące na modelu ciała doskonale czarnego. W praktyce nieznane są prawdziwe wartości wielkości mierzonych, dlatego dokładność pomiaru można scharakteryzować, posługując się niepewnością pomiarową. Niepewność pomiaru jest parametrem związanym z wynikiem pomiaru charakteryzującym rozrzut wartości, które można w uzasadniony sposób

przypisać wartości wielkości mierzonej. Niepewność uwzględnia wiele składników i wszelkie błędy powstające w trakcie pomiarów mają wpływ na końcową wartość niepewności. Metodyka szacowania niepewności pomiarowych została opisana w podstawowej literaturze metrologicznej, m.in. przewodniku wyrażania niepewności pomiarowych mającym status międzynarodowego standardu metrologicznego [60, 59]. Można posługiwać się trzema rodzajami niepewności:

- Niepewnością standardową pomiaru bezpośredniego u_s .
- Niepewnością złożoną pomiaru pośredniego u_c .
- Niepewnością rozszerzoną U .

Zarówno w pomiarach pośrednich, jak i bezpośrednich stosowane są dwa typy niepewności:

Niepewność typu A – opisuje statystyczny rozrzut danych pomiarowych wynikających z przypadkowych fluktuacji wielkości mierzonej; przedstawiana jest za pomocą odchylenia standardowego; wymaga odpowiednio dużej liczby pomiarów.

Niepewność typu B – opiera się na naukowym osądzie eksperymentatora bazującym na wiedzy o procesie pomiarowym; najczęściej zakłada równomierny rozkład prawdopodobieństwa; stosowana jest, gdy np. dysponujemy jednym wynikiem pomiaru.

Pomiar temperatury z zastosowaniem kamery termograficznej składa się z kilku etapów, począwszy od ustalania parametrów metrologicznych kamery, wykonaniu pomiaru a skończywszy na prezentacji wyników. Na każdym etapie możemy wyróżnić szereg czynników mających wpływ na niepewność pomiarów. W takim przypadku podstawą określenia niepewności pomiaru będzie tzw. budżet niepewności uwzględniający takie czynniki jak [53]:

- emisyjność;
- temperatura otoczenia i atmosfery, gdyż im są one bliższe temperaturze obiektu, tym wynik pomiaru nie jest miarodajny;
- współczynnik transmisji atmosfery;
- odległość kamery od obiektu;
- wilgotność powietrza;
- dokładność deklarowaną przez producenta kamery, uwzględniając stosowany zakres pomiarowy.

Ponieważ termograficzny pomiar temperatury jest pomiarem pośrednim, temperatura określona jest za pomocą funkcji $T = f(x_1, x_2, x_3, \dots, x_k)$, zależnej od wartości czynników x_k , dla $k = 1, 2, 3, \dots, K$, uwzględnionych w budżecie niepewności. Pozwala to zatem określić niepewność złożoną u_c jako pierwiastek kwadratowy sumy kwadratów niepewności standardowych typu A i B każdego z czynników oddziałujących na danym etapie pomiaru wg następującej zależności:

$$u_c(T) = \sqrt{\sum_{k=1}^K \left(\frac{\partial f}{\partial x_k} \right)^2 u_s^2(x_k)} \quad (3.2)$$

gdzie:

u_c – niepewność złożona,

u_s – niepewność standardowa dla k -tego czynnika x_k mającego wpływ na pomiar (parametru pomiarowego), gdzie $k = 1, 2, \dots, K$.

Analizując etapy składające się na niepewność pomiaru temperatury z zastosowaniem kamery termograficznej, można zauważyć, że niepewność pomiarów na każdym etapie ma na siebie wzajemny wpływ. Wynika z tego, że elementy składowe niepewności całkowitej

są skorelowane, co wymaga uwzględnienia przy wyznaczaniu niepewności całkowitej. Stąd niepewność złożona dla pomiaru termograficznego powinna być wyznaczona w następujący sposób [53]:

$$u_c(T) = \sqrt{\sum_{k=1}^K \left(\frac{\partial f}{\partial x_k} \right) u_s^2(x_k) + 2 \sum_{k=1}^{K-1} \sum_{l=k+1}^K \frac{\partial f}{\partial x_k} \frac{\partial f}{\partial x_l} u_s(x_k) u_s(x_l) r(x_k, x_l)} \quad (3.3)$$

gdzie:

u_c – niepewność złożona,

$u_s(x_k)$ – niepewność standardowa dla k -tego czynnika wpływającego na pomiar,

$u_s(x_l)$ – niepewność standardowa dla l -tego czynnika wpływającego na pomiar,

$r(x_k, x_l)$ – współczynnik korelacji między czynnikami x_k i x_l .

Szacowanie złożonej niepewności standardowej zazwyczaj wiąże się z jednoczesną oceną prawdopodobieństwa, z jakim wynik pomiaru mieści się wewnątrz przedziału określonego przez tę niepewność. Do ścisłego określania tego prawdopodobieństwa wprowadza się pojęcie niepewności rozszerzonej [92]:

$$U = k u_c(T) \quad (3.4)$$

gdzie:

k — współczynnik rozszerzenia,

u_c – niepewność złożona.

Niepewność rozszerzona precyzuje granice przedziału niepewności na zadanym poziomie ufności. Wartość współczynnika rozszerzenia zależy od typu rozkładu prawdopodobieństwa zmiennej wyjściowej modelu pomiaru. Zagadnienia dotyczące analizy błędów i niepewności pomiarów są przedmiotem licznych książek i publikacji [53, 93, 92, 146].

Przystępując do pomiarów temperatury z zastosowaniem kamery termograficznej, należy pamiętać, że prawidłowy pomiar temperatury nie jest możliwy w ekstremalnie trudnych warunkach atmosferycznych. Ze względu na dużą niepewność pomiaru temperatury z zastosowaniem kamery termograficznej skutecznym sposobem diagnozowania na podstawie obrazów podczerwieni zarejestrowanych w trakcie obserwacji termograficznej obiektów technicznych jest wykorzystanie względnych zmian wartości temperatur lub wartości natężenia promieniowania podczerwonego. Takie podejście uniezależnia diagnostę od konieczności rozpatrywania wielkości mierzonych, co daje możliwość wykorzystania obserwacyjnych kamer termograficznych.

4. Metodyka diagnostyki termograficznej

Przykłady zastosowań termografii w ocenie stanu obiektów technicznych i procesów przemysłowych wskazują, że możliwy jest rozwój istniejących i opracowanie nowych metod diagnozowania bazujących na obraz podczerwieni. Pole do rozwoju termograficznej metodyki diagnozowania obiektów technicznych i procesów przemysłowych można upatrywać w kilku obszarach, m.in.:

- ciągłym monitorowaniu termograficznym,
- przetwarzaniu i analizie sekwencji obrazów termograficznych,
- rozpoznawaniu obrazów termograficznych,
- automatyzacji zadań detekcji, lokalizacji i identyfikacji uszkodzeń.

W pozostałej części pracy zaproponowano i scharakteryzowano metodykę diagnozowania obiektów technicznych bazującą na sygnałach diagnostycznych pozyskiwanych w wyniku przestrzenno-czasowej analizy obrazów termograficznych rejestrowanych w trakcie obserwacji obiektu technicznego w różnych chwilach czasu jego eksploatacji. Proponowana metodyka diagnozowania na podstawie analizy obrazów termograficznych zakłada zastosowanie i skumulowanie ze sobą aktualnej wiedzy dotyczącej:

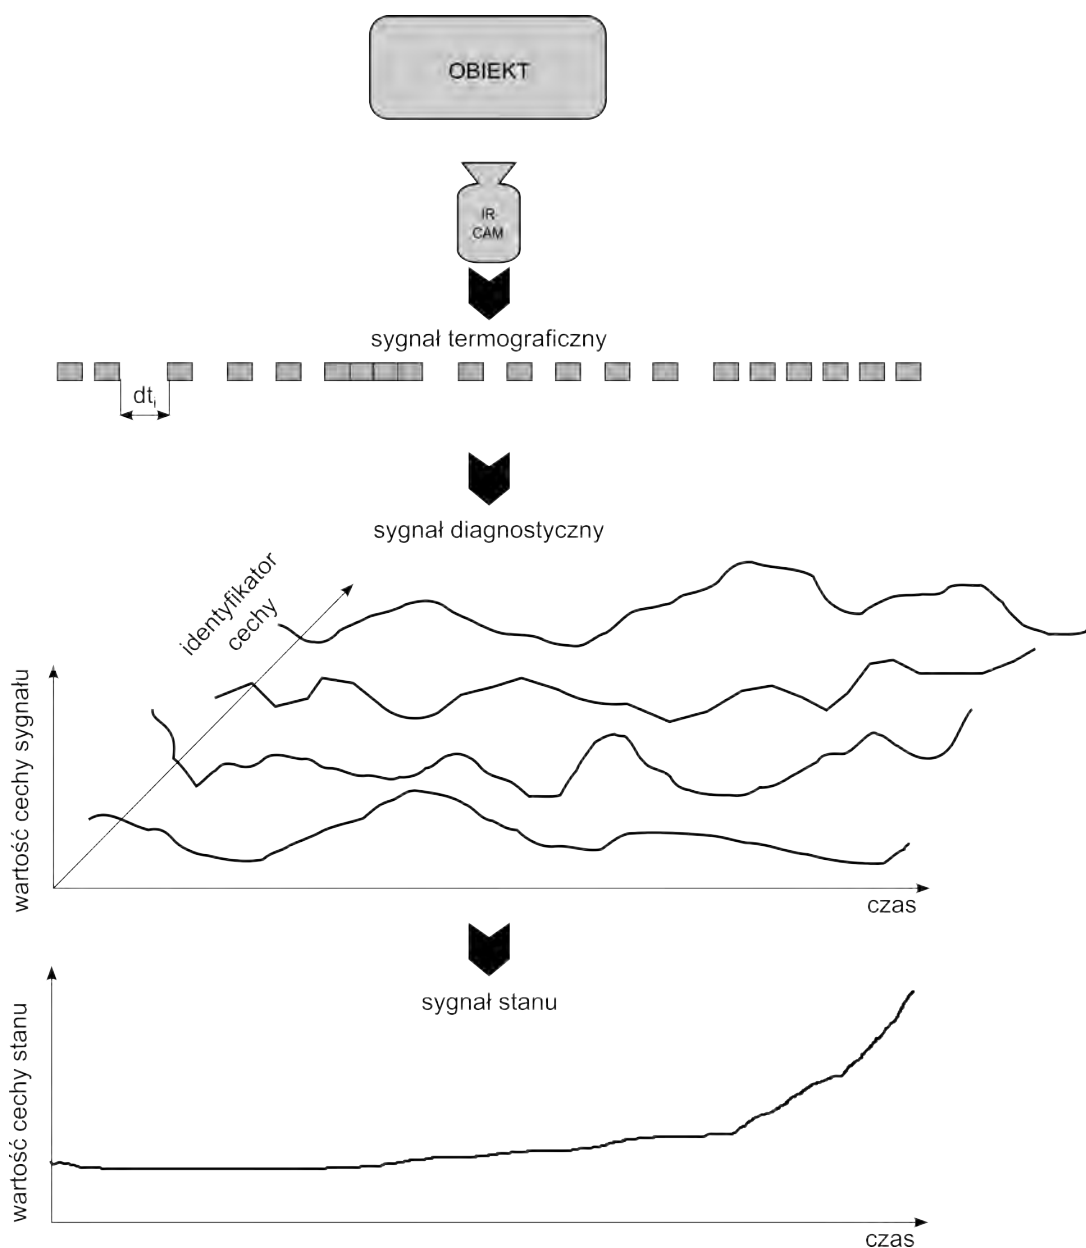
- diagnozowania maszyn i urządzeń,
- termografii w podczerwieni,
- przetwarzania i analizy obrazów,
- rozpoznawania obrazów,
- metod sztucznej inteligencji.

Jak pokazują przykłady zastosowania zaproponowanej metody (por. rozdz. 5), interdyscyplinarne podejście w realizacji procesu diagnozowania pozwala bardzo skutecznie rozpoznawać i identyfikować niesprawności obiektów technicznych.

4.1. Diagnozowanie obiektów z zastosowaniem termografii

U podstaw omawianej w dalszej części pracy metodyki diagnozowania obiektów technicznych z zastosowaniem termografii w podczerwieni leży koncepcja bazująca na wykorzystaniu obrazów podczerwieni zarejestrowanych w różnych chwilach działania diagnozowanego obiektu. Istotą proponowanego podejścia jest założenie, że możliwe jest w wyniku odpowiednio przeprowadzonej obserwacji termograficznej pozyskanie serii obrazów podczerwieni diagnozowanego obiektu działającego w określonych warunkach eksploatacyjnych, a następnie na ich podstawie przeprowadzenie wniosku diagnostycznego. Obrazy można uporządkować względem czasu ich pozyskiwania, a zatem i czasu eksploatacji obiektu. Obrazy w taki sposób uporządkowane tworzą dyskretny wielowymiarowy sygnał termograficzny $T(g(m,n),t)$. Sygnał taki, poddany przestrzenno-czasowemu przetwarzaniu i analizie pozwala wyznaczyć wielowymiarowy sygnał diagnostyczny $d(v_1, v_2, \dots, v_n, t)$ reprezentowany za pomocą przebiegów wartości cech obrazów w czasie. Wielowymiarowy sygnał diagnostyczny poddany dalszemu przetwarzaniu i analizie umożliwi detekcję, lokalizację i identyfikację niesprawności obserwowanego obiektu, a w konsekwencji określenie przebiegu funkcji opisującej zmiany stanu technicznego obiektu zachodzące w czasie

jego obserwacji. Znajomość sygnału stanu umożliwia prognozowanie horyzontu czasowego zmian stanu obiektu oraz planowanie działań eksploatacyjnych i obsługowych prowadzących do wyeliminowania nieprawidłowości w działaniu obiektu, a tym samym zapobieżeniu nagłemu nieprzewidzianemu uszkodzeniu. Na rysunku 4.1 zaprezentowano ilustrację graficzną proponowanej koncepcji diagnozowania obiektów technicznych z zastosowaniem termografii w podczerwieni.




Rys. 4.1. Ilustracja koncepcji diagnozowania obiektów technicznych z zastosowaniem obrazowania podczerwieni

4.2. Strategie obserwacji termograficznych

Obrazy podczerwieni mogą być rejestrowane w różnych odstępach czasu. Odstępy te mogą być stałe lub zmieniać się w trakcie trwania obserwacji termograficznej. Częstotliwość pozyskiwania obrazów jest zwykle parametrem przyjmowanym arbitralnie przez diagnostę i zależy od charakteru procesów cieplnych zachodzących w obserwowanym obiekcie, jak i zastosowanej metody badawczej. Jak dotąd nie sformalizowano metodyki obserwacji termograficznych, dlatego uwzględniając różnorodność obiektów technicznych, zjawisk cieplnych i metod diagnostyki termograficznej, można zaproponować kilka bazowych strategii obserwacji w podczerwieni obiektów i procesów.

4.2.1. Cykliczne obserwacje termograficzne

Strategia cyklicznych obserwacji w podczerwieni polega na akwizycji obrazów termograficznych w równo odległych od siebie chwilach czasu wynikających z przyjętego stałego interwału czasowego $dt = t_c = const$. Można założyć, że aby obserwację termograficzną można było uznać za cykliczną, wartości interwału czasowego dt_i między kolejno pozyskiwanymi obrazami nie powinny się różnić od przyjętej wartości t_c o 5%. Czas t_c między kolejnymi obserwacjami uzależniony jest od klasy obserwowanego obiektu i sposobu jego eksploatacji. Dla obiektów technicznych o stabilnych parametrach punktu pracy interwał t_c pomiędzy chwilami rejestracji obrazów może wynosić tygodnie lub miesiące. W przypadku obiektów o często zmieniającym się punkcie pracy obrazy powinny być pozyskiwane częściej, a wartość interwału t_c powinna być dobrana z uwzględnieniem okresowości zmiany punktu pracy wynikającego ze zmian parametrów eksploatacyjnych. Efektem cyklicznej obserwacji termograficznej jest sekwencja obrazów podczerwieni, której długość rośnie proporcjonalnie do czasu obserwacji i eksploatacji diagnozowanego obiektu. W punkcie na osi czasu określającym chwilę rejestracji obrazu zamiast pojedynczego obrazu może być zarejestrowana z dużą częstotliwością krótka sekwencja obrazów, spośród których może być wybrany jeden najbardziej reprezentatywny obraz lub w wyniku agregacji, np. uśredniania, utworzony obraz o lepszych parametrach jakościowych. Takie rozwiązania są stosowane we współczesnych urządzeniach obrazowania podczerwieni i mają zwykle na celu redukcję szumu.




Rys. 4.2. Ilustracja istoty cyklicznych obserwacji w podczerwieni

4.2.2. Cykliczno-sekwencyjne obserwacje termograficzne

Za strategię cykliczno-sekwencyjnych obserwacji termograficznych możemy uznać sytuację, kiedy cyklicznie ze stałym interwałem czasowym t_c prowadzone są obserwacje w podczerwieni, w trakcie których rejestrowane są sekwencje obrazów o określonej długości Nt_s i z zadaną częstotliwością $f_s = 1/t_s$. Uwarunkowania dotyczące dewiacji wartości interwału czasowego między kolejnymi chwilami obserwacji są takie same jak dla strategii cyklicznych obserwacji termograficznych. Pomiedzy interwałem czasowym między kolejnymi obserwacjami t_c a okresem rejestracji obrazów w sekwencji zachodzi następujący związek

$t_s \ll t_c$. Częstotliwość akwizycji obrazów w sekwencji dobierana jest na podstawie dynamiki zjawisk cieplnych zachodzących w trakcie zmiany stanu cieplnego. Tego typu strategia jest uzasadniona w przypadku, gdy następują cykliczne zmiany stanu cieplnego obiektu wywołane np. cyklicznymi zmianami punktu pracy obiektu (np. zmianami obciążenia) lub obiekt celowo i cyklicznie jest wymuszany cieplnie w celu kontroli jego stanu, np. zgodnie z ideą badań termografii dynamicznej. Długość interwału czasowy t_c między kolejnymi obserwacjami oraz chwile obserwacji powinny wynikać ze znajomości cykliczności zmian stanu cieplnego obiektu.




Rys. 4.3. Ilustracja istoty cykliczno-sekwencyjnych obserwacji w podczerwieni

4.2.3. Acykliczne obserwacje termograficzne

Strategia acyklicznych obserwacji termograficznych uwzględnia możliwość prowadzenia nieregularnych inspekcji termograficznych, w trakcie których interwały czasowe między kolejnymi obserwacjami są różne $dt_i \neq dt_{i-1}$. Nieregularność inspekcji może mieć kilka przyczyn:

- diagnozowany obiekt wspomaga proces produkcyjny, a jego nagłe uszkodzenie nie ma znaczącego wpływu na efektywność procesu i nie generuje znaczących strat, co w wielu przypadkach determinuje konieczność prowadzenia inspekcji tylko w chwilach, gdy istnieje podejrzenie występowania nieprawidłowości w jego działaniu;
- zjawiska cieplne niosące informacje o stanie technicznym obiektu zachodzą w obiekcie w sposób acykliczny;
- informacje z systemów monitorowania i diagnostyki wskazują na konieczność przeprowadzenia inspekcji termograficznej.




Rys. 4.4. Ilustracja acyklicznych obserwacji w podczerwieni

4.2.4. Acykliczno-sekwencyjne obserwacje termograficzne

Acykliczno-sekwencyjne obserwacje termograficzne realizowane są nieregularnie zgodnie z ideą strategii obserwacji acyklicznych, jednak podczas każdej inspekcji pozyskiwane są sekwencje obrazów o zadanej długości z zadaną stałą częstotliwością w podobny sposób, jak w przypadku strategii cykliczno-sekwencyjnych obserwacji termograficznych. Sytuacje takie mogą zachodzić szczególnie w przypadku diagnostyki struktur mechanicznych z zastosowaniem metod termografii aktywnej badanych tylko w sytuacjach, gdy może


zachodzić podejrzenie o wystąpieniu uszkodzenia wywołanego zdarzeniem losowym (np. uderzenie ciała obcego w strukturę, nadmierne chwilowe przeciążenie itp.).



Rys. 4.5. Ilustracja acykliczno-sekwencyjnych obserwacji w podcierwieniu

4.2.5. Mieszane obserwacje termograficzne

Kombinacja cyklicznych, acyklicznych i sekwencyjnych obserwacji termograficznych pozwala scharakteryzować strategię mieszanych obserwacji termograficznych, która może zostać zastosowana w okresie eksploatacji określonego obiektu technicznego. Przykładem mogą być struktury kompozytowe stosowane w lotnictwie, żeglarstwie lub energetyce wiatrowej, które poza cyklicznymi inspekcjami wynikającymi z procedur bezpieczeństwa mogą być również badane w nieregularnych odstępach czasu po wystąpieniu nieprzewidzianych zdarzeń mogących stanowić zagrożenie dla obiektu. W trakcie każdorazowej inspekcji mogą być pozyskiwane sekwencje obrazów jako efekt stosowania np. termografii dynamicznej.



Rys. 4.6. Ilustracja mieszanych obserwacji w podcierwieniu

Mieszane obserwacje termograficzne mogą być również efektem działania automatycznego systemu ciągłego monitorowania i diagnostyki, w którym na podstawie sygnałów diagnostycznych i procesowych inteligentny układ wnioskowania samodzielnie uruchomi odpowiednią procedurę przeprowadzenia obserwacji termograficznej w celu np. pozyskania uzupełniających informacji niezbędnych do jednoznacznego określenia bieżącego stanu technicznego diagnozowanego obiektu.

4.3. Procedura inspekcji termograficznej

Bez względu na przyjętą strategię, każdorazowe przeprowadzenie obserwacji (inspekcji) termograficznej wymaga uwzględnienia wielu czynników mających wpływ na wiarygodność pozyskanych obrazów termograficznych. Bazując na zaleceniach zawartych w różnych publikacjach w celu pozyskania wartościowych informacji diagnostycznych, można zaproponować procedurę postępowania pozwalającą prawidłowo przygotować i przeprowadzić obserwację termograficzną. Procedura składa się z następujących kroków:

Identyfikacja procedur bezpieczeństwa – inspekcja niektórych obiektów technicznych, np. instalacji elektroenergetycznych, urządzeń petrochemicznych itp. bardzo często wiąże się z potrzebą przebywania w strefach zagrożenia różnymi czynnikami zewnętrznymi. Przed przeprowadzeniem inspekcji konieczna jest zatem identyfikacja możliwych zagrożeń dla operatora, sprzętu i badanego obiektu oraz zapoznanie się z procedurami bezpieczeństwa, a także uzyskanie odpowiedniej zgody na przebywanie w strefie zagrożenia. Bezpieczeństwo oraz skuteczność inspekcji mogą być zwiększone, gdy w trakcie badań obecny będzie pracownik znający specyfikę badanego obiektu oraz jego otoczenia.

Zapewnienie dostępności obserwacyjnej obiektu – istnieją obiekty, które ze względu na realizowane procesy są odizolowane od otoczenia różnego rodzaju osłonami tłumiącymi promieniowanie podczerwone. Przeprowadzenie obserwacji wymaga zapewnienia dostępności obserwacyjnej poprzez usunięcie osłon i przeszkód leżących na ścieżce obserwacyjnej lub wykonanie odpowiednich okien wziernikowych.

Identyfikacja własności i właściwości obiektu – krok ten należy zaliczyć do podstawowych i najistotniej wpływających na jakość pozyskiwanych termogramów. W kroku tym konieczna jest:

- ocena własności geometrycznych obiektu (rozmiar, kształty, nierównomierności powierzchni);
- ocena własności obserwowanych powierzchni pod kątem emisyjności, ze szczególnym uwzględnieniem występowania obszarów o różnych własnościach (np. elementy metalowe pokryte rdzą, elementy z metali nieżelaznych lub stali nierdzewnych w otoczeniu powierzchni pokrytych powłokami malarskimi itp.);
- identyfikacja zakresu zmian temperatury obiektów na podstawie dokumentacji techniczno-ruchowej, danych historycznych lub wywiadu z operatorami lub służbami utrzymania ruchu.

Identyfikacja własności i właściwości otoczenia – warunki otoczenia są szczególnie istotne, jeśli celem inspekcji jest pomiar temperatury. Zmiana własności i właściwości otoczenia w czasie jest również krytyczna, w przypadku gdy stosowana jest strategia sekwencyjnych obserwacji termograficznych. Planując inspekcję, należy zidentyfikować i odnotować takie cechy otoczenia jak:

- temperaturę otoczenia i zakresu możliwych zmian w trakcie eksploatacji obiektu, jak również w trakcie prowadzonej inspekcji;
- obecność zewnętrznych sztucznych (maszyny, piece itp) i naturalnych (słońce, nieboskłon) źródeł promieniowania cieplnego w otoczeniu obiektu;
- obecność substancji tłumiących promieniowanie podczerwone w przestrzeni między obserwowanym obiektem a kamerą (pyły, aerozole, ciecze, ciała stałe itp.);
- istnienie nadmiernych niskoczęstotliwościowych wibracji w miejscu usytuowania kamery.

Określenie lokalizacji punktu(ów) obserwacji – obiekt poddawany inspekcji termograficznej bardzo często zlokalizowany jest w taki sposób, że jego obserwacja może odbywać się z ograniczonej liczby miejsc. Identyfikacja miejsc, z których może być prowadzona obserwacja termograficzna, ułatwia określenie parametrów urządzenia obrazującego w podczerwieni, a w szczególności właściwości jego układu optycznego (np. pole widzenia, czułość itp.).

Wybór urządzenia obrazowania – na podstawie własności i właściwości obserwowanego obiektu, jego otoczenia możliwe jest dobranie odpowiedniego urządzenia obrazowania, kierując się przy tym koniecznością uwzględnienia m.in.:

- zakresu widmowego, w którym działa urządzenie – zakres widmowy głównie dobierany jest wg prawa Plancka, uwzględniając temperaturę obiektu (por. rozdz. 2.1);
- rozdzielczości przestrzennej;
- parametrów układu optycznego (pole widzenia);
- odpowiednich osłon, obudów, filtrów chroniących urządzenie obrazowania i tłumiących promieniowanie podczerwone pochodzące z zewnętrznych źródeł.

Konfiguracja parametrów urządzenia obrazującego – przed przeprowadzeniem obserwacji każde urządzenie wymaga konfiguracji polegającej na:

- doborze pola widzenia;
- zogniskowaniu układu optycznego na wybranym obszarze obiektu;
- ustawieniu zakresu pomiarowego;
- ustawieniu parametrów niezbędnych dla prawidłowego pomiaru temperatury jak: emisyjność, transmisyjność, temperatura otoczenia, temperatura ścieżki pomiarowej;
- określenie szybkości akwizycji w przypadku rejestracji sekwencji obrazów (określenie interwału czasowego t_s);
- określenie częstotliwości korekcji dryftu temperaturowego urządzenia.

Przygotowanie obiektu do pomiarów – pomiar temperatury eksploatowanego obiektu technicznego wymaga:

- zapewnienie obciążenia nominalnego;
- naniesienie lub określenie obszarów korekcyjnych na potrzeby szacowania emisyjności (np. powłoki lakiernicze o znanej emisyjności);
- zastosowanie znaczników będących na stałe zamontowanymi elementami widocznymi jako punkty na obrazach podczerwieni i obrazach wizyjnych. Znaczniki pozwalają dopasować wzajemnie obrazy podczerwieni rejestrowane w różnych chwilach eksploatacji obiektu przy różnych parametrach kąta widzenia i pola widzenia. Za pomocą znaczników możliwe jest również dopasowanie obrazów wizyjnych jednocześnie rejestrowanych z obrazami podczerwieni, co bardzo często zachodzi w trakcie inspekcji termograficznych,
- demontaż osłon ochronnych lub wykonanie okien wziernikowych;
- montaż osłon tłumiących promieniowanie pochodzące z zewnętrznych źródeł.

Konfiguracja dodatkowych urządzeń badawczych – w trakcie inspekcji może zachodzić konieczność zastosowania dodatkowych urządzeń badawczych, które poza instalacją wymagają również konfiguracji. Można uwzględnić zastosowanie:

- układów dodatkowych wymuszeń cieplnych (źródło wraz z układem sterującym) niezbędne w termografii aktywnej;
- układy pomiaru temperatury otoczenia, wilgotności, zapylenia, wibracji itp.

4.4. System termograficznego monitorowania i diagnostyki obiektów technicznych

Realizacja każdej z zaproponowanych strategii obserwacji termograficznej może być oparta na inspekcjach termograficznych wykonanych przez przeszkolony personel. Większość aktualnie stosowanych badań diagnostycznych obiektów technicznych bazuje na takim podejściu. Zaproponowane strategie mogą być również zrealizowane w trybie automatycznym przez stacjonarne lub mobilne systemy monitorowania i diagnostyki obiektów technicznych. W ramach badań prowadzonych przez autora zaproponowano koncepcję automatycznego systemu monitorowania i diagnostyki obiektów technicznych i procesów przemysłowych bazującego na obserwacjach w podczerwieni i świetle widzialnym. Opracowana koncepcja systemu monitorowania i diagnostyki uwzględnia przedstawianą w pracy metodykę diagnozowania bazującą na analizie obrazów termograficznych (por. 4.1). Omówienie zagadnień dotyczących systemów termograficznych automatycznie monitorujących i diagnozujących obiekty techniczne i procesy wydaje się ważne choćby z tego powodu, że aktualne publikacje w niewystarczający sposób charakteryzują tę problematykę szczególnie w kontekście zasad ich projektowania i stosowania.

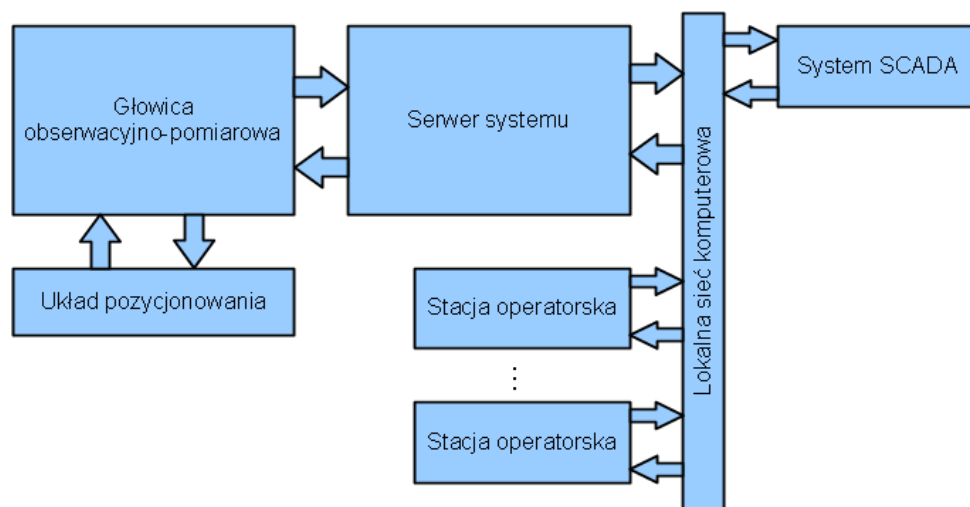
Na potrzeby opracowania struktury i koncepcji działania proponowanego systemu termograficznego monitorowania i diagnostyki obiektów przyjęto kilka podstawowych założeń:

- system może pracować autonomicznie lub współpracować z innymi nadrzędnymi systemami nadzoru i diagnostyki;
- system może być zastosowany do monitorowania i diagnostyki jednego lub kilku obiektów – założenie to wynika z możliwości wykorzystania mechanizmów automatycznego przemieszczania kamery i zmiany jej obszaru oraz pola widzenia przez zastosowania zautomatyzowanej (zrobotyzowanej) głowicy panoramicznej oraz zautomatyzowanych obiektywów o zmiennej ogniskowej;
- system pozwala pozyskiwać obrazy podczerwieni w każdej chwili eksploatacji obiektu(ów) – determinuje to konieczność zapewnienia jego pracy w trybie on-line;
- system powinien umożliwiać pozyskiwanie obrazów wizyjnych lub w innym zakresie promieniowania elektromagnetycznego uzależnionego od specyfiki obiektu – tego typu sytuacja może zachodzić przy badaniu np. połączeń spawanych z zastosowaniem podczerwieni i promieniowania X;
- system w trakcie swojego działania pozyskuje informacje z czujników monitorujących warunki zewnętrzne w celu automatycznej korekcji parametrów urządzeń obrazowania;
- system pozwala na zastosowanie różnych oferowanych przez rynek urządzeń obrazowania;
- zastosowane urządzenia obrazowania są chronione przed niekorzystnymi czynnikami zewnętrznymi;
- system pozwala mierzyć parametry dodatkowe w sposób bezkontaktowy (np. drgania, dźwięk);
- system wyposażony jest w serwer, którego podstawowym zadaniem jest komunikacja z urządzeniami obrazowania, konfiguracja i sterowanie parametrami obserwacji badanych obiektów, akwizycja, przetwarzanie, analiza i rozpoznawanie obrazów, gromadzenie danych (baza danych) oraz komunikacja z warstwami nadrzędnymi kompleksowego systemu diagnostyki i eksploatacji (np. systemy SCADA, zewnętrzne centra diagnostyczne itp.).

Bazując na przyjętych założeniach, zaproponowano strukturę systemu, którą podzielono na część sprzętową i część programową.

4.4.1. Struktura sprzętowa systemu

Schemat blokowy części sprzętowej przedstawiono na rys. 4.7. Podstawowym elementem systemu monitorowania jest zintegrowana głowica obserwacyjno-pomiarowa składająca się z urządzeń obrazowania w podczerwieni i paśmie promieniowania widzialnego oraz moduł sensorów dodatkowych pozwalający mierzyć dodatkowe wielkości fizyczne, a także moduł wstępnego przetwarzania i przygotowania danych. Głowica obserwacyjno-pomiarowa współpracuje z układem pozycjonowania zapewniającym przemieszczanie się głowicy według zadanej ścieżki, a także ustawianie wcześniej zaprogramowanego pola widzenia. Odpowiednio przygotowane dane z głowicy, poprzez moduły komunikacyjne, przesyłane są do serwera systemu, w którym realizowane są zadania ich gromadzenia, przetwarzania i analizy. Na podstawie wyznaczonych parametrów diagnostycznych moduł wnioskowania diagnostycznego przygotowuje informacje dotyczące stanu technicznego obiektu. Informacje o bieżącym stanie mogą być przesyłane do nadrzędnych układów nadzoru diagnostycznego i/lub prezentowane operatorowi systemu. Mając na uwadze konieczność zapisywania i zarządzania dużą ilością różnorodnych danych, serwer systemu ma za zadanie obsługę odpowiednio zaprojektowanej bazy danych diagnostycznych. Informacje diagnostyczne dostarczane przez system mają za zadanie wspomóc kadrę zarządzającą w podjęciu odpowiednich działań eksploatacyjnych. Jeśli strategia obserwacji i diagnozowania stanu obiektu bazuje na metodach termografii dynamicznej, należy zapewnić odpowiednie źródło pobudzenia cieplnego, wyzwalanego i zsynchronizowanego z głowicą obserwacyjno-pomiarową.



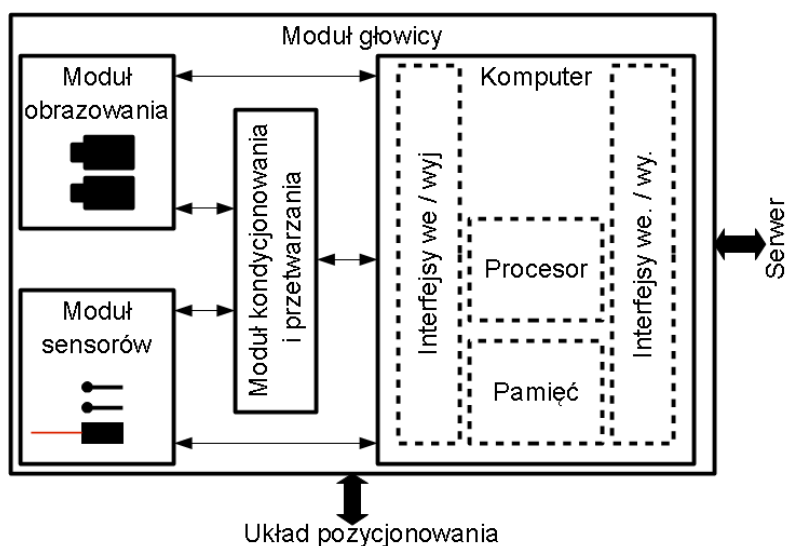
Rys. 4.7. Schemat blokowy ogólnej struktury sprzętowej termograficznego systemu monitorowania i diagnostyki

Przyjęto założenie, że system może w sposób dynamiczny zmieniać strategię obserwacji obiektów w zależności od decyzji diagnostycznej podejmowanej w sposób automatyczny. Idea proponowanej dynamicznej zmiany strategii obserwacji polega na tym, że w trakcie eksploatacji obiektu badany jest na bieżąco jego stan techniczny i jeśli stan obiektu uznawany jest za dobry w granicach przyjętego pola tolerancji, czas trwania cyklu pomiarowego jest długi. Jeżeli mechanizm wnioskowania diagnostycznego wykryje znaczącą zmianę wartości którejkolwiek z wyznaczanych cech, wtedy automatycznie uruchamiana jest procedura skracająca interwał między obserwacjami w celu dokładniejszej identyfikacji powstałej anomalii.

4.4.1.1. Zintegrowana głowica obserwacyjno-pomiarowa

Fundamentalnym i integralnym elementem całego systemu jest zintegrowana głowica obserwacyjno-pomiarowa składająca się z takich modułów jak (rys. 4.8):

- moduł obrazowania,
- moduł sensorów dodatkowych,
- moduł kondycjonowania i przetwarzania danych,
- moduł komputera głowicy.



Rys. 4.8. Schemat blokowy zintegrowanej głowicy obserwacyjno-pomiarowej termograficznego systemu monitorowania i diagnostyki

Moduł obrazowania

Moduł obrazowania wyposażony jest w kamery, których zadaniem kamer jest jednoczesna obserwacja obiektu w podczerwieni i świetle widzialnym w obszarze ograniczonym przez zdefiniowane i ustawione pola widzenia stosowanych urządzeń. O polu widzenia kamer decydują układy optyczne. Kamery mogą być wyposażone w obiektywy o stałej lub zmiennej ogniskowej. Obiektywy o stałej ogniskowej należy dobrać tak, aby obszary widzenia były do siebie zbliżone. W przypadku obiektywów o zmiennej ogniskowej konieczne jest zaplanowanie w układzie sterowania odpowiednich procedur synchronizacji nastaw obszarów widzenia.

Przyjęto, że kamera termograficzna jest podstawowym źródłem danych diagnostycznych w opisywanym systemie monitorowania i diagnostyki. Kamera wizyjna pełni funkcję pomocniczą i ma za zadanie dostarczyć obrazy w świetle widzialnym przedstawiające obiekt i jego otoczenie. Na podstawie obrazów wizyjnych możliwa jest ocena wpływu zmian zachodzących w otoczeniu obiektu (przechodzący ludzie, poruszające się źródła ciepła) i zmian oświetlenia obiektu na wartości wyznaczanych cech obrazów termograficznych. Dodatkowo obraz wizyjny może być wykorzystany do identyfikacji markerów kalibracyjnych oraz identyfikacji obszarów bezkontaktowych pomiarów parametrów dodatkowych. Obraz wizyjny w systemie może być traktowany zarówno jako niezależne źródło danych, jak i element niezbędny do generowania syntetycznego obrazu diagnostycznego w wyniku fuzji obrazów wizyjnych i termowizyjnych. Niektóre urządzenia wizyjne posiadają detektory działające w zakresie bliskiej podczerwieni, co przy zastosowaniu odpowiednich filtrów może

być wykorzystane do pozyskiwania uzupełniających informacji o wysokotemperaturowych zjawiskach cieplnych zachodzących w obrębie pola widzenia kamery. Uwzględniając aktualny stan rozwiązań technicznych stosowanych na rynku urządzeń obrazowania, można przyjąć, że obrazy formowane przez urządzenia obrazowania reprezentowane będą w postaci cyfrowej. Do modułu obrazowania należy jeszcze zaliczyć wszelkie dodatkowe układy pozwalające na sterowanie kamerą za pomocą sygnałów zewnętrznych (np. układy generujące sygnały wyzwalające proces akwizycji itp.).

Moduł sensorów dodatkowych

Obserwacje termograficzne bardzo często wymagają identyfikacji warunków środowiskowych na potrzeby określenia parametrów konfiguracyjnych urządzeń obrazowania w podczerwieni. Ze względu na przyjęte założenie, że omawiany system będzie działał w sposób automatyczny, przyjęto, że głowica wyposażona zostanie w dodatkowe sensory pozwalające na ocenę wpływu otoczenia maszyny i warunków zewnętrznych na ścieżkę transmisji promieniowania. Podstawowymi czujnikami dodatkowymi mogą być czujniki temperatury i wilgotności. Ponadto można zastosować również sensory oświetlenia, ciśnienia, zapylenia, pomiaru odległości itp. Ocena warunków zewnętrznych ma na celu detekcję zmian w wartościach przebiegów sygnałów diagnostycznych niezwiązanych z faktycznym stanem obiektu, a zatem ograniczenie liczby fałszywych przekroczeń wartości progowych sygnałów diagnostycznych wyznaczanych z sekwencji obrazów termograficznych.

Moduł kondycjonowania sygnałów

Sensory dodatkowe mogą generować sygnały analogowe i cyfrowe o różnych parametrach. Podstawowym zadaniem modułu kondycjonowania sygnałów jest zasilanie czujników, wzmocnienie (tłumienie) sygnałów wyjściowych, filtracja, decymacja itp. Zabiegi kondycjonowania mają na celu podniesienie jakości sygnałów i dopasowanie ich parametrów na potrzeby kolejnego etapu, jakim jest przetwarzanie sygnałów. W przypadku czujników z wyjściami cyfrowymi etap kondycjonowania może zostać pominięty. Istnieje szeroki wybór różnorodnych kompaktowych rozwiązań pozwalających na akwizycję sygnałów z różnych sensorów, które mogą znaleźć zastosowanie w głowicy obserwacyjnej.

Moduł przetwarzania sygnałów

Przetwarzanie do postaci cyfrowej jest koniecznym, z punktu widzenia dalszej analizy, etapem przygotowania sygnałów pochodzących ze źródeł analogowych. Szeroki asortyment urządzeń przetwarzania analogowo-cyfrowego pozwala bez przeszkód dobrać odpowiednie rozwiązanie, mogące znaleźć zastosowanie w opisywanej koncepcji głowicy. Podstawowymi parametrami, jakie należy uwzględnić, dobierając przetwornik analogowo-cyfrowy, są: częstotliwość próbkowania, zakres dynamiczny oraz zakres napięć wejściowych. W przypadku gdy inspekcja termograficzna będzie uwzględniała stosowanie metod termografii dynamicznej, należy uwzględnić obecność układu generującego sygnały sterujące dla źródeł wymuszających cieplnie badane obiekty oraz dodatkowego kanału pomiarowego zapewniającego synchronizację sygnału wymuszającego z modułem obrazowania.

Moduł komputera głowicy


Obrazy oraz sygnały dodatkowe reprezentowane w postaci cyfrowej, w zależności od przyjętej strategii obserwacji obiektu mogą być generowane na bieżąco, co z punktu widzenia ich transmisji do serwera systemu może wymagać zastosowania zaawansowanych metod

i sprzętu. Zakładając, że głowica obserwacyjno-pomiarowa ma być mobilna, transmisja danych będzie odbywała się w sposób przewodowy i/lub bezprzewodowy na duże odległości. W trakcie transmisji strumień danych może być narażony na zakłócenia. Mogą również nastąpić nieprzewidziane przerwy w transmisji prowadzące do utraty danych. Z tego powodu przyjęto założenie, że głowica wyposażona zostanie w wewnętrzny komputer, którego zadaniem będzie pozyskiwanie, wstępne przetwarzanie i analiza oraz kompresja danych pochodzących z modułów wewnętrznych głowicy, a także ze źródeł zewnętrznych. Wstępne przygotowanie i przetwarzanie danych w module głowicy pozwoli podnieść efektywność działania całego systemu. Dodatkową zaletą zintegrowania komputera z głowicą będzie możliwość wykorzystania go do komunikacji z opisanym poniżej modulem pozycjonowania głowicy oraz jeśli będzie to wymagane, z innymi dodatkowymi układami współpracującymi z głowicą. Przetwarzanie wstępne w przypadku obrazów może polegać na selekcji obszarów zainteresowania wg predefiniowanych parametrów, normalizację obrazów, bezstratną kompresję itp. W przypadku sygnałów z sensorów dodatkowych można rozważyć ich ocenę z zastosowaniem odpowiednio dobranych cech liczbowych i/lub przekształcenie do dziedziny częstotliwości. Istotnymi cechami komputera powinny być zastosowanie odpowiednich interfejsów wejściowych i wyjściowych pozwalających na pobieranie i wysyłanie danych ze wszystkich modułów głowicy, serwera systemu oraz modułu pozycjonowania.

4.4.1.2. Układ pozycjonowania

Koncepcja głowicy obserwacyjnej zakłada jej mobilność i możliwość pozycjonowania w celu obserwacji różnych obiektów pracujących w jej otoczeniu. Z tego powodu założono, że powinna ona być wyposażona w układ pozycjonowania w celu pozyskiwania obrazów z różnych punktów i kierunków obserwacji. Ideę pozycjonowania głowicy można uzasadnić, posługując się przykładem hali maszyn, w której działa duża liczba obiektów należących do tej samej lub różnych klas. Można założyć, że w hali znajduje się suwnica lub może zostać zamontowany mobilny układ mechatroniczny pozwalający na przemieszczanie głowicy do określonego punktu w przestrzeni hali. Jeśli dodatkowo głowica będzie wyposażona w układ zapewniający obrót głowicy w dwóch osiach, a także zmianę pola widzenia układów optycznych, to przy odpowiednio zaprogramowanej kombinacji przemieszczania głowicy, obrotu osi pozycjonera oraz ustawionym polu widzenia, możliwa będzie obserwacja obiektu w dowolnym miejscu hali, w dogodny na potrzeby dalszej analizy rejestrowanych sygnałów i obrazów sposób (rys. 4.9). Cały układ zapewniający przemieszczanie głowicy, pozycjonowanie i ustawienie pola widzenia można zatem nazwać układem pozycjonowania.

Podstawowymi elementami układu pozycjonowania powinny być układy wykonawcze (serwomechanizmy) współpracujące z układami mechanicznymi, sensory określające położenie i bieżącą konfigurację przestrzenną i moduł sterowania. Moduł sterowania układu pozycjonowania może się komunikować z komputerem głowicy za pomocą odpowiednich interfejsów wejścia i wyjścia oraz protokołów komunikacyjnych (np. magistrala CAN). Komputer głowicy stanowiłby układ wstępnie przetwarzający i buforujący dane pochodzące z układu pozycjonowania i serwera systemu.



Rys. 4.9. Ilustracja istoty działania układu pozycjonowania głowicy

4.4.1.3. Serwer systemu

Nadrzędnym elementem systemu jest serwer, którego podstawowe zadania to:

- komunikacja z głowicą obserwacyjno-pomiarową systemu,
- gromadzenie danych pochodzących z komputera głowicy,
- przesyłanie danych do komputera głowicy,
- przetwarzanie i analiza danych pochodzących z głowicy systemu,
- automatyczne wnioskowanie diagnostyczne na podstawie pozyskanych danych,
- prezentacja wyników przetwarzania, analizy i rozpoznawania stanu operatorowi systemu w celu wspomagania w podejmowaniu decyzji diagnostycznych,
- zapewnienie operatorowi komunikacji i kontroli nad całym systemem,
- współpraca z zewnętrznymi układami monitorowania i diagnostyki poprzez sieci komputerowe.

Serwer systemu powinien być wydajnym wieloprocessorowym komputerem umieszczonym w bezpiecznym miejscu, odpornym na trudne warunki przemysłowe, mogącym pracować w trybie ciągłym i posiadającym odpowiednią pojemność pamięci operacyjnej i masowej, a także mechanizmy wykonywania kopii bezpieczeństwa oraz układy podtrzymujące zasilanie. Ze względu na różnorodność i powszechną dostępność tego typu rozwiązań opis szczegółowej specyfikacji serwera pominięto.

4.4.2. Struktura programowa

Część sprzętowa systemu obsługiwana jest z poziomu części programowej składającej się z czterech współdziałających ze sobą bloków: bloku oprogramowania komputera głowicy, bloku oprogramowania układu pozycjonowania, bloku oprogramowania serwera systemu i bloku bazy danych.

4.4.2.1. Oprogramowanie komputera głowicy

Oprogramowanie komputera głowicy obejmuje system operacyjny wraz ze sterownikami oraz program, którego podstawowym zadaniem powinno być realizowanie zadań związanych z pozyskiwaniem danych z urządzeń obrazowania i sensorów dodatkowych, wstępnym przetwarzaniem danych oraz przesyłaniem wyników do serwera systemu. Dodatkowe funkcje oprogramowania, jakie muszą być zaimplementowane, to współpraca z urządzeniami zewnętrznymi i możliwość zdalnej zmiany ich ustawień, obsługa układu pozycjonowania, zapewnienie obsługi interfejsów wejściowych i wyjściowych, sygnalizowanie nieprawidłowości działania (autodiagnostyka) itp.

4.4.2.2. Oprogramowanie serwera systemu

Serwer systemu poza systemem operacyjnym powinien posiadać oprogramowanie realizujące zadania rejestracji, przetwarzania i analizy danych pochodzących z głowicy obserwacyjno-pomiarowej. Odpowiednie moduły oprogramowania powinny umożliwić sklasyfikowanie bieżącego stanu technicznego, podjęcie decyzji diagnostycznej i prognozowanie zmian stanu technicznego. Informacje wygenerowane przez moduły wnioskowe diagnostycznego stanowią przesłanki dla operatora systemu oraz układu sterowania obiektu do podjęcia odpowiednich działań eksploatacyjnych. W oprogramowaniu serwera należy również przewidzieć moduły operatorskie i konfiguracyjne pozwalające na ustawienie i zapisanie wszelkich parametrów konfiguracyjnych i kalibracyjnych dla wszystkich modułów systemu. Założono, że zarządzanie systemem może odbywać się w sposób zdalny poprzez sieć Internet z poziomu przeglądarki internetowej.

4.4.2.3. Oprogramowanie układu pozycjonowania

Ze względu na konieczność zastosowania sterowników układów wykonawczych pozycjonujących głowicę konieczne będzie opracowanie oprogramowania dedykowanego dla układów sterujących. Ze względu na różnorodność układów sterujących struktura oprogramowania będzie zależeć od zastosowanego rozwiązania sprzętowego. Oprogramowanie powinno umożliwiać komunikację z komputerem głowicy, odczyt danych konfiguracyjnych oraz przygotowanie i przesyłanie bieżących ustawień w celach weryfikacyjnych i archiwizacyjnych.

4.4.2.4. Baza danych systemu

Wielomodalne dane generowane podczas działania systemu termograficznego monitorowania i diagnostyki obiektów powinny być gromadzone w odpowiednio zaprojektowanej bazie danych. W dziedzinie diagnostyki technicznej gromadzenie i zarządzanie zasobami danych prowadzone jest na różne sposoby [24]. Stosowane są komercyjne systemy bazodanowe oraz systemy zunifikowane [90].

W projektowaniu bazy danych można korzystać z wielu istniejących oryginalnych rozwiązań, które częściowo odpowiadają wymaganiom stawianym diagnostycznym bazom danych. Do ciekawszych pomysłów należą [24]:

- stosowanie struktury hierarchicznej w celu ograniczenia ilości danych opisujących obiekty techniczne i historię ich eksploatacji;
- wprowadzanie słowników nazw w celu unifikacji baz danych oraz umożliwienia łączenia fragmentów baz zakładanych przez różnych użytkowników;
- częściowe globalne zarządzanie wartościami identyfikatorów w celu umożliwienia w prosty sposób stosowania baz rozproszonych i przystosowania ich do wzajemnego wymieniania fragmentów swoich zasobów;
- specyficzny zapis czasu wystąpienia rejestrowanych w bazie zdarzeń i celowe ograniczenie stopnia szczegółowości zapisanych danych w celu ograniczenia redundancji danych wynikającej z istnienia długich ciągów wartości niezmiennych w czasie będących efektem cyklicznych pomiarów i analiz;
- integracja środowisk komputerowych poprzez stosowanie, np. specyfikacji COM, COBRA;
- stosowanie wielowarstwowych struktur oprogramowania w celu ujednoczenia sposobów komunikowania się końcowego użytkownika z oprogramowaniem np. poprzez przeglądarkę internetową;
- reprezentacja danych w postaci dokumentów, których treść zapisano za pomocą specjalnych języków, np. SGML, XML;
- unifikacja słowników stosowanych nazw poprzez wprowadzenie przez W3C możliwości równoczesnego stosowania wielu słowników, gdzie globalny charakter mają wyłącznie ich nazwy.

Utworzenie bazy danych diagnostycznych dla termowizyjnego systemu monitorowania i diagnostyki maszyn wymaga przeanalizowania różnych aspektów działania projektowanego systemu, jak również uwzględnienia konieczności komunikacji i przesyłania danych do otoczenia. Przyjęto założenie, że baza danych powinna umożliwić gromadzenie danych zmiennych zawierających wyniki pomiarów i analiz, zmienne eksploatacyjne i uwagi (odpowiedzi na pytania) wprowadzane bezpośrednio przez użytkownika, a także danych stałych informujących o strukturze diagnozowanych obiektów i ich stanie. Dane te mogą być aktualizowane okresowo na podstawie danych zmiennych. Aby ułatwić budowę tablic, dane można podzielić na kilka kategorii, mianowicie:

- dane o obserwowanych obiektach,
- dane o zarejestrowanych sygnałach i obrazach,
- dane o nastawach pomiarowych,
- wartości cech sygnałów,
- dane procesowe i eksploatacyjne (w tym remontowe),
- dane o parametrach torów pomiarowych,
- dane konfiguracyjne,
- decyzje diagnostyczne,
- dane prognozowane.

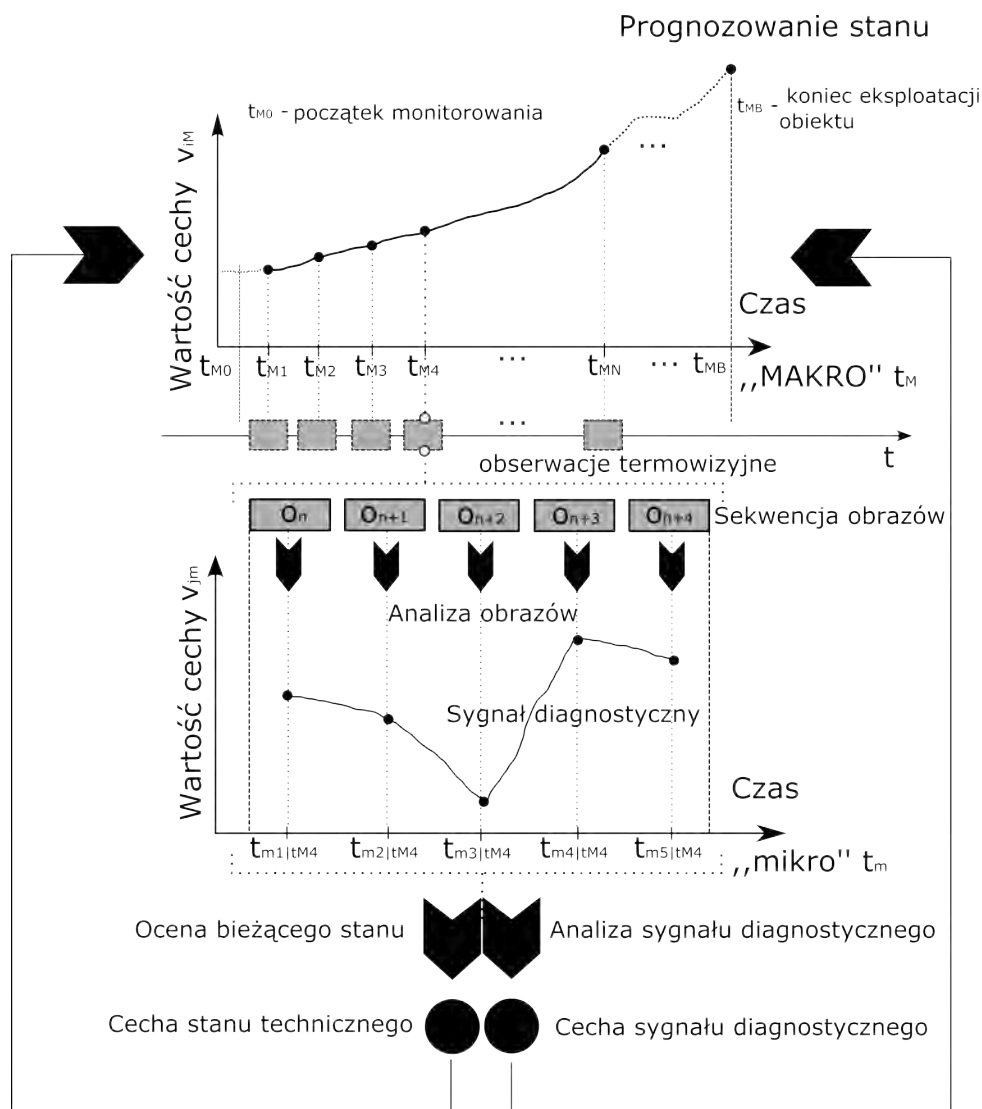
Omawiany system może działać na przestrzeni długiego okresu, co wiąże się z systematycznym gromadzeniem dużej ilości danych. Taka sytuacja wymaga przyjęcia założeń dotyczących obsługi systemu, administracji oraz pielęgnacji bazy, jak również ograniczenia objętości zapisywanych danych.

Uwzględniając istnienie innych systemów monitorowania i diagnostyki maszyn mogących działać równolegle z proponowanym układem, należy rozważyć wprowadzenie mechanizmów zdalnego dostępu do danych i ich wymianę z innymi diagnostycznymi bazami danych.

4.5. Koncepcja diagnozowania z wykorzystaniem analizy obrazów termograficznych

Zaproponowane strategie termograficznej obserwacji obiektów (por. 4.2) pozwalają na scharakteryzowanie i analizowanie zarówno szybkozmiennych i wolnozmiennych zjawisk cieplnych zachodzących w trakcie eksploatacji obserwowanego obiektu oraz zintegrowanie aktualnie istniejących obok siebie pasywnych i aktywnych metod diagnostyki termograficznej, zapewniając tym samym możliwość podniesienia skuteczności procesu diagnozowania obiektów technicznych i procesów przemysłowych. W zaproponowanych strategiach obserwacji termograficznych można zauważyć, że punkt na osi czasu związany jest z pojedynczą obserwacją termograficzną trwającą minuty lub godziny, jak również z rejestracją sekwencji obrazów opisującej zjawiska zachodzące w trakcie sekund lub minut. Jeśli będziemy rozpatrywać informacje zebrane w ramach kilku lub kilkudziesięciu obserwacji wg jednej z omówionych strategii, będą one uporządkowane na przestrzeni dni, tygodni lub miesięcy. Wynika z tego, że wybór dowolnej strategii obserwacji determinuje konieczność posługiwania się różnymi skalami czasu zegarowego. Aby sformalizować problem różnych skal czasowych w kontekście analizy wielowymiarowego sygnału termograficznego rejestrowanego w trakcie stosowania dowolnej z zaproponowanych strategii obserwacji termograficznej, można posłużyć się umownym podziałem dziedziny czasu rzeczywistego na czas „mikro” (dynamiczny) i czas „makro” (eksploatacyjny) (por. 2.4). Dzięki takiemu podziałowi sekwencję obrazów zarejestrowanych w trakcie pojedynczej obserwacji termograficznych można rozpatrywać i analizować w czasie „mikro”, czyli np. sekundach lub minutach, natomiast sekwencję obrazów powstałą w wyniku przeprowadzenia kilku lub kilkudziesięciu obserwacji termograficznej obiektu w ciągu kilku miesięcy można opisać w dziedzinie czasu „makro” (rys. 4.10). Jeśli założymy, że każdy obraz należący do sekwencji opisanej czy to w czasie „mikro”, czy w czasie „makro” poddamy analizie z zastosowaniem tych samych metod, wtedy dla każdego obrazu uzyskany zostanie zbiór cech, których wartości uporządkowane w obu omawianych dziedzinach czasu mogą być traktowane jako sygnały diagnostyczne i poddawane dalszej analizie. Rozpatrzmy przykładową sekwencję obrazów uporządkowaną w dziedzinie czasu „mikro” zarejestrowaną w trakcie pojedynczej obserwacji termograficznej w chwili czasu „makro”. Założmy, że w wyniku analizy każdego obrazu w sekwencji wyznaczono cechę v_{jm} . Porządkując wartości cechy według chwil czasu „mikro”, w których zarejestrowano analizowane obrazy, pozyskany zostanie jednowymiarowy sygnał diagnostyczny. Jeśli tak uzyskany sygnał diagnostyczny poddamy analizie, możliwe będzie wyznaczenie zbioru cech tego sygnału, których wartości mogą posłużyć do dwóch celów. W pierwszym przypadku do identyfikacji bieżącego stanu technicznego w wyniku rozpoznawania wzorca utworzonego przez te cechy w przestrzeni ich wartości. Wynikiem identyfikacji stanu będzie cecha stanu, której można przypisać chwilę czasu „makro”, co w przypadku przyjętej strategii obserwacji termograficznych pozwoli uzyskać przebieg sygnału stanu w dziedzinie czasu „makro”. W drugim przypadku każda wartość cechy sygnału diagnostycznego opisanego w czasie „mikro” może stać się wartością sygnału diagnostycznego w określonej chwili czasu „makro”. Mając do dyspozycji wyniki wielu obserwacji termograficznych, możliwe jest utworzenie przebiegu sygnału diagnostycznego w czasie „makro” i na jego podstawie prowadzić detekcję niesprawności działania obiektu. Przyjęcie dziedziny czasu „mikro” pozwala na scharakteryzowanie obiektu za pomocą dwóch klas sygnałów w czasie „makro”: sygnału stanu powstałego w wyniku rozpoznawania wzorców oraz sygnału diagnostycznego powstałego

w wyniku oceny sekwencji obrazów termograficznych w czasie „mikro”. Sygnały te mogą stanowić podstawę do diagnozowania oraz realizacji zadań prognozowania stanu technicznego. W powyższym opisie proponowanej koncepcji posłużono się szczególnym przypadkiem, gdy zarówno w czasie „mikro”, jak i w czasie „makro” wyznaczane są jednowymiarowe sygnały diagnostyczne. Rozważania te mogą być rozszerzone do przypadków wielowymiarowych sygnałów diagnostycznych, co determinuje przyjęcie odpowiednich metod ich analizy.



Rys. 4.10. Koncepcja diagnozowania z zastosowaniem analizy obrazów podczerwieni w czasie „mikro” i „makro”

Zaproponowana metodyka analizy obrazów termograficznych może być rozumiana szerzej, gdyż dotyczy nie tylko obrazów termograficznych powstałych w urządzeniu do obrazowania podczerwieni, ale również wzorców będących swego rodzaju obrazami w przestrzeni wartości cech uzyskanej w wyniku analizy pierwotnych obrazów termograficznych.

Na każdym etapie analizy, czy to sekwencji obrazów termograficznych, czy też sygnałów diagnostycznych, należy uwzględnić operację selekcji lub ekstrakcji cech w celu pozyskania cech relewantnych. Na etapie analizy obrazów termograficznych ze zbioru cech powstałego w wyniku zastosowania różnych metod analizy obrazów termograficznych możliwe

jest wskazanie podzbioru relewantnych cech obrazów, z których utworzone mogą być sygnały diagnostyczne. Analiza sygnałów diagnostycznych utworzonych na podstawie cech relewantnych obrazów pozwala na wyznaczanie przestrzeni cech sygnałów diagnostycznych, z których ponownie w wyniku selekcji lub ekstrakcji cech możliwe jest utworzenie podzbioru cech relewantnych, które będą stanowiły wzorce (obrazy przestrzeni cech) niezbędne dla realizacji procesu klasyfikacji stanu technicznego obserwowanego obiektu i utworzenia sygnału stanu.

4.5.1. Strategie analizy obrazów termograficznych i sygnałów diagnostycznych

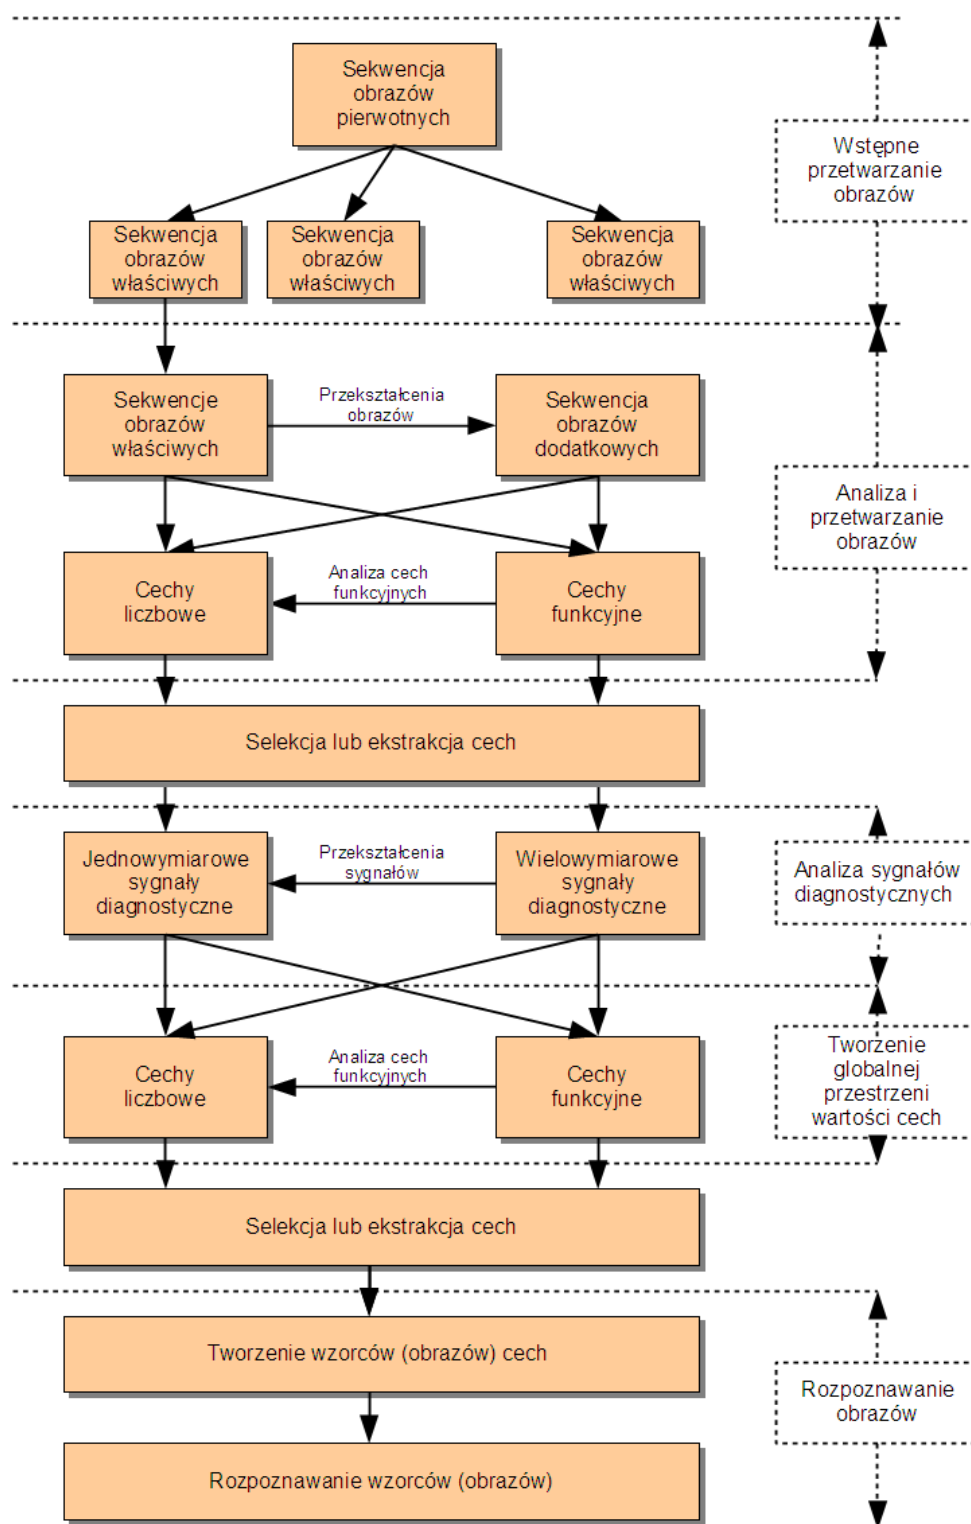
Istotnym elementem proponowanej koncepcji diagnozowania jest pozostawienie szerokiego pola możliwości w opracowaniu i zastosowaniu różnych strategii postępowania w celu wyznaczania wartości sygnałów diagnostycznych, ich analizy, a następnie identyfikacji stanu technicznego. Elementami każdej z możliwych strategii mogą być różne istniejące i/lub oryginalne metody przetwarzania i analizy obrazów oraz sygnałów. Jak dotąd, istniejące metody przetwarzania i analizy obrazów w diagnostyce termograficznej są stosowane w ograniczonym i zdaniem autora niewystarczającym stopniu.

W celu przedstawienia istoty postępowania z danymi diagnostycznymi w zaproponowanej koncepcji diagnozowania zaproponowano ogólny, wielowariantowy schemat (rys. 4.11) możliwych sposobów postępowania prowadzących do pozyskania informacji diagnostycznej z obrazów termograficznych i sygnałów diagnostycznych. Na schemacie możemy wydzielić pięć podstawowych etapów postępowania:

- wstępne przetwarzanie pierwotnych obrazów podczerwieni,
- analiza właściwych obrazów podczerwieni,
- przetwarzanie i analiza sygnałów diagnostycznych,
- tworzenie wzorców (obrazów) cech,
- rozpoznawanie wzorców (obrazów).

4.5.1.1. Wstępne przetwarzanie pierwotnych obrazów podczerwieni

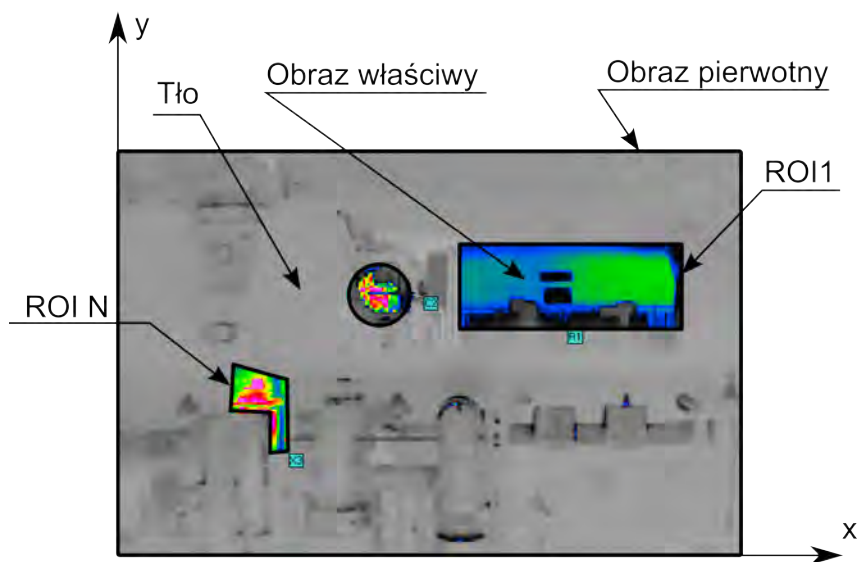
Przyjęto, że zarejestrowane obrazy podczerwieni przed zastosowaniem jakichkolwiek operacji przetwarzania i analizy nazwane będą obrazami pierwotnymi. Proces pozyskiwania danych diagnostycznych rozpoczyna się od wstępnego przetwarzania każdego z zarejestrowanego i uporządkowanego w czasie pierwotnego obrazu podczerwieni. Zastosowanie operacji wstępnego przetwarzania ma dwa podstawowe cele. Pierwszy z nich to zdefiniowanie obszarów zainteresowania ROI (ang. *Region Of Interest*) (por. 2.5.1.5). Drugim celem jest podniesienie jakości obrazów (por. 2.5). Definiowanie obszarów zainteresowania (rys. 4.12) pozwala na usunięcie elementów obrazu zawierających nieistotne dla analizy zakłócenia pochodzące z tła. Rozpatrywanie obszarów zainteresowania pozwala również podnieść szybkość działania poszczególnych procedur przetwarzających i analizujących obraz dzięki mniejszej ilości danych wejściowych. Definiowanie obszarów zainteresowania powinno być operacją wykonywaną jednorazowo dla obrazów diagnozowanego obiektu na etapie konfiguracji systemu monitorowania i diagnostyki. Parametry (kształt, rozmiar i położenie) każdego zdefiniowanego obszaru zainteresowania nie powinny ulegać zmianie w trakcie obserwacji termograficznych realizowanych wg określonej strategii dla określonego obiektu.



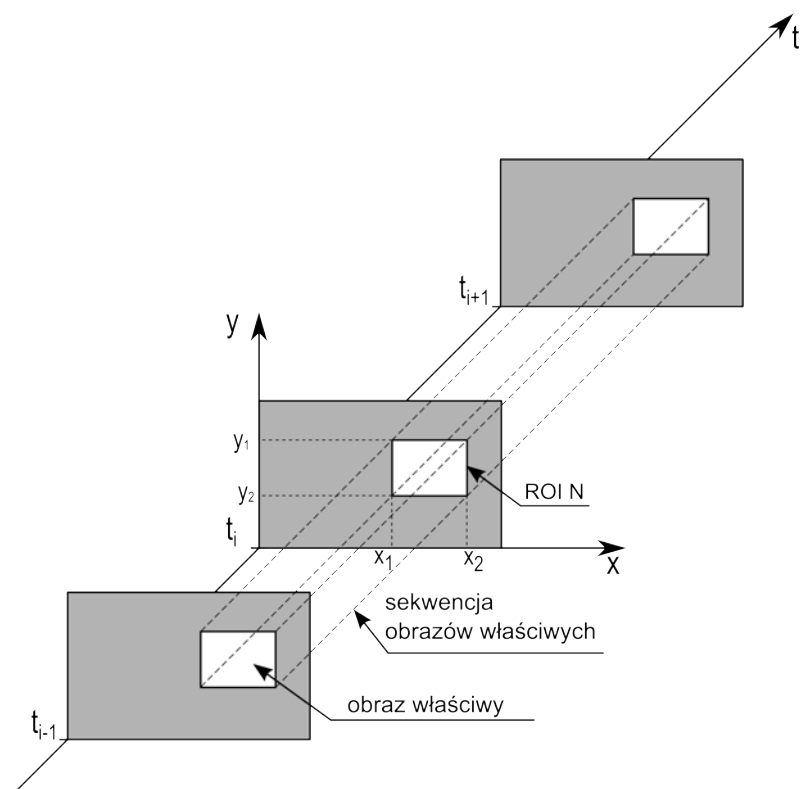
Rys. 4.11. Schemat możliwych sposobów postępowania z danymi diagnostycznymi w zaproponowanej koncepcji diagnozowania

Należy założyć, że rozmiar obszaru zainteresowania jest mniejszy od rozmiaru obrazu pierwotnego i przedmiotem dalszej analizy jest fragment obrazu określony przez obszar zainteresowania. Z tego powodu fragment obrazu ograniczony obszarem zainteresowania będzie w dalszych rozważaniach nazywany obrazem właściwym (rys. 4.13). Jeśli zdefiniowanych

zostanie kilka obszarów zainteresowania, będzie się to wiązało z koniecznością analizy kilku obrazów właściwych według odrębnej strategii opracowanej niezależnie dla każdego z nich. Rozpatrywanie kilku różnych obszarów zainteresowania pozwala również na uwzględnienie możliwości analizy kontekstowej [138] pozwalającej zidentyfikować wzajemne związki między danymi diagnostycznymi wyznaczonymi w tych obszarach.



Rys. 4.12. Definiowanie obszarów zainteresowania



Rys. 4.13. Sposób definiowania obrazu właściwego

Na potrzeby dalszych rozważań przyjęto, że rozpatrywana będzie pojedyncza sekwencja obrazów właściwych powstała na podstawie jednego obszaru zainteresowania, co uwzględniono na rysunku 4.11. Całe rozumowanie może być powtórzone dla obrazów właściwych powstałych w wyniku zdefiniowania innych obszarów zainteresowania. Dla poprawy jakości obrazów właściwych można rozpatrywać różne metody przetwarzania przedstawione w rozdziale 2.5. Dobór odpowiednich metod powinien być wynikiem wstępnych badań, tak aby wyeliminować możliwość zniekształcenia i zafałszowania informacji diagnostycznej zawartej w obrazie pierwotnym.

4.5.1.2. Analiza właściwych obrazów podczerwieni

Obrazy właściwe stanowią podstawę do ich dalszej analizy. Należy jednak pamiętać, że dzięki zastosowaniu odpowiednich przekształceń można otrzymać reprezentację obrazów właściwych w innej dziedzinie wartości. Przekształcone obrazy właściwe można nazwać obrazami dodatkowymi i poddawać je również równoległej analizie razem z obrazami właściwymi. Obrazami dodatkowymi mogą być m.in. F-obrazy, amplitudogramy i fazogramy powstałe w wyniku stosowania jednowymiarowej i/lub dwuwymiarowej transformaty Fouriera lub obrazy aproksymacji i szczegółów powstałe w wyniku stosowania transformaty falkowej. Na tym etapie analizy obrazów możliwe jest również zastosowanie przekształceń przestrzenno-czasowych całych sekwencji zarówno obrazów właściwych, jak i dodatkowych. Mogą to być przekształcenia bazujące na analizie składowych głównych, analizie czynnikowej itp. Wyznaczenie obrazów dodatkowych rozszerza przestrzeń wartości poddawanych dalszej ocenie w celu wyznaczenia cech obrazów. Cechy mogą być wyznaczane w obrębie całego obszaru obrazu właściwego lub dodatkowego. Są jednak również sytuacje, gdy na obrazie właściwym można w wyniku zastosowania segmentacji wydzielić obszar, w obrębie którego z wartości punktów obrazu mogą być wyliczone różnego rodzaju cechy. Z tego powodu wprowadza się pojęcie obszaru analizy ROA (ang. *Region Of Analysis*) (rys. 4.14), będącego fragmentem obrazu właściwego lub dodatkowego, na podstawie którego możliwe jest wyznaczenie specyficznych cech istotnych dla charakterystycznego obszaru, a mogących być również cechami reprezentatywnymi dla całego obrazu właściwego. Zakłada się, że obszar analizy może mieć dowolne kształty, a jego rozmiary graniczne nie powinny być większe niż rozmiary obrazu właściwego. Szczególnym przypadkiem obszaru analizy jest obraz właściwy.

Cechy obrazów termograficznych

Na podstawie obrazów właściwych, dodatkowych i obrazów będących wynikiem przekształceń przestrzenno-czasowych, a także z obszarów analizy ROA zawierających się w tych obrazach, mogą być wyznaczane różne cechy. Cechy można podzielić na dwie grupy: cechy jakościowe oraz cechy ilościowe. Wśród cech jakościowych można wyróżnić takie jak, np.: ujawnianie się punktów lokalnych o odmiennej charakterystyce cieplnej, podwyższona temperatura w określonym obszarze maszyny. Cechy te można uwzględnić przy budowie reguł diagnostycznych dla np. układów wnioskujących systemów doradczych. Cechy jakościowe mogą być określone przez operatora w trakcie analizy zarejestrowanych obrazów. Z punktu widzenia automatyzacji zadań diagnozowania duże znaczenie mają cechy ilościowe, które można podzielić na cechy bezwzględne i cechy względne. Cechy bezwzględne można wyznaczyć bezpośrednio na podstawie obrazów termograficznych reprezentowanych w różnych przestrzeniach wartości. Jako cechy względne należy rozumieć cechy, które mogą być wyznaczone na podstawie porównania ze sobą wybranych obszarów w obrębie pojedynczego obrazu, porównania obrazów właściwych rozpatrywanych w różnych punktach



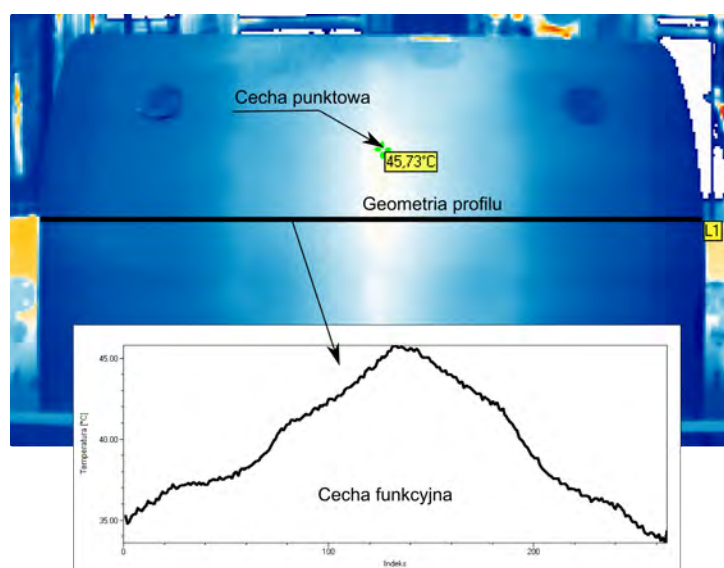
Rys. 4.14. Idea obszaru analizy (ROA)

przestrzeni obrazów pierwotnych (różnych obszarów zainteresowania) i/lub porównania obrazów zarejestrowanych w różnych chwilach obserwacji termograficznej. Mogą to być również cechy wynikające z porównania obrazów z określonymi wzorcami wyznaczonymi w ramach eksperymentów diagnostycznych lub symulacji modeli numerycznych. Najprostszym przykładem cechy względnej jest różnica $v_r = g_i(m, n) - g_{i-1}(m, n)$ między wartością obrazu $g_i(m, n)$ o współrzędnych m i n zarejestrowanego w chwili czasu i a wartością obrazu o tych samych współrzędnych zarejestrowanego w chwili poprzedniej $i - 1$.

Cechy ilościowe są najczęstszym rodzajem danych branych pod uwagę w procesie diagnozowania. Cechy ilościowe mogą być sklasyfikowane na cechy liczbowe (punktowe) lub cechy funkcyjne (rys. 4.15). Za cechy liczbowe można uznać zarówno wartości punktów obrazu o odpowiednich współrzędnych lub wartości wyznaczone ze zbiorów punktów obrazów należących do obszarów analizy (ROA), np. parametry statystyczne, bezwzględne parametry kształtu itp. Za interesującą grupę cech liczbowych można uznać względne cechy topologiczne i/lub geometryczne opisujące np. wzajemne relacje zachodzące w kilku obszarach analizy.

Poza cechami liczbowymi wyznaczone mogą być również cechy funkcyjne. Cechami funkcyjnymi mogą być, np. profile wartości obrazów dla zdefiniowanych obiektów geometrycznych (prostych lub krzywych), funkcje powstałe w wyniku porównania różnych zbiorów punktów obrazu, np. funkcje korelacji, widma itp. Cech funkcyjnych nie należy utożsamiać tylko z funkcjami jednowymiarowymi, mogą to być funkcje wielowymiarowe. Cechy funkcyjne stanowią cel dodatkowej analizy, w wyniku której możliwe jest pozyskanie dodatkowego zbioru cech liczbowych.

Do cech obrazów termograficznych można również zaklasyfikować tzw. cechy heurystyczne. Cechą heurystyczną można nazwać każdą cechę określoną w wyniku analizy istoty zjawiska fizycznego poddanego obserwacji w podczerwieni. Są to cechy określone na podstawie badań wstępnych i stosowania metod heurystycznych oraz pozwalają skutecznie opisywać specyficzne zjawiska charakterystyczne tylko dla określonych obiektów technicznych lub procesów przemysłowych.



Rys. 4.15. Przykład cechy liczbowej i cechy funkcyjnej obrazu termograficznego

Szerokie możliwości wyznaczania różnych klas cech obrazów termograficznych mogą skutkować powstaniem dużego zbioru cech, z którego należy wybrać cechy relewantne. Wybór ten może być przeprowadzony w wyniku zastosowania odpowiednich operacji selekcji i ekstrakcji cech.

4.5.1.3. Przetwarzanie i analiza sygnałów diagnostycznych

Wybrane w wyniku selekcji lub ekstrakcji optymalne (relewantne) cechy liczbowe i cechy funkcyjne, uporządkowane w czasie, pozwalają na wyznaczenie jednowymiarowych i wielowymiarowych sygnałów diagnostycznych obrazujących przebieg zmian wartości cechy w funkcji czasu. Tego typu sygnały stanowią przedmiot dalszego przetwarzania i analizy. Na podstawie sygnałów wielowymiarowych poprzez zastosowanie odpowiednich operacji przekształcania przestrzeni ich wartości, np. poprzez stosowanie analizy składowych głównych (PCA), można wyznaczyć sygnały jednowymiarowe, a także cechy funkcyjne (np. przebieg korelacji wzajemnej, widmo sygnału itp.), które poddane analizie pozwalają uzupełnić zbiór cech liczbowych jednowymiarowych sygnałów diagnostycznych. Zagadnienia przetwarzania i analizy sygnałów jednowymiarowych stanowią bardzo dobrze opisaną [20, 75, 160] i ciągle rozwijaną dziedzinę nauki, toteż szczegółowa dyskusja dotycząca metod analizy sygnałów została pominięta.

4.5.1.4. Przestrzenie obrazów cech

Zbiór cech liczbowych i funkcyjnych sygnałów diagnostycznych stanowi podstawę do dalszych działań prowadzących do identyfikacji i oceny stanu technicznego rozpatrywanego obiektu. Uzyskany w wyniku analizy sygnałów diagnostycznych zbiór cech może być bardzo duży i zawierać poza cechami istotnymi dla oceny stanu technicznego obiektu również cechy redundantne mogące wprowadzać szum informacyjny. Podstawowym działaniem poprzedzającym ocenę stanu technicznego jest selekcja i/lub ekstrakcja cech relewantnych sygnałów diagnostycznych.

Cechy relewantne sygnałów diagnostycznych mogą utworzyć pewną wielowymiarową przestrzeń wartości cech, w której cechy tworzą charakterystyczny dla danego stanu

technicznego obraz (wzorzec) w przestrzeni cech. Odpowiednio manipulując i przekształcając przestrzeń wartości cech, możliwe jest uzyskanie obrazu (wzorca) definiującego relację diagnostyczną między stanem obiektu a wartościami cech sygnałów diagnostycznych. Dysponując odpowiednią liczbą wzorców danych pochodzących z różnych chwil eksploatacji obiektu i opisujących jego różne stany techniczne, możliwe jest rozpoznawanie i identyfikowanie bieżącego stanu technicznego obiektu poprzez realizację np. zadania klasyfikacji.

Zarówno operacje przekształceń przestrzeni obrazów cech, jak i rozpoznawanie stanu obiektu mogą być realizowane z zastosowaniem różnych metod z dziedzin inżynierii wiedzy, jak również sztucznej inteligencji. Metody te streszczono w rozdziale 2.7.

5. Przykłady zastosowania metodyki

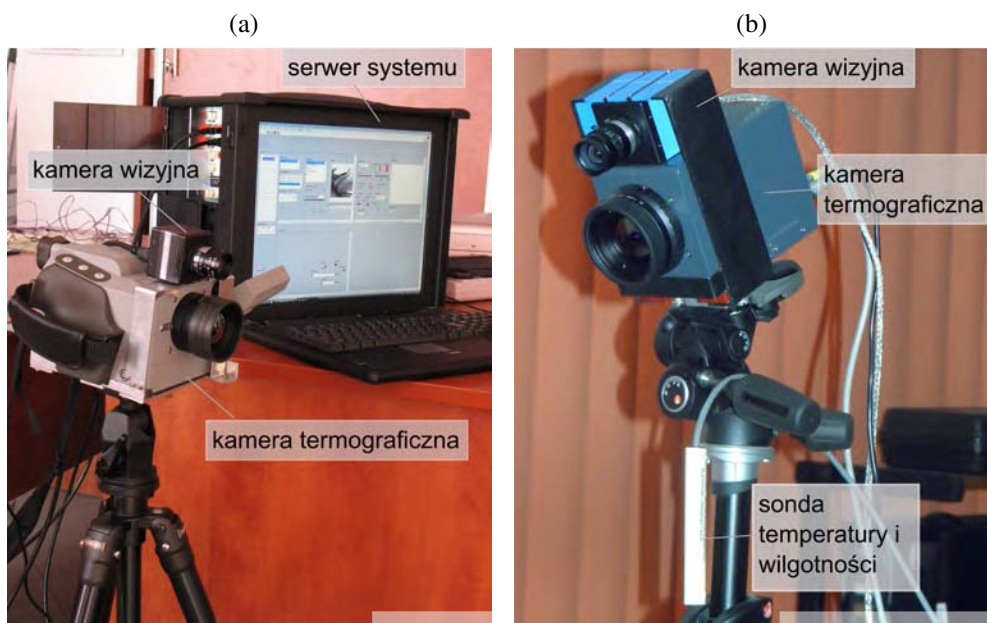
Zaproponowaną w poprzednim rozdziale metodykę zastosowano w różnych przypadkach diagnozowania stanu obiektów technicznych i procesów przemysłowych. Poniżej przedstawiono wybrane przykłady pokazujące różne podejścia do każdego z etapów proponowanej metodyki.

5.1. Przykład systemu termograficznego monitorowania obiektów i procesów

Na podstawie zaproponowanej koncepcji systemu termograficznego monitorowania i diagnozowania obiektów (por. 5.1) opracowano wersję prototypową systemu, którą przetestowano w warunkach laboratoryjnych i przemysłowych.

Ze względu na ograniczenia finansowe strukturę systemu ograniczono do głowicy obserwacyjnej i serwera systemu, który pełnił jednocześnie funkcję komputera głowicy. Układ pozycjonowania zrealizowano na bazie ręcznie regulowanej głowicy panoramicznej stosowanej w statywach fotograficznych. Część sprzętowa systemu skompletowana została z elementów zakupionych ze środków projektów badawczych zrealizowanych w Instytucie Podstaw Konstrukcji Maszyn. W trakcie trwania badań przygotowano dwie generacje systemu różniące się głównie elementami głowicy oraz modułami oprogramowania. W pierwszej generacji głowica obserwacyjno-pomiarowa zbudowana została z kamery termowizyjnej (VarioCam firmy Infratec) z niechłodzonym detektorem bolometrycznym i pozwalająca pozyskiwać obrazy o rozdzielczości 320×240 pikseli z maksymalną prędkością 50 Hz. Do obserwacji w świetle widzialnym zastosowano monochromatyczną kamerę (DMK21AF04 firmy ImagingSource) z matrycą CCD o rozdzielczości 640×480 pikseli. W drugiej generacji systemu zastosowano kamerę termowizyjną (VarioCam Head firmy Infratec) z niechłodzonym detektorem bolometrycznym o rozdzielczości 640×480 pikseli i obudowie przemysłowej. Kamera wizyjna pozostała bez zmian. W obu generacjach głowicy kamery zostały zintegrowane za pomocą samodzielnie zaprojektowanych i wytworzonych adapterów mocujących kamerę wizyjną z kamerą termowizyjną oraz zapewniających odpowiednie ustawienie osi optycznych kamer (rys. 5.1). Osie optyczne pokrywały się ze sobą w płaszczyźnie pionowej i były przesunięte względem siebie w pionie o 70 mm i 60 mm odpowiednio w pierwszej i drugiej generacji głowicy.

W obu generacjach systemu kamery pozwalały na stosowanie wymiennych obiektów dobieranych w zależności od obiektu obserwacji. Kamery termowizyjne wyposażane były w obiektywy 25 mm i 50 mm. Dla kamer wizyjnych dostępne były obiektywy o ogniskowych 8, 16, 25 i 50 mm. Kamery zastosowane w głowicy fabrycznie posiadały zainstalowane interfejsy FireWire (IEEE 1394) umożliwiające współpracę z komputerem. Na potrzeby kontroli parametrów środowiskowych głowicę obserwacyjno-pomiarową wyposażono w zintegrowany czujnik temperatury i wilgotności (EI-1050 firmy Electronic Innovations Corporation), który połączono z kartą przetwornika analogowo-cyfrowego (LabJack U12), wyposażonego w interfejs USB pozwalający na komunikację z komputerem. Za serwer systemu posłużył wydajny komputer klasy PC w przenośnej obudowie przemysłowej



Rys. 5.1. Pierwsza (a) i druga (b) generacja głowicy obserwacyjnej prototypowego systemu termograficznego monitorowania obiektów i procesów

cechującej się dużą odpornością na działanie czynników zewnętrznych. Poza standardowymi interfejsami wejścia–wyjścia (m.in. USB) komputer dodatkowo wyposażono w dwa interfejsy FireWire pozwalające podłączyć kamery głowicy obserwacyjnej. Na dysku twardym serwera systemu, poza systemem operacyjnym i niezbędnymi sterownikami obsługującymi część sprzętową, zainstalowano biblioteki programistyczne zawierające funkcje pozwalające na obsługę urządzeń głowicy obserwacyjno-pomiarowej. Uwzględniając prototypowy charakter proponowanego systemu monitorowania oraz konieczność zapewnienia dużej elastyczności w zakresie jego modyfikacji i rozbudowy, zdecydowano, że aplikacja kliencka systemu zostanie zrealizowana samodzielnie w środowisku programistycznym LabView. Środowisko LabView zapewnia duże możliwości w obsłudze różnego rodzaju aparatury pomiarowej i standardów komunikacyjnych oraz baz danych. Aplikację kliencką systemu zaprojektowano w taki sposób, aby miała ona strukturę modułową. Jądem całej aplikacji jest serwer modułów. Pełni on funkcję nadrzędną względem innych modułów, a do jego podstawowych zadań można zaliczyć:

- uruchamianie i zatrzymywanie poszczególnych modułów funkcjonalnych,
- nadzorowanie przepływu danych pomiędzy modułami,
- synchronizację działania modułów,
- obsługę zmiennych konfiguracyjnych (globalnych) niezbędnych do poprawnego funkcjonowania systemu.

Ze względu na charakter systemu niektóre z modułów mogą być w czasie normalnej pracy systemu wielokrotnie uruchamiane i zatrzymywane w celu zmniejszenia rozmiaru wykorzystywanej pamięci. Podczas prac nad systemem opracowano moduły pozwalające na:

- konfigurację i buforowaną akwizycję obrazów z kamer działających w świetle widzialnym,
- konfigurację i buforowaną akwizycję obrazów z kamery termowizyjnej,
- konfigurację i buforowaną akwizycję danych z sondy temperatury i wilgotności,
- zapis obrazów z kamer na dysku komputera,
- komunikację i obsługę bazy danych systemu,
- zapis wartości temperatur i wilgotności do bazy danych,

- dopasowanie obrazów wizyjnych i termowizyjnych,
- fuzję obrazów wizyjnych i termowizyjnych,
- określanie regionów zainteresowań (ROI) na obrazach i zapis ROI w postaci obrazów na dysku,
- progowanie obrazów termowizyjnych wyodrębnionych w ramach obszarów zainteresowań,
- wyznaczanie cech statystycznych obrazów wizyjnych i termowizyjnych,
- wyznaczanie cech geometrycznych obiektów na obrazach termograficznych.

Procedury akwizycji obrazów oraz sygnałów pomocniczych działały w sposób synchroniczny poprzez generowanie w module serwera sygnału wyzwalającego pobranie danych z urządzeń głowicy obserwacyjno-pomiarowej. Zapewniono możliwość sterowania częstotliwością akwizycji danych. Każdy z modułów akwizycji posiada również możliwość pracy z lokalną częstotliwością wyzwalania, co pozwala na realizację dowolnej z przyjętych strategii obserwacji termograficznej. Modułowa struktura systemu i rozdzielenie zadań akwizycji oraz zapisu umożliwiły wykorzystanie wielowątkowości z automatycznym przydziałem rdzeni procesora realizowanym przez środowisko LabView.

Wielomodalne dane generowane podczas działania termograficznego systemu monitorowania i diagnostyki zapisywane były w specjalnie do tego celu opracowanej relacyjnej bazie danych [44], którą utworzono w darmowym systemie MySQL. Moduł aplikacji głównej odpowiedzialny za obsługę omawianej bazy danych został zaimplementowany w środowisku LabView. Podczas implementacji aplikacji obsługującej bazę danych poza standardowymi funkcjami dostępnymi w oprogramowaniu LabView posłużono się darmową biblioteką `sql_LV`, która pozwalała na dostęp do funkcji biblioteki DLL komunikującej się z serwerem bazy danych poprzez interfejs ODBC oraz bezpośrednio wykonywanie skryptów SQL z poziomu środowiska LabView a co za tym idzie:

- otwieranie i zamykanie połączenia z serwerem,
- wyświetlenie listy tabel,
- przeglądanie zawartości tabel,
- zapis i odczyt danych z bazy,
- kasowanie rekordów z bazy.

Opracowana baza danych pozwala na gromadzenie danych o obserwowanych obiektach, urządzeniach pomiarowych, rejestrowanych sygnałach oraz ich cechach, jak również gromadzenie wartości cech stanów technicznych i decyzje podejmowane przez układ wnioskowania diagnostycznego. Na rysunku 5.2 zaprezentowano strukturę opracowanej bazy danych, w której można wyróżnić następujące tabele:

objects – zawierająca podstawowe informacje o obserwowanym obiekcie, takie jak: nazwa, typ, numer seryjny, data produkcji oraz krótki opis;

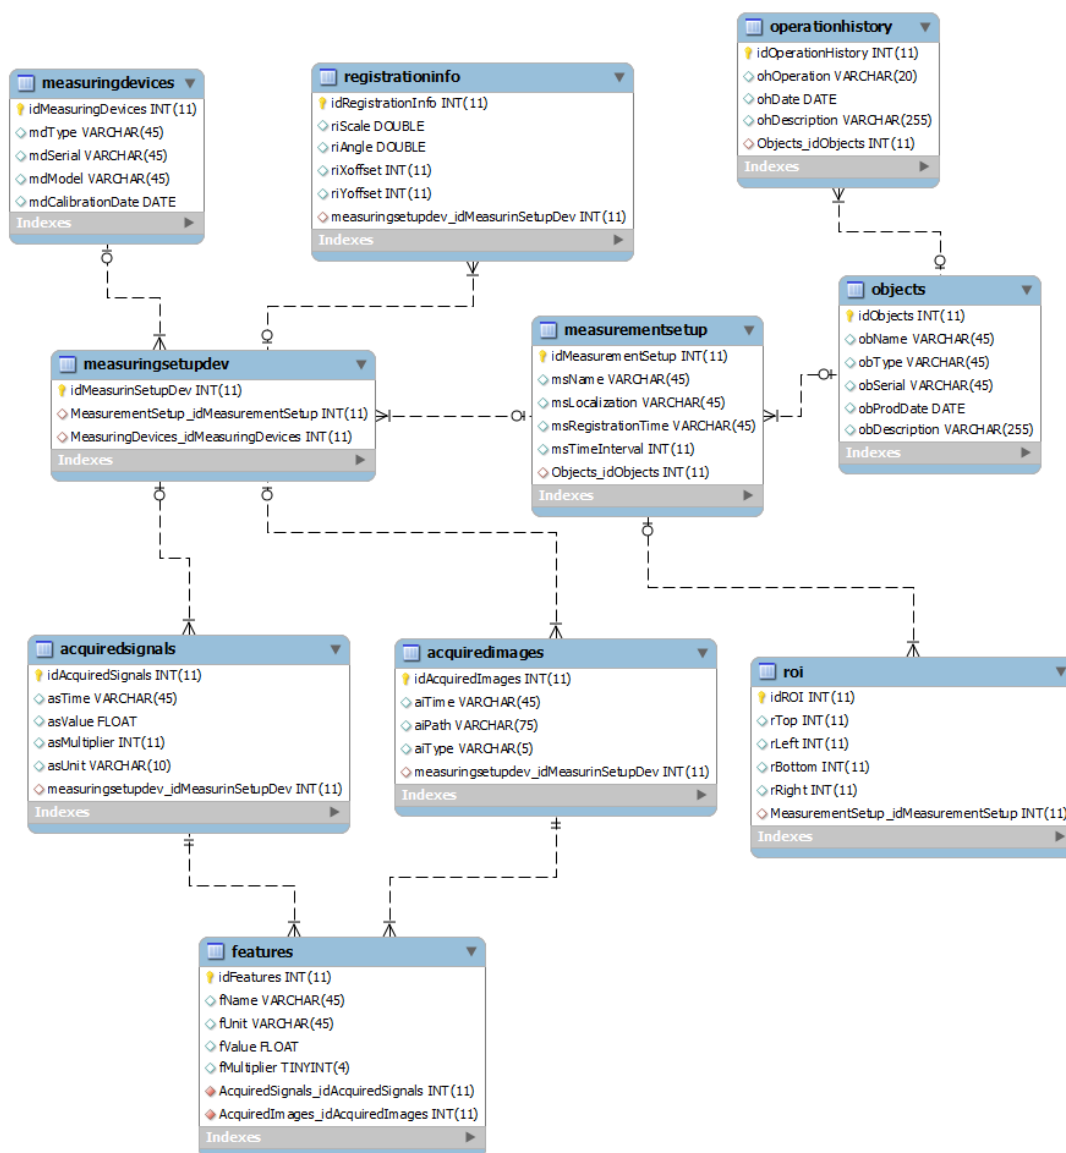
operationhistory – pozwalająca zapisywać informacje o historii użytkowania obiektu (remonty, przeglądy, awarie, naprawy itp.), wraz z krótkim opisem każdego działania;

measuringdevices – przeznaczona do gromadzenia informacji o urządzeniach wykorzystywanych do różnorodnych pomiarów. Umożliwia zapisanie informacji o typie, modelu i numerze seryjnym urządzenia oraz dacie ostatniej kalibracji;

measuerementsetup – przeznaczona do gromadzenia informacji o przeprowadzonych pomiarach. W tej tabeli zawarto nazwę przeprowadzonej operacji, czas i miejsce operacji oraz id obserwowanego obiektu;

measurementsetupdev – umożliwiająca przyporządkowanie urządzeń pomiarowych do aktualnie przeprowadzonego pomiaru;

- registrationinfo** – zawierająca parametry dopasowania pomiędzy obrazami dla danego zestawu kamer;
- acquiredimages** – służąca do przechowywania informacji o zarejestrowanych obrazach, takich jak ścieżka obrazu, typ obrazu, czas akwizycji;
- acquiredsignals** – wykorzystywana do gromadzenia chwilowych wartości zarejestrowanych sygnałów dodatkowych. Dodatkowo możliwe jest zapisanie jednostki mierzonej wielkości oraz czas rejestracji;
- roi** – zawierająca współrzędne obszarów zainteresowań, które mogą być definiowane podczas obserwacji obiektu;
- features** – zawierająca typ, wartość oraz jednostkę wyznaczonej cechy, dla pojedynczego obrazu lub dla danego sygnału diagnostycznego uzyskanego w wyniku przetwarzania zgromadzonych danych.



Rys. 5.2. Struktura relacyjnej bazy danych zaimplementowanej w systemie termograficznego monitorowania obiektów

Wszystkie zarejestrowane obrazy i realizacje sygnałów zapisywano na dysku lokalnym serwera systemu w katalogach o odpowiedniej strukturze. Na dysku lokalnym utworzono folder główny o nazwie `CurrentData`, w którym zapisywane są pliki z danymi pozyskiwanymi podczas pomiarów. Dane z każdego pomiaru zapisywane są w podfolderze, którego nazwa tworzona jest w sposób automatyczny na podstawie danych zawartych w bazie i informacji przekazywanych przez system monitorowania. Nazwa podkatalogu wskazuje na czas, w którym rozpoczęto pomiar. W podkatalogu znajdują się jeszcze dwa subfoldery o nazwach `Images` i `Signals`, w których zapisywane są pliki. Nazwa każdego z plików zapisanych w odpowiednim podkatalogu składa się z identyfikatora urządzenia pomiarowego i identyfikatora chwili czasu, w którym zapisano dane do pliku.

Ze względu na znaczny rozmiar i liczbę plików, jakie mogą być zapisywane, dla każdego z urządzeń pomiarowych w aplikacji klienckiej obsługującej bazę zaimplementowano procedurę automatycznego zastępowania podkatalogów ze zgromadzonymi w trakcie obserwacji danymi (`SnapId`), (obrazami, sygnałami itp.) ich wersjami skompresowanymi. Kompresowanie może następować w stałych, określonych przez użytkownika odstępach czasowych (np. odpowiedni dzień miesiąca, każdego dnia o określonej godzinie itp.) i dotyczyć podkatalogów historycznych z ustalonego czasu.

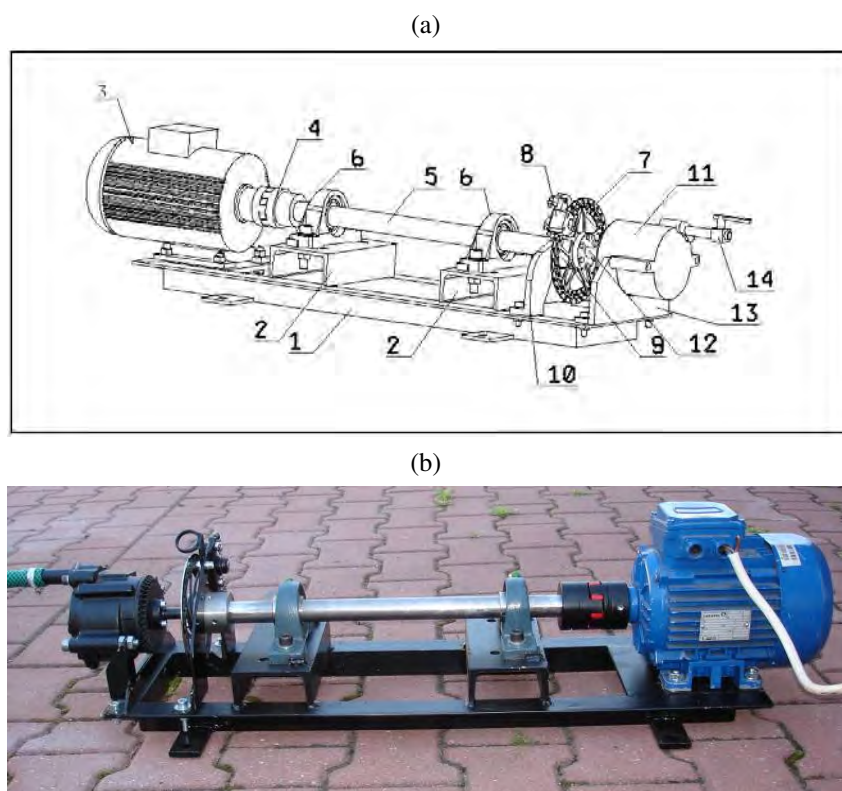
Bazę danych wyposażono w procedury zapewniające sporządzanie kopii bezpieczeństwa zgodnie z określonym harmonogramem, np. kilka razy w miesiącu w ustalonych dniach lub tworzenie kopii bezpieczeństwa w sposób wymuszony przez użytkownika w dowolnym momencie działania aplikacji. Do wykonywania kopii zapasowych bazy wykorzystano program `MySqlDump`. Pozwala on na tworzenie niezależnych od platformy systemowej plików tekstowych zawierających pełną kopię zawartości bazy, która dzięki temu może również zostać przeniesiona na inny serwer SQL (niekoniecznie MySQL). Dodatkowo program umożliwia eksport bazy danych do pliku typu CSV lub XML. Ze względu na rozdzielenie sposobu przechowywania obrazów i sygnałów od pozostałych danych zaproponowano rozwiązanie polegające na dołączaniu skompresowanych kopii tych danych do kopii zapasowej.

Obsługa bazy danych odbywa się z poziomu graficznego interfejsu użytkownika całego systemu monitorowania. Graficzny interfejs użytkownika pozwala na intuicyjne wprowadzanie danych do bazy danych oraz przeglądanie i zarządzanie bazą danych w stopniu pozwalającym na zapewnienie prawidłowego działania całej aplikacji.

Prototypy pierwszej i drugiej generacji systemu termograficznego monitorowania zastosowano na potrzeby pozyskiwania danych badawczych w trakcie obserwacji termograficznych wybranych obiektów technicznych. Obserwacje prowadzono w warunkach laboratoryjnych i przemysłowych. Dane zarejestrowane w trakcie obserwacji posłużyły do weryfikacji zaproponowanej metodyki diagnozowania bazującej na obrazach termograficznych.

5.2. Przykład termograficznego diagnozowania laboratoryjnego modelu maszyny

Opracowany system termograficznego monitorowania obiektów technicznych (por. 5.1) przetestowano w trakcie czynnych eksperymentów diagnostycznych prowadzonych na stanowisku laboratoryjnym zlokalizowanym w Pracowni Diagnostyki Technicznej Instytutu Podstaw Konstrukcji Maszyn. Celem prowadzonych eksperymentów było pozyskanie sekwencji obrazów termograficznych na potrzeby weryfikacji zaproponowanej metodyki diagnozowania obiektów technicznych. Przyjęto, że przedmiotem obserwacji będzie obiekt techniczny należący do klasy maszyn wirnikowych. Uwzględniając takie kryteria jak m.in. możliwość szybkiej modyfikacji struktury mechanicznej obiektu, możliwość wprowadzania i symulacji różnego rodzaju niesprawności czy obserwowalność zjawisk cieplnych, zdecydowano się na zaprojektowanie i wykonanie laboratoryjnego modelu maszyny wirnikowej. Model bryłowy obiektu oraz wykonaną maszynę przedstawiono na rysunku 5.3.



Rys. 5.3. Laboratoryjny model maszyny wirnikowej poddany obserwacji termograficznej; (a) model bryłowy CAD; (b) maszyna wytworzona na podstawie dokumentacji projektowej

Podstawowymi elementami składowymi zaprojektowanego i wytworzonego modelu fizycznego maszyny wirnikowej były (wg rys. 5.3(a)):

- 1) rama stalowa,
- 2) wsporniki podpór łożyskowych,
- 3) silnik elektryczny prądu przemiennego o mocy 1,5 kW i obrotach znamionowych 2835 obr/min sterowany falownikiem,
- 4) sprzęgło kłowe,
- 5) wał stalowy,

- 6) zespoły łożyskowe (oprawa z łożyskiem samonastawnym),
- 7) tarcza hamulcowa (rowerowa),
- 8) mechaniczny zacisk hamulcowy współdziałający z tarczą i przeznaczony do wprowadzania obciążenia,
- 9) sprzęgło mocujące tarczę do wału,
- 10) uchwyt mocujący zacisk hamulcowy do ramy,
- 11) pompa powietrza,
- 12) sprzęgło łączące pompę powietrza z wałem napędowym,
- 13) uchwyt mocujący pompę powietrza do ramy,
- 14) zawór kulowy przeznaczony do dławienia powietrza z pompy.


Maszyna została zaprojektowana w taki sposób, aby możliwe było zaplanowanie badań, w trakcie których mogłyby być symulowane różne stany techniczne, takie jak:

- maszyna całkowicie sprawna;
- maszyna działająca pod różnym obciążeniem wywoływanym przez pompę powietrza. Zmiana obciążenia odbywała się poprzez dławienie strumienia powietrza wyjściowego z pompy za pomocą zaworu kulowego. Stopień dławienia regulowano ręcznie w pełnym zakresie działania zaworu;
- maszyna działająca pod obciążaniem wprowadzanym za pomocą hamulca tarczowego;
- maszyna działająca pod obciążeniem wprowadzanym za pomocą hamulca tarczowego dodatkowo chłodzonego powietrzem wylotowym z pompy;
- maszyna działająca z poluzowaną oprawą łożyskową;
- niesprawność węzła łożyskowego poprzez montaż uszkodzonego łożyska kulkowego;
- przycieranie klocków hamulcowych o tarczę hamulcową;
- niewyosiowanie linii wałów.

5.2.1. Eksperymenty diagnostyczne

Wytworzony model maszyny wirnikowej wykorzystano do realizacji czynnych eksperymentów diagnostycznych, w trakcie których prowadzono cykliczną obserwację termograficzną i pozyskiwano obrazy termograficzne maszyny. W tym celu przygotowano stanowisko badawcze składające się z uprzednio wytworzonej maszyny zamocowanej do stalowych podstaw oraz kamery termograficznej usytuowanej w odległości $L = 1600$ mm od obiektu (rys. 5.4). W trakcie realizacji eksperymentów diagnostycznych system termograficznego monitorowania był w trakcie opracowywania i wykorzystano tylko podstawowe moduły oprogramowania systemu, m.in. moduł do akwizycji obrazów termograficznych. Głowica obserwacyjna składała się tylko z kamery termograficznej.

Na podstawie wcześniej przeprowadzonych testów maszyny wirnikowej przyjęto prędkość obrotową silnika wynoszącą 1200 obr/min. Obrazy termograficzne pozyskiwano co 30 sekund. Kamerę termowizyjną skonfigurowano, wprowadzając odpowiednie ustawienia dotyczące temperatury ścieżki pomiarowej, temperatury otoczenia, odległości między obiektem i kamerą oraz emisyjności powierzchni obserwowanego obiektu. Ze względu na zróżnicowany charakter powierzchni obserwowanego obiektu przyjęto średnią emisyjność równą 0,8. W kamerze termowizyjnej ustawiono tryb automatycznego dopasowania poziomu temperaturowego, a interwał kompensacji dryftu temperaturowego wynosił 60 sekund. Przeprowadzono szereg eksperymentów, w trakcie których symulowano następujące stany techniczne:



Rys. 5.4. Stanowisko badawcze stosowane w trakcie prowadzenia laboratoryjnych eksperymentów diagnostycznych

Stan S1 – obiekt sprawny – za obiekt sprawny uznano maszynę wyosiowaną bez zadanego obciążenia, z otwartym zaworem kulowym na pompie powietrza, sprawne i nasmarowane łożyska. Stan S1 obejmował okres działania maszyny od chwili uruchomienia ze stanu zimnego do chwili ustabilizowania się temperatur poszczególnych elementów maszyny na stałym poziomie.

Stan S2 – Praca z obciążeniem wywołanym 50% dławieniem strumienia powietrza wytwarzanego przez pompę – w stanie tym, poza zmianą ustawienia zaworu dławiącego pozostałe cechy stanu pozostawiono takie same jak w stanie sprawnym S1. Maszynę do stanu S2 wprowadzono bezpośrednio ze stanu S1 bez jej zatrzymywania.

Stan S3 – Praca z obciążeniem wywołanym 90% dławieniem strumienia powietrza wytwarzanego przez pompę – w stanie tym, poza zmianą ustawienia zaworu dławiącego pozostałe cechy stanu pozostawiono takie same jak w stanie sprawnym S1. Maszynę do stanu S3 wprowadzono bezpośrednio ze stanu S2 bez jej zatrzymywania.

Stan S4 – Praca z poluzowaną oprawą łożyskową nr 2 i obciążeniem wywołanym 90% dławieniem strumienia powietrza wytwarzanego przez pompę. Maszynę do stanu S4 wprowadzono bezpośrednio ze stanu S3 bez jej zatrzymywania.

Stan S5 – Praca z obciążeniem wywołanym hamulcem tarczowym – poziom obciążenia dobrano eksperymentalnie w trakcie badań wstępnych. Maszynę do stanu S5 wprowadzono bezpośrednio ze stanu S1 bez jej zatrzymywania.

Stan S6 – Praca z niesprawnym łożyskiem zespołu łożyskowego nr 2 – niesprawność wywołano, usuwając środek smary i zanieczyszczając łożysko piaskiem.

W wyniku obserwacji termograficznej maszyny wirnikowej, w każdym z symulowanych stanów technicznych pozyskano sekwencje obrazów termograficznych. W tabeli 5.1 zestawiono czasy trwania każdej obserwacji oraz liczbę obrazów tworzących sekwencję zarejestrowaną w symulowanym stanie technicznym.

Tab. 5.1. Charakterystyka sekwencji obrazów podczerwieni zarejestrowanych w trakcie eksperymentów

Stan techniczny	Czas trwania obserwacji, min	Liczba zarejestrowanych obrazów
S1	120	240
S2	60	120
S3	60	120
S4	60	120
S5	60	120
S6	60	120

5.2.2. Przykład oceny stanu obiektu na podstawie statystycznej analizy obrazów termograficznych

Obrazy termograficzne zarejestrowane w trakcie eksperymentów diagnostycznych przeprowadzonych w warunkach laboratoryjnych poddano analizie statystycznej w celu identyfikacji stanu badanego obiektu. Przyjęty sposób postępowania prowadzący do identyfikacji stanu technicznego maszyny wirnikowej oparto na szczególnym przypadku zaproponowanego ogólnego algorytmu analizy obrazów termograficznych i składał się on z następujących kroków:

- definiowania obszarów zainteresowania i tworzenia sekwencji obrazów właściwych,
- ekstrakcji cech obrazów właściwych,
- wyznaczaniu cech statystycznych,
- selekcji cech statystycznych,
- detekcji zmian stanu na podstawie sygnałów diagnostycznych,
- rozpoznawania wzorców i klasyfikacji stanu technicznego.

5.2.2.1. Tworzenie sekwencji obrazów właściwych

Sekwencje obrazów termograficznych zarejestrowanych w trakcie eksperymentów diagnostycznych przeprowadzonych na maszynie wirnikowej 5.2.1 zostały poddane operacji wstępnego przetwarzania polegającej na zdefiniowaniu obszarów zainteresowania tworzących jednocześnie sekwencje obrazów właściwych poddanych dalszej analizie. Do celów badań zdefiniowano 5 obszarów zainteresowania (rys. 5.5):

ROI1 – obszar silnika,

ROI2 – obszar sprzęgła łączącego wał silnika i wał maszyny,


ROI3 – obszar podpory łożyskowej nr 1,

ROI4 – obszar podpory łożyskowej nr 2,

ROI5 – obszar pompy powietrza.

5.2.2.2. Ekstrakcja cech obrazów właściwych

Na potrzeby analizy statystycznej sekwencji obrazów właściwych przyjęto założenie, że każda wartość piksela obrazu może być potraktowana jako jego cecha. Podejście takie skutkuje koniecznością rozpatrywania licznego zbioru cech wymagającego ograniczenia. Jednym ze sposobów ograniczenia zbioru cech jest przeprowadzenie ich ekstrakcji i utworzenie nowego zbioru wartości poddawanych dalszej analizie.



Rys. 5.5. Obszary zainteresowania zdefiniowane na potrzeby pozyskania sekwencji obrazów właściwych

W rozpatrywanym przykładzie posłużono się pięcioma metodami ekstrakcji cech stosującymi:

- wektor histogramu,
- macierz gradientu,
- macierz rozkładu długości pasm RLM (ang. *Run-Lenght Matrix*),
- macierz zdarzeń COM (ang. *Co-Occurance Matrix*),
- model autoregresji (AR).

Krótką charakterystykę każdej z metod przedstawiono w dodatku A.

5.2.2.3. Wyznaczanie cech statystycznych

Zbiory przekształconych cech każdego obrazu właściwego poddano analizie statystycznej, w wyniku której dla każdego obrazu właściwego każdej z rozpatrywanej sekwencji wyznaczono 259 cech, w tym:


- 9 cech wyliczonych na podstawie wektora histogramu (wartość średnia, wariancja, skośność, kurtoza, percentyle 1%, 10%, 50%, 90% i 99%);
- 5 cech wyliczonych na podstawie macierzy gradientu (średnia bezwzględna gradientu, wariancja, skośność, kurtoza, odsetek wartości z niezerowym gradientem);
- 220 cech wyliczonych na podstawie macierzy zdarzeń (COM) (11 cech wyznaczonych dla macierzy zdarzeń uwzględniających pięć odległości między pikselami obrazu ($d = 1, 2, 3, 4, 5$) i cztery kierunki $\varphi = 0^\circ, 45^\circ, 90^\circ, 135^\circ$; przykładowo cecha o identyfikatorze $S(2, -2)Correlat$ jest współczynnikiem korelacji wyliczonym dla macierzy zdarzeń utworzonej dla odległości między pikselami $d = 2$ w kierunku $\varphi = 135^\circ$);
- 20 cech wyliczonych na podstawie macierzy rozkładu długości pasm (RLM) (5 cech takich jak: odwrotny moment uwydatnienia krótkich pasm, moment uwydatnienia długich pasm, niejednorodność poziomu szarości, niejednorodność pasm, część obrazu w pasmach, wyznaczono dla 4 kierunków $\varphi = 0^\circ, 45^\circ, 90^\circ, 135^\circ$);
- 5 cech wyliczonych na podstawie modelu autoregresji (AR) (cztery wybrane związki między pikselami $\theta_i = 1, \dots, 4$, odchylenie standardowe szumu).

Szczegółowe definicje i objaśnienia identyfikatorów cech statystycznych stosowanych w dalszej części pracy zamieszczono w dodatku A.

Analizę statystyczną przeprowadzono z zastosowaniem programu MaZda należącego do pakietu analizy i klasyfikacji obrazów teksturowych opracowanych w Instytucie Elektroniki Politechniki Łódzkiej w ramach międzynarodowego projektu badawczego COST-B11 pt. *Ilościowa analiza tekstury obrazów tomograficznych rezonansu magnetycznego* [133]. Programy udostępniono bezpłatnie do celów naukowych na stronie internetowej projektu [25].

5.2.2.4. Wstępna analiza sygnałów diagnostycznych



Wartości każdej z cech uporządkowane według czasu akwizycji każdego obrazu sekwencji można traktować jako sygnał diagnostyczny, na podstawie którego możliwa jest detekcja i identyfikacja zmian stanu technicznego obiektu. Na rysunku 5.6 przedstawiono przykładowe sygnały diagnostyczne będące przebiegami wartości średniej wyznaczonej na podstawie histogramów obrazów właściwych zdefiniowanych dla różnych podzespołów obserwowanej maszyny.



Rys. 5.6. Sygnały diagnostyczne wartości średniej wyznaczone w wyniku estymacji sekwencji właściwych obrazów termograficznych


Można zauważyć, że w niektórych przypadkach, np. dla obrazów właściwych pompy (ROI5), można zidentyfikować zmiany stanu technicznego. W przypadku podpór łożyskowych identyfikacja zmian stanu technicznego na podstawie sygnału wartości średniej jest trudna do przeprowadzenia. Na rysunkach 5.7 i 5.8 przedstawiono przykłady sygnałów diagnostycznych będących przebiegami kontrastu wyznaczonego dla dwóch różnych przypadków macierzy zdarzeń. Uwzględniano tylko przebiegi dla obszarów zainteresowania ROI3 i ROI4 obejmujących podpory łożyskowe. Widać, że przebiegi znacznie się różnią i każdy z nich w różnym stopniu pozwala na identyfikację zmian stanu technicznego. Jak pokazują wykresy przebiegu sygnału kontrastu, duży wpływ na jego wartości ma sposób ekstrakcji cech obrazów właściwych.

Uwzględniając charakter (liczebność i rodzaj cech) rozpatrywanego zbioru cech statystycznych, należy się spodziewać, że między niektórymi wartościami cech wystąpi silna korelacja, a inne cechy nie pozwolą na separację stanów technicznych.


Rys. 5.7. Sygnał diagnostyczny kontrastu dla macierzy zdarzeń $S(2,-2)$ Rys. 5.8. Sygnał diagnostyczny kontrastu dla macierzy zdarzeń $S(4,0)$

Na rysunku 5.9 przedstawiono przykładowy wykres rozkładu wartości cechy $Horz1_Fraction$ wyznaczonej w obrębie obszaru ROI3 wskazujący na bardzo słabą separację symulowanych stanów. W rozpatrywanym zbiorze cech istnieją również takie cechy np. $S(3,0)Contrast$, których wartości wyznaczone dla obszaru ROI3 pozwalają na separację pojedynczych stanów technicznych, np. stanu S4 (rys. 5.10).

Wstępna analiza wartości sygnałów diagnostycznych pokazuje, że aby można było skutecznie rozpoznawać stan techniczny, konieczny jest wybór zbioru cech relewantnych. W trakcie badań rozpatrywano kilka metod wyboru cech. Metody oraz wyniki ich stosowania przedstawiono poniżej.



Rys. 5.9. Przykład rozkładu wartości cechy uniemożliwiającej separację stanów



Rys. 5.10. Przykładowe wykresy wartości cech umożliwiających separację niektórych stanów


5.2.2.5. Selekcja cech z zastosowaniem współczynnika korelacji

Metoda współczynnika korelacji bazuje na korelacji liniowej Pearsona, którą dla dwóch zmiennych losowych X, Y można zdefiniować następującym wyrażeniem:


$$\rho = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{E((X - \mu_X)(Y - \mu_Y))}{\sigma_X \sigma_Y} \quad (5.1)$$

gdzie: μ_X, μ_Y są wartościami średnimi, σ_X i σ_Y to odchylenia standardowe, E operator wartości oczekiwanej, a cov oznacza kowariancję. Współczynnik Pearsona ρ określa stopień zależności liniowej między wartościami zmiennych X i Y i przyjmuje wartości z przedziału $[-1, 1]$, przy czym wartość ρ określa siłę zależności, a jej znak charakter (wprost/odwrotnie

proporcjonalne). Przykładowo $\rho = 1$ wskazuje na rosnącą zależność liniową, $\rho = -1$ informuje o malejącej zależności liniowej, a $\rho = 0$ o braku zależności między zmiennymi X i Y . W celu detekcji zależności nieliniowych dane mogą być poddane transformacji np. logarymicznej. W przypadku rozpatrywanego zbioru cech występuje wiele cech o wysokim stopniu zależności liniowej. Na rysunku 5.11 przedstawiono przykład zależności między dwiema cechami, dla których współczynnik korelacji wynosił $\rho = 0,99$.



Rys. 5.11. Przykład zależności między wartościami cech o współczynniku korelacji ($\rho = 0,99$)



Rys. 5.12. Przykład zależności między wartościami cech o współczynniku korelacji ($\rho = 0,88$)

Cechy o wysokim współczynniku korelacji są cechami redundantnymi. W celu oceny stanu obiektu z rozpatrywanej pary cech należy wybrać jedną z nich, przy czym konieczne jest podjęcie decyzji, którą z dwóch cech wybieramy. Jednym ze sposobów wyboru jest sprawdzenie relacji funkcyjnej z innymi cechami. Poza cechami mocno skorelowanymi można wskazać

cechy, dla których współczynnik korelacji jest nieznacznie mniejszy od wartości 1. Przykład zależności między cechami skorelowanych ze sobą na poziomie $\rho = 0,88$ zaprezentowano na rys. 5.12.

Bazując na wyznaczonych współczynnikach korelacji, dla każdej sekwencji obrazów właściwych wybrano podzbiory cech, których współczynniki korelacji spełniały warunek $\rho < 0,85$. Liczebności i identyfikatory poszczególnych cech zebrano w tabeli 5.2.

Tab. 5.2. Podzbiory cech statystycznych obrazów termograficznych wybrane w wyniku zastosowania korelacyjnej metody selekcji cech

	ROI1	ROI2	ROI3	ROI4	ROI5
Liczba cech	15	11	35	24	7
Wybrane cechy	Mean Variance Skewness Kurtosis S(1,0)AngScMom S(1,0)Contrast S(1,0)SumOfSqs S(1,0)InvDfMom S(1,0)SumAverg S(1,0)DifEntrp Horzl_RLNonUni Vertl_GLevNonU 135dr_ShrtREmp GrKurtosis Teta2	Mean S(1,0)AngScMom S(1,0)Contrast S(1,0)SumAverg S(0,1)Contrast S(0,1)InvDfMom S(0,2)Contrast Vertl_RLNonUni Vertl_ShrtREmp Teta1 Teta4	Mean Variance Skewness S(1,0)AngScMom S(1,0)Contrast S(1,0)InvDfMom S(1,0)SumAverg S(0,1)SumOfSqs S(0,1)InvDfMom S(1,1)InvDfMom S(1,-1)InvDfMom S(2,0)InvDfMom S(0,2)InvDfMom S(0,2)SumVarnc S(2,2)InvDfMom S(2,-2)InvDfMom S(3,0)InvDfMom S(0,3)InvDfMom S(3,3)InvDfMom S(3,-3)InvDfMom S(4,0)InvDfMom S(0,4)InvDfMom S(4,4)InvDfMom S(3,-3)InvDfMom S(4,0)InvDfMom S(0,4)InvDfMom S(4,4)InvDfMom S(4,-4)InvDfMom S(5,0)InvDfMom S(0,5)InvDfMom S(5,5)InvDfMom S(5,-5)InvDfMom GrSkewness GrKurtosis GrNonZeros Teta2 Teta3 Sigma	Mean Skewness Perc.01% S(1,0)AngScMom S(1,0)Contrast S(1,0)InvDfMom S(1,0)SumAverg S(0,1)Contrast S(0,2)InvDfMom S(2,-2)InvDfMom S(0,3)InvDfMom S(3,3)Contrast S(3,3)InvDfMom S(3,3)DifVarnc S(3,-3)InvDfMom S(0,4)InvDfMom S(4,4)Contrast S(4,4)InvDfMom S(4,-4)InvDfMom S(0,5)InvDfMom S(5,5)Contrast S(5,5)InvDfMom S(5,-5)InvDfMom GrNonZeros	Mean Kurtosis S(1,0)Contrast S(1,0)SumOfSqs S(1,0)SumAverg GrMean GrSkewness

Selekcja przeprowadzona metodą korelacyjną pozwoliła na znaczącą redukcję liczby cech dla każdej z rozpatrywanych sekwencji. Analizując strukturę podzbiorów wartości cech, łatwo zauważyć, że dominują cechy statystyczne drugiego rzędu, głównie wyznaczone na podstawie macierzy zdarzeń. Spośród cech statystycznych pierwszego rzędu cechą wspólną dla wszystkich podzbiorów jest wartość średnia, co wskazuje na jej dużą uniwersalność i przydatność w dalszej ocenie stanu technicznego. Znaczenie zastosowanych w tabeli identyfikatorów cech wyjaśniono w dodatku A.

5.2.2.6. Selekcja cech z zastosowaniem współczynnika Fishera

Selekcja cech może być prowadzona na podstawie współczynnika Fishera [126], którego wartość jest proporcjonalna do wariancji różnic między klasami D , a odwrotnie proporcjonalna do wariancji cech wewnątrz klas V :

$$F = \frac{D}{V} = \frac{\frac{1}{1 - \sum_{i=1}^K P_i^2} \sum_{i=1}^K \sum_{j=1}^K P_i P_j (\mu_i - \mu_j)^2}{\sum_{i=1}^K P_i V_i} \quad (5.2)$$

gdzie:

μ_i – średnia wartość cechy w klasie i ,

μ_j – średnia wartość cechy w klasie j ,

V_i – wariancja cechy w klasie i ,

P_i – prawdopodobieństwo klasy i wyznaczone jako stosunek liczby wartości cech opisujących klasę i do liczby wszystkich cech,

P_j – prawdopodobieństwo klasy j wyznaczone jako stosunek liczby wartości cech opisujących klasę j do liczby wszystkich cech,

K – liczba klas.

Wyboru cech dokonuje się na podstawie największych wartości współczynnika Fishera. Spośród zbioru rozpatrywanych cech statystycznych, korzystając z wyznaczonych współczynników Fishera wybrano 10 cech reprezentatywnych dla wszystkich rozpatrywanych obszarów zainteresowania. Zastosowano algorytm selekcji cech zaimplementowany w oprogramowaniu Mazda [25]. Wybranymi cechami były:

- kontrast na kierunku (2,-2) [S(2,-2)Contrast],
- kontrast na kierunku (3,3) [S(3,3)Contrast],
- kontrast na kierunku (3,-3) [S(3,-3)Contrast],
- kontrast na kierunku (4,0) [S(4,0)Contrast],
- odwrotny moment różnicowy na kierunku (0,4) [S(0,4)InvDfMom],
- kontrast na kierunku (4,4) [S(4,4)Contrast],
- kontrast na kierunku (5,0) [S(5,0)Contrast],
- kontrast na kierunku (5,5) [S(5,5)Contrast],
- wartość średnia gradientu [GrMean],
- wartość kurtozy gradientu [GrKurtosis].

Wybrane cechy są cechami statystycznymi drugiego rzędu, a dominuje wśród nich kontrast wyliczony dla różnych przypadków macierzy zdarzeń.

5.2.2.7. Selekcja cech z zastosowaniem jednoczesnej analizy minimalnego prawdopodobieństwa błędu klasyfikacji i minimalnego średniego współczynnika korelacji

Innym sposobem ograniczenia liczebności zbioru cech statystycznych było zastosowanie metody selekcji cech bazującej na minimalizacji prawdopodobieństwa błędu klasyfikacji POE (ang. *Probability Error*) i średniego współczynnika korelacji ACC (ang. *Average Correlation Coefficient*) pomiędzy wybranymi cechami [28, 95]. W omawianej metodzie pierwsza cecha f^1 wybierana jest w celu minimalizacji prawdopodobieństwa błędu klasyfikacji dla wszystkich klas:

$$f^1 = f_j : \min_j [POE(f_j)] \quad (5.3)$$

gdzie $POE(f_j)$ jest prawdopodobieństwem błędu klasyfikacji dla cechy f_j . Prawdopodobieństwo to definiowane jest jako stosunek nieprawidłowo sklasyfikowanych przykładów do całkowitej liczby przykładów w analizowanym zbiorze danych, przy stosowaniu tylko cechy f_j do klasyfikacji. Kolejna cecha jest wybierana przez minimalizację następującej sumy dla wszystkich cech wyłączając f^1 :

$$f^2 = f_j : \min_j [POE(f_j) + |CC(f^1, f_j)|] \quad (5.4)$$

gdzie $|CC(f^1, f_j)|$ jest wartością bezwzględną współczynnika korelacji pomiędzy wcześniej wybraną cechą f^1 i nową cechą f_j . Cecha n -ta jest wybierana poprzez minimalizację następującej sumy dla wszystkich pozostałych cech (z wyjątkiem już wybranych):

$$f^n = f_j : \min_j [POE(f_j) + \frac{1}{n-1} \sum_{k=1}^{n-1} |CC(f^k, f_j)|] = \min_j [POE(f_j) + ACC(f_j)] \quad (5.5)$$

gdzie średnia suma została rozszerzona do współczynników korelacji pomiędzy wcześniej wybranymi cechami i cechą f_j . Suma ta nazywa się średnim współczynnikiem korelacji (ACC).

W celu kontroli wpływu wartości POE i ACC na proces selekcji cech, do wcześniejszego wyrażenia wprowadzono wagi w_1 i w_2 , które na potrzeby obliczeń wynosiły $w_1 = w_2 = 0,5$.

$$f^n = \min_j [w_1 POE(f_j) + w_2 ACC(f_j)] \quad (5.6)$$

Stosując wyżej przedstawioną metodę selekcji cech, ze zbioru cech statystycznych również wyselekcjonowano 10 cech reprezentatywnych dla wszystkich obszarów zainteresowania. Zastosowano algorytm selekcji cech zaimplementowany w oprogramowaniu Mazda [25]. Wybranymi cechami były:

- kontrast na kierunku (1,-1) [S(1,-1)Contrast],
- korelację na kierunku (0,2) [S(0,2)Correlat],
- kontrast na kierunku (2,-2) [S(2,-2)Contrast],
- kontrast na kierunku (0,3) [S(0,3)Contrast],
- kontrast na kierunku (0,4) [S(0,4)Contrast],
- suma kwadratów na kierunku (0,4) [S(0,4)SumOfSqs],
- kontrast na kierunku (4,4) [S(4,4)Contrast],
- kontrast na kierunku (5,5) [S(5,5)Contrast],
- nierównomierność pasma na kierunku 45° [45dgr_RLNonUni],
- wartość kurtozy gradientu [GrKurtosis].

Podobnie jak w przypadku selekcji z zastosowaniem współczynników Fishera, wśród cech wybranych metodami POE i ACC dominuje kontrast wyliczony na podstawie różnych macierzy zdarzeń.

5.2.2.8. Selekcja cech z zastosowaniem teorii zbiorów przybliżonych

Zbiór cech statystycznych postanowiono również ograniczyć, stosując do wyboru podzbioru cech relewantnych metodę selekcji cech bazującą na teorii zbiorów przybliżonych. W teorii zbiorów przybliżonych analizowana jest tabela decyzyjna T zdefiniowana następująco [108]:

$$T = (U, A \cup \{d\}) \quad (5.7)$$

gdzie: $U = \{x_1, x_2, \dots, x_N\}$ jest niepustym i skończonym zbiorem przykładów uczących nazwanych *uniwersum*, $A = \{a_1, a_2, \dots, a_M\}$ jest zbiorem cech warunkowych i d oznacza cechę (klasę) decyzyjną. Wiedza jest formalnie reprezentowana przez relację równoważności *IND* nazywaną relacją nierozróżnialności zdefiniowaną następująco [108]:

$$\text{IND}(A) = \{(x, y) \in U \times U : \forall a \in A, a(x) = a(y)\} \quad (5.8)$$

Cecha $a \in A$ jest redundantna w zbiorze cech A tabeli decyzyjnej T , jeśli [128]:

$$\text{IND}(A) = \text{IND}(A \setminus \{a\}) \quad (5.9)$$

w przeciwnym przypadku a jest cechą relewantną (znaczącą) w A . Jeśli wszystkie cechy $a_i \in A$ ($i = 1 \dots, M$) są znaczące, wtedy zbiór A nazywany jest ortogonalnym. Zbiór wszystkich znaczących cech w A nazywany jest rdzeniem (jądrem) tabeli T i oznaczany przez $\text{CORE}(T)$.

Jeśli $B \subseteq A$ i każda cecha $a \in B$ jest relewantna w B i $\text{IND}(B) = \text{IND}(A)$, wtedy podzbiór B nazywany jest *reduktem* w T i oznaczany przez R . Innymi słowy, redukt jest najmniejszym podzbiorem cech w A , który rozróżnia wszystkie przykłady $x_j \in U$ w T . Rodzina wszystkich reduktów w T oznaczana jest przez $\text{RED}(T)$, a zatem:

$$\text{CORE}(T) = \bigcap_{R \in \text{RED}(T)} R \quad (5.10)$$

Zbiory rozmyte stosowane są do danych dyskretnych (jakościowych). Jeśli dane mają ciągłe wartości rzeczywiste, muszą zostać zdyskretyzowane. Niech a będzie cechą o wartości rzeczywistej, w dziedzinie $\text{Dom}(a) = \langle l, r \rangle \subset \mathfrak{R}$. Zbiór par:

$$\pi_a = \{\langle c_0^a, c_1^a \rangle, \langle c_1^a, c_2^a \rangle, \dots, \langle c_{k-1}^a, c_k^a \rangle\} \quad (5.11)$$

gdzie:

$$c_0^a = l, c_{i-1}^a < c_i^a, c_k^a = r, i = 1, 2, \dots, k \quad (5.12)$$

określa liniowe przekształcenie dziedziny rzeczywistych wartości cech a w dziedzinę cech jakościowych a^q :

$$f_a : \text{Dom}(a) \rightarrow \text{Dom}(a^q) \quad (5.13)$$


Przekształcenie to zdefiniowane jest jako [22]:

$$f_a(v) = \begin{cases} j, & \text{gdy } c_j^a \leq v < c_{j+1}^a, \\ k-1, & \text{gdy } c_{k-1}^a \leq v \leq c_k^a, \\ \text{dla } j = 0, 1, \dots, k-2 \end{cases} \quad (5.14)$$

a wartości c_j^a , ($j = 1, \dots, k$) nazywane są *punktami rozcinającymi* cechę a . Graficzną interpretację punktów rozcinających zaprezentowano na rysunku 5.13, na którym przedstawiono przykład dwóch klas (czarne i białe koła) opisane przez wartości dwóch cech a_1 i a_2 . Dla określonego zbioru przykładów zdeterminowano następujące punkty rozcinające: $c_1^{a_1}, c_2^{a_1}$ dla cechy a_1 , i $c_1^{a_2}, c_2^{a_2}$ dla cechy a_2 .

Ogólnie można rozróżnić następujące metody przekształceń:

- metody globalne i lokalne [11, 22],
- metody nadzorowane i nienadzorowane [35],
- metody ze z góry określoną liczbą punktów rozcinających i metody z obliczoną na podstawie badań liczbą punktów rozcinających [72].



Rys. 5.13. Geometryczna interpretacja punktów rozcinających [98]

Tab. 5.3. Podzbiory cech relewantnych dla każdego z rozpatrywanych obszarów zainteresowania wyznaczone z zastosowaniem metody zbiorów przybliżonych

	ROI1	ROI2	ROI3	ROI4	ROI5
Liczba cech	13	15	11	11	8
Wybrane cechy	Mean S(0,1)SumAverg S(0,1)DifEntrp S(1,1)DifEntrp S(1,-1)SumEntrp S(2,0)InvDfMom S(0,2)Correlat S(3,0)Correlat S(5,0)Correlat S(5,0)InvDfMom S(0,5)Correlat S(5,5)SumVarnc Horzl_GLevNonU	Mean Variance Perc.01% S(0,1)DifVarnc S(1,1)Correlat S(1,1)DifVarnc S(1,-1)SumAverg S(2,2)Correlat S(3,-3)Correlat S(5,0)DifVarnc S(5,-5)SumVarnc Vertl_RLNonUni 135dr_ShrtREmp Teta1 Teta4	Mean Variance S(1,-1)Contrast S(1,-1)Correlat S(2,2)Correlat S(3,0)InvDfMom S(0,4)Correlat S(4,-4)InvDfMom S(5,-5)InvDfMom 45dgr_LngREmph GrVariance	Mean Skewness S(1,0)Contrast S(1,0)Correlat S(1,0)SumEntrp S(2,0)SumEntrp S(3,-3)InvDfMom S(4,0)Contrast S(0,4)Correlat S(5,0)Correlat S(5,5)Contrast	Mean Perc.90% S(2,0)Correlat S(0,2)Correlat S(4,-4)SumVarnc S(5,0)Contrast S(5,-5)DifVarnc GrKurtosis

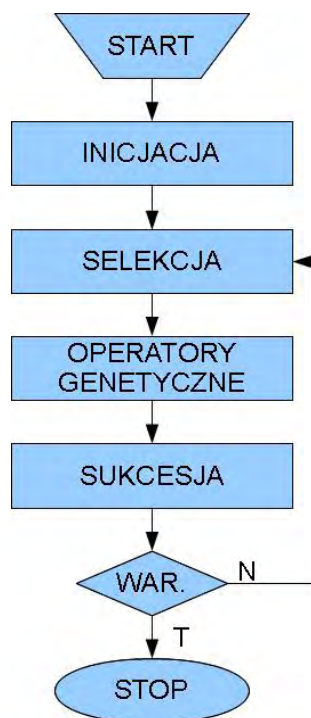
W opisywanych badaniach zastosowano metodę globalną, [11] korzystając z systemu RSES [121]. Stosując strategię globalną, zbiór przecięć jest mniejszy niż w przypadku strategii lokalnej, która jest prostsza w realizacji. Zastosowanie mniejszego zbioru przecięć powoduje, że wiedza wyindukowana z danych jest oczywista i bardziej ogólna. Wyniki selekcji cech z zastosowaniem zbiorów przybliżonych zaprezentowano w tabeli 5.3.

Wśród cech wybranych metodą zbiorów przybliżonych dominują cechy drugiego rodzaju wyznaczone dla różnych macierzy zdarzeń. Łatwo zauważyć, że ważną cechą jest korelacja, która występuje we wszystkich podzbiórach. Znaczenie zastosowanych w tabeli identyfikatorów cech wyjaśniono w dodatku A.

5.2.2.9. Selekcja cech z zastosowaniem algorytmów ewolucyjnych

Kolejnym podejściem zastosowanym w celu ograniczenia zbioru cech statystycznych obrazów termograficznych było wykorzystanie algorytmów ewolucyjnych. Algorytmy ewolucyjne są niezależną od dziedziny, heurystyczną i adaptacyjną metodą sztucznej inteligencji bazującą na analogii do ewolucji biologicznej zachodzącej w przyrodzie. Algorytmy

ewolucyjne są wydajnym narzędziem pozwalającym globalnie i szybko przeszukiwać duże przestrzenie wartości, które trudno opisać za pomocą modelu bazującego na teorii i wiedzy dziedzinowej. Celem algorytmów ewolucyjnych jest optymalizacja populacji przy określonych kryteriach maksymalizacji funkcji dopasowania [142]. Podstawową ideę działania algorytmu ewolucyjnego zaprezentowano na rysunku 5.14.



Rys. 5.14. Ogólna zasada działania algorytmu ewolucyjnego

Wykorzystanie algorytmu ewolucyjnego w realizacji zadań selekcji cech zwykle wymaga przeprowadzenia następujących operacji [155]:

- wyboru sposobu kodowania informacji w chromosomie. Zwykle osobniki reprezentowani są przez podzbiór cech zakodowany jako ciąg binarny, gdzie każda wartość (gen) stanowi o obecności (1) lub braku (0) danej cechy;
- zdefiniowanie funkcji przystosowania wykorzystywanej do oceny potencjalnego rozwiązania;
- określenie sposobu selekcji osobników (np. metodą rankingową);
- określenie operatorów genetycznych stosowanych w przekształceniu rozwiązań. Najczęściej stosuje się operatory krzyżowania i mutacji;
- określenie parametrów sterujących (np. prawdopodobieństwo zastosowania konkretnego operatora genetycznego, rozmiar populacji itp.).

Na potrzeby selekcji wyznaczonych cech statystycznych zastosowano różne strategie obliczeń ewolucyjnych. Algorytmy ewolucyjne stosowane we wszystkich zaproponowanych strategiach poszukiwania zbioru cech relewantnych miały klasyczną strukturę (rys. 5.14) i stosowały następujące operatory genetyczne:

- selekcję proporcjonalną,
- dwupunktowe krzyżowanie (zamianę cech),
- równomierną mutację,
- sukcesję elitarną.

W celu zapobieżenia powtarzania się cech w genotypie w rozpatrywanych algorytmach zastosowano operator naprawy. Jediną cechą odróżniającą algorytmy były różne warunki zakończenia ich działania. Do oceny kandydatów w każdej populacji wykorzystano maksymalną wartość sprawności klasyfikacji wyznaczaną z zastosowaniem klasyfikatora bazującego na sztucznej sieci neuronowej (por. 5.2.2.10). Klasyfikator stosujący sztuczną sieć neuronową był trenowany każdorazowo, jeśli była potrzeba oceny osobnika. Klasyfikator ten posłużył również do oceny stanu technicznego na podstawie wybranych cech statystycznych.

Wybór 10 cech z zastosowaniem klasycznego algorytmu ewolucyjnego

Proces poszukiwania podzbioru cech relewantnych obrazów termograficznych rozpoczęto od zastosowania klasycznego algorytmu ewolucyjnego. Jego zadaniem miało być znalezienie z góry założonej liczby 10 cech relewantnych. Bazując na wynikach wstępnych badań określono populację 20 osobników i dla każdego z nich genotyp składający się z 10 wybranych identyfikatorów cech z zakresu od 1 do 259. Warunki zakończenia ustalono na osiągnięcie 100 generacji lub 20 generacji bez wzrostu wartości funkcji dopasowania. Wyniki selekcji przedstawiono w tabeli 5.4. Znaczenie zastosowanych w tabeli identyfikatorów cech wyjaśniono w dodatku A.

Tab. 5.4. Podzbiory cech relewantnych dla każdego z rozpatrywanych obszarów zainteresowania wyznaczone z zastosowaniem klasycznego algorytmu ewolucyjnego

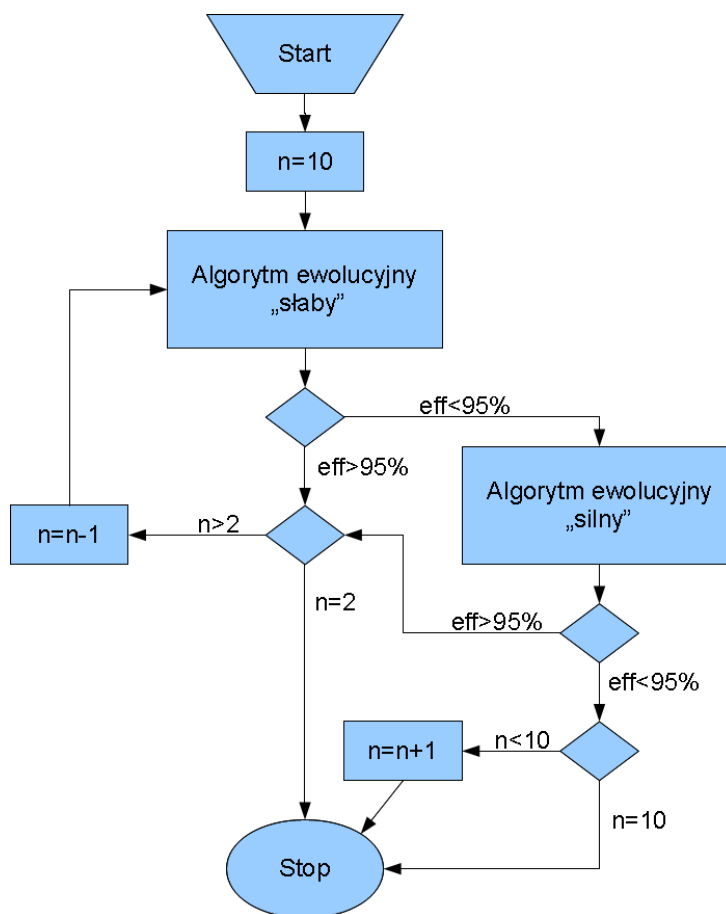
	ROI1	ROI2	ROI3	ROI4	ROI5
Liczba cech	10	10	10	10	10
Wybrane cechy	S(3,-3)Correlat S(3,0)Contrast S(4,0)AngScMom S(1,1)InvDfMom S(2,0)Contrast S(2,0)Correlat S(0,3)Entropy S(2,-2)DifVarnc S(2,-2)Contrast GrMean	S(2,0)Correlat Perc.01% S(4,0)AngScMom S(1,0)DifVarnc GrKurtosis S(1,0)DifEntrp S(3,-3)InvDfMom S(2,2)Entropy S(4,0)DifEntrp S(0,4)Correlat	S(1,1)InvDfMom S(4,-4)Entropy S(1,0)Entropy 45dgr_Fraction S(5,0)DifVarnc S(0,1)InvDfMom S(3,3)SumVarnc Vertl_GLevNonU S(0,3)Correlat S(4,0)SumVarnc	S(4,0)InvDfMom S(2,2)Entropy S(2,0)SumEntrp Teta2 S(3,3)SumVarnc S(3,-3)DifVarnc S(4,4)Contrast Perc.99% S(4,4)SumVarnc S(2,-2)Correlat	Horzl_RLNonUni S(0,5)SumVarnc S(2,0)AngScMom Vertl_ShrtREmp S(0,4)DifVarnc Perc.50% S(1,-1)SumVarnc S(1,0)Contrast S(2,-2)SumOfSqs S(5,5)SumAverg

W wybranym podziorze cech relewantnych dominują różne cechy statystyczne drugiego rodzaju wyliczone na podstawie macierzy zdarzeń.

Wybór cech z zastosowaniem kombinacji algorytmów „silny-słaby”

Ze względu na bardzo długi czas obliczeń z zastosowaniem klasycznego podejścia zmodyfikowano strategię poszukiwań podzbioru cech relewantnych, stosując kombinację algorytmów ewolucyjnych nazwaną „słaby-silny” (rys. 5.15). Głównym celem przyjętej strategii poszukiwania było znalezienie dla każdego obszaru zainteresowania podzbioru zawierającego nie więcej niż 10 cech, przy założeniu, że sprawność klasyfikatora dla wybranego podzbioru cech nie powinna być mniejsza niż 95%.

Kombinacja algorytmów „słaby-silny” działała w następujący sposób. Na początku obliczeń algorytm „słaby” wybierał 10 cech. Jeśli sprawność klasyfikatora była większa niż 95%, liczba cech była redukowana o jedną i ponownie uruchamiano algorytm „słaby”. W przypadku gdy sprawność klasyfikatora była mniejsza niż 95%, swoje działanie rozpoczynał algorytm „silny”, którego zadaniem była lepsza eksploracja przestrzeni cech. Jeśli sprawność klasyfikacji ponownie osiągnęła wartość mniejszą niż 95%, obliczenia zatrzymywano, ponieważ założono,




Rys. 5.15. Sposób poszukiwania podzbioru cech relewantnych z zastosowaniem kombinacji algorytmów ewolucyjnych „słaby-silny”

że mniejsza liczba cech nie będzie w stanie podnieść sprawności klasyfikacji. Jeśli sprawność klasyfikatora była większa niż 95%, liczbę cech pomniejszono o jeden i ponownie uruchomiono algorytm „słaby”. Cały proces powtarzano do chwili osiągnięcia optymalnego podzbioru cech. W stosowanych algorytmach przyjęto populację składającą się z 20 osobników. Genotyp osobnika składał się z $n = 10$ wybranych losowo identyfikatorów cech. Fenotypem osobnika była sprawność klasyfikacji wyznaczona na podstawie wartości cech, których identyfikatory zakodowano w genotypie. W tym celu zastosowano klasyfikator bazujący na sztucznej sieci neuronowej (por. 5.2.2.10). W przypadku algorytmu „słabego” warunkiem zakończenia było osiągnięcie 5 generacji. Algorytm „silny” kończył swoje działanie, jeśli osiągnięto 100 generacji lub 20 generacji bez wzrostu wartości funkcji dopasowania. Wyniki selekcji cech z zastosowaniem opisaney strategii przedstawiono w tabeli 5.5.

Tab. 5.5. Podzbiory cech relewantnych wybrane z zastosowaniem kombinacji algorytmów „słaby-silny”

ROI1	ROI2	ROI3	ROI4	ROI5
S(2,0)DifVarnc GrMean	S(0,1)SumVarnc S(0,4)SumOfSqs	S(0,2)SumVarnc S(5,5)DifVarnc	Perc.50% S(4,-4)Contrast	S(1,-1)Entropy GrKurtosis

Zaproponowana strategia pozwoliła na znalezienie dla każdego z obszarów zainteresowania podzbioru składającego się z dwóch cech. Podobnie jak we wcześniej rozpatrywanym przypadku, wśród wybranych cech dominują cechy statystyczne drugiego rodzaju wyznaczone na podstawie macierzy zdarzeń. Znaczenie zastosowanych w tabeli identyfikatorów cech wyjaśniono w dodatku A. Na rysunkach 5.16 i 5.17 zaprezentowano rozkład wzorców stanów technicznych w dwuwymiarowej przestrzeni cech odpowiednio dla rozpatrywanych obszarów zainteresowania ROI3 i ROI4. Dostrzegalna jest słaba rozróżnialność stanów S2 i S3, co potwierdza osiągnięcie zamierzonego celu w trakcie przeprowadzonych eksperymentów. Separacja międzyklasowa jest gorsza dla obszaru ROI3 obejmującego łożysko nr 1, co jest związane z mniejszym obciążeniem łożyska i mniejszymi różnicami zarejestrowanych temperatur.




Rys. 5.16. Rozkład wzorców stanów technicznych dla obszaru ROI3 w dwuwymiarowej przestrzeni cech wybranych z zastosowaniem algorytmów ewolucyjnych „słaby-silny”

Automatyczny wybór liczby i rodzajów cech z zastosowaniem klasycznego algorytmu ewolucyjnego

Kolejna strategia selekcji cech bazująca na obliczeniach ewolucyjnych, w przeciwieństwie do wcześniej przedstawionych, miała za zadanie samodzielnie ustalić rozmiar podzbioru cech relewantnych oraz rodzaj cech do niego przynależnych. W tym celu zastosowano klasyczny algorytm genetyczny składający się z populacji 30 osobników, genotypu osobnika składającego się z binarnego wektora 259 wartości identyfikatorów cech. Warunkami zakończenia działania algorytmu było osiągnięcie 1000 generacji lub 500 generacji przy braku wzrostu wartości funkcji dopasowania. Wyniki selekcji zaprezentowano w tabeli 5.6.

Można zauważyć, że zastosowanie klasycznego algorytmu ewolucyjnego do wyboru podzbiorów cech w sposób automatyczny nie przyniosło pożądanych rezultatów. Liczebność cech w wyznaczonych podzbiórach wahała między 15 a 21. Spodziewano się uzyskać o wiele mniejsze podzbiory cech zawierające nie więcej niż 10 cech. Wśród wybranych cech ponownie dominowały cechy statystyczne drugiego rodzaju wyznaczone na podstawie macierzy zdarzeń.



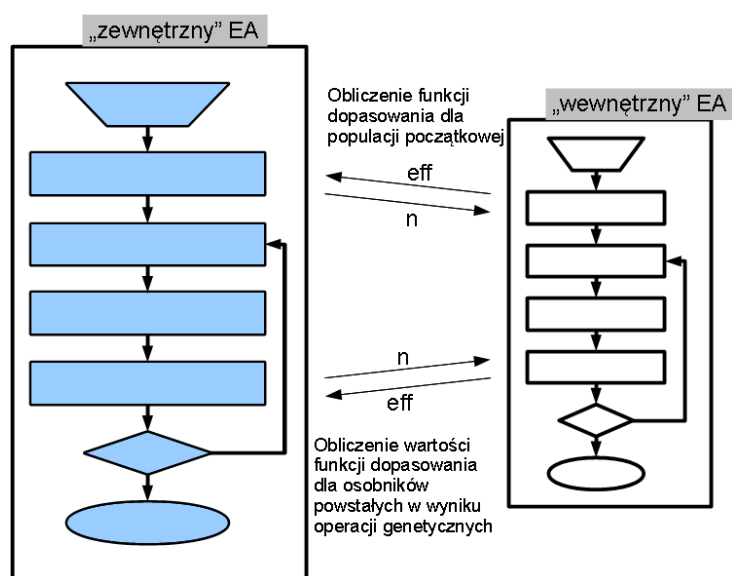
Rys. 5.17. Rozkład wzorców stanów technicznych dla obszaru ROI4 w dwuwymiarowej przestrzeni cech wybranych z zastosowaniem algorytmów ewolucyjnych „słaby-silny”

Tab. 5.6. Podzbiory cech wybrane z zastosowaniem klasycznego algorytmu ewolucyjnego w sposób automatyczny

	ROI1	ROI2	ROI3	ROI4	ROI5
Liczba cech	20	21	18	16	19
Wybrane cechy	S(1,0)SumEntrp S(0,1)Correlat S(0,1)SumOfSqs S(1,1)DifVarnc S(1,1)DifEntrp S(2,0)DifEntrp S(0,2)SumOfSqs S(2,2)SumOfSqs S(2,2)SumAverg S(2,2)DifVarnc S(3,0)DifEntrp S(3,3)AngScMom S(3,3)SumVarnc S(4,4)SumOfSqs S(4,4)DifVarnc S(4,-4)InvDfMom S(4,-4)SumAverg S(5,-5)DifVarnc 45dgr_RLNonUni 135dr_RLNonUni	S(1,1)Correlat S(1,1)SumOfSqs S(1,1)SumEntrp S(1,-1)Contrast S(2,0)Entropy S(2,2)SumVarnc S(2,-2)Correlat S(2,-2)DifEntrp S(3,3)SumVarnc S(3,3)DifEntrp S(4,0)SumEntrp S(4,0)Entropy S(0,4)SumVarnc S(0,4)Entropy S(4,-4)SumOfSqs S(0,5)AngScMom S(0,5)SumOfSqs S(4,-4)SumEntrp S(5,0)Correlat S(5,0)SumEntrp S(5,0)DifVarnc S(5,5)AngScMom Horzl_GLevNonU Vertl_RLNonUni 135dr_LngREmph	S(0,1)DifVarnc S(1,1)DifVarnc S(1,-1)Contrast S(2,0)SumVarnc S(3,0)SumAverg S(3,-3)SumAverg S(3,-3)DifVarnc S(4,0)SumVarnc S(0,4)Contrast S(0,4)Entropy S(4,-4)SumOfSqs S(0,5)AngScMom S(0,5)SumOfSqs S(5,5)SumOfSqs S(5,-5)SumVarnc Vertl_GLevNonU 135dr_RLNonUni GrNonZeros	Perc.01% S(1,-1)SumVarnc S(0,2)Contrast S(0,2)SumVarnc S(2,2)DifVarnc S(2,-2)SumAverg S(3,0)SumAverg S(3,-3)SumEntrp S(4,0)SumOfSqs S(4,0)InvDfMom S(4,-4)AngScMom S(5,5)SumVarnc S(5,5)DifVarnc Vertl_ShrtREmp 45dgr_Fraction 135dr_LngREmph	S(1,1)SumAverg S(1,1)SumEntrp S(1,-1)Correlat S(0,2)SumEntrp S(3,0)SumAverg S(0,3)Contrast S(3,3)SumAverg S(3,3)DifVarnc S(3,-3)SumOfSqs S(4,4)Correlat S(5,0)AngScMom S(5,0)InvDfMom S(0,5)SumEntrp S(5,5)Correlat S(5,5)SumEntrp S(5,-5)SumOfSqs S(5,-5)DifEntrp Vertl_RLNonUni Sigma

Automatyczny wybór liczby i rodzajów cech z zastosowaniem kombinacji algorytmów ewolucyjnych „zewnętrzny-wewnętrzny”

Automatyczny wybór cech z zastosowaniem klasycznego algorytmu ewolucyjnego był procesem bardzo czasochłonnym i nieefektywnym. W celu osiągnięcia lepszych wyników selekcji cech zaproponowano strategię bazującą na kombinacji dwóch klasycznych algorytmów ewolucyjnych, którą nazwano „zewnętrzny-wewnętrzny”. Ideę strategii zaprezentowano na rysunku 5.18.




Rys. 5.18. Idea funkcjonowania kombinacji algorytmów „zewnętrzny-wewnętrzny”

Działanie kombinacji algorytmów „zewnętrzny-wewnętrzny” polegało na tym, że w pierwszej kolejności stosowano algorytm „zewnętrzny” na potrzeby optymalizacji liczby cech n . W algorytmie stosowano genotyp składający się z 259 identyfikatorów cech. Fenotyp zawierał cechy wybrane przez „wewnętrzny” algorytm. Wartościami funkcji dopasowania były sprawność klasyfikatora. Algorytm „wewnętrzny” umożliwiał wybór rodzaju cech, a ich liczba wynikała z wyników działania algorytmu „zewnętrznego”. Takie podejście maksymalizowało sprawność klasyfikatora. Warunkami zakończenia działania algorytmów było osiągnięcie 1000 generacji lub 50 generacji bez wzrostu wartości funkcji dopasowania. Zastosowanie zaproponowanej kombinacji algorytmów znacząco skróciło czas obliczeń i pozwoliło znaleźć dla każdego obszaru zainteresowania podzbiory cech relewantnych składające się tylko z dwóch cech (tab. 5.7).


Tab. 5.7. Cechy relewantne wyznaczone z zastosowaniem kombinacji algorytmów ewolucyjnych „zewnętrzny-wewnętrzny”

ROI1	ROI2	ROI3	ROI4	ROI5
S(3,0)DifEntrp	Perc.01%	S(5,0)Correlat	S(1,0)Contrast	S(1,-1)InvDfMom
Teta4	S(5,-5)DifEntrp	HorzLngREmph	S(3,0)Correlat	GrSkewness

Analiza zawartości podzbiorów cech relewantnych wyselekcjonowanych z zastosowaniem kombinacji algorytmów ewolucyjnych „zewnętrzny-wewnętrzny” wskazuje, że dominują cechy drugiego rodzaju wyznaczone na podstawie macierzy zdarzeń. Znaczenie zastosowanych w tabeli identyfikatorów cech wyjaśniono w dodatku A. Dwuwymiarowe przestrzenie wartości cech dla obszarów ROI3 i ROI4 przedstawiających rozkład wzorców stanów technicznych zaprezentowano odpowiednio na rysunkach 5.19 i 5.20. Podobnie jak w przypadku strategii „słaby-silny” wybrane cechy pozwalają na dyskryminację wybranych stanów w różnym stopniu zależnym od rozpatrywanego obszaru zainteresowania.




Rys. 5.19. Rozkład wzorców stanów technicznych dla obszaru ROI3 w dwuwymiarowej przestrzeni cech wybranych z zastosowaniem algorytmów ewolucyjnych „zewnątrzny-wewnętrzny”



Rys. 5.20. Rozkład wzorców stanów technicznych dla obszaru ROI4 w dwuwymiarowej przestrzeni cech wybranych z zastosowaniem algorytmów ewolucyjnych „zewnątrzny-wewnętrzny”

5.2.2.10. Rozpoznawanie wzorców i klasyfikacja stanu

Wybrane różnymi metodami selekcji podzbiory relewantnych cech statystycznych obrazów termograficznych mają różne liczebności i strukturę. Aby ocenić przydatność metod selekcji, a tym samym wskazać podzbiór najlepiej charakteryzujący rozpatrywane stany techniczne badanej maszyny przeprowadzono rozpoznawanie wzorców z zastosowaniem klasyfikatora wykorzystującego sztuczną sieć neuronową. Ten sam klasyfikator stosowany był podczas obliczeń ewolucyjnych do wyznaczania wartości funkcji dopasowania. Strukturę klasyfikatora neuronowego przedstawiono na rysunku 5.21.



Rys. 5.21. Struktura sztucznej sieci neuronowej stosowanej w zadaniu klasyfikacji stanu

Wejściami sieci były wartości cech należących do wybranego podzbioru cech. W zależności od liczby rozpatrywanych wejść, parametry sieci neuronalnej ulegały zmianie. Liczba neuronów warstwy wejściowej L_{WE} zależna była od liczby cech, na podstawie których prowadzono klasyfikację. Liczba neuronów warstwy wyjściowej L_{WY} dla wszystkich rozpatrywanych przypadków była stała i wynosiła 1. Liczba neuronów warstwy ukrytej L_1 w zależności od liczby wejść ulegała zmianie i przyjmowano ją na podstawie wyników wstępnych badań oraz zaleceń literaturowych [115]. Liczbę neuronów warstwy ukrytej L_2 obliczono z następującej zależności:

$$L_2 = \frac{P_S}{L_1 + L_{WY}} - \frac{L_1 + L_{WE}}{L_1 + L_{WY}} \quad (5.15)$$

Przy założeniu, że całkowita liczba parametrów sieci P_S wynosi:

$$P_S = \frac{D_{ucz}}{5} \quad (5.16)$$

gdzie: liczba danych uczących – $D_{ucz} = 70\%$ liczby obrazów.

Przyjęto, że próbek uczących będzie 70% całej populacji liczącej 840 próbek. Próbek testujących było 30% całej populacji, czyli 252 próbki testujące. Dla każdego obszaru zainteresowania przeprowadzono osobną klasyfikację neuronową. Uczenie sieci neuronowej prowadzono przez 1000 iteracji. W trakcie procesu trenowania na wejście sieci podawano identyfikatory liczbowe charakteryzujące rozpatrywane stany techniczne. Wzorcowe wartości identyfikatorów stanu id_{w_s} wynosiły: 0,0 dla stanu S1; 0,2 dla stanu S2; 0,4 dla stanu S3; 0,6 dla stanu S4; 0,8 dla stanu S5 i 1,0 dla stanu S6. Wszystkie neurony warstwy wejściowej posiadały wartości wag równe 1 i wartości przesunięcia (bias) równe 0. Na warstwę wejściową podawano wartości wcześniej wyselekcjonowanych cech relewantnych. We wszystkich warstwach stosowano logarytmiczno-sigmoidalną funkcję aktywacji. Parametry neuronów warstw ukrytych oraz warstwy wyjściowej określono w wyniku trenowania sieci z wykorzystaniem powszechnie znanego algorytmu wstecznej propagacji błędów. Sprawność klasyfikacji wyznaczano na podstawie względnej liczby poprawnie sklasyfikowanych przykładów:

$$eff = \frac{l_1}{l_w} \cdot 100\% \quad (5.17)$$

gdzie:

l_1 — liczba poprawnie sklasyfikowanych przykładów,

l_w — liczba wszystkich rozpatrywanych przykładów.

Przykład testujący uznawano za poprawnie sklasyfikowany, jeśli różnica między wartością wyjściową sieci a spodziewaną wartością identyfikatora stanu nie przekraczała 25% wartości identyfikatora stanu $|id_s - id_{w_s}| < 0,25id_{w_s}$. Zatem każdy przykład, którego błąd przekraczał założoną wartość, klasyfikowany był jako niepoprawny bez względu na to czy był błędnie zaklasyfikowany, czy nierozpoznany. Obliczenia przeprowadzono z oprogramowaniu Matlab, wykorzystując do tego celu samodzielnie opracowane skrypty i funkcje.

Wyniki klasyfikacji dla wszystkich rozpatrywanych podzbiorów cech relewantnych wyznaczonych na podstawie wcześniej przeprowadzonej selekcji cech zaprezentowano w tabeli 5.8.

Tab. 5.8. Zestawienie wyników klasyfikacji stanu technicznego maszyny uzyskane dla różnych zbiorów relewantnych cech statystycznych

Identyfikator obszaru zainteresowania ROI	1	2	3	4	5
Zbiór wszystkich rozpatrywanych cech					
Liczba cech (L_{WE})	259	259	259	259	259
Sprawność klasyfikacji [%]	100	98	100	100	100
Wsp. Fishera					
Liczba cech (L_{WE})	10	10	10	10	10
Sprawność klasyfikacji [%]	100	95	99	96	100
POE+ACC					
Liczba cech (L_{WE})	10	10	10	10	10
Sprawność klasyfikacji [%]	100	83	100	98	100
Korelacja 0,85					
Liczba cech (L_{WE})	15	11	35	24	7
Sprawność klasyfikacji [%]	100	98	100	98	100
Zbiory przybliżone					
Liczba cech (L_{WE})	13	15	11	11	8
Sprawność klasyfikacji [%]	96	97	100	100	99
Alg. genetyczny 1					
Liczba cech (L_{WE})	10	10	10	10	10
Sprawność klasyfikacji [%]	100	100	100	100	100
Alg. genetyczne „słaby-silny”					
Liczba cech (L_{WE})	2	2	2	2	2
Sprawność klasyfikacji [%]	100	98	99	100	100
Alg. genetyczny 2					
Liczba cech (L_{WE})	20	21	18	16	19
Sprawność klasyfikacji [%]	92	92	94	94	93
Alg. genetyczne „zewnętrzny-wewnętrzny”					
Liczba cech (L_{we})	2	2	2	2	2
Sprawność klasyfikacji [%]	98	98	98	98	98

W tabeli dla porównania umieszczono również przypadek klasyfikacji stanu na podstawie wszystkich cech. Wraz z wynikami klasyfikacji w tabeli zaprezentowano również informację o liczbie cech (liczbie wejść sieci neuronalnej) branych pod uwagę w trakcie klasyfikacji.

Wyniki wskazują na fakt, że cechy statystyczne pozwalają na uzyskanie bardzo dobrych wyników klasyfikacji stanu technicznego maszyny i powinny być stosowane do analizy obrazów termograficznych w celu oceny stanu technicznego obiektów. Bardzo wysokie sprawności klasyfikacji mogą wynikać z faktu, że dane pochodzą z czynnego eksperymentu diagnostycznego przeprowadzonego w sposób sterowany oraz z niedoskonałości w sposobie wyboru danych uczących sieci neuronowej. Pomimo przeszacowania wartości klasyfikacji możliwe było zidentyfikowanie obszaru zainteresowania, który w znacznym zakresie nie pozwala na poprawną klasyfikację stanu – jest to obszar ROI2 (obszar sprzęgła). Gorsze wyniki w tym obszarze mogą być powodem istnienia ruchu obrotowego sprzęgła, a zatem i ciągłych zmian temperatury obserwowanej powierzchni wywołanych wymuszonym chłodzeniem.

5.2.3. Ocena stanu technicznego z zastosowaniem jednowymiarowej transformaty Fouriera

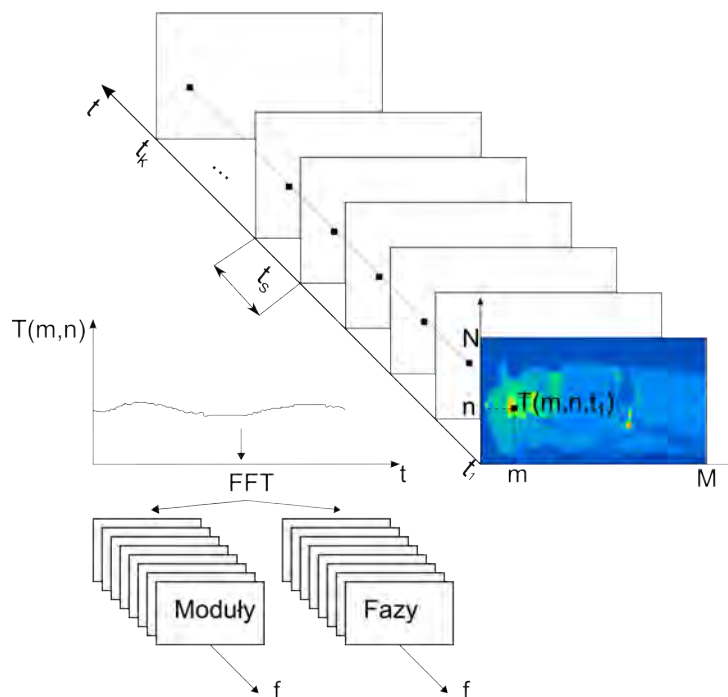
Zaproponowana metodyka analizy obrazów termograficznych na potrzeby oceny stanu technicznego obiektów technicznych zakłada wykorzystanie obrazów dodatkowych powstałych w efekcie zastosowania różnych metod transformacji (por. 2.5.6) obrazów właściwych. Przydatną metodą transformacji wartości obrazów jest jednowymiarowa transformata Fouriera [84, 136].

Jednowymiarowa transformata Fouriera może znaleźć dwojaki zastosowanie w analizie sygnału termograficznego: jako podstawa do budowy algorytmu transformaty dwuwymiarowej i jako przekształcenie wielowymiarowego sygnału temperatury z dziedziny czasu do dziedziny częstotliwości. Drugie zastosowanie jest powszechne w termografii dynamicznej do detekcji strukturalnych defektów materiałowych i zostało wykorzystane w zaproponowanym poniżej algorytmie pozwalającym identyfikować zmiany stanu technicznego. Zastosowanie jednowymiarowej transformaty Fouriera wymaga posiadania sekwencji K obrazów termograficznych (sygnału termograficznego) zarejestrowanych ze stałym interwałem czasowym t_s , posiadających takie same rozmiary M, N i przedstawiających tę samą scenę (rys. 5.22). W trakcie rejestracji sekwencji obrazów obiekt oraz kamera nie mogą zmieniać swojego położenia. Na podstawie sekwencji termograficznej możliwe jest utworzenie $S = M \times N$ sygnałów $T_{(m,n)}(t_k)$ (wektorów wartości pikseli w funkcji czasu), gdzie $m = 1, 2, \dots, M$, $n = 1, 2, \dots, N$ i $k = 1, 2, \dots, K$. Każdy z sygnałów przekształcany jest do dziedziny częstotliwości z zastosowaniem jednowymiarowej transformaty Fouriera, w wyniku czego otrzymuje się szereg wartości zespolonych dla każdej dyskretnej częstotliwości f_k obliczonej następująco:

$$f_k = \frac{k}{Kt_s} \quad (5.18)$$

gdzie: K – liczba obrazów termograficznych w sekwencji, t_s – interwał czasowy między rejestracją poszczególnych obrazów $k = 0, 1, \dots, K/2$.

Reprezentując wartości zespolone widma w postaci wartości modułu i fazy, możliwe jest utworzenie dla każdej z dyskretnych częstotliwości nowych obrazów przedstawiających przestrzenny rozkład wartości modułów i fazy. Obrazy te nazywane są również amplitudogramami i fazogramami. Jak wskazują źródła literaturowe [84], obrazy modułu są wrażliwe na nierównomierności w nagrzewaniu. Obrazy fazy pozwalają identyfikować



Rys. 5.22. Idea jednowymiarowej transformaty Fouriera sekwencji obrazów termograficznych

zjawiska cieplne zachodzące pod powierzchnią obserwowanego obiektu i są mniej wrażliwe na zakłócenia optyczne (brak ostrości) lub nierównomierne nagrzewanie. W przypadku sekwencji zarejestrowanej w trakcie obserwacji obiektów technicznych, na podstawie analizy obrazów modułu i fazy można wykrywać cykliczne nierównomierności w nagrzewaniu powierzchni wywołane np. uszkodzeniami lub identyfikować odstępstwa od cyklicznych zmian zjawisk cieplnych wynikających z normalnego funkcjonowania obiektu lub procesu. Ponadto możliwe jest wykrywanie wszelkich zmian w rozkładzie wartości temperatur wywołanych zmianami stanu. Wizualna analiza obrazów modułu i fazy jest trudna i bardzo czasochłonna, ponieważ aby znaleźć obraz niosący cenne informacje diagnostyczne, konieczne jest rozpatrzenie dużej liczby obrazów dla różnych częstotliwości. Obrazy te często są trudne w interpretacji. W celu wykorzystania obrazów modułu i fazy w identyfikacji stanu technicznego obiektów zaproponowano metodę bazującą na analizie obrazów amplitudy i fazy w sposób automatyczny. Metoda wymaga przygotowania reprezentatywnej sekwencji obrazów zarejestrowanych dla obiektu działającego w nominalnym stanie technicznym. Sekwencja ta stanowi źródło danych odniesienia. Metoda może być opisana za pomocą algorytmu składającego się z następujących podstawowych kroków:

Wybór sekwencji odniesienia – pozyskanie lub utworzenie z posiadanych danych sekwencji obrazów reprezentujących obserwowany obiekt w nominalnym dla jego działania stanie technicznym.

Identyfikacja sygnału odniesienia – krok ten realizowany jest dla sekwencji odniesienia, dla której poszukiwane są współrzędne piksela, którego sygnał (wektor jego wartości w czasie) posiada największą wariancję.

Wyznaczenie widma odniesienia – w wyniku transformaty Fouriera wcześniej zidentyfikowanego sygnału o największej wariancji (sygnału odniesienia) uzyskiwane jest jednostronne widmo mocy.

Poszukiwanie częstotliwości charakterystycznych – w kroku tym, na podstawie widma sygnału o największej wariancji, wyznaczanych jest L częstotliwości f_k odpowiadających kolejnym wartościom maksymalnym widma (modom widma). W analizie pomijana jest składowa stała widma (wartość prążka widma dla częstotliwości 0 Hz).


Analiza charakterystycznych obrazów modułu i fazy dowolnej sekwencji obrazów – znajomość częstotliwości charakterystycznych pozwala na wybór i analizowanie obrazów dowolnych sekwencji zarejestrowanych w różnych stanach technicznych obiektu. Analiza obrazów może być prowadzona z zastosowaniem odpowiednio dobranych dla charakteru obrazu metod (np. statystycznych, analizy geometrycznej obiektów itp.).

Identyfikacja i/lub rozpoznawanie stanu obiektu – dysponując zidentyfikowanymi relacjami diagnostycznymi między cechami stanu obiektu a cechami charakterystycznych obrazów modułu i/lub fazy możliwa jest identyfikacja stanu technicznego obiektu. Jeśli dla każdego stanu wyznaczony zostanie reprezentatywny zbiór cech uczących, możliwe będzie np. na drodze klasyfikacji rozpoznawanie stanu technicznego w sposób automatyczny.

W celu weryfikacji zaproponowanej metody przeprowadzono analizę obrazów termograficznych zarejestrowanych w trakcie eksperymentów diagnostycznych w warunkach laboratoryjnych (por. 5.2.1). W przykładzie posłużono się sekwencjami obrazów właściwych wyznaczonych dla obszarów zainteresowania ROI3 i ROI4 obejmujących podpory łożyskowe badanego modelu maszyny wirnikowej. Obszary łożysk maszyny były interesujące z dwóch względów. Po pierwsze większość uszkodzeń maszyn jest identyfikowana w węzłach łożyskowych. Po drugie wcześniejsze badania wskazały, że symulowane niesprawności w różnym stopniu wpływają na ilość ciepła wytwarzanego w każdym z węzłów. Na rysunku 5.6 przedstawiono przebiegi sygnału średniej wartości temperatury wyznaczonej na podstawie wartości obrazów dla obszarów węzłów łożyskowych ROI3 i ROI4. Łatwo zauważyć, że przejścia maszyny ze stanu technicznego S1 do S2 oraz S2 do S3 są słabo rozróżnialne w obu obszarach, podczas gdy stan S6 związany z uszkodzeniem łożyska nr 2 daje bardzo wyraźne symptomy w postaci wzrostu wartości średniej temperatury w obszarze ROI4. Celem analizy jest uzyskanie lepszej rozpoznawalności zmian między stanami słabo rozróżnialnymi. W przedstawionym przykładzie wyróżniono stan S0, który odpowiada rozruchowi maszyn i reprezentowany jest przez kolejno zarejestrowane obrazy o numerach 1–120.


Bazując na zaproponowanej metodzie oceny stanu, wybrano sekwencję odniesienia, którą była sekwencja kolejno zarejestrowanych obrazów termograficznych o numerach 121–240 pozyskana podczas działania maszyny bez obciążenia w stanie S1. Na podstawie sekwencji obrazów odniesienia zidentyfikowano współrzędne piksela, dla którego sygnał wartości temperatury ma największą wariancję. Następnie sygnał ten poddano transformacji Fouriera, w wyniku której uzyskano jednostronne widmo mocy, na podstawie którego zidentyfikowano cztery pierwsze częstotliwości charakterystyczne f_k , gdzie $k = 1, 2, 3, 4$. Przykładowe widmo amplitudowo-fazowe sygnału referencyjnego wraz z zaznaczonymi składowymi charakterystycznymi przedstawiono na rysunku 5.23.

Uwzględniając składowe charakterystyczne, dla wszystkich rozpatrywanych stanów wyznaczono obrazy modułu i fazy. Na rysunku 5.24 zaprezentowano przykładowe obrazy modułu i fazy dla stanu S1 wyznaczone na podstawie sekwencji obrazów właściwych w obszarze ROI3. Jakościowa analiza wyznaczonych obrazów jest trudna z uwagi na małą rozdzielczość obrazów pierwotnych i wysoki poziom szumów szczególnie w przypadku obrazów dla wyższych wartości częstotliwości oraz obrazów fazy. Można zauważyć, że obraz modułu dla najniższej częstotliwości charakterystycznej posiada więcej szczegółów niż dla



Rys. 5.23. Przykład widna odniesienia wraz ze składowymi charakterystycznymi dla obszaru ROI3


częstotliwości wyższej, co może świadczyć o tym, że nierównomierność nagrzewania jest procesem wolnozmiennym.



Rys. 5.24. Obrazy modułu i fazy wyznaczone na podstawie sekwencji obrazów obszaru ROI3 dla maszyny działającej w stanie S1

Rysunek 5.25 przedstawia obrazy modułu i fazy obszaru ROI4 dotyczące stanu S6, w trakcie którego symulowano uszkodzenie łożyska nr 2. W przeciwieństwie do stanu S1 zarówno obrazy modułu i fazy posiadają mniejszy poziom szumów oraz zawierają więcej czytelnych szczegółów. Jakość obrazów maleje wraz z częstotliwością. Taka różnica między obrazami ze stanu S1 i obszaru ROI3 wynika z większej intensywności zjawisk cieplnych zachodzących


w podporze łożyskowej wywołanych złym stanem łożyska. Można zatem stwierdzić, że obrazy modułu i fazy są wrażliwe na występujące zmiany stanu i ich intensywność.



Rys. 5.25. Obrazy modułu i fazy wyznaczone na podstawie sekwencji obrazów obszaru ROI4 dla maszyny działającej w stanie S6


Na rysunku 5.26 przedstawiono obrazy modułu i fazy wyznaczone w obszarze ROI4 dla wszystkich rozpatrywanych stanów dla częstotliwości charakterystycznej f_1 .

Łatwo zauważyć, że dla stanu S0 (rys. 5.26(a)), S4 (rys. 5.26(e)) i S6 (rys. 5.25(a)) obrazy są czytelne i niosą więcej informacji niż te dla pozostałych stanów, które charakteryzują się dużym poziomem szumu. Jeśli uwzględnić przejściowy charakter sygnału diagnostycznego, wartości średniej w obrębie tych stanów (rys. 5.6), można wnioskować, że zaproponowany sposób analizy bardzo dobrze rozpoznaje zjawiska cieplne o zmiennym charakterze, czyli idealnie może nadawać się do detekcji chwil wystąpienia niesprawności, podczas których mogą pojawić się nieustalone stany cieplne w obserwowanym obiekcie. Zgodnie z algorytmem zaproponowanej metody, kolejnym krokiem była analiza obrazów amplitudy i fazy w celu wyznaczenia ich cech. W rozpatrywanym przykładzie do oceny obrazów posłużono się analizą statystyczną wartości pikseli, w wyniku której wyznaczano m.in. takie cechy jak wartość średnia, RMS, kurtoza, entropia, itp. (por. dodatek C i A). Na rysunkach 5.27, 5.28, 5.29 przedstawiono wartości wybranych cech wyznaczone dla obrazów modułu i fazy oraz rozpatrywanych stanów technicznych. W przypadku RMS wyraźnie widać, że wartość cechy dla obrazów modułu (rys. 5.27(a)) rośnie odwrotnie proporcjonalnie do częstotliwości charakterystycznych, a rozpoznawalność poszczególnych stanów jest lepsza dla niższych częstotliwości charakterystycznych. W przypadku obrazów fazy (rys. 5.27(b)) wartość RMS zależy tylko od częstotliwości i od stanu technicznego, przy czym w rozpatrywanym przykładzie najlepszą rozróżnialność stanów otrzymano dla drugiej



Rys. 5.26. Obrazy modułu i fazy wyznaczone na podstawie sekwencji obrazów obszaru ROI4 dla stanów technicznych S0-S5 i częstotliwości f_1 . Obraz dla stanu S6 zaprezentowano na rysunku 5.25(a)


częstotliwości charakterystycznej f_2 . Wartości RMS uzyskane dla stanów S1 i S2 nie pozwalają na jednoznaczne ich rozróżnienie.




Rys. 5.27. Wartości RMS wyznaczone dla obrazu modułu (a) i fazy (b) dla obszaru ROI3 i wszystkich rozpatrywanych częstotliwości charakterystycznych

W przypadku kurtozy wyznaczonej zarówno dla obrazów modułu 5.28(a) i fazy 5.28(b) jej wartość zależy od charakteru rozkładu wartości pikseli w obrazie. Gdy jest on losowy, czyli obraz posiada duży poziom szumu, wartości kurtozy dążą do liczby 3. Dla obrazów modułu wartości kurtozy lepiej dyskryminują poszczególne stany niż dla obrazów fazy.

Analiza sygnałów wartości entropii wyznaczonej dla obrazów modułu 5.29(a) i fazy 5.29(b) pozwala stwierdzić, że cecha ta najlepiej dyskryminuje rozpatrywane stany, a jej wartość w przypadku obrazów modułu rośnie wprost proporcjonalnie do wartości częstotliwości charakterystycznych, dla których wyznaczone były obrazy. Wskazuje to na fakt, że entropia dobrze charakteryzuje zawartość informacyjną w obrazach. Wartość entropii jest mniejsza dla obrazów lepszej jakości.



Rys. 5.28. Wartości kurtozy wyznaczone dla obrazu modułu (a) i fazy (b) dla obszaru ROI3 i wszystkich rozpatrywanych częstotliwości charakterystycznych



Rys. 5.29. Wartości entropii wyznaczone dla obrazu modułu (a) i fazy (b) dla obszaru ROI3 i wszystkich rozpatrywanych częstotliwości charakterystycznych

Wyniki przeprowadzonej oceny stanu z zastosowaniem metody bazującej na jednowymiarowej transformacji Fouriera sekwencji obrazów termograficznych pozwalają stwierdzić, że zaproponowane podejście dobrze charakteryzuje stany przejściowe. Ocena obrazów modułu i fazy z zastosowaniem takich parametrów jak np. RMS lub entropia pozwala na rozpoznawanie różnych stanów i ich dobrą separację. Dysponując odpowiednimi danymi uczącymi i stosując odpowiednio dobrany klasyfikator, możliwe jest skuteczne rozpoznawanie stanów technicznych. Należy również zaznaczyć, że zaproponowaną metodę można stosować do szybkozmiennych zjawisk cieplnych, dobierając odpowiednio częstotliwość akwizycji obrazów. Pozwoli to rozszerzyć pasmo częstotliwości, dla których mogą być wyznaczone obrazy modułu i fazy.

5.2.4. Ocena stanu technicznego z zastosowaniem dwuwymiarowej transformaty Fouriera

Kolejnym sposobem wyznaczania dodatkowych obrazów mogących znaleźć zastosowanie w ocenie stanu technicznego obiektu jest dwuwymiarowa transformata Fouriera (por. 2.5.6).


Wynikiem zastosowania dwuwymiarowej transformaty Fouriera jest dwuwymiarowy zbiór liczb zespolonych, który może być prezentowany w formie tzw. F-obrazów reprezentujących część rzeczywistą, urojoną, moduł i fazę przekształcenia Fouriera obrazu źródłowego. F-obrazy

są trudne w interpretacji ze względu na brak bezpośredniego związku z cechami fizycznymi widocznymi na obrazie. Stanowią one odrębną reprezentację obrazu rzeczywistego i mogą nieść cenne informacje diagnostyczne w porównaniu z obrazem rzeczywistym. Na F-obrazach można dostrzec charakterystyczne wzorce wynikające z własności dwuwymiarowej transformaty Fouriera. Analiza charakterystycznych wzorców umożliwia ilościową ocenę takich obrazów, a w przypadku ich sekwencji możliwe jest generowanie nowych sygnałów diagnostycznych. W ramach przeprowadzonych badań zastosowano dwuwymiarową transformatę Fouriera obrazów zarejestrowanych w trakcie eksperymentów diagnostycznych prowadzonych na laboratoryjnym modelu maszyny wirnikowej (por. 5.2.1). Podobnie jak w przypadku rozważań dotyczących zastosowania jednowymiarowej transformaty Fouriera, wykorzystano obrazy właściwe obszarów ROI3 i ROI4 przedstawiających podpory łożyskowe. Po przekształceniu obrazów właściwych do nowej postaci F-obrazów amplitudy i fazy oraz przesunięciu ćwiartek, F-obrazy poddano dalszej analizie. Rozpatrywano algorytmy pozwalające wyznaczać takie parametry jak:

- osiowa charakterystyka wzdłużna i poprzeczna F-obrazu,
- charakterystyka kołowa F-obrazu,
- charakterystyka polarna F-obrazu,
- geometryczne cechy kształtu F-obrazu,
- wzdłużna, poprzeczna i kołowa wartość średnia F-obrazów.

5.2.4.1. Detekcja zmian stanu obiektu na podstawie osiowej charakterystyki wzdłużnej i poprzecznej F-obrazów


F-obrazy cechują się symetrią, która wynika z własności dwuwymiarowej transformaty Fouriera. Symetria w F-obrazach występuje względem poziomej i pionowej osi obrazu. Pionowa i pozioma oś symetrii przecina się w punkcie środkowym obrazu, w którym występuje składowa stała $CC = FA(X/2 + 1, Y/2 + 1)$ (dla obrazów o parzystej liczbie wierszy). Osie przebiegają wzdłuż wartości obrazu, co pozwala na identyfikowanie wektorów wartości obrazów w kierunku osi pionowej i poziomej (rys. 5.30).




Rys. 5.30. Idea wyznaczania wzdłużnej i poprzecznej charakterystyki osiowej F-obrazu

Na podstawie takich wektorów możliwe jest utworzenie osiowych charakterystyk wartości obrazu w funkcji jego szerokości i wysokości. Charakterystyki te nazwano wzdłużną i poprzeczną. Można je traktować jako cechy funkcyjne F-obrazu. Na rysunku

5.31 przedstawiono przykładowe przebiegi wzdłużnej A_w i poprzecznej A_p charakterystyki wybranego F-obrazu amplitudy dla obszaru ROI3.



Rys. 5.31. Przykład wzdłużnej A_w i poprzecznej A_p charakterystyki osiowej wybranego F-obrazu amplitudy dla obszaru zainteresowania ROI3




Rys. 5.32. Przykład sygnałów diagnostycznych wariacji wyznaczonych na podstawie wzdłużnej i poprzecznej charakterystyki osiowej F-obrazów amplitudy dla obszaru zainteresowania ROI3 i ROI4

Charakterystyki wzdłużna i poprzeczna mogą zostać poddane dalszej analizie w celu wyznaczenia ich charakterystycznych parametrów. Przy czym, ze względu na symetrię, analizie wystarczy poddać połowę wartości charakterystyki. Wartości każdego z parametrów można wykorzystać do utworzenia sygnału diagnostycznego przydatnego w identyfikacji stanu technicznego obiektu. Na rysunku 5.32 przedstawiono przykładowe sygnały diagnostyczne

wariancji wyznaczone na podstawie charakterystyk wzdłużnych i poprzecznych. Na podstawie sygnałów wariancji możliwa jest detekcja zmian stanu technicznego, co świadczy o ich przydatności w ocenie stanu technicznego obiektów technicznych.


5.2.4.2. Detekcja zmian stanu obiektu na podstawie charakterystyki kołowej F-obrazów

Podobnie jak w przypadku osiowych charakterystyk wzdłużnych i poprzecznych F-obrazów, możliwe jest określenie charakterystyki kołowej na podstawie wartości obrazu leżących na profilu o kształcie okręgu o średnicy D , którego środek pokrywa się ze środkiem F-obrazu (5.33) w punkcie $CC = FA(X/2 + 1, Y/2 + 1)$. Charakterystyka kołowa jest funkcją $C = f(\alpha)$, której argumentem jest kąt między prostą przechodzącą przez punkt obrazu leżący na okręgu o określonej średnicy D i osią poziomą obrazu. Wartości charakterystyki będą uzależnione od średnicy okręgu D mogącej przyjmować wartości w granicach $D \in (1, \min[M, N])$. Dobór średnicy okręgu D może być przedmiotem optymalizacji.




Rys. 5.33. Idea wyznaczania profilu kołowego

Na rysunku 5.34 przedstawiono przykładowe przebiegi charakterystyk kołowych wyznaczonych na podstawie F-obrazów amplitudy w obszarze ROI3 dla trzech różnych stanów technicznych. Przyjęta wartość średnicy okręgu D wynosiła 50% minimalnej szerokości obrazu.



Rys. 5.34. Przykładowe przebiegi charakterystyk kołowych dla F-obrazów reprezentujących różne stany techniczne

Charakterystykę kołową również można poddać analizie w celu wyznaczenia jej cech. W trakcie badań wyznaczano różne cechy statystyczne charakterystyk kołowych F-obrazów. Przykładowy przebieg sygnału wartości RMS charakterystyk kołowych F-obrazów amplitudy dla obszarów ROI3 i ROI4 zaprezentowano na rysunku 5.35.

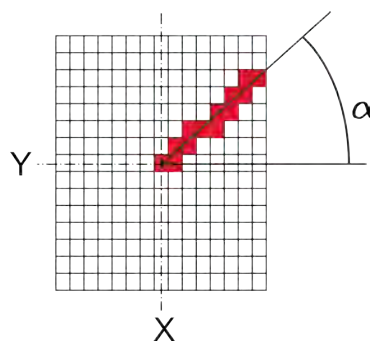


Rys. 5.35. Przykłady sygnałów diagnostycznych wyznaczonych na podstawie charakterystyk kołowych F-obrazów

Sygnały diagnostyczne powstałe w wyniku oceny charakterystyk kołowych również pozwalają identyfikować zmiany stanu technicznego. Dodatkowo można zaobserwować, że dla zjawisk cieplnych o większej intensywności (jak w przypadku bardziej obciążonego węzła łożyskowego nr 2) sygnały charakteryzują się mniejszym szumem.

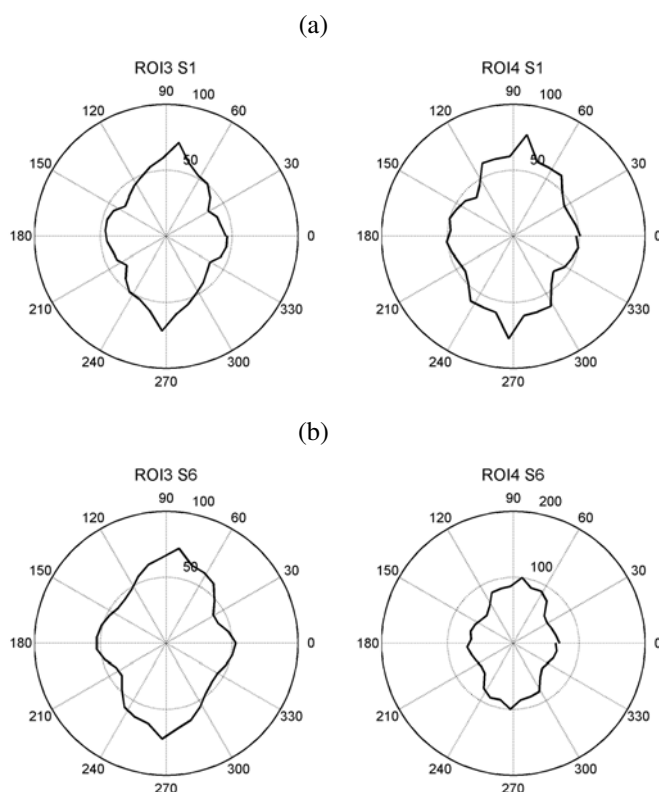
5.2.4.3. Detekcja zmian stanu obiektu na podstawie charakterystyki polarnej F-obrazów

Innym sposobem analizy F-obrazów jest metoda polegająca na obliczaniu sumy wartości pikseli F-obrazu $SL_{\alpha} = \sum L(i)$ wzdłuż prostej wodzącej zaczepionej w środkowym punkcie obrazu i zmieniającej swoje położenie kątowe α względem osi poziomej (rys. 5.36). Składnikami sumy jest wektor wartości pikseli, przez które przechodzi prosta.



Rys. 5.36. Istota wyznaczania charakterystyki polarnej

Na podstawie wartości sum wyznaczonych wzdłuż linii położonych pod różnymi kątami α możliwe jest utworzenie charakterystyki polarnej. Na rysunku 5.37 przedstawiono przykładowe charakterystyki polarne wyznaczone dla przykładowych F-obrazów w obszarach zainteresowania ROI3 i ROI4 oraz reprezentujących stany techniczne S1 i S6.



Rys. 5.37. Przykładowe charakterystyki polarne wyznaczone dla F-obrazów reprezentujących obszar zainteresowania ROI3 i ROI4 oraz stany S1 (a) i stan S6 (b)

Charakterystyki są źródłem cennych informacji o zmianie stanu i mogą być przedmiotem dalszej analizy. Analiza ta może polegać na wyznaczaniu parametrów takich jak kąt, dla którego wystąpiła maksymalna wartość sumy pikseli wzdłuż prostej wodzącej LS . Wykorzystanie tej cechy do wyznaczenia sygnału diagnostycznego pozwoli śledzić położenie charakterystycznych obiektów na obrazie i na tej podstawie oceniać zmiany stanu technicznego. Do oceny charakterystyk polarnych zastosowane mogą być również metody analizy obrazów wykorzystujące geometryczne cechy kształtów.


5.2.4.4. *Detekcja zmian stanu obiektu na podstawie geometrycznych cech obiektów na F-obrazach*

F-obrazy przedstawiają często bardzo trudne do interpretacji obiekty o osiowo-symetrycznych kształtach, które zmieniają się wraz z zawartością obrazu, na podstawie którego wyznaczany był F-obraz. Powyższe stwierdzenie szczególnie mocno odnosi się do F-obrazów amplitudy. Wszelkie zmiany stanu technicznego powodują, że na obrazach termograficznych również pojawiają się zmiany w rozkładzie wartości temperatur, co skutkuje zmianami cech F-obrazów. Zmiany te można zidentyfikować, analizując kształty obiektów na F-obrazach amplitudy. W trakcie badań zaproponowano algorytm analizy F-obrazów i wyznaczania jednowymiarowego sygnału diagnostycznego. Algorytm polega na realizacji następujących kroków:

- binaryzacja F-obrazu z określonym globalnym górnym progiem th ,
- przetwarzanie obrazu po binaryzacji,

- wyznaczenie geometrycznej cechy kształtu obiektu powstałego w wyniku binaryzacji,
- utworzenie sygnału diagnostycznego na podstawie geometrycznej cechy kształtu,
- ocena sygnału diagnostycznego,
- identyfikacja i ocena stanu technicznego.


Bazując na F-obrazach obszarów zainteresowania ROI3 i ROI4, przeprowadzono ich binaryzację z górnym progiem. Wartość progu wynosiła $th = 0,95$ i była wartością globalną taką samą dla wszystkich obrazów. Wartość progu binaryzacji wyznaczono w sposób eksperymentalny, jednak można wskazać również inne strategie doboru progu, np.: wyznaczony dla reprezentatywnej sekwencji F-obrazów dla wybranego stanu odniesienia, np. dla stanu S1, gdy maszyna działała bez obciążenia. Innym sposobem jest przeprowadzenie optymalizacji. Przy czym kryterium optymalizacji może być np. minimalizacja poziomu szumu w sygnale diagnostycznym lub maksymalizacja rozrzutu międzyklasowego. Na rysunku 5.38 przedstawiono wybrane wersje binarne F-obrazów dla różnych stanów technicznych po przeprowadzeniu operacji progowania. Dostrzegalne są wyraźne różnice w kształcie i położeniu obiektów na obrazach.



Rys. 5.38. Przykładowe F-obrazy modułu i fazy po binaryzacji zarejestrowane w różnych stanach technicznych: (a) stan S1; (b) stan S2; (c) stan S3; (d) stan S4; (e) stan S5; (f) stan S6

Obiekty powstałe po binaryzacji poddano analizie geometrycznej. Istnieje duży zbiór geometrycznych cech kształtu, które można zastosować w analizie tego typu obrazów binarnych. Zostały one przedstawione w dodatku do pracy (por. dodatek B). W omawianym przykładzie dla każdego zbinaryzowanego F-obrazu wyznaczono cechę, jaką było względne pole powierzchni A_{rel} będące ilorazem pola powierzchni obszaru obrazu binarnego powyżej doświadczalnie dobranego progu A_{th} do powierzchni odniesienia A_{tot} , którą był obszar całego obrazu. Wyznaczone w ten sposób cechy dla całej sekwencji F-obrazów pozwoliły na utworzenie sygnałów diagnostycznych. Na rysunku 5.39 przedstawiono sygnały diagnostyczne względnego pola powierzchni w zależności od indeksu kolejno rejestrowanego obrazu wyznaczone na podstawie zbinaryzowanych F-obrazów dla obszarów ROI3 i ROI4.

Wyznaczone przebiegi sygnałów diagnostycznych pozwalają na skuteczną detekcję zmian stanu technicznego i umożliwiają śledzenie zmian stanów cieplnych obiektu.




Rys. 5.39. Przebiegi sygnałów diagnostycznych względnego pola powierzchni zbinaryzowanych F-obrazów dla obszaru ROI3 (a) i ROI4 (b) 5.39(b)

Dysponując reprezentatywnym zbiorem różnych przebiegów tego typu sygnału, dla każdego ze stanów możliwe jest przygotowanie przestrzeni cech uczących i przeprowadzenie skutecznej klasyfikacji stanu technicznego.

5.2.4.5. Ocena stanu obiektu na podstawie wzdłużnej, poprzecznej i kołowej wartości średniej F-obrazów

Na podstawie obserwacji charakterystycznych wzorców pojawiających się na F-obrazach wyznaczonych dla różnych stanów działania maszyny, zaproponowano 3 cechy parametryczne pozwalające oceniać ilościowo zmiany w obrazach. Cechy są uogólnieniem opisanych wcześniej osiowej wzdłużnej i poprzecznej charakterystyki F-obrazu oraz charakterystyki kołowej wyznaczonej na podstawie profilu okręgu. Cechy pozwalają na wyznaczenie średniej wartości F-obrazów w prostokątnych i kołowym obszarze umieszczonych symetrycznie względem osi poziomej, pionowej i środka F-obrazu (rys. 5.40).



Rys. 5.40. Koncepcja wyznaczania wzdłużnej (a), poprzecznej (b) i kołowej (c) wartości średniej F-obrazów

Rozpatrywane cechy F-obrazów termograficznych zdefiniowano w następujący sposób:

HFP – wzdłużna wartość średnia F-obrazu (rys. 5.40(a)):

$$HFP = \frac{1}{XH} \sum_{x=1}^X \sum_{y=\frac{Y-H}{2}+1}^{\frac{Y+H}{2}} F(x,y) \quad (5.19)$$

VFP – poprzeczna wartość średnia F-obrazu (rys. 5.40(b)):

$$VFP = \frac{1}{YV} \sum_{x=\frac{X-W}{2}+1}^{\frac{X+W}{2}} \sum_{y=1}^Y F(x,y) \quad (5.20)$$

CFP – kołowa wartość średnia F-obrazu (rys. 5.40(c)):

$$CFP = \sum_{r=\frac{X-D}{2}+1}^{\frac{X+D}{2}} \sum_{1 \leq x^2+y^2 \leq r} F(x,y) \quad (5.21)$$

gdzie:

X – szerokość F-obrazu w pikselach,

Y – wysokość F-obrazu w pikselach,

W – szerokość pionowego obszaru środkowego F-obrazu w pikselach,

H – szerokość poziomego obszaru środkowego F-obrazu w pikselach,

D – średnica koła o środku pokrywającym się ze środkiem F-obrazu w pikselach,

$x = 1, 2, \dots, X$ – indeksy pikseli szerokości obrazu,

$y = 1, 2, \dots, Y$ – indeksy pikseli wysokości obrazu.

Wyznaczenie cech wymaga doboru ich parametrów. W ramach przeprowadzonych badań parametry *H*, *W* oraz *D* dobrano na drodze optymalizacji, przy czym funkcją celu była maksymalna sprawność klasyfikacji stanu technicznego. Na potrzeby optymalizacji zdefiniowano warunki brzegowe, jakimi były zaprezentowane poniżej minimalne i maksymalne wartości parametrów cech F-obrazów:

— *HFP*, $H_{min} = 1$, $H_{max} = 30$,

— *VFP*, $W_{min} = 1$, $W_{max} = 20$,

— *CFP*, $D_{min} = 1$, $D_{max} = 20$.

Warunki te wynikają z rozmiarów rozpatrywanych F-obrazów. Ze względu na niewielką przestrzeń możliwych rozwiązań optymalne parametry cech wyznaczono za pomocą poszukiwań systematycznych.

Na potrzeby poszukiwania optymalnych wartości parametrów posłużono się klasyfikatorem *k* najbliższych sąsiadów (*k*-NN). W celu oceny trafności klasyfikacji estymację błędu klasyfikacji prowadzono z zastosowaniem metody walidacyjnej leave-one-out (LOO). Miarą sprawności klasyfikatora była względna liczba błędnych klasyfikacji *err*:

$$err = \frac{N_e}{N} \quad (5.22)$$

gdzie:

N – liczba rozpatrywanych przykładów,

N_e – liczba błędnie sklasyfikowanych przykładów.

Na podstawie względnej liczby błędnych klasyfikacji wyznaczono sprawność klasyfikatora eff w następujący sposób:

$$eff = (1 - err) \cdot 100\% \quad (5.23)$$

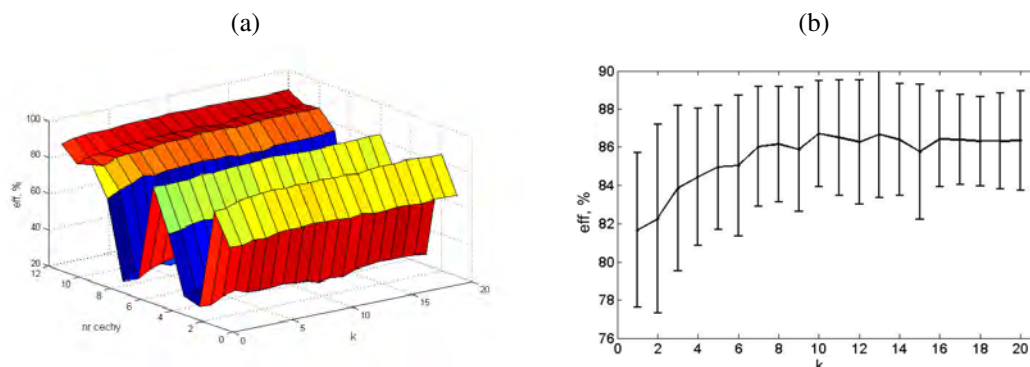
Istotnym parametrem klasyfikatora k-NN jest wartość k . W opisywanym przykładzie wartość ta dobrana została iteracyjnie podczas optymalizacji parametrów cech.

Klasyfikację prowadzono, wykorzystując wartości cech F-obrazów (HFP, VFP, CFP) wyznaczone dla dwóch rodzajów F-obrazów – amplitudy i fazy oraz dwóch obszarów zainteresowania ROI3 i ROI4. Dało to w efekcie końcowym dla każdego F-obrazu 12 różnych cech, których nazwy zakodowano według następującego schematu:

<Id obszaru zainteresowania ROI>_<Id cechy>_<Typ F-obrazu>

np.: ROI3_HFP_P oznacza nazwę cechy, której wartość wyznaczono wg wzoru 5.2.4.5 dla F-obrazu fazy i obszaru zainteresowania ROI3.

Na rysunku 5.41 przedstawiono wyniki poszukiwania optymalnej wartości liczby najbliższych sąsiadów k . Na podstawie 5 najwyższych wartości sprawności klasyfikacji wybranych z przestrzeni możliwych rozwiązań 5.41(a) przyjęto wartość $k = 10$. Na rysunku 5.41(b) przedstawiono przebieg średniej sprawności klasyfikacji w zależności od liczby najbliższych sąsiadów k używanych w zastosowanym klasyfikatorze.



Rys. 5.41. Wyniki optymalizacji wartości liczby najbliższych sąsiadów k : (a) – przestrzeń sprawności klasyfikacji dla różnych cech i parametrów klasyfiaktora k ; (b) – przebieg średniej wartości klasyfikatora w funkcji liczby najbliższych sąsiadów k

Wyniki klasyfikacji oraz wartości optymalnych parametrów cech F-obrazów przedstawiono w tabeli 5.9. Przyjęto, że optymalną wartością parametru cechy była ta, dla której uzyskano maksymalną wartość sprawności klasyfikacji. W tabeli zamieszczono również pozostałe statystyki opisujące wartości uzyskanych sprawności klasyfikacji. Rozrzut wartości sprawności klasyfikatora jest duży i zależy od rodzaju cechy F-obrazu. Najniższe wartości sprawności klasyfikacji (29%–34%) otrzymano na podstawie oceny F-obrazów fazy z zastosowaniem cech HFP i VFP. Te same cechy pozwalają uzyskać zadowalające wyniki klasyfikacji dla F-obrazów amplitudy (63%–83%). Najlepsze wyniki klasyfikacji zarówno dla F-obrazów amplitudy, jak i fazy otrzymano, stosując cechę CFP (73%–88%).


Na podstawie uzyskanych wyników klasyfikacji można również stwierdzić, że F-obrazy dla obszaru ROI4 są bardziej reprezentatywne na potrzeby identyfikacji stanu technicznego niż F-obrazy dla obszaru ROI3, dla którego wyniki klasyfikacji są w przeważającej mierze gorsze. Potwierdzają to również wyniki oceny stanu uzyskane w wyniku stosowania

Tab. 5.9. Maksymalne sprawności klasyfikatora wyznaczone dla wszystkich rozpatrywanych stanów technicznych


Lp.	nazwa cechy	parametr cechy	wartość parametru	max. eff. %	średnia eff. %	min. eff. %	std %	var %
1	ROI3_VFP_A	H	20	64	59	54	1,90	0,03
2	ROI4_VFP_A	H	18	83	80	76	1,82	0,03
3	ROI3_VFP_P	H	2	27	23	20	2,03	0,04
4	ROI4_VFP_P	H	7	33	25	21	2,03	0,06
5	ROI3_HFP_A	W	29	65	56	43	6,18	0,38
6	ROI4_HFP_A	W	26	85	80	74	2,21	0,04
7	ROI3_HFP_P	W	9	34	28	24	2,27	0,05
8	ROI4_HFP_P	W	9	29	24	20	2,14	0,04
9	ROI3_CFP_A	D	14	74	62	49	7,11	0,51
10	ROI4_CFP_A	D	20	84	75	61	5,42	0,29
11	ROI3_CFP_P	D	6	83	37	20	17,71	3,14
12	ROI4_CFP_P	D	6	89	43	26	21,41	4,58

innych metod analizy F-obrazów. Rozbieżności w wynikach klasyfikacji są efektem różnego obciążenia łożysk. Z badawczego punktu widzenia dane reprezentujące obszar ROI3 są jednak bardziej interesujące, ponieważ pozwalają porównywać różne strategie estymacji F-obrazów i identyfikacji stanu pod kątem wykrywania stanów słabo rozpoznawalnych. Na rysunkach 5.42, 5.43, 5.44 przedstawiono wybrane przebiegi wartości sprawności klasyfikacji w funkcji parametrów rozpatrywanych cech F-obrazów. Funkcje pokazują istnienie zależności między parametrami cechy a wartościami sprawności klasyfikacji. W przypadku cech F-obrazów amplitudy widać tendencje do wzrostu sprawności klasyfikacji wraz ze wzrostem wartości parametru cechy. W niektórych przypadkach wartość maksymalną sprawności uzyskano dla wartości maksymalnej parametru, co świadczy o tym, że wystarczającym parametrem pozwalającym oceniać F-obrazy może być wartość średnia wyznaczona dla całego obszaru obrazu. Analiza funkcji sprawności klasyfikatora i parametrów cech F-obrazów amplitudy pozwala również stwierdzić, że wartości parametrów cech powinny być większe od połowy wartości granicznych wynikających z rozmiarów F-obrazu. Na podstawie analizy funkcji sprawności klasyfikacji wyznaczonej dla cech F-obrazów fazy można zauważyć szereg lokalnych minimów i maksimów. We wszystkich rozpatrywanych przypadkach F-obrazów fazy, optymalne wartości parametrów cech były mniejsze niż połowa przyjętych granicznych wartości. Ze względu na złożony charakter F-obrazów fazy, wyjaśnienie fluktuacji wartości sprawności klasyfikatora w przypadku cechy CFP jest trudne. Należy się spodziewać, że jest to złożony efekt wynikający z treści F-obrazu, jego małej rozdzielczości, sposobu estymacji (w przypadku obrazu cyfrowego okrąg jest przybliżany za pomocą fragmentów liniowo ułożonych pikseli).


Wyniki klasyfikacji (tab. 5.9) są zadowalające i wskazują, że przyjęte podejście do analizy F-obrazów i oceny stanu technicznego maszyny jest skuteczne. Łatwo zauważyć, że cechy pozwalają identyfikować każdy z rozpatrywanych stanów technicznych z różną skutecznością i wzajemnie mogą się uzupełniać. Wynika z tego, że dobrym rozwiązaniem byłoby rozpatrywać cechy F-obrazów łącznie. Istnieją metody łącznej analizy danych diagnostycznych [41, 50]. Jednym z ciekawych rozwiązań może być zastosowanie fuzji klasyfikatorów (por. 2.8.2).



Rys. 5.42. Wartości sprawności klasyfikacji w funkcji parametru D cechy CFP wyznaczonej dla F-obrazu amplitudy i fazy odpowiednio w obszarze ROI3 i ROI4



Rys. 5.43. Wartości sprawności klasyfikacji w funkcji parametru H cechy HFP wyznaczonej dla F-obrazu amplitudy i fazy w obszarze ROI3



Rys. 5.44. Wartości sprawności klasyfikacji w funkcji parametru W cechy VFP wyznaczonej dla F-obrazu amplitudy i fazy w obszarze ROI4

5.2.4.6. Przykład podniesienia skuteczności oceny stanu poprzez zastosowanie fuzji klasyfikatorów

W celu połączenia wyników klasyfikacji uzyskanych niezależnie dla każdego z rozpatrywanych cech F-obrazów zastosowano metodę fuzji klasyfikatorów bazującą na teorii Dezerta-Smarandache (DSmT) (por. 2.8.2).

W trakcie badań rozpatrywano różne aspekty fuzji klasyfikatorów zależne od rodzaju rozpatrywanych cech oraz obszarów zainteresowania. Aby ograniczyć zakres rozważań,

w dalszej części ograniczono się do rozpoznawania dwóch stanów technicznych S2 i S3, ze względu na wcześniejsze trudności w ich skutecznej identyfikacji. Dla celów porównania wyników fuzji klasyfikatorów w tabeli 5.10 zestawiono wyniki klasyfikacji otrzymane poprzez stosowanie niezależnych klasyfikatorów bazujących na każdej z rozpatrywanych 12 cech. Stosowano wcześniej opisywany schemat klasyfikacji (k-nn i LOO). Wartości sprawności zależą od obszaru zainteresowania. Dla obszaru ROI3 stan S2 sklasyfikowano na maksymalnym poziomie 17%, podczas gdy dla obszaru ROI4 maksymalna sprawność klasyfikacji wyniosła 58%. Dla stanu S3 najlepsze wyniki klasyfikacji wynosiły 100% dla obszaru ROI3 i 75% dla obszaru ROI4. Jak widać, najlepsze wyniki klasyfikacji otrzymano dla F-obrazów amplitudy.

Tab. 5.10. Sprawności klasyfikacji dla stanów S2 i S3 uzyskane w wyniku stosowania niezależnych klasyfikatorów

	ROI3						ROI4					
	HFP		VFP		CFP		HFP		VFP		CFP	
	A	P	A	P	A	P	A	P	A	P	A	P
S2	17%	17%	8%	0%	17%	0%	58%	17%	58%	0%	58%	50%
S3	92%	8%	100%	0%	92%	0%	42%	8%	25%	17%	75%	17%

Pierwszym badanym aspektem zastosowania fuzji klasyfikatorów był jej wpływ na zdolności rozpoznawania stanu przy połączeniu informacji pochodzących z dwóch klasyfikatorów wyznaczonych na podstawie cech tego samego rodzaju określonych dla F-obrazów amplitudy i fazy odnoszących się tylko do jednego obszaru zainteresowania. W tabeli 5.11 zestawiono sprawności klasyfikacji dla tego przypadku. Porównując z wynikami dla niezależnych klasyfikatorów, widoczny jest wzrost średniej sprawności klasyfikacji dla wszystkich rozpatrywanych stanów. Można zaobserwować, że w przypadku niezależnie rozpatrywanych cech, gdzie uzyskano wysokie sprawności np. dla ROI3_VFP_A – 100%, fuzja klasyfikatorów spowodowała obniżenie sprawności. Efekt ten wynika z jednorodności danych charakteryzujących tylko jeden obszar zainteresowania. Zgodnie z istotą stosowanej metody fuzji wymaga ona danych niejednorodnych.

Tab. 5.11. Sprawność klasyfikacji po fuzji dwóch klasyfikatorów dla tego samego typu cech wyznaczonych na podstawie F-obrazów amplitudy i fazy

	ROI3			ROI4		
	HFP	VFP	CFP	HFP	VFP	CFP
	A&P	A&P	A&P	A&P	A&P	A&P
S2	22%	17%	67%	58%	25%	42%
S3	67%	75%	83%	58%	75%	58%

Uwzględniając własność metody fuzji, przeprowadzono obliczenia dla klasyfikatorów wyznaczonych na podstawie tych samych rodzajów cech, lecz różnych obszarów zainteresowania. Wybrane łączne sprawności klasyfikacji zestawiono w tabeli 5.12, w której zaznaczono maksymalne wartości sprawności klasyfikacji. Można dostrzec wyraźną poprawę średniej sprawności klasyfikacji w stosunku do poprzednich wyników. Jest to efektem wprowadzenia informacji diagnostycznej o globalnym stanie technicznym poprzez uwzględnienie w procesie

fuzji, klasyfikatorów wyznaczonych dla cech z innego obszaru zainteresowania. Innymi słowy poprawę uzyskano, obniżając stopień korelacji między cechami uwzględnianymi podczas klasyfikacji.

Tab. 5.12. Sprawność klasyfikacji po fuzji dwóch klasyfikatorów dla tego samego typu cech wyznaczonych na podstawie F-obrazów amplitudy i fazy oraz różnych obszarów zainteresowania

	HFP	VFP	CFP
S2	R3_HFP_A & R4_HFP_A 58%	R3_HFP_A & R4_HFP_A 33%	R3_CFP_A & R4_CFP_P 70%
S3	R3_HFP_A & R4_HFP_A 91%	R3_HFP_A & R4_HFP_P 92%	R3_CFP_A & R4_CFP_P 84%

W celu dalszego podniesienia łącznej sprawności klasyfikacji fuzji poddano pary klasyfikatorów wyznaczonych dla różnych cech i obszarów zainteresowania. Wybrane sprawności klasyfikacji zaprezentowano w tabeli 5.13. Uzyskane wyniki są lepsze od poprzednich, o czym świadczy maksymalna sprawność klasyfikacji dla stanu S2 wynosząca 72% dla klasyfikatorów ROI3_CFP_A i ROI4_HFP_A. Przypadku stanu S3 uzyskano najwyższą możliwą sprawność klasyfikacji 100% dla kombinacji klasyfikatorów ROI3_HFP_A i ROI4_CFP_P. Wyniki wskazują, że zaproponowane podejście stosujące fuzję klasyfikatorów jest przydatne w procesie oceny stanu technicznego maszyny.

Tab. 5.13. Sprawności klasyfikacji uzyskane w wyniku fuzji kombinowanych par klasyfikatorów

Kombinacja klasyfikatorów	S2	Kombinacja klasyfikatorów	S3
ROI3_CFP_A & ROI4_HFP_A	72 %	ROI3_HFP_A & ROI4_CFP_P	100%
ROI3_CFP_A & ROI4_CFP_P	67 %	ROI3_VFP_A & ROI4_VFP_A	100%
ROI3_CFP_A & ROI4_CFP_A	58%	ROI3_VFP_A & ROI4_HFP_A	92%

W dotychczasowych rozważaniach procesowi fuzji poddawano pary klasyfikatorów, jednak zastosowana reguła agregacji (PCR6) nie wprowadza ograniczeń co do liczby kombinowanych klasyfikatorów. W związku z tym w ramach dalszych badań fuzji poddano trzy klasyfikatory wyznaczone w obrębie jednego obszaru zainteresowania. Wybrane wyniki klasyfikacji zaprezentowano w tabeli 5.14. Uzyskane sprawności klasyfikacji są wyższe niż średnie sprawności dla klasyfikatorów rozpatrywanych niezależnie.

Tab. 5.14. Sprawności klasyfikacji uzyskane w wyniku fuzji 3 klasyfikatorów dla cech F-obrazów w obrębie pojedynczego obszaru zainteresowania

	ROI3	ROI4
S2	ROI3_HFP_A ROI3_HFP_P ROI3_CFP_P 58%	ROI4_VFP_A ROI4_HFP_A ROI4_CFP_P 67%
S3	ROI3_VFP_A ROI3_HFP_A ROI3_CFP_A 100%	ROI4_VFP_A ROI4_VFP_P ROI4_CFP_P 75%

W celu dalszej poprawy sprawności klasyfikacji fuzji poddano kombinacje 3 klasyfikatorów dla różnych cech i obszarów zainteresowania. Wyniki zaprezentowano w tabeli 5.15. W odniesieniu do przypadku, gdy rozpatrywano trzy klasyfikatory dla pojedynczych obszarów zainteresowania, nie zaobserwowano zmiany w sprawności klasyfikacji. W porównaniu z najlepszą sprawnością dla pojedynczego klasyfikatora sprawność klasyfikacji stanu S2 poprawiła się o 9%.

Tab. 5.15. Sprawność klasyfikacji po fuzji 3 klasyfikatorów wyznaczonych na podstawie cech F-obrazów dla obszarów zainteresowania ROI3 i ROI4

ROI3&ROI4	
S2	ROI3_CFP_A ROI3_CFP_P ROI4_CFP_P 67%
S3	ROI3_VFP_A ROI4_VFP_A ROI3_HFP_A 100%

W celu pełnego przedstawienia zalet fuzji klasyfikatorów w ocenie stanu technicznego maszyny wirnikowej, wyniki fuzji klasyfikatorów porównano z wynikami klasyfikacji uzyskanymi dla pojedynczego klasyfikatora wytrenowanego dla wielowymiarowej przestrzeni cech F-obrazów amplitudy i fazy. Rozpatrywano dwa przypadki:

- klasyfikator uwzględniający jednocześnie przestrzeń wszystkich 12 cech (3 cechy dla dwóch rodzajów F-obrazów i 2 obszarów zainteresowania),
- klasyfikator uwzględniający przestrzeń 5 cech, dla których średnia sprawność klasyfikacji dla wszystkich stanów była najwyższa (5.9).

Wyniki klasyfikacji dla stanów S2 i S3 przedstawiono w tabeli 5.16. Łatwo zauważyć, że uwzględnienie całej przestrzeni cech dało lepsze wyniki niż dla przypadku 5 najlepszych cech opisujących globalny stan obiektu. Jednak w porównaniu z wynikami fuzji 3 klasyfikatorów (tab. 5.15) sprawności są niższe o 5% i 19% odpowiednio dla stanów S2 i S3. Potwierdza to zalety stosowania fuzji klasyfikatorów.

Tab. 5.16. Maksymalne sprawności klasyfikacji w % dla wszystkich rozpatrywanych stanów technicznych wyznaczone dla wielowymiarowej przestrzeni wartości cech

Liczba cech	S2	S3
5	69 %	65 %
12	71 %	81 %

Dalsze badania polegające na zwiększaniu liczby pojedynczych klasyfikatorów w procesie fuzji nie spowodowały wzrostu sprawności klasyfikacji dla rozpatrywanych stanów technicznych. Wynika z tego, że istnieje graniczna liczba klasyfikatorów, których fuzja powoduje osiągnięcie maksymalnej wartości sprawności klasyfikacji.

5.2.5. Przykład zastosowania transformaty falkowej obrazów termograficznych w detekcji zmian stanu technicznego

Stosując analogię do metodyki wykorzystywanej w termografii aktywnej w trakcie realizacji badań, opracowano metodę analizy sekwencji obrazów z zastosowaniem transformaty falkowej, która wymagała przeprowadzenia następujących działań:

- wstępne przetwarzanie obrazów,
- wybór falki,
- ustalenie poziomu dekompozycji i analiza wielorozdzielcza,
- wyznaczenie sygnałów diagnostycznych,
- analiza otrzymanych wyników.

Do badań wykorzystano obrazy zarejestrowane w trakcie eksperymentów diagnostycznych przeprowadzonych na modelu maszyny wirnikowej. Podobnie jak w poprzednio opisanych przypadkach rozpatrywano sekwencje obrazów w obrębie obszarów zainteresowania ROI3 i ROI4.

5.2.5.1. Wstępne przetwarzanie obrazów


Pierwszą operacją wstępnego przetwarzania była normalizacja obrazów. Operacja ta skaluje wartości poszczególnych pikseli (wartości temperatury poszczególnych obszarów) do zakresu (0-255) odpowiedniego dla obrazów cyfrowych reprezentowanych przez 256 odcieni szarości. Operacja taka zmienia wartości temperatur, jednak nie ma wpływu na wyniki analizy, ponieważ na potrzeby identyfikacji zmian stanu technicznego istotne są względne różnice wartości pikseli w obrazie, a nie bezwzględne wartości temperatur.

5.2.5.2. Wybór funkcji bazowej przekształcenia falkowego

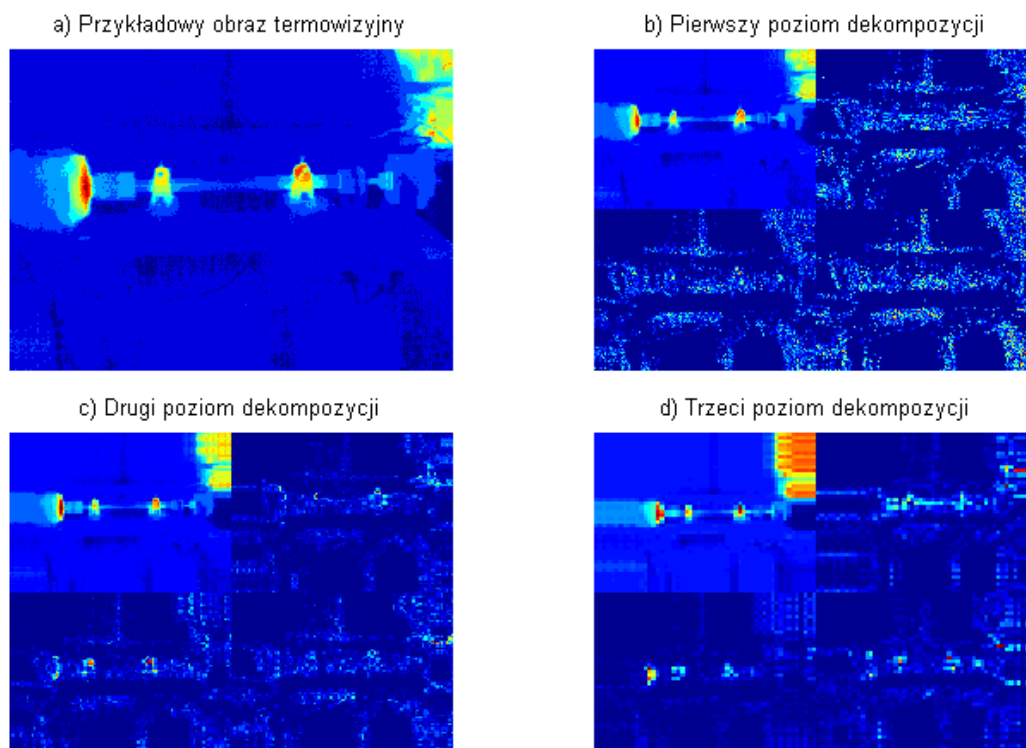
Przeprowadzenie analizy falkowej wymaga doboru odpowiedniej funkcji bazowej (falki). Na potrzeby badań, spośród wielu istniejących rodzin funkcji bazowych, rozpatrywano zbiór najczęściej stosowanych w analizie obrazów falek, takich jak *haar*, *db2*, *sym4*, *coif3* i *bior4*. Wyboru dokonano na podstawie wyników badań wstępnych polegających na analizie obrazów wzorcowych dla każdego z rozpatrywanych stanów maszyny. Na tym etapie badań rozpatrywano obrazy obejmujące całą obserwowaną maszynę. Takie podejście wpłynęło na skrócenie czasu całej procedury, gdyż obrazy całego obiektu dają globalny pogląd o charakterze zjawisk w nim zachodzących. Obrazy wzorcowe wyznaczano w ten sposób, że z sekwencji obrazów odpowiadającej danemu stanowi maszyny wybrano 10 obrazów reprezentantów i uśredniono ich wartości. Wynikiem takiego postępowania było 6 różnych obrazów wzorcowych reprezentujących stany maszyny S1–S6 (rys. 5.45).

Każdy z obrazów wzorcowych poddany został dyskretnemu przekształceniu falkowemu z zastosowaniem każdej z rozpatrywanych funkcji bazowych. Wyznaczono dekompozycje falkową na trzech poziomach (rys. 5.46).

Na pierwszym poziomie obrazy szczegółów charakteryzowały się dużą liczbą wartości losowych charakterze szumu. Poziom drugi dał zadowalające wyniki, natomiast na poziomie trzecim widać pogorszenie jakości obrazów. Procedurę wyboru funkcji bazowej przeprowadzono na podstawie obrazów aproksymacji i szczegółów uzyskanych dla drugiego poziomu dekompozycji. W wyniku transformacji falkowej 6 obrazów wzorcowych z zastosowaniem 5 różnych funkcji bazowych otrzymano 30 zestawów wzorcowych obrazów aproksymacji i szczegółów (poziomego, pionowego i diagonalnego) na drugim poziomie dekompozycji. Na podstawie wartości obrazów reprezentujących szczegóły poziome (LH), pionowe (HL)




Rys. 5.45. Ilustracja sposobu wybór obrazów reprezentantów dla każdego z rozpatrywanych 6 stanów technicznych obiektu



Rys. 5.46. Przykładowy obraz wzorcowy (a) poddany trójpoziomowej dekompozycji falkowej z zastosowaniem falki symlet 4

i diagonalne (HH) każdego obrazu wzorcowego wyznaczono wartości skuteczne RMS. Wartości skuteczne uporządkowano ze względu na rodzaj funkcji bazowej przekształcenia falkowego i obliczono wariancję wartości RMS dla każdej rozpatrywanej falki. W ten sposób możliwe było wybranie falki, dla której wariancja wartości skutecznej obrazów szczegółów uzyskała wartość najwyższą. Takie podejście wynikało z założenia, że obraz szczegółów o wysokiej wariancji powinien najlepiej odzwierciedlać zmiany stanu maszyny. Okazało się,

że największą wariancją wartości skutecznej (RMS) charakteryzują się obrazy szczegółów uzyskane z zastosowaniem falki *symlet 4* i *coiflet 3* (rys. 5.47). Do dalszych badań wybrano falkę *coiflet 3*.



Rys. 5.47. Porównanie wariancji wartości RMS obrazów szczegółów dla rozpatrywanych falek

5.2.5.3. Wybór poziomu dekompozycji i analiza wielorozdzielcza


Kolejnym krokiem prowadzącym do zastosowania przekształcenia falkowego w ocenie stanu maszyny był wybór poziomu dekompozycji, dla którego obrazy szczegółów posłużą do oceny stanu technicznego. Wstępny wybór poziomu dekompozycji przeprowadzono na podstawie jakościowej ceny porównawczej zdekomponowanych obrazów wzorcowych. Ocenie poddano głównie obrazy szczegółów. Zauważono, że obrazy na 4 i 5 poziomie dekompozycji nie nadawały się do dalszej analizy ze względu na niedostateczną jakość i zbyt małą rozdzielczość. Obrazy na pierwszym poziomie charakteryzowały się dominacją wysokiego poziomu szumu, szczególnie na obrazach szczegółów poziomych (LH) i diagonalnych (HH). Na kolejnym poziomie dekompozycji udział szumu był mniejszy i jego pozostałości widoczne były tylko na obrazie szczegółów diagonalnych (HH). Po dokładnym przeanalizowaniu przekształconych obrazów wzorcowych dla różnych stanów technicznych na potrzeby dalszych badań wybrano trzeci poziom rozwinięcia. Obrazy szczegółów na tym poziomie dekompozycji wydawały się najbardziej przydatne do ich dalszej analizy. Potwierdzeniem słuszności wyboru trzeciego poziomu dekompozycji są przebiegi sygnałów diagnostycznych przedstawione na rysunkach 5.48, 5.49 i 5.50.

5.2.5.4. Wyznaczenie sygnałów diagnostycznych i identyfikacja zmian stanu maszyny

Efektom stosowania transformaty falkowej o odpowiednio dobranej funkcji bazowej i poziomie dekompozycji są obrazy niosące nowe informacje o stanie technicznym obserwowanego w podczerwieni obiektu. Aby umożliwić wyznaczenie sygnałów diagnostycznych, obrazy reprezentowane przez obszary zainteresowania ROI3 i ROI4 zostały poddane trójpoziomowej dekompozycji falką *coiflet 3*, w wyniku czego otrzymano dwa zestawy sekwencji obrazów aproksymacji i szczegółów poziomych, pionowych i diagonalnych. Dla pokazania idei zastosowania transformaty falkowej obrazów termograficznych w diagnozowaniu obiektów technicznych, każdy obraz po dekompozycji falkowej został poddany analizie w celu wyznaczenia sygnałów diagnostycznych. Do wyznaczania sygnałów diagnostycznych posłużono się prostymi metodami statystycznymi umożliwiającymi wyznaczenie takich cech jak wartość

średnia, wariancja, odchylenie standardowe, wartość skuteczna itp. (por. dodatek C). W dalszej części rozważań posłużono się sygnałami diagnostycznymi wartości skutecznej (RMS).


Sygnały diagnostyczne wartości skutecznej wyznaczone dla sekwencji nowych obrazów dodatkowych powstałych w wyniku zastosowania trójpoziomowej transformaty falkowej przedstawiono na rys. 5.48 i 5.49.



Rys. 5.48. Przebieg sygnałów diagnostycznych wartości RMS dla obrazów aproksymacji (RMS_A) i szczegółów (RMS_H , RMS_V , RMS_D) powstałych na trzecim poziomie dekompozycji falkowej termogramów w obszarze ROI3


Ogólna analiza wykresów pozwala stwierdzić, że sygnały diagnostyczne wyznaczone dla obszaru ROI3 nie pozwalają jednoznacznie zidentyfikować wszystkich zmian stanu technicznego maszyn w przeciwieństwie do sygnałów wyznaczonych dla obszaru ROI4. Wynika to z faktu różnic w obciążeniu poszczególnych węzłów łożyskowych.

Można zauważyć, że w rozpatrywanym przypadku sygnał diagnostyczny RMS dla obrazów szczegółów pionowych (RMS_V) w obu obszarach zainteresowania umożliwia bardzo wyraźną identyfikację zmiany stanu S1 do S2 i S4 do S5. Dobrze wykrywalna jest również zmiana stanu S3 do S4. Trudniejsze, ale możliwe jest zidentyfikowanie zmian stanu S5 do S6. Sygnał ten jednak nie pozwala jednoznacznie zidentyfikować zmiany stanu S2 do S3. Przejścia ze stanu S3 do S4 lepiej oddaje przebieg sygnału diagnostycznego wyznaczony dla obrazów szczegółów diagonalnych (RMS_D) dla obszaru ROI3. Pomimo wysokiej wariancji pozwala on również dobrze zidentyfikować zmiany stanu S5 do S6 dla obu obszarów zainteresowania. Sygnał szczegółów poziomych (RMS_D) umożliwia zidentyfikowanie zmian stanu S1 do S2 i S4 do S5, natomiast nie pozwala jednoznacznie wykryć nieznacznych zmian stanu maszyny występujących między stanami S2 i S3 oraz S3 i S4. Sygnał aproksymacji (RMS_A) w rozpatrywanym przypadku nie niósł żadnych informacji. Taki przebieg sygnału wynika z rozmiarów obszaru zainteresowania i początkowej rozdzielczości obrazu, która spada wraz z każdym poziomem dekompozycji. Aby potwierdzić słuszność przyjętego sposobu postępowania przy wyborze poziomu dekompozycji, na rysunku 5.50 przedstawiono



Rys. 5.49. Przebieg sygnałów diagnostycznych wartości RMS dla obrazów aproksymacji (RMS_A) i szczegółów (RMS_H , RMS_V , RMS_D) powstałych na trzecim poziomie dekompozycji falkowej termogramów w obszarze ROI4


przebiegi sygnałów diagnostycznych wartości RMS dla obrazów aproksymacji i szczegółów na pierwszym i drugim poziomie dekompozycji wyznaczone dla obszaru ROI3. Dekompozycję przeprowadzono z zastosowaniem falki *coiflet 3*.



Rys. 5.50. Porównanie sygnałów diagnostycznych wartości RMS dla obrazów aproksymacji i szczegółów wyznaczonych na pierwszym (a) i drugim (b) poziomie dekompozycji falkowej

Łatwo zauważyć, że sygnały diagnostyczne dla obrazów szczegółów na pierwszym i drugim poziomie dekompozycji mają większy poziom szumów w porównaniu z sygnałami dla trzeciego poziomu dekompozycji, co utrudnia identyfikację niewielkich zmian stanu. Widoczny sygnał diagnostyczny wyznaczony na podstawie obrazów aproksymacji (RMS_A) daje ogólny pogląd o zmianach stanu technicznego szczególnie w odniesieniu do zjawisk, których czas trwania jest długi jak np. nagrzewanie maszyny, co widać dla obrazów od 1 do 120. Zauważono, że informacje o zmianach stanu obiektów zawarte w przebiegach sygnałów diagnostycznych wyznaczonych na podstawie obrazów szczegółów wzajemnie się uzupełniają. Można zatem

przyjąć, że najskuteczniej będzie prowadzić proces wnioskowania diagnostycznego, rozpatrując jednocześnie wszystkie sygnały diagnostyczne szczegółów. Jednym ze sposobów jednoczesnej analizy wielu sygnałów może być ich fuzja. W trakcie badań zastosowano prostą metodę fuzji sygnałów polegającą na wyborze wartości maksymalnej spośród trzech sygnałów wartości skutecznej wyznaczonych dla obrazów szczegółów poziomych, pionowych i diagonalnych (RMS_H , RMS_V , RMS_D). Przed operacją fuzji wartości sygnałów ujednolicono do zakresu (0,1). Na rysunku 5.51 przedstawiono przykładowe przebiegi sygnałów obrazów szczegółów po fuzji dla pierwszego, drugiego i trzeciego poziomu dekompozycji falkowej z zastosowaniem falki *coiflet 3*. Zaproponowana metoda fuzji poza wzrostem poziomu szumów, szczególnie dla sygnałów na pierwszym i drugim poziomie dekompozycji, pozwoliła również podnieść zdolności detekcyjne zmian stanu technicznego. Jest to dobrze widoczne dla sygnału na trzecim poziomie dekompozycji, gdzie wyraźniej widać zmianę stanu z S2 do S3 i S5 do S6. Skuteczność detekcji i identyfikacji zmian stanu można dodatkowo podnieść poprzez stosowanie wobec sygnałów diagnostycznych odpowiednich metod filtracji.



Rys. 5.51. Przykładowe przebiegi sygnałów diagnostycznych powstałe jako efekt fuzji sygnałów wartości RMS obrazów szczegółów. Fuzja polegała na wyborze wartości maksymalnej $RMS_{H,V,S} = \max(RMS_H^N, RMS_V^N, RMS_D^N)$

5.2.6. Zastosowanie analizy składowych głównych (PCA) w analizie sekwencji obrazów termowizyjnych

Analiza składowych głównych PCA (ang. *Principal Component Analysis*) jest popularną metodą analizy danych opartą na statystykach drugiego rzędu i stosowaną do kompresji danych, poszukiwania ich liniowych zależności oraz pozyskiwania informacji ze zbiorów danych. Metoda PCA może znaleźć zastosowanie do analizy sekwencji obrazów termowizyjnych [86], [117]. Rozpatrzmy sekwencję K obrazów podczerwieni o rozmiarze $M \times N$ pikseli pozyskanych podczas obserwacji termograficznej działającego obiektu technicznego. Rozpatrywana sekwencja zarejestrowanych obrazów może być reprezentowana jako trójwymiarowy zestaw danych $\mathbf{V}(i, j, t)$, gdzie $i = 1, 2, \dots, M$, $j = 1, 2, \dots, N$, i $t = 1, 2, \dots, K$. Informacja o stanie

technicznym obserwowanego obiektu, zawarta w oryginalnym zbiorze danych \mathbf{V} , pochodzi zarówno ze zmian przestrzennych na obrazie, jak i zmian zachodzących na obrazie w czasie rejestracji (np. zmiana kontrastu termicznego). Aby możliwe było przeprowadzenie analizy PCA, konieczne jest przekształcenie trójwymiarowego zbioru danych \mathbf{V} do dwuwymiarowej macierzy \mathbf{A} . Istnieją dwa sposoby przekształcenia:

- 1) Trójwymiarowy zbiór danych \mathbf{V} rozważany jest jako sekwencja termogramów, macierz \mathbf{A}_1 zawiera $M \times N$ wierszy i K kolumn i powstaje w wyniku rozwinięcia każdego obrazu do pojedynczego wektora i umieszczeniu go jako kolumny w macierzy \mathbf{A}_1 . W tym przypadku z punktu widzenia wymiarowego (przestrzennego) główne osie reprezentują obrazy, a rzutowane dane są profilami czasowymi.
- 2) Zbiór danych \mathbf{V} jest rozważany jako zbiór sygnałów wartości obrazów (profilu temperaturowych) w czasie obserwacji, wówczas macierz \mathbf{A}_2 składa się z K wierszy (każdy wiersz jest profilem czasowym) oraz $M \times N$ kolumn. W tym przypadku główne osie przedstawiają profile czasowe, a rzutowane dane są reprezentacją przestrzenną obrazów.


Przedstawione sposoby budowy macierzy \mathbf{A} można rozpatrywać również w kontekście zaproponowanej koncepcji diagnozowania stanu obiektu w dziedzinie czasu „mikro” i czasu „makro”. W omawianym przykładzie rozpatrywano pierwszy przypadek transformacji zbioru danych \mathbf{V} do macierzy \mathbf{A}_1 . Analiza PCA macierzy \mathbf{A}_1 o wymiarach $(M \times N) \times K$ polega na zamianie jej na tymczasową macierz składowych $\mathbf{TC}_s = \mathbf{U}_s^T \mathbf{A}_1^T$ o mniejszym wymiarze $s \times K$, gdzie $(s < (M \times N))$ poprzez rzutowanie macierzy \mathbf{A}_1 na nowy układ osi głównych. \mathbf{U}_s jest macierzą, gdzie s kolumn stanowi wektory rzutowania maksymalizujące wariancję danych. Każda oś główna odpowiada normalizowanemu ortogonalnemu wektorowi własnemu rozproszonej macierzy $\mathbf{S} = (\mathbf{A} - A_{mean})(\mathbf{A} - A_{mean})^T$ zawierającej $(M \times N) \times (M \times N)$ elementów. Proste podejście do PCA zakłada rozkład macierzy \mathbf{S} na wartości szczególne (SVD): $\mathbf{S} = \mathbf{U}\mathbf{D}\mathbf{U}^T$, gdzie \mathbf{U} jest macierzą zawierająca wektory własne (i.e. macierz modalna), \mathbf{D} jest macierzą diagonalną, której elementy diagonalne odpowiadają wartościom własnym macierzy \mathbf{S} (ułożone w porządku malejącym). Wybór wartości s zależy od wymaganej sumy proporcji wariancji obliczanej dla pierwszych s wartości własnych:

$$r = \frac{\sum_{i=1}^s d_i}{\sum_{i=1}^{M \times N} d_i} \quad (5.24)$$


gdzie: d_i jest i -tym elementem (wartością własną) macierzy diagonalnej \mathbf{D} .

W wielu przypadkach więcej niż 95% informacji zawarte jest w pierwszych trzech lub czasem pierwszych pięciu składowych głównych. Analizę PCA zastosowano do sekwencji obrazów termograficznych zarejestrowanych podczas obserwacji termograficznej laboratoryjnego modelu maszyny wirnikowej. Rozpatrywano obrazy właściwe dla obszarów zainteresowania ROI3 i ROI4. W wyniku analizy PCA sekwencji obrazów przekształconej do macierzy \mathbf{A}_1 wyznaczono 600 składowych głównych, przy czym w dalszych rozważaniach wzięto pod uwagę jedynie trzy pierwsze. Przebiegi pierwszych trzech składowych głównych przedstawiono odpowiednio dla obszaru ROI3 na rys. 5.52 i dla obszaru ROI4 na rys. 5.53.

W przypadku sygnału składowych głównych dla obrazów w obszarze ROI3 wyraźnie widoczne są zmiany wartości związane ze zmianą stanu technicznego maszyny. W przypadku sygnału diagnostycznego wyznaczonego dla obszaru ROI4 nie wszystkie zmiany stanu znajdują wyraźne odzwierciedlenie w zmianie wartości składowych głównych. Różnice w zdolności identyfikacji zmiany stanu w przypadku rozważanych podpór łożyskowych wynikają z różnego obciążenia łożysk. Podczas eksperymentu maszyna działała w dwóch bardzo podobnych



Rys. 5.52. Przebieg sygnałów diagnostycznych pierwszych trzech składowych głównych powstałych w wyniku zastosowania analizy PCA wobec obrazów termograficznych w obszarze ROI3



Rys. 5.53. Przebieg sygnałów diagnostycznych pierwszych trzech składowych głównych powstałych w wyniku zastosowania analizy PCA wobec obrazów termograficznych w obszarze ROI4

stanach technicznych S2 i S3. Zmianę między stanami trudno jest rozróżnić, szczególnie w przypadku obszaru ROI4 oraz przy analizie przebiegu zmian wartości pierwszej składowej głównej. Jednocześnie, analizując przebiegi drugiej i trzeciej składowej głównej, wykrycie zmiany stanu S2 na S3 jest już możliwe i dodatkowo dużo łatwiejsze niż podczas analizy przebiegu pierwszej składowej. W celu ilościowej oceny sygnałów uzyskanych, dzięki zastosowaniu analizy PCA przeprowadzona została klasyfikacja stanu technicznego maszyny z zastosowaniem wcześniej opisanego klasyfikatora bazującego na sztucznej sieci neuronowej (por. 5.2.2.10). Wejściem do sieci były wartości sześciu składowych głównych wyznaczone dla rozpatrywanych obszarów zainteresowania ROI3 i ROI4. Sieć posiadała jedną warstwę ukrytą z 3 neuronami. Wyjściem sieci były identyfikatory liczbowe rozpoznawanych stanów technicznych. Pozostałe parametry klasyfikatora neuronalnego pozostały takie jak opisano

w rozdziale 5.2.2.10. Sprawność klasyfikacji uzyskana w wyniku zastosowania klasyfikatora bazującego na sztucznej sieci neuronowej dla obu obszarów wynosiła 100%, co wskazuje, że zaproponowany algorytm analizy obrazów bazujący na analizie składowych głównych pozwala na identyfikację stanu technicznego. Dodatkowo badania wykazały, że analiza przebiegu wartości drugiej i trzeciej składowej jest bardziej użyteczna niż pierwszej składowej głównej.

5.3. Przykład oceny stanu na podstawie geometrycznych cech kształtu

Analiza geometrycznych cech obiektów na obrazach polega na ilościowym opisie kształtu i położenia fragmentu obrazu wyznaczonego przez uporządkowaną grupę pikseli tworzących obiekt o określonych cechach geometrycznych. Obiektem poddawany analizie może być zarówno obserwowany obiekt rzeczywisty, jak i nierealistyczny obiekt charakteryzujący pewne zarejestrowane na obrazie zjawisko, np. sposób padania światła czy rozkład temperatury. Do opisu kształtu obiektu wyodrębnionego z obrazu można zastosować wiele różnych cech. Są wśród nich cechy bezpośrednie i cechy pośrednie. Pierwsze z nich wynikają z bezpośredniej analizy rozpatrywanego obiektu i mogą być reprezentowane np. przez współrzędne obiektu, pole powierzchni, obwód. Do drugiej grupy można zaliczyć cechy wyznaczane w wyniku obliczeń prowadzonych na wybranych parametrach bezpośrednich. Przykładem takich cech mogą być momenty, kierunki i współczynniki np. zawartości. Szczegółową charakterystykę geometrycznych cech kształtu rozpatrywanych w trakcie badań zamieszczono w dodatku B.

W omawianym przykładzie geometryczna analiza kształtu została wykorzystana do oceny sekwencji obrazów właściwych opisanych za pomocą obszarów zainteresowania ROI3 i ROI4, a przedstawiających podpory łożyskowe badanego modelu maszyny wirnikowej.


5.3.1. Binaryzacja obrazów termograficznych

Niektóre z metod analizy obrazów (np. metody oceny kształtu obiektów) zamiast uwzględniać informacje niesione przez pojedyncze piksele, uwzględniają informacje zawarte w regionach homogenicznych pod względem pewnej własności obrazu, według przyjętego kryterium (kolor, tekstura, intensywność). Podstawowym sposobem wyznaczania jednorodnych struktur na obrazie jest segmentacja, a najprostszą metodą jest zastosowanie progowania. W ramach badań dokonano przeglądu i testowania m.in. takich metod progowania jak:

- metoda z ręcznym wyborem progu,
- metoda Niblacka,
- metoda korekcji tła,
- progowanie przez grupowanie (*clustering*),
- progowanie przez entropię,
- progowanie metryczne,
- progowanie względem momentów,
- progowanie przez wariancję,
- progowanie adaptacyjne,
- progowanie metodą Otsu.

W opisywanych badaniach obrazy termograficzne w obszarach zainteresowania ROI3 i ROI4 binaryzowano, stosując próg binaryzacji wyznaczony za pomocą metody zaproponowanej przez Otsu [68], która pozwala wyznaczyć próg binaryzacji th na podstawie histogramu poziomów jasności obrazu, traktując go jako zazębiające się dwa rozkłady

normalne odpowiadające tłu i obiektowi. Wartość progu th ustala się w zależności od wartości średnich μ_1 , μ_2 i odchyłeń standardowych rozkładów prawdopodobieństw tła i obiektu. Próg odcięcia przypada w miejscu maksymalnej wartości wariancji międzyklasowej. Na rysunku 5.54 zaprezentowano przykład zastosowania binaryzacji termogramów dla obszarów zainteresowania ROI3 i ROI4.



Rys. 5.54. Reprezentacje binarne przykładowych obrazów termograficznych dla obszarów zainteresowania ROI3 (a) i ROI4 (b)

Binaryzacja każdego obrazu analizowanej sekwencji termogramów może być zrealizowana z wykorzystaniem jednej z góry ustalonej wartości progu lub wyznaczeniem jej każdorazowo dla nowego obrazu sekwencji. W pierwszym przypadku konieczne jest dysponowanie reprezentatywnym zbiorem obrazów, na podstawie którego będzie można ustalić wartość progu wspólnego dla wszystkich obrazów. W trakcie badań zaproponowano wyznaczenie średniej wartości progu na podstawie wzorcowej sekwencji obrazów opisujących maszynę w stanie technicznym uznawanym za prawidłowy. W przypadku rozpatrywanych danych średnia wartość progu binaryzacji wyznaczona została dla sekwencji 100 obrazów pozyskanych podczas działania maszyny w stanie technicznym S1.

W przypadku gdy próg wyznaczany jest każdorazowo dla kolejnych obrazów termograficznych rozpatrywanej sekwencji, jego wartość może stanowić parametr diagnostyczny. Jeśli założyć, że możliwe jest wyznaczenie średniego progu binaryzacji na podstawie sekwencji obrazów zarejestrowanych dla maszyny działającej w stanie technicznym uznawanym jako sprawny, to można taką wartość potraktować jako wartość odniesienia dla wartości progów binaryzacji wyznaczanych dla kolejno rejestrowanych obrazów w trakcie eksploatacji maszyny w innych stanach technicznych. W takim przypadku wartości wyznaczonych progów dla obrazów zarejestrowanych dla stanów technicznych odbiegających od stanu odniesienia powinny się różnić od przyjętej wartości progu odniesienia. Wynik porównania wartości progu odniesienia z wartością progu wyznaczoną dla bieżącego obrazu będzie miarą zmian stanu technicznego, która może być traktowana jak wartość sygnału diagnostycznego. Czynnikiem decydującym o możliwości identyfikacji takich odchyłeń jest opracowanie odpowiedniej metody wyznaczania progu.

5.3.2. Wyznaczanie sygnałów diagnostycznych

Dla każdego zbinaryzowanego obrazu termograficznego wyznaczono zbiór 81 geometrycznych cech kształtu. Wykorzystano do tego oprogramowanie LabView i moduł do projektowania systemów wizyjnych (*NI Visio Development Module*), w którym zaimplementowano funkcję pozwalającą na analizę obiektów z zastosowaniem miar powierzchniowych, współrzędno-

ściowych, długości, cech eliptycznych, prostokątnych, cech odnoszących się do powierzchni, momentów i innych współczynników. Charakterystykę stosowanych cech przedstawiono w dodatku B. Wynikiem analizy geometrii kształtów obiektów na obrazach termowizyjnych był bardzo liczny zbiór cech zawierający zarówno cechy relewantne, jak również cechy redundantne. Duża liczebność zbioru cech, a przy tym istnienie cech nadmiarowych stanowi źródło problemów w określeniu stanu technicznego obiektu, dlatego zdecydowano się na przeprowadzenie selekcji geometrycznych cech kształtu w celu określenia zbioru cech relewantnych.

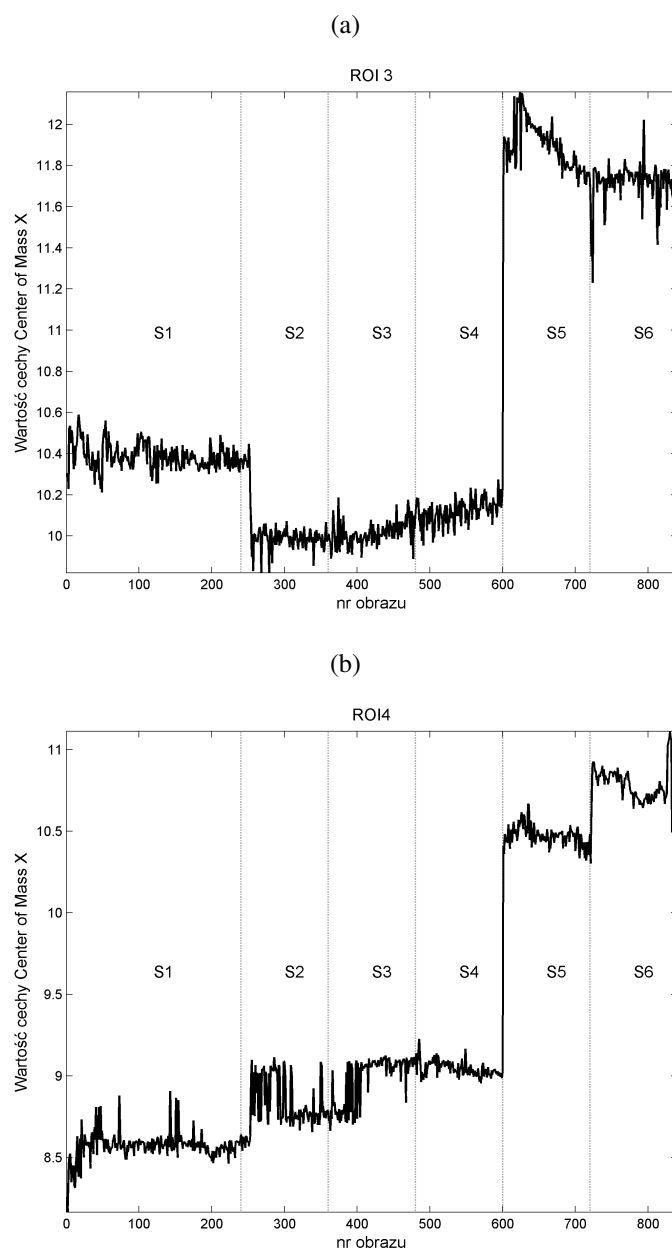
Wyboru cech relewantnych dokonano poprzez zastosowanie dyskryminacyjnej metody selekcji cech bazującej na kryterium Fishera. Przyjęto, że poszukiwanych będzie 10 cech najistotniejszych. W tabeli 5.17 zestawiono wybrane w wyniku selekcji cechy relewantne dla obszarów zainteresowania ROI3 i ROI4 uszeregowane według ich ważności. Można zauważyć, że w wyznaczonych podzbiorach cech relewantnych można wskazać cechy wspólne nadające się do opisu stanu maszyny na podstawie zmian aktywności cieplnej w obu podporach łożyskowych maszyny.

Tab. 5.17. Relewantne geometryczne cech kształtu dla obszarów ROI3 i ROI4 (por. dodatek B)

ROI3	ROI4
Orientation	Center of Mass X
Center of Mass X	Center of Mass Y
Moment of Inertia XY	Moment of Inertia XXX
Center of Mass Y	Moment of Inertia YYY
Max Feret Diameter Start Y	Max Horiz. Segment Length Left
Sum XXX	Sum XXX
Sum XX	Norm. Moment of Inertia YY
Elongation Factor	Norm. Moment of Inertia YYY
Bounding Rect Height	Bounding Rect Width
Norm. Moment of Inertia XX	Sum XX

Na rysunkach 5.55, 5.56, 5.57 przedstawiono przykładowe przebiegi sygnałów diagnostycznych wyznaczonych na podstawie wybranych geometrycznych cech kształtu dla obszarów zainteresowania ROI3 i ROI4. Przebiegi sygnałów pozwalają zidentyfikować wszystkie symulowane zmiany stanu technicznego maszyny. Porównując sygnały wartości cechy *Środek masy względem osi X (Center of mass X)* dla obszarów obu łożysk, dostrzega się różnice w wartościach cech, co pozwala na zidentyfikowanie różnic w działaniu i obciążeniu łożysk maszyny.


W trakcie prowadzenia eksperymentu diagnostycznego symulowano stany techniczne S2 i S3, które z założenia powinny być bardzo trudne w detekcji na podstawie sygnałów diagnostycznych wyznaczonych w wyniku analizy obrazów zmian cieplnych opraw łożyskowych w obszarach ROI3 i ROI4. W przeciwieństwie do wcześniejszych wyników badań, w przypadku sygnałów diagnostycznych wyznaczonych na podstawie geometrycznych cech kształtu możliwa jest identyfikacja zmiany stanu technicznego z S2 do S3, co świadczy o istotnym znaczeniu tej grupy cech w diagnostyce termograficznej obiektów.




Rys. 5.55. Przebieg wartości sygnału diagnostycznego wyznaczonego dla obszaru ROI3 (a) i ROI4 (b) na podstawie geometrycznej cechy kształtu *Środek masy względem osi X*

5.3.3. Klasyfikacja stanu technicznego maszyny na podstawie geometrycznych cech kształtu

W celu jakościowej oceny sygnałów diagnostycznych wygenerowanych na podstawie wybranych relewantnych geometrycznych cech kształtu przeprowadzono klasyfikację stanu technicznego badanej maszyny. Jako klasyfikator stanu posłużyła sztuczna sieć neuronowa o liczbie wejść $L_{we} = 10$, jednej warstwie ukrytej liczącej 3 neurony i warstwie wyjściowej posiadającej jedno wyjście. Na wejście sieci podawano wartości cech relewantnych, wyjściem z sieci były identyfikatory liczbowe każdej z klasy stanu. Pozostałe własności sieci były takie same jak w rozdziale 5.2.2.10. Klasyfikacji stanu technicznego dokonano tylko



Rys. 5.56. Przebieg wartości sygnału diagnostycznego wyznaczonego dla obszaru ROI3 na podstawie wartości geometrycznej cechy kształtu *Orientacja*



Rys. 5.57. Przebieg wartości sygnału diagnostycznego wyznaczonego dla obszaru ROI4 na podstawie wartości geometrycznej cechy kształtu *Moment bezwładności*

dla sygnałów diagnostycznych wyznaczonych na podstawie obrazów termograficznych dla obszarów zainteresowania ROI3 i ROI4 dotyczących podpór łożyskowych.

Uzyskane wartości sprawności klasyfikatora wynosiły dla obszaru ROI3 – 98%, a dla obszaru ROI4 – 99%, co można uznać za wyniki bardzo dobre.

5.4. Przykład termograficznego monitorowania i diagnozowania obiektu rzeczywistego


W celu weryfikacji zaproponowanej metodyki diagnozowania przeprowadzono obserwację termograficzną obiektu rzeczywistego, którym był turbozespół energetyczny dużej mocy (rys. 5.58), zlokalizowany w jednej z polskich elektrowni.



Rys. 5.58. Widok hali maszyn energetycznych z turbozespołem TG-1 poddany cyklicznej obserwacji termograficznej

Ze względu na ograniczenia związane z dostępem do obiektu oraz możliwościami wpływania na jego warunki pracy, przeprowadzone badania miały charakter biernego eksperymentu diagnostycznego. Eksperyment polegał na przeprowadzeniu sekwencyjnej obserwacji termograficznej w okresie 24 godzin eksploatacji turbozespołu w nominalnych dla niego warunkach pracy. Przyjęty czas obserwacji był minimalny, w trakcie którego można zaobserwować cały dobowy cykl zmian obciążenia turbozespołu wynikający z nierównomierności zapotrzebowania na energię elektryczną w ciągu doby. Na rysunku 5.59 przedstawiono przebieg zmian mocy czynnej w trakcie prowadzenia obserwacji termowizyjnej. Wykres pozwala zidentyfikować różne poziomy obciążenia, które miały miejsce w trakcie obserwacji. Na podstawie rozmów przeprowadzonych ze służbami diagnostycznymi, stan turbozespołu w chwili jego obserwacji sklasyfikowano jako sprawny. Obserwację przeprowadzono za pomocą opracowanego prototypu termograficznego systemu monitorowania i diagnostyki pierwszej generacji.

Głowicę obserwacyjną oraz serwer systemu umieszczono na galerii widokowej hali maszyn elektrowni, co pozwoliło na obserwację turbogeneratora oraz pozostałych maszyn będących w zasięgu pola widzenia kamer głowicy. Obrazy rejestrowano w trakcie działania obiektu w okresie od 15 grudnia, godziny 11:30 do 16 grudnia, godziny 11:52. Obrazy rejestrowano co 20 sekund, co pozwoliło zgromadzić sekwencję składającą się z 4405 obrazów o rozdzielczości 320×240 pikseli opisujących zmiany stanu eksploatacyjnego turbozespołu. Oprogramowanie systemu przed każdym pozyskaniem obrazu dokonywało korekcji dryftu temperaturowego.



Rys. 5.59. Zmiany wartości mocy czynnej turbogeneratora w czasie trwania jego obserwacji termowizyjnej

Na rysunku 5.60 przedstawiono przykładowe, zarejestrowane w trakcie eksperymentu, obrazy termograficzny i wizyjny obserwowanego turbozespołu.




Rys. 5.60. Przykładowy obraz termograficzny 5.60(a) i wizyjny 5.60(b) zarejestrowane w trakcie obserwacji turbogeneratora energetycznego

Dzięki wyposażeniu głowicy w układ pomiaru warunków zewnętrznych pozyskano również wartości temperatury i wilgotności dla całego okresu obserwacji, których przebiegi zaprezentowano na rysunku 5.61.


Dodatkowo, dzięki uprzejmości służb diagnostycznych, pozyskano sygnały temperatury i drgań łożysk rejestrowanych przez system monitorowania turbozespołu. Dane dotyczą okresu eksploatacji turbozespołu, w trakcie którego prowadzono jego obserwację termograficzną.

Na rysunku 5.62 przedstawiono przykładowe przebiegi temperatury łożyska nr 5. Dane temperatury łożyska były nieregularnie rejestrowane przez system SCADA.

Przebiegi temperatury mierzone w łożyskach i rejestrowane przez system monitorowania turbozespołu nie pozwoliły na jednoznaczną identyfikację zmiany stanów eksploatacyjnych w przeciwieństwie do przebiegu mocy czynnej generowanej przez turbozespół. Na podstawie przebiegu mocy czynnej zidentyfikowano i scharakteryzowano stany eksploatacyjne



Rys. 5.61. Przebieg temperatury i wilgotności w otoczeniu głowicy obserwacyjnej w trakcie trwania obserwacji termograficznej turbozespołu




Rys. 5.62. Przebieg temperatury łożyska nr 5 turbozespołu mierzonej w sposób kontaktowy z przodu i z tyłu

turbozespołu w trakcie jego obserwacji, co przedstawiono na rysunku 5.63. Z przebiegu mocy czynnej wyraźnie widać, że na początku obserwacji obiekt działał w stanie ustalonym, dając moc około 196 MW, następnie o godzinie 21:58 nastąpiło trwające przez 1h 18 min zmniejszenie obciążenia do poziomu 130 MW. Przez następne 6 godzin turbozespół pracował w stanie ustalonym z mocą około 130 MW. Od godziny 05:30 do 07:10 nastąpiło powolne narastanie mocy do poziomu 176 MW. Przez kolejne 1,5 godziny układ pracował w stanie ustalonym na poziomie 176 MW. Okres pracy od godziny 08:43 do 09:04 to intensywne narastanie mocy do poziomu maksymalnego 213 MW. Od godziny 09:04 turbozespół działał przy pełnej mocy do końca trwania obserwacji. Na podstawie przebiegu mocy czynnej zdefiniowano następujące stany eksploatacyjne obiektu (rys. 5.63):

1. SE1 – okres pracy przy stałej mocy na poziomie 196 MW,
2. SE2 – zrzut mocy do poziomu 130 MW,
3. SE3 – okres pracy przy niskim poziomie mocy 130 MW,

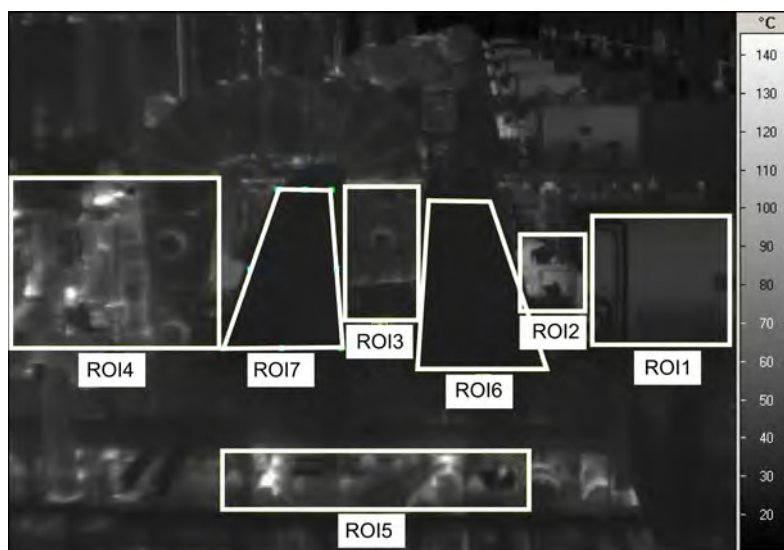
4. SE4 – łagodne narastanie mocy do poziomu 176 MW,
5. SE5 – okres pracy przy niskim poziomie mocy 176 MW,
6. SE6 – gwałtowny wzrost mocy do poziomu maksymalnego 212 MW,
7. SE7 – praca przy mocy maksymalnej 213 MW.



Rys. 5.63. Zidentyfikowane stany eksploatacji turbozespołu na podstawie przebiegu zmian mocy czynnej


Informacje o chwilach zaistnienia, zidentyfikowanych na podstawie mocy czynnej stanów eksploatacyjnych posłużyły jako dane odniesienia na potrzeby analizy sygnałów diagnostycznych zidentyfikowanych na podstawie analizy obrazów termograficznych turbozespołu. Sekwencję zarejestrowanych w trakcie obserwacji turbozespołu obrazów termograficznych poddano wstępnemu przetwarzaniu i analizie. Przetwarzanie polegało na wyborze obszarów zainteresowania. Rozważano siedem obszarów, które zdefiniowano dla różnych elementów turbozespołu (rys. 5.64). Były to:

- ROI1** – fragment generatora,
- ROI2** – obszar łożyska nr 5 turbiny i łożyska nr 6 generatora,
- ROI3** – obszar rurociągu pary w części niskoprężnej,
- ROI4** – fragment instalacji części średnioprężnej,
- ROI5** – fragment instalacji (rurociągów) zlokalizowanych pod turbozespołem,
- ROI6** – obszar prawej osłony części niskoprężnej turbiny,
- ROI7** – obszar lewej osłony części niskoprężnej turbiny.



Rys. 5.64. Obszary zainteresowania zdefiniowane dla obrazów termograficznych turbozespołu

Dla każdego obrazu zarejestrowanej sekwencji przyjęto takie same rozmiary i położenie obszarów zainteresowania. Obrazy w obrębie zdefiniowanych obszarów zainteresowania poddano estymacji, wyznaczając podstawowe cechy liczbowe, jak wartość średnia, wariancja itp. Pozwoliło to utworzyć sygnały diagnostyczne, na podstawie których identyfikowano zmiany stanu eksploatacyjnego obiektu. Na rysunku 5.65 zaprezentowano przebiegi sygnałów wartości średnich temperatur wyznaczone w obrębie rozpatrywanych obszarów zainteresowania.




Rys. 5.65. Przebiegi sygnałów wartości średnich temperatur wyznaczone w obrębie rozpatrywanych obszarów zainteresowania


Na wykresach liniami pionowymi zaznaczono granice zidentyfikowanych stanów eksploatacyjnych. Łatwo można zauważyć występowanie zmian średnich wartości temperatur w obrębie obszarów wywołane zmianami stanów eksploatacyjnych. Aby ujednoczyć zakres wartości analizowanych przebiegów, sygnały poddano normalizacji. Znormalizowane przebiegi wartości sygnałów diagnostycznych zaprezentowano na rysunku 5.66. Przebiegi sygnałów w większości przypadków pokrywają się. W przypadku sygnału dla obszaru łożysk nr 5 i 6 turbogeneratorsa zmiany są mniej intensywne. Jeśli porównać kształt i przebiegu zmian wartości mocy czynnej z otrzymanymi przebiegami sygnałów diagnostycznych, łatwo zauważyć analogię. Na podstawie sygnałów można zidentyfikować zmiany stanów, jednak ze względu na inercję cieplną turbozespołu nie jest możliwe zidentyfikowanie szybkich zmian obciążenia. Możliwość wykrywania zmian obciążenia na podstawie obrazów termograficznych wynika ze zmian stanu cieplnego wywołanego zmianami w przepływie strumienia pary zasilającej turbozespoł podczas zmian zapotrzebowania na moc turbozespołu.

Na rysunku 5.67 przedstawiono przykład przebiegu sygnału diagnostycznego wartości maksymalnej dla każdego obrazu w obrębie rozpatrywanych obszarów zainteresowania. W przypadku tego sygnału diagnostycznego detekcja zmian obciążenia na podstawie obszaru łożyska nr 5 jest niemożliwa. Wydaje się to naturalne ze względu na brak bezpośredniego występowania w obszarze nr 2 instalacji związanych z zasilaniem turbiny parą.

Na rysunku 5.68 przedstawiono wybrane przebiegi znormalizowanych sygnałów diagnostycznych wartości maksymalnej wyznaczonej w obrębie obszarów: generatora (ROI1), łożysk nr 5 i 6 (ROI2) oraz instalacji zasilających turbozespoł (ROI5). Zestawienie tych sygnałów




Rys. 5.66. Przebiegi znormalizowanych sygnałów wartości średnich temperatury wyznaczone w obrębie rozpatrywanych obszarów zainteresowania



Rys. 5.67. Przebiegi znormalizowanych sygnałów wartości maksymalnych temperatury wyznaczone w obrębie rozpatrywanych obszarów zainteresowania

wyraźnie pokazuje wrażliwość każdego z obszarów na zmiany stanu wywołane zmianami obciążenia. W przypadku obszaru generatora zmiany wartości sygnału diagnostycznego są skorelowane ze zmianami obciążenia, jednak przebieg jest mocno zaszumiony, co wynika z faktu, że generator osłonięty jest obudową i chodzony wodorem. Możliwość identyfikacji zmian obciążenia jest prawdopodobnie wywołana zmianami w ilości ciepła wytwarzanego podczas pracy generatora. W przypadku sygnału wartości maksymalnej dla obszaru łożyska trudno dostrzec związek między przebiegiem mocy czynnej, przypomina on bardziej sygnał wartości temperatury łożyska mierzonej przez system monitorowania. Przebieg maksymalnej wartości temperatury dla obszaru węzłów łożyskowych jest mocno zaszumiony, co świadczy o dużym wpływie czynników zewnętrznych. W trzecim przypadku sygnału wartości maksymalnej w obszarze ROI5, można dostrzec bardzo wygładzony przebieg


ujawniający lokalne fluktuacje wartości maksymalnej temperatury w obszarze. Tak dobra jakość sygnału jest efektem obserwacji fragmentu instalacji zasilania turbozespołu, w której wraz ze wzrostem mocy nasiliła się emisja promieniowania ciepłego wywołana intensywnością przepływu mediów w elementach instalacji.



Rys. 5.68. Przebiegi znormalizowanych sygnałów wartości maksymalnych temperatury wybranych obszarów zainteresowania


Zdefiniowanie obszaru zainteresowania obejmującego konkretne elementy instalacji pozwoli na monitorowanie ich stanu w sposób ciągły.

Na podstawie sekwencji obrazów termograficznych zarejestrowanych w trakcie przeprowadzonej obserwacji termograficznej turbozespołu możliwe jest pokazanie jednej z głównych idei zaproponowanej metodyki diagnozowania. Jest nią możliwość jednoczesnej obserwacji i monitorowania wielu obiektów. W omawianym przypadku obszar widzenia kamery termograficznej obejmował nie tylko jeden turbozespół, lecz całą halę maszyn, na której można dostrzec kolejnych pięć turbozespołów. Aby można było śledzić zmiany stanu eksploatacyjnego każdego z widocznych turbozespołów, zdefiniowano szereg obszarów zainteresowania obejmujących beczki generatorów (rys. 5.69).




Rys. 5.69. Przykład jednoczesnej obserwacji wielu obiektów

Dla obszarów zainteresowania obejmujących wszystkie generatory (G1,...,G6) wyznaczono cały szereg sygnałów diagnostycznych. Na rysunku 5.70 zaprezentowano znormalizowane przebiegi sygnału diagnostycznego wartości średniej, która najlepiej obrazuje zakres zmian wartości temperatury generatorów w trakcie obserwacji termograficznej. Na rysunku widoczne są różnice w przebiegach wartości sygnałów diagnostycznych wynikające z różnych stopni obciążenia każdego z turbozespołów w trakcie ich obserwacji termograficznej.



Rys. 5.70. Przebiegi znormalizowanych wartości średniej dla obszarów różnych generatorów energetycznych

Rozpatrując przebiegi znormalizowanych wartości maksymalnych w zdefiniowanych obszarach generatorów, można zauważyć wyraźne różnice w przebiegu wartości dla generatora nr 3 (rys. 5.71). Z uwagi na trudność w dostępie do szczegółowych danych (wartości mocy czynnej) z systemu monitorowania pozostałych turbozespołów, nietypowy przebieg dla generatora nr 3 (G3) jak i przebiegi dla pozostałych obiektów są trudne w interpretacji.

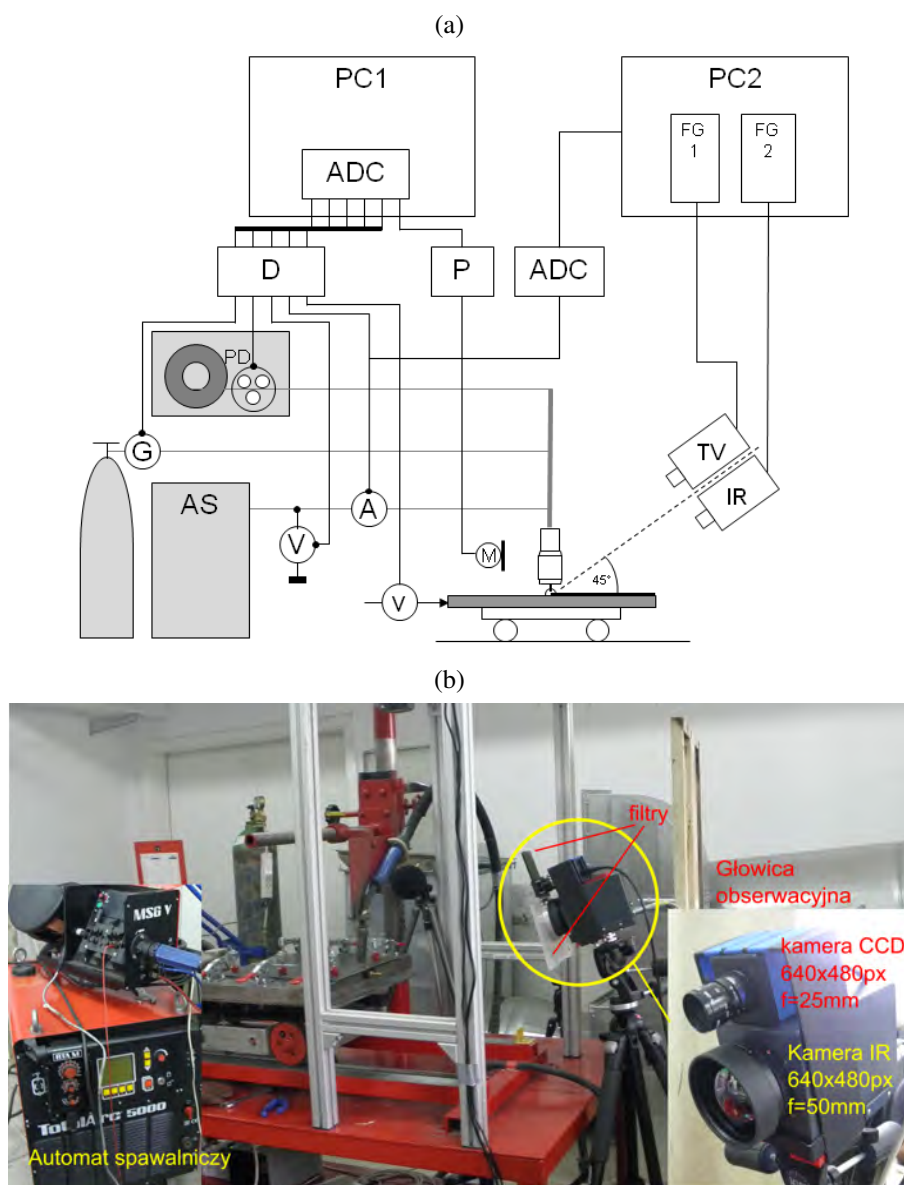


Rys. 5.71. Przebiegi znormalizowanych wartości maksymalnych temperatury dla obszarów generatorów różnych turbozespołów energetycznych

Zaprezentowany przykład potwierdza, że dobrze przygotowana obserwacja termograficzna prowadzona z zastosowaniem odpowiedniego sprzętu pozwala na identyfikację zmian stanu eksploatacyjnego nie tylko jednego, ale kilku obiektów jednocześnie. Ze względu na trudności w ciągłym dostępie termograficznym do rzeczywistego obiektu eksploatowanego w dłuższym odcinku czasu, można założyć, że skoro możliwe było wykrycie zmian cieplnych wywołanych zmianami obciążenia, powinno być możliwe również wykrycie nieprawidłowości w działaniu obiektu i jego podzespołów.

5.5. Przykład termograficznego monitorowania i diagnozowania procesu przemysłowego

Proces spawania można traktować jako system, który przekształca masę (materiał dodatkowy, materiał rodzimy), energię (elektryczną) i informację (nominalne wartości parametrów procesowych) na połączenie nierozłączne o wymaganych własnościach i właściwościach. W trakcie realizacji procesu spawania mogą wystąpić uszkodzenia środków technicznych biorących udział w realizacji procesu spawania, a także mogą wystąpić zakłócenia losowe przepływu masy, energii i informacji. Wszystkie uszkodzenia i zakłócenia mają bezpośrednio lub pośrednio niekorzystny wpływ na własności i właściwości złącza spawanego, objawiając się niezgodnościami spawalniczymi. Niezgodności spawalnicze można wykrywać w wyniku stosowania niszczących i nieniszczących badań połączeń spawanych. Badania nieniszczące realizowane są w trybie off-line oraz on-line. Badania realizowane w trybie on-line w większości przypadków pozwalają wykrywać niezgodności spawalnicze pośrednio na podstawie symptomów nieprawidłowości procesu zidentyfikowanych na podstawie wyników analizy przebiegów sygnałów diagnostycznych. Bezpośrednie zidentyfikowanie niezgodności spawalniczych wymaga znajomości relacji diagnostycznych między symptomami uszkodzeń procesu spawania i cechami niezgodności spawalniczych złącza spawanego. Identyfikację uszkodzeń procesu spawania w trybie on-line prowadzi się najczęściej, monitorując i oceniając parametry procesowe (np. prąd spawania, napięcie łuku itp). Dzięki rozwojowi systemów wizyjnych i technologii szybkiego przetwarzania obrazów, diagnostyka procesu spawania w trybie on-line coraz częściej prowadzona jest na podstawie wyników analizy obrazów wizyjnych i termograficznych. Podstawą do stosowania metod obrazowania procesu spawania w jego diagnostyce jest ścisły związek między zjawiskami wizualnymi oraz cieplnymi powstającymi podczas spawania, a mocą promieniowania elektromagnetycznego emitowanego do otoczenia w zakresie promieniowania ultrafioletowego, widzialnego i zakresie podczerwieni. Opracowaną metodykę diagnozowania stanu technicznego obiektów technicznych, bazującą na wielowariantowej koncepcji analizy obrazów termograficznych, zastosowano do diagnozowania stanu procesu przemysłowego, którym był proces spawania. W tym celu opracowany prototyp systemu termograficznego monitorowania i diagnostyki drugiej generacji (por. 5.1) zastosowano na potrzeby monitorowania i diagnostyki procesu spawania realizowanego w warunkach laboratoryjnych w Instytucie Podstaw Konstrukcji Maszyn. Stanowisko badawcze i plan czynnych eksperymentów diagnostycznych przygotowano przy współpracy z Katedrą Spawalnictwa Politechniki Śląskiej. Badania polegały na spawaniu blach stalowych S235JR o wymiarach płyty próbnej 300×300×5 mm. Stanowisko badawcze przedstawiono na rys. 5.72. Składało się ono ze stołu wraz z zespołem suportów do mocowania uchwytu spawalniczego oraz traktora spawalniczego pozwalającego wykonywać prostoliniowe złącza spawane na podkładce miedzianej wyposażonej w mechaniczny docisk łączonych blach. W trakcie eksperymentów do spawania wykorzystano półautomat spawalniczy typu TotalArc 5000 firmy Castolin wraz z podajnikiem drutu, pozwalający realizować proces spawania łukowego metodą MIG/MAG. Przed spawaniem krawędzie łączonych blach ukosowano pod kątem $\alpha = 60^\circ$, a odstęp między łączonymi blachami wynosił $b = 1$ mm. Materiałem dodatkowym stosowanym podczas spawania był drut elektrodowy lity o średnicy 1,2 mm. Osłonę gazową stanowiła mieszanka gazowa M21 (82%Ar + 18%CO₂) przy natężeniu przepływu 15 l/min. Nominalne parametry spawania zamieszczono w tabeli 5.18.



Rys. 5.72. Schemat laboratoryjnego stanowiska badawczego do termograficznego monitorowania procesu spawania (a) i jego rzeczywisty wygląd (b): V – układ pomiaru napięcia, A – układ pomiaru prądu, v – układ pomiaru prędkości spawania, G – układ pomiaru przepływu gazu, M – mikrofon pomiarowy, IR – kamera termograficzna, TV – kamera wizyjna, AS – automat spawalniczy, PD – podajnik drutu, D – układ dopasowania sygnałów i zasilania, P – przedwzmacniacz mikrofonowy, ADC – przetwornik analogowo-cyfrowy, FG – frame grabber, PC – komputer

Tab. 5.18. Parametry procesu spawania

Prąd spawania A	Napięcie łuku V	Prędkość spawania cm/min	Prędkość podawania drutu m/min	Natężenia przepływu gazu osłonowego l/min	Wylot elektrody mm
240	25	32	7,4	15	15

Podczas każdego z eksperymentów destabilizowano różne parametry spawania, co pozwoliło na symulacje 8 różnych nieprawidłowości procesu spawania, wpływając tym samym na cechy jakościowe złącza spawanego. Symulowanymi stanami procesu spawania były:

- SW1** – prawidłowy proces spawania;
- SW2** – proces spawania, w trakcie którego nastąpił zanik przepływu gazu osłonowego;
- SW3** – proces spawania blach z wyraźnymi ogniskami korozji atmosferycznej na powierzchniach spawanych;
- SW4** – proces spawania blach z nieregularnymi krawędziami łączonych blach od strony grani;
- SW5** – proces spawania, w trakcie którego następowały zmiany wartości prądu spawania;
- SW6** – proces spawania blach o różnych odstępach;
- SW7** – proces spawania, w trakcie którego następowały zmiany wartości napięcia łuku;
- SW8** – proces spawania blach o niewłaściwej geometrii rowka spawalniczego.

Obserwacje procesu spawania prowadzono z zastosowaniem głowicy obserwacyjno-pomiarowej drugiej generacji usytuowanej w odległości $d = 500$ mm od osi palnika spawalniczego, a osie obiektywów skierowano pod kątem 45° do powierzchni spawanych blach. Wybór kąta obserwacji termowizyjnej ma wpływ na wartość emisyjności powierzchni widzianej przez optykę kamery. Można przyjąć, że granicznym kątem, przy którym zjawisko zmiany emisyjności nie jest tak intensywne, jest kąt 45° . Dobre obiektywy i dystans głowicy od palnika pozwoliły na obserwację obszaru łuku spawalniczego i strefy wpływu ciepła. Przykładowe obrazy zarejestrowane w trakcie jednego z eksperymentów zaprezentowano na rysunku 5.73.




Rys. 5.73. Przykładowy obraz termograficzny (a) i wizyjny (b) zarejestrowane w trakcie obserwacji procesu spawania

Odpowiedni dobór obiektywów pozwolił na ujednoczenie rozmiarów pola widzenia, co ograniczyło konieczność stosowania programowych metod geometrycznej transformacji obrazów w celu ich późniejszego dopasowania. W celu ochrony obiektywów kamer przed odpryskami spawalniczymi oraz przed nadmiernym promieniowaniem elektromagnetycznym mogącym przesterować sensory w matrycach zastosowanych kamer, obiektywy wyposażono w dodatkowe filtry. W kamerze termograficznej był to filtr polietylenowy, natomiast obiektyw kamery wizyjnej chroniono eksperymentalnie dobranym pakietem szkieł stosowanych w maskach spawalniczych. Część programowa systemu poddana została modyfikacji, aby dodatkowo możliwa była rejestracja parametrów procesowych, takich jak prąd i napięcie łuku, prędkość podawania drutu spawalniczego, prędkość spawania oraz natężenie przepływu gazu osłonowego. Mierzono również poziom ciśnienia akustycznego za pomocą mikrofonu pojemnościowego.

5.5.1. Przetwarzanie i analiza obrazów podczerwieni rejestrowanych w trakcie procesu spawania

Obrazy termowizyjne pozyskiwane podczas procesu spawania niosą wiele ważnych informacji pozwalających na identyfikację zmian stanu procesu spawania oraz niezgodności w powstającej spoinie. Wydzielenie tych informacji ułatwia dalszy proces oceny stanu procesu spawania i jest możliwe poprzez zastosowanie podstawowej operacji wstępnego przetwarzania polegającej na wyodrębnieniu z obserwowanego obrazu obszarów zainteresowania. Podział obrazu na obszary zainteresowania umożliwia pozyskanie odrębnych obrazów właściwych, które mogą być dalej przetwarzane i analizowane z zastosowaniem różnych, indywidualnie dobranych do każdego obszaru metod. W ramach badań zaproponowano rozpatrywanie trzech następujących obszarów zainteresowania (rys. 5.74):

- obszaru łuku spawalniczego (ROI_Arc),
- obszaru krzepnięcia spoiny (ROI_Solid),
- obszaru stygnięcia spoiny (ROI_Cool).



Rys. 5.74. Sposób podziału obrazu podczerwieni zarejestrowanego podczas spawania na obszary zainteresowania

Parametry każdego z zaproponowanych obszarów zainteresowania jak kształt, rozmiary i położenie obszaru, mogą być określone jednorazowo na podstawie badań wstępnych i wykorzystane dla wszystkich obrazów sekwencji rejestrowanej podczas obserwacji procesu spawania. Zapewnienie stałych parametrów obszaru zainteresowania wymaga uwzględnienia dynamiki zmian kształtów oraz rozmiarów ocenianych obiektów, jak również dewiacje lokalizacji źródła obserwowanego zjawiska lub lokalizacji kamery. Określenie parametrów każdego z obszarów zainteresowania może być przeprowadzone przez operatora systemu przetwarzania i analizy obrazów w sposób arbitralny na podstawie wiedzy i intuicji. Można również do tego celu wykorzystać metodę automatyczną, bazującą na metodach segmentacji i zbiorze obrazów reprezentatywnych [40]. W badaniach wykorzystano oba podejścia, przy czym podejście automatyczne bazowało na obrazach wizyjnych rejestrowanych w trakcie eksperymentów diagnostycznych.

Kolejną operacją przetwarzania obrazów termograficznych zarejestrowanych w trakcie spawania może być normalizacja wartości temperatur w obrębie każdego z obszarów zainteresowania. Normalizację wartości temperatury każdego piksela termogramu można przeprowadzić względem temperatury odniesienia T_r zgodnie z następującą zależnością:

$$T_n(i, j) = \frac{T(i, j)}{T_r} \quad (5.25)$$

gdzie $T(i, j)$ to wartość termopiksela przed normalizacją, a $T_n(i, j)$ to wartość znormalizowana termopiksela.


Wybór wartości temperatury odniesienia T_r wymaga przeprowadzenia wstępnej analizy zarejestrowanych obrazów lub przyjęcia z góry założonej wartości temperatury związanej ze zjawiskiem cieplnym obserwowanym w danym obszarze zainteresowania. Za temperaturę odniesienia można przyjąć np. temperaturę topnienia łączonych materiałów lub temperaturę odpowiadającą wybranym przemianom metalurgicznym zgodnie z wykresem żelazo-węgiel. Należy zaznaczyć, że zaproponowane postępowanie jest uzasadnione, gdy parametry pomiarowe kamery IR zostały dobrane w taki sposób, aby mierzone wartości temperatur w przybliżeniu odpowiadały wartościom rzeczywistym. W innym przypadku temperatura odniesienia może być dobrana w sposób doświadczalny tak, aby zakres wartości znormalizowanych pozwalał w prosty sposób identyfikować znane zjawiska i procesy zachodzące podczas łączenia materiałów. Na potrzeby omawianych badań przyjęto wartość temperatury odniesienia jako średnią z wartości maksymalnych wyznaczonych dla każdego obszaru (ROI) z osobna na podstawie sekwencji obrazów zarejestrowanych podczas procesu spawania uznawanego za prawidłowy. Normalizacja realizowana w opisany sposób pozwala ograniczyć dynamikę zmian wartości pikseli obrazu do zakresu $(0, 1)$ oraz uprościć późniejsze operacje na obrazie, jak również ułatwić interpretację wartości wyznaczanych cech obrazów, a zatem i sygnałów diagnostycznych.

Wobec obrazów termograficznych rejestrowanych w trakcie procesu spawania można również stosować inne metody przetwarzania (por. rozdz. 2.5) dobierane w zależności od przyjętej strategii analizy obrazów. Mogą to być np. metody poprawy jakości obrazów czy metody binaryzacji (segmentacji).

Analiza obrazów podczerwieni w obrębie zdefiniowanych obszarów zainteresowania może być prowadzona w różnorodny sposób. W ramach badań stosowane były metody wykorzystujące omówioną we wcześniejszych przykładach analizę statystyczną, analizę geometrycznych cech kształtu i analizę widmową.

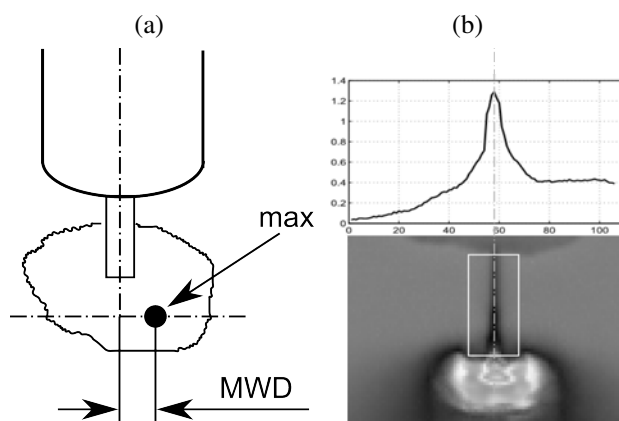
Interesującym sposobem estymacji obrazów termograficznych zarejestrowanych w trakcie spawania jest wykorzystanie przebiegów rozkładów wartości pikseli wzdłuż linii przechodzących przez określone punkty rozpatrywanego obszaru zainteresowania nazywane profilami. Szczególnym przypadkiem takich funkcji są profile pionowe i poziome. Zgodnie z zaproponowaną strategią analizy obrazów termograficznych profile należy traktować jako cechy funkcyjne obrazów, które pozwalają na generowanie jedno i wielowymiarowych sygnałów diagnostycznych. Generowanie jednowymiarowych sygnałów diagnostycznych na podstawie profili wyjaśniono na rysunku 5.75.

Profil wyznaczony dla każdego obrazu sekwencji termograficznej, zarejestrowanej w trakcie spawania, traktowany jest jak przebieg cechy funkcyjnej o specyficznym charakterze i może być poddawany ocenie z zastosowaniem różnych cech liczbowych, których wartości uporządkowane w czasie pozwalają utworzyć jednowymiarowy sygnał diagnostyczny opisujący



Rys. 5.76. Cechy profilu poziomego obszaru łuku

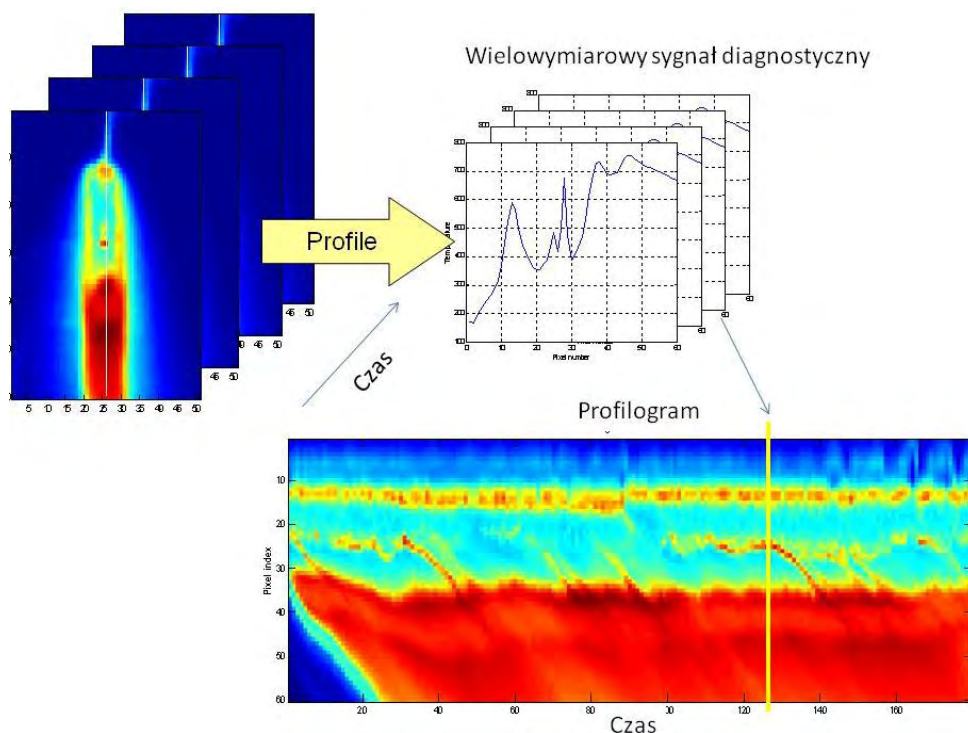
o wartości maksymalnej obrazu a osią drutu elektrodowego wyrażoną w liczbie pikseli (rys. 5.77).



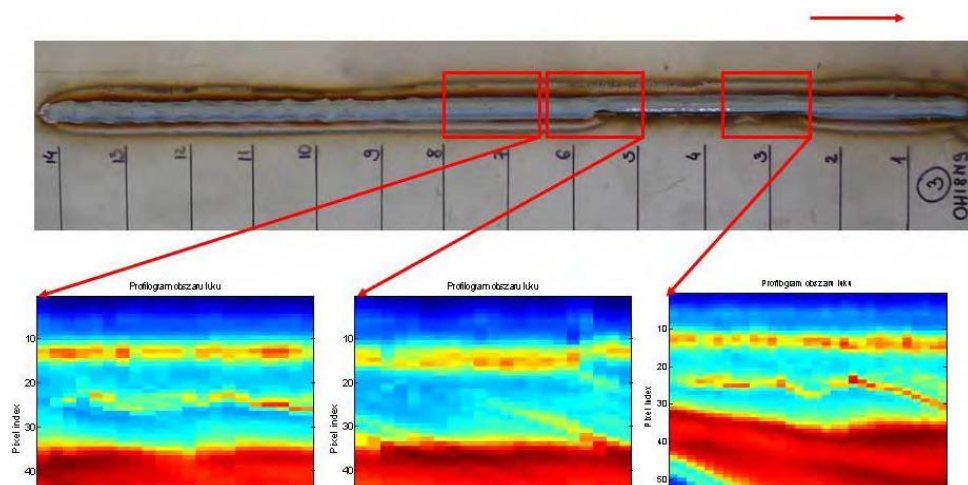
Rys. 5.77. Idea wyznaczania poziomej odległości między pikselem o wartości maksymalnej i osią symetrii drutu MWD (ang. *max-wire distance*) (a); sposób wyznaczania osi symetrii drutu na bazie profilu skumulowanego (b)

Innym przykładem analizy obrazów termograficznych zarejestrowanych w trakcie procesu spawania może być wykorzystanie profili pionowych do tworzenia wielowymiarowego sygnału diagnostycznego. Dysponując profilami temperaturowymi zdefiniowanymi w taki sam sposób dla kolejnych obrazów termograficznych w zarejestrowanej sekwencji, możliwe jest uszeregowanie ich przebiegów w funkcji czasu trwania procesu spawania i utworzenie wielowymiarowego sygnału diagnostycznego. Sygnał ten można poddawać dalszej analizie. Jednym z przykładów jest przedstawianie wielowymiarowego sygnału diagnostycznego w postaci obrazu profili, który nazwano profilogramem. Istotę wyznaczania wielowymiarowego sygnału diagnostycznego oraz jego reprezentację w postaci profilogramu przedstawiono na rysunku 5.78.

Na podstawie profilogramów możliwa jest identyfikacja wystąpienia niestabilności procesu spawania. Rysunek 5.79 przedstawia doczołowe złącze spawane wykonane podczas badań oraz wyniki analizy obrazów termowizyjnych zarejestrowanych w obrębie wyselekcjonowanych odcinków spoiny. Przedstawiono profilogramy obszaru stygnięcia powstałe na podstawie profili równoległych do osi spoiny wyznaczanych dla każdego z zarejestrowanych termogramów.



Rys. 5.78. Idea wyznaczania wielowymiarowego sygnału diagnostycznego i możliwość jego reprezentacji w postaci obrazu



Rys. 5.79. Przykłady profilogramów wyznaczonych podczas wykonywania doczołowego złącza spawanego i odnoszące się do różnych fragmentów spoiny

Przedstawione przykłady nie wyczerpują możliwości analizy obrazów termograficznych zarejestrowanych w trakcie spawania, a zbiór cech liczbowych oraz funkcyjnych można rozszerzyć o cechy zarówno już stosowane w praktyce analizy obrazów, jak również nowe, zdefiniowane w oparciu o specyficzne własności procesu spawania lub potrzeby diagnostyczne. Szersze omówienie możliwości przetwarzania i analizy obrazów termograficznych zarejestrowanych w trakcie spawania można znaleźć m.in. w [17, 42, 43].

5.5.2. Identyfikacja stanu procesu spawania na podstawie wartości cech profilu poziomego

Sekwencje obrazów termograficznych zarejestrowane w trakcie serii eksperymentów diagnostycznych, po przeprowadzeniu operacji wstępnego przetwarzania i wydzieleniu obszaru zainteresowania obejmującego obszar łuku, poddano ocenie za pomocą scharakteryzowanych wcześniej ośmiu cech profilowych (rys. 5.76) oraz cechy opisującej poziomy dystans między wartością maksymalnej i osią drutu (rys. 5.77). Wyznaczone w wyniku analizy obrazów obszaru łuku sygnały diagnostyczne cech profilowych oceniono, korzystając ze znanych w diagnostyce technicznej i zdefiniowanych w dodatku C cech sygnałów takich jak: wartość średnia, wartość skuteczna, wartość międzyszczytowa czy kurtoza. Otrzymane wartości liczbowe cech sygnałów były podstawą do przeprowadzenia operacji rozpoznawania stanu procesu spawania na drodze klasyfikacji. Dla każdego z rozpatrywanych stanów procesu spawania zarejestrowano średnio po 8 sekwencji obrazów (z wyjątkiem stanu uznawanego za prawidłowy, dla którego zarejestrowano 16 przykładów). Po estymacji obrazów za pomocą cech profilowych każdy stan reprezentowany był przez 48 sygnałów diagnostycznych. W wyniku ich estymacji dla każdego stanu uzyskano przestrzeń 768 wartości cech. Każda sekwencja obrazów termograficznych scharakteryzowana była zatem przez wzorzec składający się z 96 cech. Ze względu na niewielką ilość wzorców (przykładów uczących) reprezentujących każdy stan, zadanie klasyfikacji rozwiązano stosując omawiany wcześniej klasyfikator minimalno-odległościowy wykorzystujący metodę k -najbliższych sąsiadów. Liczba sąsiadów k została ustalona eksperymentalnie na podstawie badań wstępnych i wynosiła 7. Estymacji błędu klasyfikatora dokonano metodą N -krotnej krosvalidacji (ang. *leave-one-out*). Sprawność klasyfikacji wyznaczano wg wzoru 5.17. W tabeli 5.19 zebrano wartości 10 najwyższych średnich sprawności klasyfikacji dla rozpatrywanych stanów procesu spawania uzyskane na podstawie wartości cech sygnałów diagnostycznych wyznaczonych z sekwencji obrazów termograficznych estymowanych za pomocą parametrów profilowych.

Tab. 5.19. Sprawności klasyfikacji stanu procesu spawania na podstawie cech sygnałów diagnostycznych wyznaczonych dla cech profilowych obrazów termograficznych

Cecha profilu	Cecha sygnału diag.	Sprawność klasyfikacji eff , %								Śr. spraw. μ_{eff} , %
		SW1	SW2	SW3	SW4	SW5	SW6	SW7	SW8	
LIW	F	100	0	29	0	100	0	14	0	30
LIW	PP	55	100	0	0	0	0	0	0	19
CW	Ave	36	67	100	29	0	17	43	0	36
LEW	S	18	33	71	71	0	0	0	0	24
CW	S	73	0	43	43	100	67	0	0	41
RIW	Mean	55	0	14	0	29	67	0	0	21
RIW	S	73	0	0	0	100	17	57	0	31
CW	L	36	33	0	0	29	0	0	57	19

Średnie wartości sprawności klasyfikacji należy uznać za mierne. Jednak szczególne przypadki dla różnych stanów procesu spawania pokazują, że zastosowanie cech profilowych pozwala skutecznie identyfikować wybrane nieprawidłowości procesu spawania. Spośród

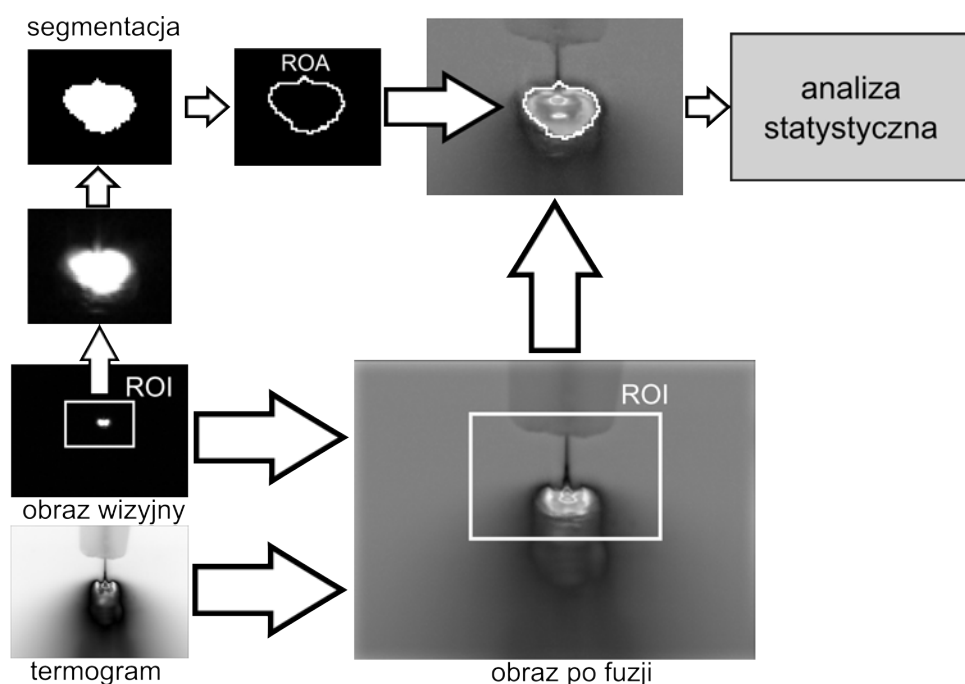
zapropionowanego zbioru cech profilowych za istotne należy uznać lewą (LIW) i prawą (RIW) szerokość oraz szerokość środkową (CW). Słabą zdolność rozpoznawania stanów procesu spawania uzyskaną na podstawie cech profilowych można podnieść, przeprowadzając fuzję klasyfikatorów [67].

5.5.3. Przykład wykorzystania fuzji obrazów do oceny stanu procesu przemysłowego

Zastosowanie prototypowej wersji termograficznego systemu monitorowania i diagnostyki do obserwacji procesu spawania pozwoliło pozyskać nie tylko obrazy termograficzne, ale również obrazy wizyjne. Proces spawania generuje cenne informacje diagnostyczne zarówno w zakresie widzialnym promieniowania elektromagnetycznego, jak również w podczerwieni. Z tego powodu zdecydowano się do oceny procesu spawania wykorzystać nowoczesną metodę łączenia informacji obrazowej w wyniku zastosowania fuzji obrazów (por. 2.8.1). W celu oceny stanu procesu spawania zaproponowano metodę, w której obraz wizyjny stosowany był zarówno do na potrzeby fuzji, jak i do wyznaczenia obszaru analizy (ROA). Ogólny algorytm metody przedstawiono na rysunku 5.80. Na pierwszym etapie analizy na podstawie reprezentatywnego zbioru obrazów wizyjnych łuku spawalniczego zarejestrowanych dla różnych stanów technicznych określany jest obszar zainteresowania. Obszar zainteresowania pozwala wyodrębnić obrazy właściwe z sekwencji obrazów zarejestrowanych podczas prawidłowego (wolnego od zakłóceń) procesu spawania. W ten sposób tworzona jest sekwencja obrazów, która w dalszym ciągu stanowi podstawę dla operacji segmentacji w celu wydzielenia na każdym obrazie jednolitego obszaru opisującego kształt promieniowania świetlnego łuku. Obrazy wizyjne po segmentacji poddawane są sumowaniu, co pozwala zdefiniować jeden wspólny obszar nazywany obszarem analizy (ROA). Po zdefiniowaniu obszaru analizy (ROA), obrazy termograficzne i wizyjne poddawane są procesowi fuzji. Z obrazów po fuzji wyznaczane są obrazy właściwe poprzez wycięcie z nich obszarów o takich samych parametrach jak obszar zainteresowania zdefiniowany dla obrazów wizyjnych. Definiowanie obszarów zainteresowania dla obrazów po fuzji jest operacją niezbędną, ponieważ obrazy po fuzji posiadają bardzo często niepożądane artefakty na swoich krawędziach. Są one efektem translacji i skalowania obrazów na etapie ich dopasowania. Wyznaczony wcześniej obszar analizy (ROA) stanowi maskę na potrzeby analizy właściwego obrazu będącego efektem fuzji. Dlatego istotne jest, aby obszar analizy pokrywał się z obszarem łuku na obrazie po fuzji. Można to uzyskać, wykorzystując parametry dopasowania obrazów termograficznego i wizyjnego wyznaczane na etapie ich fuzji. W ostatnim kroku algorytmu wartości obrazu po fuzji zawierające się w obszarze analizy (ROA), poddawane są estymacji z wykorzystaniem cech statystycznych obrazów.

W trakcie realizacji zaproponowanej metody istotnym etapem jest fuzja obrazów (por. rozdz. 2.8.1). Fuzja obrazów jest procesem wieloetapowym i w większości przypadków wyróżnić można trzy podstawowe etapy: dopasowanie obrazów, agregację obrazów oraz często pomijany post-processing polegający głównie na przestrzennej filtracji wyostrzającej obrazu wynikowego.

W literaturze opisano różne algorytmy dopasowania oraz agregacji obrazów. W przypadku metod dopasowania obrazów przeprowadzone badania porównawcze [64, 63] wybranych algorytmów dowodzą, że zasadne jest zastosowanie algorytmów hybrydowych, wykorzystujących zarówno rozkład jasności obszarów na obrazie, jak i informację krawędziową. Jedną z takich metod, opisana w [71], została zastosowana do geometrycznego dopasowania obrazów wizyjnych i termograficznych łuku spawalniczego zarejestrowanych w trakcie eksperymentów. Metoda ta wykorzystuje mapy orientacji krawędzi. Na ich podstawie oraz na podstawie wartości




Rys. 5.80. Idea metody analizy obrazów łuku spawalniczego po fuzji z zastosowaniem koncepcji obszaru analizy ROA

jasności pikseli wyznaczany jest histogram 3D. Funkcja celu określa niepewność dopasowania odpowiadającym krawędziom obiektów znajdujących się na obrazach wejściowych oraz odcieni szarości poszczególnych obszarów. Dzięki temu możliwe jest uzyskanie małego poziomu błędów dopasowania. Na potrzeby połączenia uprzednio dopasowanych obrazów termograficznych i wizyjnych w jeden obraz wyjściowy zastosowano algorytm agregacji bazujący na niezmienniczości względem przesunięcia modyfikacji dyskretnej transformaty falkowej (ang. *Shift Invariant Haar Wavelet*, SIH) [120]. W metodzie tej w porównaniu do dyskretnej transformaty falkowej kolejne kopie obrazu nie są poddawane operacji decymacji, co sprawia, że otrzymywana jest wysoce redundantna reprezentacja obrazu. Algorytm ten do łączenia informacji ze zdekomponowanych obrazów wejściowych wykorzystuje adaptacyjną regułę Burta [16]. Pozwala ona na łączenie obrazów przez uśrednianie lub selekcję pikseli w zależności od zmian wariancji jasności pikseli w pewnym sąsiedztwie danego piksela. Jak wskazywały wcześniej przeprowadzone badania, algorytm ten najlepiej sprawdzał się w zadaniach fuzji obrazów termograficznych i wizyjnych obszaru łuku spawalniczego [64].

Na rysunku 5.81 przedstawiono przykłady obrazów po fuzji. Przy czym obraz z rysunku 5.81(b) otrzymano, stosując opisany wcześniej algorytm agregacji bazujący na niezmienniczości względem przesunięcia modyfikacji dyskretnej transformaty falkowej, natomiast dla porównania rysunek 5.81(a) przedstawia efekt agregacji polegającej na uśrednianiu wartości pikseli obrazów wejściowych.

Oba obrazy zawierają informację zawartą zarówno w obrazie zarejestrowanym w świetle widzialnym, jak i w obrazie termograficznym, jednak, jak łatwo zauważyć, obraz uśredniony jest nieostry. Dodatkowo kontrast obszaru reprezentującego rozkład temperatury został zmniejszony. Obraz uzyskany wskutek agregacji metodą SIH charakteryzuje się dużo większym kontrastem oraz ostrością konturów. Wpływ obrazu termograficznego na obraz wynikowy jest znaczny, co ułatwia opis obrazu zarówno za pomocą miar biorących pod uwagę



Rys. 5.81. Przykładowe obrazy po fuzji przedstawiające łuk spawalniczy uzyskane przez agregację wartości: (a) za pomocą uśredniania, (b) z zastosowaniem metody SIH

rozkład światłości łuku spawalniczego, jak również tych bazujących na promieniowaniu podczerwonym.

Ocenę statystyczną elementów obrazu w obrębie obszaru analizy (ROA) przeprowadzono, stosując 15 wybranych cech statystycznych pierwszego i drugiego rodzaju, których identyfikatory i nazwy przedstawiono w tabeli 5.20.

Tab. 5.20. Cechy statystyczne zastosowane do oceny wartości obrazów po fuzji w obrębie obszaru analizy ROA

Cechy pierwszego rodzaju		Cechy drugiego rodzaju	
Identyfikator	Nazwa cechy	Identyfikator	Nazwa cechy
sp1	Średnia	sd1	Kontrast
sp2	Średnia bezwzgl.	sd2	Wsp. korelacji
sp3	War. średniokwadratowa	sd3	Energia
sp4	RMS	sd4	Entropia
sp5	Wariancja	sd5	Inercja
sp6	Odchylenie stan.	sd6	Spójność
sp7	War. maksymalna	sd7	Wsp. kowariancji
sp8	War. minimalna		

W wyniku analizy każdej z rozpatrywanych sekwencji obrazów uzyskano zbiór sygnałów diagnostycznych, który podobnie jak w omawianym wcześniej przykładzie dotyczącym oceny stanu procesu spawania na podstawie cech profilowych, poddano analizie z zastosowaniem klasycznych estymatorów liczbowych (por. C). Pozwoliło to na uzyskanie wzorców wykorzystanych w klasyfikacji stanu procesu. Do klasyfikacji stanu procesu spawania, podobnie jak poprzednio, zastosowano klasyfikator minimalno-odległościowy k najbliższych sąsiadów oraz N -krotną krosvalidację metodą LOO (*leave-one-out*). Sprawność klasyfikacji wyznaczono ze wzoru 5.17. Wyniki klasyfikacji dla wybranych cech obszaru analizy obrazów po fuzji (ROA) i sygnałów diagnostycznych, dla których średnia sprawność klasyfikacji była najwyższa, zaprezentowano w tabeli 5.21.

Tab. 5.21. Sprawności klasyfikacji stanu procesu spawania na podstawie cech sygnałów diagnostycznych obrazów termograficznych i wizyjnych po operacji ich fuzji estymowanych za pomocą cech statystycznych w obrębie obszaru analizy ROA

Cecha obrazu	Cecha sygnału diag.	Sprawność klasyfikacji eff , %								Śr. spraw. μ_{eff} , %
		SW1	SW2	SW3	SW4	SW5	SW6	SW7	SW8	
sd4	Ave	100	0	57	0	43	67	0	0	33
sp6	Var	73	83	57	0	71	0	0	0	36
sp4	L	55	17	86	0	71	0	0	0	29
sp4	Mean	45	17	86	100	57	67	0	0	46
sp7	Peak	82	17	29	0	100	0	14	0	30
sp1	S	27	0	0	57	0	83	0	0	21
sd6	K	64	17	0	0	0	50	57	57	31
sp6	Peak	73	0	0	0	86	67	0	71	37

Średnia sprawność klasyfikacji otrzymana na podstawie statystycznej estymacji obrazów po fuzji uznano za dostateczną. Uzyskane średnie wartości sprawności klasyfikacji są jednak wyższe od wartości będących wynikiem estymacji obrazów z zastosowaniem cech profilowych. Analiza szczególnych przypadków dla każdego stanu pokazuje jednak, że możliwe jest również skuteczne rozpoznawanie nieprawidłowości procesu spawania, stosując odpowiednią kombinację estymatorów statystycznych obrazu w obrębie obszaru analizy ROA i sygnału diagnostycznego. Do oceny obrazów w obszarze analizy najbardziej nadają się takie cechy jak RMS i odchylenie standardowe. Zdolność rozpoznawania stanów procesu spawania można podnieść, przeprowadzając fuzję klasyfikatorów [67].

6. Uwagi końcowe

Termografia w podczerwieni jest od lat skutecznie stosowanym narzędziem diagnostyki technicznej. Najbardziej rozpowszechnioną formą diagnostyki termograficznej są inspekcje prowadzone przez przeszkolony personel służb diagnostycznych. Inną formą zastosowania urządzeń i metod termograficznych jest ciągłe monitorowanie i diagnostyka obiektów technicznych i procesów. W porównaniu z klasycznymi inspekcjami termograficznymi ta forma badań termograficznych nie jest upowszechniona w takim stopniu, w jakim zdaniem autora mogłaby być stosowana. Jedną z przyczyn jest brak spójnej metodyki dotyczącej zarówno zasad projektowania systemów termograficznego monitorowania i diagnostyki, jak również późniejszego przetwarzania i analizy dużej ilości danych diagnostycznych generowanych w trakcie działania systemu. W głównej mierze dostrzegalny jest jednak brak metod tworzenia relacji diagnostycznych między cechami obrazów termograficznych a cechami stanu obiektu diagnozowania w celu ich wykorzystania w układach automatycznego wnioskowania stosowanych w systemach diagnostycznych działających w trybie on-line. W niniejszej pracy podjęto próbę sformułowania spójnej metodyki monitorowania i diagnozowania obiektów i procesów przemysłowych, która może być pomocna w projektowaniu systemów diagnostycznych bazujących na obrazach termograficznych pozyskiwanych w trakcie ciągłej obserwacji termograficznej obiektów i procesów.

6.1. Podsumowanie

W monografii przedstawiono ogólną metodykę monitorowania i diagnozowania obiektów technicznych i procesów na podstawie ich ciągłej obserwacji z zastosowaniem urządzeń obrazowania podczerwieni. Metodyka zakłada, że ocena stanu technicznego może być prowadzona na podstawie wyników analizy sygnałów diagnostycznych będących przebiegami wartości cech obrazów termograficznych poddanych wcześniejszym operacjom przetwarzania i analizy. W metodyce wykorzystano koncepcję podziału czasu zegarowego na czas „mikro” i czas „makro”, co pozwala na scharakteryzowanie szybkich i wolnych zmian stanu obiektu zachodzących w trakcie jego eksploatacji. Ponadto sformułowano wielowariantowy algorytm pozwalający na dobór odpowiedniej kombinacji metod przetwarzania, analizy i rozpoznawania obrazów termograficznych i sygnałów diagnostycznych. Metodyka uwzględnia możliwość jej zastosowania w układach ciągłego monitorowania i diagnostyki poprzez zaproponowanie czterech różnych strategii obserwacji termograficznych diagnozowanych obiektów. Sformułowane strategie pozwoliły na opracowanie szczegółowej koncepcji systemu termograficznego monitorowania i diagnostyki obiektów technicznych i procesów przemysłowych. Opracowana metodyka jest wsparta o wiedzę z zakresu takich dziedzin nauki i techniki jak diagnostyka techniczna, termografia w podczerwieni, przetwarzanie i analiza sygnałów, rozpoznawanie wzorców, sztuczna inteligencja. Interdyscyplinarne podejście wykorzystane w opracowanych koncepcjach i metodach wymagało zamieszczenia w pierwszej części pracy syntetycznego przeglądu wybranych zagadnień z zakresu termografii w podczerwieni, metod przetwarzania, analizy i rozpoznawania obrazów oraz metod diagnostyki termograficznej. W dalszej części pracy usystematyzowano i sformułowano ogólne reguły postępowania niezbędne do

przygotowania i prowadzenia termograficznych badań diagnostycznych obiektów technicznych i procesów przemysłowych. Główną część pracy stanowi charakterystyka opracowanej metodyki, a także opis koncepcji termograficznego systemu monitorowania i diagnostyki obiektów, pozwalającego na implementację zaproponowanej metodyki na potrzeby ciągłej diagnostyki termograficznej obiektów technicznych i/lub procesów. W ostatniej części przedstawiono przykłady realizacji koncepcji termograficznego systemu monitorowania i diagnostyki obiektów oraz trzy przykłady jej zastosowania. Przykłady pokazują różne scenariusze stosowania metodyki i bazują na trzech różnych sekwencjach obrazów termograficznych zarejestrowanych w trakcie czynnych eksperymentów diagnostycznych przeprowadzonych w warunkach laboratoryjnych jak również w trakcie biernego eksperymentu diagnostycznego zrealizowanego w warunkach przemysłowych. Obiektami poddawanych monitorowaniu termograficznemu były: zaprojektowany i samodzielnie wytworzony laboratoryjny model maszyny wirnikowej, proces spawania oraz turbozespół energetyczny. Dane w trakcie eksperymentów pozyskiwano za pomocą prototypowego systemu monitorowania i diagnostyki obiektów opracowanego w oparciu o zaproponowaną koncepcję. Do analizy obrazów termograficznych wykorzystywano metody statystyczne, metody oceny cech geometrycznych oraz samodzielnie opracowane metody polegające m.in. na analizie profili temperaturowych. Analizie poddano również reprezentacje obrazów termograficznych powstałe po zastosowaniu transformat Fouriera, transformaty falkowej oraz analizy składowych głównych (PCA). Cechy obrazów będące efektem analizy termogramów poddawano procesowi ekstrakcji i selekcji w celu utworzenia zbioru cech relewantnych. Na podstawie wektorów cech relewantnych przeprowadzono rozpoznawanie stanu technicznego obiektów z zastosowaniem klasyfikatorów bazujących na sztucznych sieciach neuronowych i metodach odległościowych. W badaniach wykorzystano również metody fuzji obrazów i fuzji klasyfikatorów, które w znaczący sposób zwiększyły skuteczność prawidłowej identyfikacji słabo rozpoznawalnych stanów technicznych.

6.2. Wnioski

Na podstawie zaprezentowanych w pracy przykładów stosowania opracowanej i opisanej w rozdziale 4 metodyki można stwierdzić, że może ona być w skuteczny sposób zastosowana do opracowania szczegółowych metod diagnozowania stanu obiektów technicznych i procesów przemysłowych. Metody diagnozowania powstałe na podstawie metodyki umożliwiają skuteczne diagnozowanie stanu obiektów technicznych i procesów przemysłowych, co potwierdzają wyniki przedstawione w rozdziale 5. Zaprezentowane przykłady stosowania opracowanych metod pokazują, że możliwa jest detekcja niewielkich zmian stanu technicznego obiektu i skuteczne rozpoznawanie klas stanów różnych obiektów i procesów. W przypadkach stanów trudnych do identyfikacji możliwe jest podniesienie skuteczności rozpoznawania poprzez zastosowanie metod fuzji danych. Przykład zastosowania metodyki przedstawiony w rozdziale 5.4 pokazuje, że możliwe jest jednoczesne i niezależne od siebie monitorowanie i diagnozowanie termograficzne wielu obiektów znajdujących się w polu widzenia głowicy systemu termograficznego monitorowania i diagnostyki. Wyniki przetwarzania i analizy obrazów termograficznych oraz klasyfikacji stanu technicznego na podstawie zbioru cech relewantnych zaprezentowane w przykładach w rozdziale 5 pokazują, że można określić relacje diagnostyczne między cechami stanu a cechami sygnałów diagnostycznych. Jest to możliwe zarówno na podstawie danych pochodzących z eksperymentów diagnostycznych, jak również

z danych historycznych pozyskanych z obiektów tej samej klasy. Bazując na zaprezentowanej w rozdziale 5.1 koncepcji systemu termograficznego monitorowania i diagnostyki, możliwa jest jego fizyczna realizacja, uruchomienie i wykorzystanie dla ciągłego monitorowania i oceny zmian stanu obiektów i procesów przemysłowych.

Poza przedstawionymi powyżej wnioskami ogólnymi można sformułować również wnioski szczegółowe dotyczące wyników badań zaprezentowanych w przykładach zastosowania opracowanej metodyki (por. 5). Na podstawie statystycznej analizy obrazów termograficznych stwierdzono, że skuteczną grupą cech są cechy statystyczne drugiego rodzaju wyznaczone na podstawie macierzy zdarzeń. Wyjątkiem jest wartość średnia, która również bardzo dobrze nadaje się w estymacji wartości obrazów w obrębie wybranych obszarów zainteresowania. Geometryczne cechy kształtu obiektów wyekstrahowane z obrazów termograficznych są szczególnie przydatne w procesie diagnozowania termograficznego obiektów, na których rozkład temperatury objawia się w postaci zwartych obszarów o równomiernie rozłożonych wartościach temperatur. Skutecznymi narzędziami przetwarzania obrazów termograficznych na potrzeby analizy geometrycznych cech kształtu są metody segmentacji bazujące na rozroście obszarów oraz progowanie obrazów na jednym lub kilku poziomach w celu pozyskania obszarów izotermicznych. Zastosowanie metod transformacyjnych, a w szczególności transformaty Fouriera i analizy składowych głównych, pozwoliło na pozyskanie bardzo cennych informacji diagnostycznych przydatnych w skutecznej identyfikacji stanu badanego obiektu. Jednowymiarowa analiza Fouriera ma szczególne znaczenie w analizie procesów cieplnych, w których może dochodzić do okresowych zmian ich intensywności, pozwalając tym samym identyfikować zakłócenia wywołane niesprawnościami. Dwuwymiarowa analiza Fouriera i F-obrazy otrzymywane w jej wyniku mają ogromny potencjał informacyjny i mogą znaleźć zastosowanie w ciągłej ocenie stanu obiektów technicznych, jak również procesów, np. procesu spawania. Ważne w ocenie obrazów termograficznych są profile temperaturowe obrazu. Ich odpowiednia analiza i ocena pozwalają pozyskać cechy charakteryzujące zjawiska cieplne obserwowane na obrazach podczerwieni. Potwierdzają to wyniki analizy obrazów termograficznych procesu spawania, na potrzeby analizy którego zaproponowano oryginalny sposób definiowania profilu temperaturowego i jego ocenę. Obrazy termograficzne i wizyjne rejestrowane przez prototypową wersję systemu monitorowania w przypadku niektórych procesów przemysłowych jak np. procesu spawania mogą być analizowane łącznie przez zastosowanie metod fuzji obrazów, która pozwala na pozyskanie danych relewantnych z obu obrazów, tłumiąc jednocześnie dane redundantne. W przypadku gdy możliwe jest wyodrębnienie na obrazie termograficznym wielu obszarów zainteresowania, których niezależna analiza i identyfikacja dają informacje diagnostyczne charakteryzujące różne stany techniczne obiektu w różny sposób, możliwe jest zagregowanie tych informacji poprzez zastosowanie fuzji klasyfikatorów. Takie postępowanie w istotny sposób podnosi skuteczność identyfikacji globalnego stanu technicznego obiektu. Interesujące wyniki badań uzyskano w trakcie obserwacji termograficznej turbosespołu energetycznego. Zaobserwowano, że wyniki analizy zarejestrowanej sekwencji obrazów termograficznych pozwoliły wyznaczyć przebieg sygnału diagnostycznego, na którym możliwe było wykrycie zmian stanu eksploatacyjnego wywołanego zmianami obciążenia turbosespołu. Zmiany te skorelowane były z przebiegiem sygnału mocy czynnej pozyskanym z układu monitorowania turbosespołu. Potwierdza to, że zaproponowana metodyka jest skuteczna i może znaleźć zastosowanie w szybkiej, bezkontaktowej ocenie stanu technicznego jednego lub wielu obiektów jednocześnie. Potwierdzeniem przydatności opracowanej metodyki diagnozowania jest jej zastosowanie

do identyfikacji nieprawidłowości procesu spawania. Przeprowadzone badania pozwoliły na wykrywanie różnych niezgodności spawalniczych na podstawie analizy sekwencji obrazów termowizyjnych zarejestrowanych w trakcie obserwacji procesu spawania.

6.3. Oryginalne elementy pracy

Realizacja pracy pozwoliła zaproponować zdaniem autora wiele oryginalnych i nowatorskich elementów, do których można zaliczyć:

- koncepcję systemu monitorowania wykorzystującego mobilną głowicę obserwacyjno-pomiarową umożliwiającą zarówno pozyskiwanie obrazów w podczerwieni, jak również w świetle widzialnym oraz bezkontaktowy pomiar wielkości dodatkowych;
- wielowariantowy algorytm przetwarzania analizy i rozpoznawania obrazów bazujący m.in. na cechach liczbowych i funkcyjnych obrazów termograficznych;
- metodę analizy obrazów modułu i fazy będących wynikiem zastosowania jednowymiarowej transformaty Fouriera wobec sekwencji obrazów termograficznych;
- metody przetwarzania obrazów łuku spawalniczego i złącza spawanego prowadzące do uzyskania nowych obrazów zwanych profilogramami.
- sposób oceny obrazów termograficznych łuku spawalniczego z zastosowaniem cech profilowych;
- metodę analizy obrazów wizyjnych i termograficznych po fuzji, w której wykorzystano koncepcję obszaru analizy (ROA) wyznaczanego na bazie obrazu wizyjnego poddanego wcześniejszej segmentacji.

6.4. Kierunki dalszych badań

Główny kierunek dalszych badań powinien dotyczyć poszukiwania nowych metod przetwarzania i analizy obrazów termograficznych, uwzględniających własności i właściwości różnych obiektów technicznych, np. istnienie podzespołów tego samego typu, ale różnie obciążonych, których względne różnice temperatur mogą świadczyć o konkretnym stanie technicznym całego obiektu. Innym z możliwych sposobów rozwoju zaproponowanej w pracy metodyki może być weryfikacja znanych, lecz dotąd niestosowanych w diagnostyce termograficznej metod przetwarzania, analizy i rozpoznawania obrazów wizyjnych. Szczególnie ważnym w dalszych badaniach będzie poszukiwanie i definiowanie nowych cech obrazów. Odnosi się to szczególnie do obrazów będących efektem stosowania różnych transformacji przestrzenno-czasowych sekwencji obrazów podczerwieni. Zaobserwowano, że przydatnym i wymagającym dalszych badań jest rozwój i zastosowanie metod szeroko pojętej fuzji danych w celu agregacji informacji diagnostycznej zawartej w obrazach wizyjnych, multispektralnych obrazach podczerwieni, sygnałach diagnostycznych wyznaczanych na podstawie obrazów termograficznych, sygnałach niosących informację o warunkach działania obiektu i warunkach otoczenia oraz sygnałach pochodzących z istniejących systemów monitorowania.

Dodatek A. Przegląd cech statystycznych obrazów teksturowych

W dodatku zamieszczono wykaz identyfikatorów i nazw cech statystycznych pierwszego i drugiego rodzaju (tab. A.1) stosowanych w ocenie obrazów termograficznych analizowanych w trakcie badań omówionych w pracy. W dalszej części dodatku przedstawiono definicję każdej cechy oraz omówiono metody ekstrakcji cech obrazów. Dodatek przygotowano na podstawie dokumentacji oprogramowania Mazda [25, 133].

Tab. A.1. Wykaz identyfikatorów i nazwy cech statystycznych obrazów termograficznych stosowanych w trakcie badań

Id cechy	Nazwa cechy	Podstawa wyznaczania cechy
Mean	Średnia	Wektor histogramu (por. A.1)
Variance	Wariancja	
Skewness	Skośność	
Kurtosis	Kurtoza	
Perc.01%	Percentyl 1%	
Perc.10%	Percentyl 10%	
Perc.50%	Percentyl 50%	
Perc.90%	Percentyl 90%	
Perc.99%	Percentyl 99%	
GrMean	Średnia	Macierz gradientu (por. A.2)
GrVariance	Wariancja	
GrSkewness	Skośność	
GrKurtosis	Kurtoza	
NonZeros	Procent pikseli z niezerowym gradientem	
XX_RLNonUni	Nierównomierność pasma	Macierz długości pasm (por. A.4)
XX_GLevNonU	Nierównomierność szarości	
XX_ShrtREmp	Uwydatnienie krótkich pasm	
XX_LngREmp	Uwydatnienie długich pasm	
XX_Fraction	Część obrazu w pasmach	
S(d,θ)AngScMom	Drugi moment kątowy	Macierz zdarzeń (por. A.3)
S(d,θ)Contrast	Kontrast	
S(d,θ)Correlat	Korelacja	
S(d,θ)SumOfSqs	Suma kwadratów	
S(d,θ)InvDfMom	Odwrotny moment różnicowy	
S(d,θ)SumAverg	Sumaryczna średnia	
S(d,θ)SumVarnc	Sumaryczna wariancja	

Kod cechy	Nazwa cechy	Podstawa wyznaczania cechy
S(d,θ)SumEntrp	Sumaryczna entropia	
S(d,θ)Entropy	Entropia	
S(d,θ)DifVarnc	Wariancja różnicowa	
S(d,θ)DifEntrp	Entropia różnicowa	
Teta1	θ_1	Model autoregresji (por. A.5)
Teta2	θ_2	
Teta3	θ_3	
Teta4	θ_4	
Sigma	σ	

A.1. Cechy wyznaczone na podstawie histogramu

Histogram to funkcja zawierająca informację na temat tego, ile pikseli o danym poziomie szarości występuje na obrazie (równanie A.1).

$$h(l) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} \delta(f(x,y), l) \quad (\text{A.1})$$

gdzie:

- $f(x,y)$ – obraz jako funkcja dwóch zmiennych przestrzennych x i y , $x = 0, 1, \dots, N-1$ i $y = 0, 1, \dots, M-1$,
- $l = 0, 1, \dots, L-1$ – dyskretne wartości funkcji $f(x,y)$, gdzie L jest całkowitą liczbą poziomów intensywności występujących na danym obrazie,
- $\delta(k,l)$ to delta Kroneckera:

$$\delta(k,l) = \begin{cases} 1; & \text{dla } k = l \\ 0; & \text{dla } k \neq l \end{cases} \quad (\text{A.2})$$

Dzieląc wartości $h(l)$ przez całkowitą liczbę pikseli obrazu uzyskuje się przybliżony rozkład gęstości prawdopodobieństwa wystąpienia poszczególnych poziomów szarości:

$$p(l) = \frac{h(l)}{N \cdot M}, \quad l = 0, 1, \dots, L-1 \quad (\text{A.3})$$

Definicje cech obrazu obliczone na podstawie histogramu, w celu ilościowego opisu statystycznych własności pierwszego rzędu danego obrazu zebrano, w tabeli A.2.

Tab. A.2. Definicje cech obrazu obliczanych na podstawie histogramu

Średnia (Mean)	$\mu = \sum_{l=0}^{L-1} lp(l)$	(A.4)
Wariancja (Variance)	$\sigma^2 = \sum_{l=0}^{L-1} (l - \mu)^2 p(l)$	(A.5)
Skośność (Skewness)	$\mu_3 = \sigma^{-3} \sum_{l=0}^{L-1} (l - \mu)^3 p(l)$	(A.6)
Kurtoza (Kurtosis)	$\mu_3 = \sigma^{-4} \sum_{l=0}^{L-1} (l - \mu)^4 p(l) - 3$	(A.7)
Percentyle 1% (Perc.01%)		
Percentyle 10% (Perc.10%)		
Percentyle 50% (Perc.20%)		
Percentyle 90% (Perc.90%)		
Percentyle 99% (Perc.99%)		

A.2. Cechy wyznaczone na podstawie macierzy gradientu

Macierz gradientu opisuje bezwzględne różnice poziomów szarości pomiędzy sąsiadującymi pikselami (albo bezwzględny gradient) lub pomiędzy pikselami oddalonymi od siebie o pewną odległość d . Macierz gradientu jest obliczana z poniższej zależności:

$$G_d(x,y) = \sqrt{(l(x+d,y) - l(x-d,y))^2 + (l(x,y+d) - l(x,y-d))^2} \quad (\text{A.8})$$

Zakładając następującą postać sąsiedztwa dla piksela $l(x,y)$:

$$\begin{array}{ccccc} A & B & C & D & E \\ F & G & H & I & J \\ K & L & l(x,y) & N & O \\ P & R & S & T & U \\ V & W & X & Y & Z \end{array}$$

bezwzględna wartość gradientu dla $d = 1$ może być obliczona z następującej zależności:

$$G_3(x,y) = \sqrt{(S - H)^2 + (N - L)^2} \quad (\text{A.9})$$


A.3. Cechy wyznaczone na podstawie macierzy zdarzeń

Macierz zdarzeń $S(d,\varphi)$ (ang. *Gray Level Co-occurrence Matrix*, GLCM) (nazywana także histogramem drugiego rzędu) jest otrzymywana przez zliczanie wszystkich przejść od piksela o poziomie szarości l_1 do piksela o poziomie szarości l_2 w określonym kierunku φ i danej odległości między pikselami d dla wszystkich występujących kombinacji poziomów szarości l_1

Tab. A.3. Definicje cech obrazu obliczanych na podstawie gradientu

Średni bezwzględny gradient (GrMean)	$G\mu = \frac{1}{g} \sum_{x,y} G_d(x,y)$	(A.10)
Wariancja bezwzględnego gradientu (GrVariance)	$(G\sigma)^2 = \frac{1}{g} \sum_{x,y} (G_d(x,y) - G\mu)^2$	(A.11)
Skośność bezwzględnego gradientu (GrSkewness)	$G\mu_3 = \frac{1}{(\sqrt{G\sigma})^3} \frac{1}{g} \sum_{x,y} (G_d(x,y) - G\mu)^3$	(A.12)
Kurtoza bezwzględnego gradientu (GrKurtosis)	$G\mu_4 = \frac{1}{(\sqrt{G\sigma})^4} \frac{1}{g} \sum_{x,y} (G_d(x,y) - G\mu)^4 - 3$	(A.13)
Procent pikseli o niezerowym gradiencie (NonZeros)	gdzie: g to liczba elementów w macierzy gradientu	

i l_2 . Macierz ta może być normalizowana przez dzielenie poszczególnych jej wartości przez całkowitą liczbę pikseli. Przykładową macierz zdarzeń dla par pikseli przesuniętych w osi poziomej o 1 piksel ($d = 1$, $\varphi = 0^\circ$) wyznaczoną na podstawie obrazu w skali szarości (rys. A.1(a)) o zakresie intensywności od 1 do 4 zaprezentowano na rysunku A.1(b). Macierz zdarzeń jest zwykle obliczana dla kierunków $\varphi = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$. Odległości i kierunki dla współrzędnych (x, y) (gdzie początkiem układu jest lewy dolny róg obrazu) mogą być wyrażone w formie następujących wektorów: $[d, 0]$, $[d, d]$, $[0, d]$, $[d, -d]$. Zapis ten oznacza, że macierz zdarzeń wyznaczona dla wektora $[3, -3]$ odpowiada odległości $d = 3$ i kierunkowi $\varphi = 135^\circ$ co można zapisać jako $S(3, -3)$.



Rys. A.1. Przykład obliczania macierzy zdarzeń $S(1,0)$ z obrazu (a) posiadającego cztery odcienie szarości; pokazano przykład poszukiwania przejścia między pikselami o wartościach 1 i 2; wartość macierzy zdarzeń (b) o współrzędnych $P(1,2)$ zostały wyznaczone w następujący sposób: zlokalizowano na obrazie (a) wszystkie piksele o intensywności równej 1, zliczono wszystkie piksele, mające w swoim sąsiedztwie piksel o intensywności 2, przesunięte o 1 piksel w prawo od piksela bazowego ($d = 1$, $\varphi = 0^\circ$). Znalaziono dwie takie pary pikseli, dlatego $P(1,2) = 2$

Cechy wyznaczone na podstawie macierzy zdarzeń zebrano w tabeli A.4.

Tab. A.4. Definicje cechy obrazu obliczane na podstawie macierzy zdarzeń

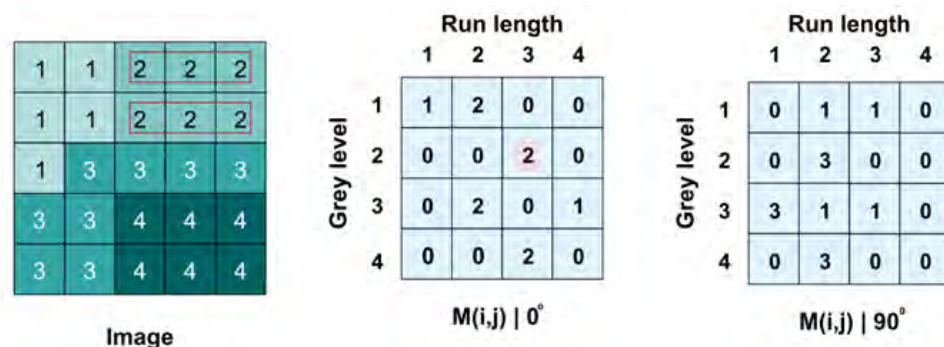
Energia (drugi moment kątowy)	$f_1 = \sum_{i=1}^L \sum_{j=1}^L [p(i, j)]^2$	(A.14)
Kontrast	$f_2 = \sum_{n=0}^{L-1} n^2 \left[\sum_{i=1}^L \sum_{j=1}^L p(i, j) \right]$	(A.15)
Korelacja	$f_3 = \sum_{i=1}^L \sum_{j=1}^L \frac{(ij)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$	(A.16)
Wariancja (Suma kwadratów)	$f_4 = \sum_{i=1}^L \sum_{j=1}^L (i - \mu)^2 p(i, j)$	(A.17)
Jednorodność (Odwrotny moment różnicowy)	$f_5 = \sum_{i=1}^L \sum_{j=1}^L \frac{1}{1 + (i + j)^2} p(i, j)$	(A.18)
Sumaryczna średnia	$f_6 = \sum_{i=2}^{2L} i p_{x+y}(i)$	(A.19)
Sumaryczna wariancja	$f_7 = \sum_{i=2}^{2L} (i - f_6)^2 p_{x+y}(i)$	(A.20)
Sumaryczna entropia	$f_8 = - \sum_{i=2}^{2L} p_{x+y}(i) \log[p_{x+y}(i)]$	(A.21)
Entropia	$f_9 = - \sum_{i=1}^L \sum_{j=1}^L p(i, j) \log(p(i, j))$	(A.22)
Wariancja różnicowa	$f_{10} = \text{var}(p_{x-y})$	(A.23)
Entropia różnicowa	$f_{11} = - \sum_{i=0}^{L-1} p_{x-y}(i) \log[p_{x-y}(i)]$	(A.24)

gdzie:

- μ_x, μ_y i σ_x, σ_y to wartości średnie i odchylenia standardowe macierzy p_x i p_y ,
- $p(i, j)$ – element (i, j) w znormalizowanej macierzy zdarzeń, $p(i, j) = P(i, j)/R$,
- $p_x(i)$ i $p_y(j)$ – elementy i i j w macierzy prawdopodobieństwa marginalnego, uzyskanej w wyniku sumowania elementów odpowiednio w wierszach i kolumnach macierzy $p(i, j)$,
- L – liczba różnych poziomów szarości w skwantowanym obrazie.

A.4. Cechy wyznaczone na podstawie macierzy długości pasm

Macierz długości pasm $R(i, j)$ (ang. *Run–Length Matrix*, RLM) opisuje, ile razy w obrazie wystąpiło pasmo pikseli o intensywności i mające długość j . Pasma poziome szarości jest grupą współliniowych pikseli mających taki sam poziom szarości. Pasma określa się przy założonych ograniczeniach kątowych najczęściej $\varphi = \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$ określających kierunek przebiegu pasma. Przykład wyznaczania macierzy RLM zaprezentowano na rys. A.2.



Rys. A.2. Obliczanie wartości elementów macierzy długości pasm dla kierunków 0° i 90° . Na obrazie występują dwa poziome pasma pikseli o intensywności 2, mające długość 3 pikseli. Z tego powodu element macierzy $R(2,3)|0^\circ = 2$

Definicje parametrów macierzy długości pasm $R(i, j)$ zebrano w tabeli A.5.

Tab. A.5. Definicje parametrów macierzy długości pasm

Niejednorodność pasm	$RLN = \frac{\sum_{j=1}^N (\sum_{i=0}^L R(i, j))^2}{c_1}$	(A.25)
Niejednorodność poziomego szarości	$GLN = \frac{\sum_{i=0}^{L-1} (\sum_{j=1}^N R(i, j))^2}{c_1}$	(A.26)
Odwrotny moment uwytatnienia krótkich pasm	$ShREIM = \frac{\sum_{i=0}^{L-1} \sum_{j=1}^N \frac{R(i, j)}{j^2}}{c_1}$	(A.27)
Moment uwytatnienia długich pasm	$LREM = \frac{\sum_{i=0}^{L-1} \sum_{j=1}^N j^2 \cdot R(i, j)}{c_1}$	(A.28)
Część obrazu w pasmach	$Fr = \frac{c_1}{\sum_{i=0}^L \sum_{j=1}^N j \cdot R(i, j)}$	(A.29)


gdzie: L – liczba poziomów szarości, N – liczba pasm, c_1 – współczynnik zdefiniowany następująco: $c_1 = \sum_{i=0}^{L-1} \sum_{j=1}^N R(i, j)$.

A.5. Cechy wyznaczone na podstawie modelu autoregresyjnego

Model autoregresyjny (AR) zakłada, że jasność badanego piksela jest uzależniona od jasności poprzedzających go (w macierzy) pikseli (z pewnego otoczenia) (rys. A.3). Zakładając, że obraz f jest polem losowym o zerowej średniej, autoregresyjny model przyczynowy zdefiniowany jest następująco:

$$f_s(x,y) = \theta_1 \cdot f_s(x,y-1) + \theta_2 \cdot f_s(x-1,y-1) + \theta_3 \cdot f_s(x-1,y) + \theta_4 \cdot f_s(x-1,y+1) + E_s \quad (\text{A.30})$$

gdzie: f_s jest obrazem w skali odcieni szarości, E_s jest funkcją losową o średniej równej zero i odchyleniu standardowym σ .



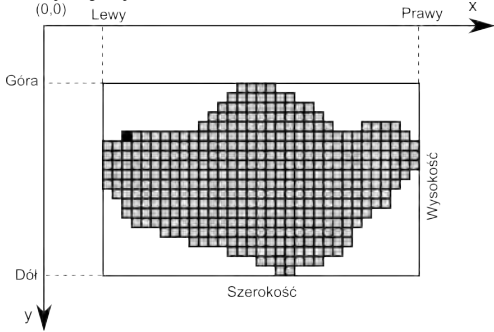
Rys. A.3. Lokalne sąsiedztwo elementu obrazu f_s

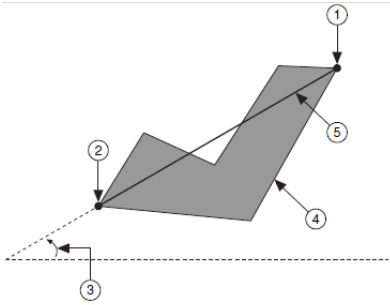

Parametry $\theta_1, \theta_2, \theta_3, \theta_4$ modelu wyznacza się tak, aby zminimalizować wartości szumu E_s .

Dodatek B. Przegląd geometrycznych cech kształtów obiektów

Dodatek prezentuje charakterystykę i definicje stosowanych w opracowaniu geometrycznych cech kształtu obszarów zidentyfikowanych na obrazie. Cechy zaprezentowano w postaci tabelarycznej. Cechy geometryczne obiektów definiowane są na podstawie kilku ogólnych koncepcji związanych z charakterystycznymi punktami lub elementami geometrycznymi związanymi z obiektami widocznymi na obrazie. Koncepcje przedstawiono w tabeli B.1. Charakterystykę i definicje cech zestawiono w tabeli B.2. Dodatek opracowano na podstawie dokumentacji oprogramowania Vision Development Module firmy National Instruments [96].

Tab. B.1. Podstawowe koncepcje i założenia dotyczące analizy geometrycznej obiektów

<p>Prostokąt otaczający (Bounding Rectangle)</p>	<p>Najmniejszy prostokąt o bokach równoległych do osi x i y, całkowicie zamykający obiekt.</p> 
<p>Obwód (<i>Perimeter</i>)</p>	<p>Długość granicy obszaru.</p>
<p>Otwór w części (Particle Hole)</p>	<p>Ciągły region pikseli o zerowej wartości całkowicie otoczony pikselami o niezerowych wartościach.</p>
<p>Kąt (<i>Angle</i>)</p>	<p>Liczba stopni obrotu, mierzona w kierunku przeciwnym do ruchu wskazówek zegara od osi x tak, że $0 \leq \theta \leq 180$.</p>
<p>Prostokąt zastępczy (Equivalent Rectangle)</p>	<p>Prostokąt o takim samym obwodzie i polu powierzchni co obiekt.</p>
<p>Elipsa zastępcza (Equivalent Ellipse)</p>	<p>Elipsa o takim samym obwodzie i polu powierzchni co obiekt.</p>

<p>Maksymalna średnica Fereta (Max Feret Diameter)</p>	<p>Odcinek łączący dwa punkty brzegowe, które są najbardziej od siebie oddalone.</p>  <p>Wymiary Fereta: 1. Początek maksymalnej średnicy Fereta, 2. Koniec maksymalnej średnicy Fereta, 3. Orientacja maksymalnej średnicy Fereta (<i>Max Feret Diameter Orientation</i>), 4. Obwód cząstki (<i>Particle Perimeter</i>), 5. Maksymalna średnica Fereta (<i>Max Feret Diameter</i>)</p>
<p>Otoczka wypukła (<i>Convex Hull</i>)</p>	<p>najmniejszy wypukły wielokąt zawierający wszystkie punkty obiektu. Rysunek poniżej ilustruje dwie cząstki w kolorze szarym, a ich otoczki wypukłe to obszary zamknięte czarnymi liniami.</p> 
<p>Długość maksymalnego segmentu poziomego (<i>Max Horiz. Segment Length</i>)</p>	<p>liczba pikseli w najdłuższym wierszu sąsiadujących pikseli w obiekcie.</p>
<p>Suma (<i>Sum</i>)</p>	<p>Momenty różnych rzędów względem osi x i osi y.</p>
<p>Moment bezwładności (<i>Moment of inertia</i>)</p>	<p>moment względem środka ciężkości obiektu. Momenty bezwładności są niezmiennie względem przesunięcia.</p>
<p>Znormalizowany moment bezwładności (<i>Normalized moment of inertia</i>)</p>	<p>Moment bezwładności odniesiony do wartości pola powierzchni cząstki, niezmienny względem przesunięcia i skali.</p>
<p>Moment Hu (<i>Hu moment</i>)</p>	<p>momenty uzyskane ze znormalizowanych momentów bezwładności, niezmiennie względem przesunięcia, skali i rotacji.</p>

Tab. B.2. Geometryczne cechy kształtu obiektów

Id cechy	Nazwa i charakterystyka cechy
Współrzędne położenia punktów charakterystycznych	
CMX	Współrzędna x środka masy $CMX = \frac{1}{A} \sum_{a=1}^A x_a$ gdzie: A–liczba elementów obiektu
CMY	Współrzędna y środka masy $CMY = \frac{1}{A} \sum_{a=1}^A y_a$
FPX	Współrzędna x pierwszego piksela obiektu położonego najbliżej lewego górnego rogu obrazu
FPY	Współrzędna y pierwszego piksela obiektu położonego najbliżej lewego górnego rogu obrazu
BL	Współrzędna x piksela najbardziej na lewo (por. rys. B.1)
BT	Współrzędna y piksela najbardziej u góry (por. rys. B.1)
BR	Współrzędna x piksela najbardziej na prawo (por. rys. B.1)
BB	Współrzędna y piksela najbardziej na dół (por. rys. B.1)
Fx1	Współrzędna x początku średnicy Fereta (por. rys. B.1)
Fy1	Współrzędna y początku średnicy Fereta (por. rys. B.1)
Fx2	Współrzędna x końca średnicy Fereta (por. rys. B.1)
Fy2	Współrzędna y końca średnicy Fereta (por. rys. B.1)
Max Horiz. Segment Length Left	Współrzędna x piksela wysuniętego najbardziej na lewo w najdłuższym zwartym rzędzie pikseli obiektu
Max Horiz. Segment Length Right	Współrzędna x piksela wysuniętego najbardziej na prawo w najdłuższym zwartym rzędzie pikseli obiektu
Max Horiz. Segment Length Row	Ilość pikseli w najdłuższym zwartym rzędzie pikseli obiektu
Odległości i długości	
W	Szerokość prostokąta otaczającego zdefiniowana jako odległość między BL a BR (por. rys. B.1)
H	Wysokość prostokąta otaczającego zdefiniowana jako odległość między BT a BB (por. rys. B.1)
Bounding Rect Diagonal	Odległość między przeciwległymi rogami prostokąta otaczającego obiekt
P	Obwód obiektu zdefiniowany jako długość zewnętrznej krawędzi obiektu.
Pch	Obwód najmniejszej powłoki wypukłej (wielokąta), w którym zawiera się cały obiekt (por. rys. B.1)
Phole	Suma obwodów otworów w obiekcie

Id cechy	Nazwa i charakterystyka cechy
F	Odległość między (F_x1, F_y1) a (F_x2, F_y2) $F = \sqrt{(F_y2 - F_y1)^2 + (F_x2 - F_x1)^2}$
E2a	Długość dłuższej osi elipsy zastępczej $E2a = \sqrt{\frac{p^2}{2\pi^2} + \frac{2A}{\pi}} + \sqrt{\frac{p^2}{2\pi^2} - \frac{2A}{\pi}}$
E2b	Długość krótszej osi elipsy zastępczej $E2b = \sqrt{\frac{p^2}{2\pi^2} + \frac{2A}{\pi}} - \sqrt{\frac{p^2}{2\pi^2} - \frac{2A}{\pi}}$
EF2b	Długość krótszej osi elipsy zastępczej, której pole jest równe polu obiektu, a długość dłuższej osi jest równa F $F_{2b} = \frac{4A_{CH}}{\pi F} \quad (B.1)$
Ra	Długość dłuższego boku prostokąta zastępczego $Ra = \frac{1}{4}p + \sqrt{p^2 - 16A}$
RFb	Długość krótszego boku prostokąta zastępczego $RFb = \frac{ACH}{F}$
Rd	Długość przekątnej prostokąta zastępczego $Rd = \sqrt{Ra^2 + Rb^2}$
Rfb	Długość krótszego boku prostokąta, którego pole jest równe polu obiektu, a dłuższy bok jest równy F
AhSL	Średnia długość zwartych rzędów pikseli obiektu $AhSL = \frac{A}{SH}$
AvSL	Średnia długość zwartych kolumn pikseli obiektu $AvSL = \frac{A}{SV}$
Hydraulic Radius	Pole powierzchni obiektu podzielone przez długość obwodu $\text{Hydraulic Radius} = \frac{A}{P}$

Id cechy	Nazwa i charakterystyka cechy
Waddel Disk Diameter	Średnica dysku o powierzchni równej polu obiektu $\text{Waddel Disk Diameter} = 2\sqrt{\frac{A}{n}}$
Pola powierzchni obiektów	
A	Pole obiektu
Ah	Suma pól „otworów” obiektu
At	Pole $A_t = A + A_h$
Ach	Pole najmniejszego wielokąta (polygon), w którym zawiera się cały obiekt
Ai	Pole obrazu
Liczebności	
Nh	Liczba „otworów” w obiekcie
Sh	Liczba rzędów pikseli obiektu
Sv	Liczba kolumn pikseli obiektu
Kąty	
Or	Kąt nachylenia prostej przechodzącej przez środek masy do osi poziomej $\text{Or} = \frac{1}{2} \text{atan} \left(\frac{2I_{xy}}{I_{xx} - I_{yy}} \right)$
OrF	Kąt nachylenia F do osi poziomej $\text{OrF} = \text{atan} \left(\frac{F_{y1} - F_{y2}}{F_{x1} - F_{x2}} \right)$
Współczynniki	
percA	% obrazu zajęty przez obiekt $\text{percA} = \frac{A}{A_i} \cdot 100\%$
percAt	% obrazu zajęty przez obiekt z uwzględnieniem pola „otworów” $\text{percAt} = \frac{A}{A_t} \cdot 100\%$
RatE2	Wskaźnik osi EE $\text{RatE2} = \frac{E_{2a}}{E_{2b}}$
RatR	Wskaźnik boków ER $\text{RatR} = \frac{R_a}{R_b}$
Elong	Współczynnik wydłużenia $\text{Elong} = \frac{F}{R_{fb}}$

Id cechy	Nazwa i charakterystyka cechy
Comp	Współczynnik zwartości $\text{Comp} = \frac{A}{W \cdot H}$
CircHey	Współczynnik cyrkularności Heywooda $\text{CircHey} = \frac{P}{2\sqrt{\pi A}}$
TypeFac	Współczynnik relacji pole–moment bezwładności $\text{TypeFac} = \frac{A^2}{4n\sqrt{\text{MoI}_{xx} \cdot \text{MoI}_{yy}}}$
Momenty pierwszego, drugiego i trzeciego rzędu względem osi x oraz osi y	
Sum X	$\sum x$
Sum Y	$\sum y$
Sum XX	$\sum xx$
Sum XY	$\sum xy$
Sum YY	$\sum yy$
Sum XXX	$\sum xxx$
Sum XXY	$\sum xxy$
Sum XYY	$\sum xyy$
Sum YYY	$\sum yyy$

Id cechy	Nazwa i charakterystyka cechy
Momenty bezwładności drugiego i trzeciego rzędu względem podanych osi niezmiennie względem przesunięcia	
Moment of Inertia XX	$\text{MoI}_{xx} = \frac{\sum xx - \sum x^2}{A}$
Moment of Inertia XY	$\text{MoI}_{xy} = \frac{\sum xy - \sum x \cdot \sum y}{A}$
Moment of Inertia YY	$\text{MoI}_{yy} = \frac{\sum yy - \sum y^2}{A}$
Moment of Inertia XXX	$\text{MoI}_{xxx} = \sum xxx - 3x \sum xx + 2x^2 \sum x$
Moment of Inertia XXY	$\text{MoI}_{xxy} = \sum xxy - 2x \sum xy - y \sum xx + 2x^2 \sum y$
Moment of Inertia XYY	$\text{MoI}_{xyy} = \sum xyy - 2x \sum xy - y \sum yy + 2x^2 \sum x$
Moment of Inertia YYY	$\text{MoI}_{yyy} = \sum yyy - 3y \sum yy + 2y^2 \sum y$
Normalizowane momenty bezwładności względem podanych osi niezmiennie względem przesunięcia i skali	
Norm. Moment of Inertia XX	$\text{NMoI}_{xx} = \frac{\text{MoI}_{xx}}{A^2}$
Norm. Moment of Inertia XY	$\text{NMoI}_{xy} = \frac{\text{MoI}_{xy}}{A^2}$
Norm. Moment of Inertia YY	$\text{NMoI}_{yy} = \frac{\text{MoI}_{yy}}{A^2}$
Norm. Moment of Inertia XXX	$\text{NMoI}_{xxx} = \frac{\text{MoI}_{xxx}}{A^{\frac{5}{2}}}$
Norm. Moment of Inertia XXY	$\text{NMoI}_{xxy} = \frac{\text{MoI}_{xxy}}{A^{\frac{5}{2}}}$
Norm. Moment of Inertia XYY	$\text{NMoI}_{xyy} = \frac{\text{MoI}_{xyy}}{A^{\frac{5}{2}}}$

Id cechy	Nazwa i charakterystyka cechy
Norm. Moment of Inertia YYY	$NMoI_{yyy} = \frac{MoI_{yyy}}{A^{\frac{5}{2}}}$
Momenty wyprowadzone z momentu normalizowanego niezmiennie względem przesunięcia, skali i obrotu	
Hu Moment 1 (HM1)	$HM1 = NMoI_{xx} + NMoI_{yy}$
Hu Moment 2 (HM2)	$HM2 = (NMoI_{xx} - NMoI_{yy})^2 + 4NMoI_{xy}^2$
Hu Moment 3 (HM3)	$HM3 = (NMoI_{xxx} - 3NMoI_{xyy})^2 + (3NMoI_{xxy} - 3NMoI_{yyy})^2$
Hu Moment 4 (HM4)	$HM4 = (NMoI_{xxx} + NMoI_{xyy})^2 + (NMoI_{xxy} - 3NMoI_{yyy})^2$
Hu Moment 5 (HM5)	$HM5 = (NMoI_{xxx} - 3NMoI_{xyy})(NMoI_{xxx} + 3NMoI_{xyy})$ $\left[(NMoI_{xxx} + 3NMoI_{xyy})^2 - 3(NMoI_{xxy} + 3NMoI_{yyy})^2 \right]$ $+ (3NMoI_{xxy} - NMoI_{yyy})(NMoI_{xxy} + NMoI_{yyy})$ $\left[(3NMoI_{xxx} + NMoI_{xyy})^2 - (3NMoI_{xxy} + NMoI_{yyy})^2 \right]$
Hu Moment 6 (HM6)	$HM6 = (NMoI_{xx} - NMoI_{yy})$ $\left[(NMoI_{xxx} + NMoI_{xyy})^2 - (NMoI_{xxy} + NMoI_{yyy})^2 \right]$ $+ 4NMoI_{xy}$ $\left[(NMoI_{xxx} + NMoI_{xyy})^2 - (NMoI_{xxy} + NMoI_{yyy}) \right]$
Hu Moment 7 (HM7)	$HM7 = (3NMoI_{xxy} - NMoI_{yyy})(3NMoI_{xxx} - NMoI_{xyy})$ $\left[(NMoI_{xxy} - NMoI_{yyy})^2 - 3(NMoI_{xxy} - NMoI_{yyy})^2 \right]$ $(3NMoI_{xxy} - NMoI_{yyy})(3NMoI_{xxy} - NMoI_{yyy})$ $\left[3(NMoI_{xxx} - NMoI_{yyy})^2 - (NMoI_{xxy} - NMoI_{yyy})^2 \right]$

Dodatek C. Cechy liczbowe sygnałów diagnostycznych

W dodatku przedstawiono definicje cech punktowych stosowanych w ocenie sygnałów diagnostycznych wyznaczanych na podstawie sekwencji obrazów termograficznych.

Tab. C.1. Wybrane cechy punktowe stosowane w diagnostyce maszyn

Id cechy	Nazwa cechy	Definicja cechy
Mean	Wartość średnia	$\mu = \frac{1}{n} \sum_{i=1}^n x_i$
Ave	Wartość średnia bezwzględna	$x_{ave} = \frac{1}{n} \sum_{i=1}^n x_i $
Ms	Wartość średnio kwadratowa	$x_{ms} = \frac{1}{n} \sum_{i=1}^n (x_i)^2$
Rms	Wartość skuteczna	$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i)^2}$
Var	Wariancja	$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$
Std	Odchylenie standardowe	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}$
Peak	Wartość szczytowa bezwzględna	$x_{peak} = \max\ x[n]\ $
Peak+	Wartość szczytowa dodatnia	$x_{peak+} = \max(x[n])$
Peak-	Wartość szczytowa ujemna	$x_{peak-} = \min(x[n])$
PP	Wartość międzyszczytowa	$x_{p-p} = x_{peak+} - x_{peak-}$
F	Bezwymiarowy współczynnik kształtu	$F = \frac{x_{rms}}{\mu}$
C	Bezwymiarowy współczynnik szczytu	$C = \frac{x_{peak}}{x_{rms}}$
I	Bezwymiarowy współczynnik impulsowości	$I = \frac{x_{peak}}{\mu}$
L	Bezwymiarowy współczynnik luzu	$L = \frac{x_{peak}}{x_{sqrt}}$
S	Asymetria	$S = \frac{\mu_3}{\sigma^3} = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^3}{(\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2)^2}$
K	Kurtoza	$K = \frac{\mu_4}{\sigma^4} = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^4}{(\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2)^2}$

Bibliografia

- [1] Acharya T., Ajoy R.: *Image Processing Principles and Applications*. A John Wiley & Sons, 2005.
- [2] Adamczewski W., Dyla K., Kajewski B., Polczyk L., Poloszyk S.: *Diagnostyka termiczna*. [w:] Cempel Cz., Tomaszewski F. (red.): *Diagnostyka Maszyn. Zasady ogólne. Przykłady zastosowań.*, s. 47–69. MCNEMT, Radom 1992.
- [3] Allen–Bradley Company: *Motor control center units based on field temperature analysis. Service/Repair Guidance for Allen–Bradley Company, Bulletin 21 0012400, May 1993.*
- [4] Almeida C. A. L., Paiva V., Caminhas W. M., Braga A. P., Martins H., Torres R.: *Intelligent detection and diagnosis of lightning arresters faults using digital thermovision image processing techniques*. VII Congresso Brasileiro de Redes Neurais, 2005.
- [5] Alpaydin E., Jordan M.: *Local linear perceptrons for classification*. IEEE Transactions on Neural Networks, nr 7, May 1996, s. 788–794.
- [6] Anderson A.: *A filter-subtract-decimate hierarchical pyramid signal analyzing and synthesizing technique*. Patent US 718104, 1987.
- [7] Andy W.: *Thermographic monitoring of refractory lined petroleum refinery equipment*. Proceedings of Inframation Conference, 2004.
- [8] ANSI: *Standard for maintenance testing specifications for electrical power equipment and systems*. Standard ANSI/NETA MTS-2011, 1997.
- [9] Augustyniak P.: *Transformacje falkowe w zastosowaniach elektrodiagnostycznych*. Uczelniane Wydawnictwo Naukowo–Dydaktyczne AGH, Kraków 2003.
- [10] Basir O., Yuan X.: *Engine fault diagnosis based on multi-sensor information fusion using dempster-shafer evidence theory*. Information Fusion, nr 8, 2007, s. 379–386.
- [11] Bazan J. G., Nguyen H. S., Nguyen S. H., Synak P., Wroblewski J.: *Rough set algorithms in classification problem*. [in:] Polkowski L., Tsumoto S., Lin T. Y. (eds.): *Rough set methods and applications: New developments in knowledge discovery in information systems*. Studies in Fuzziness and Soft Computing, s. 49–88. Physica–Verlag, Heidelberg, Germany, 2000.
- [12] Białasiewicz J. T.: *Falki i aproksymacje*. Wydawnictwa Naukowo Techniczne, Warszawa 2004.
- [13] Bieniek J., Banasiak J., Komarnicki P.: *Zastosowanie termowizji w badaniach eksploatacyjnych maszyn rolniczych*. Inżynieria Rolnicza, nr 12(87), 2006, s. 17–24.
- [14] Burakowski T.: *Termowizja w diagnostyce i racjonalnej eksploatacji*. Eksploatacja Maszyn, nr 5–6, 1985, s. 31–33.
- [15] Burt P., Adelson E.: *The laplacian pyramid as a compact image code*. IEEE Transactions on Communications, nr 31, 1983, s. 532–540.
- [16] Burt P., Kolczynski R.: *Enhanced image capture through fusion*. Proceedings of Fourth International Conference on Computer Vision, s. 173–182. IEEE, 1993.
- [17] Bzymek A., Czupryński A., Fidali M., Jamrozik W., Timofiejczuk A.: *Analysis of images recorded during welding processes*. Proceedings of QIRT Conference, Kraków, 2008.
- [18] Calmes F.: *Infrared inspections of robotic welders in automotive assembly*. Proceedings of Inframation Conference, 2000.
- [19] Cempel Cz.: *Vibroacoustic Condition Monitoring*. E. Horwood, Chichester - New York, 1991.
- [20] Cempel Cz., Tomaszewski F. (red.): *Diagnostyka maszyn. Zasady ogólne. Przykłady zastosowań*. MCNEMT, Radom, Warszawa 1992.
- [21] Charles J. A.: *Line–scan infrared imaging for papermachine diagnostics*. Proceedeengs of TAPPI Engineering Conference Anaheim, California September 13, 1999.

- [22] Chmielewski M. R., Grzymala-Busse J. W.: Global discretization of continuous attributes as preprocessing for machine learning. *International Journal of Approximate Reasoning*, s. 294–301, 1996.
- [23] Cholewa W., Kaźmierczak J.: *Data Processing and Reasoning in Technical Diagnostics*. Wydawnictwo Naukowo-Techniczne, Warszawa, 1995.
- [24] Cholewa W.: Bazy danych w diagnostyce technicznej. Międzynarodowy Kongres Diagnostyki Technicznej – Diagnostyka, 2000.
- [25] COST B11 Projekt: Ilościowa analiza tekstury obrazów tomograficznych rezonansu magnetycznego. http://www.elel.p.lodz.pl/programy/cost/projekt_cost.html, Kwiecień 2013.
- [26] Coy J., Al-Habaibeh A., Parkin R. M., Whitby D. R., Senior M.: Low-cost thermal imaging system for condition-based maintenance of mail sorting machines. *15th International Conference on Postal Automation*, s. 1–10, 2003.
- [27] Cudny W.: Matematyczne podstawy obrazowania medycznego. [w:] Nałęcz M. (red.): *Obrazowanie biomedyczne*, s. 3–42. Akademicka Oficyna Wydawnicza EXIT, 2003.
- [28] Dash M., Liu H.: Feature selection for classification. *Intelligent Data Analysis*, nr 1, 1997, s. 131–156.
- [29] Davies A.: *Handbook of Condition Monitoring: Techniques and Methodology*. Chapman & Hall, 1988.
- [30] Dezert J., Smarandache F.: DSMT: A new paradigm shift for information fusion. 2006, s. 15–17.
- [31] Dezert J., Smarandache F.: An introduction to dsmt in information fusion. *BRAIN–Broad Research in Artificial Intelligence and Neuroscience*, nr 1, 2010, s. 1–64.
- [32] Dezert J., Smarandache F., Daniel M.: The generalized pignistic transformation. *Proceedings of the 7th International Conference on Information Fusion*.
- [33] Dinca A., Cercel C., Borcosi I.: Limits in process diagnosis using thermographic images processing. [in:] Iskander M., Kapila V., Karim M. A. (eds.): *Technological Developments in Education and Automation*, s. 529–534. Springer Netherlands, 2010.
- [34] Doak J.: An evaluation of feature selection methods and their application to computer security. Technical report cse-92-18, University of California, 1992.
- [35] Dougherty J., Kohavi R., Sahami M.: Supervised and unsupervised discretization of continuous features. *Proceedings of International Conference on Machine Learning*, s. 194–202, San Francisco, 1995.
- [36] Dubois D., Prade H.: On the unicity of dempster rule of combination. *International Journal of Intelligent Systems*, nr 1, 1986, s. 133–142.
- [37] Electrophysics: Understanding infrared camera thermal image quality. *Scientific Imaging White Paper*, 2011.
- [38] Epperly R. A., Heberlein E. G., Eads L. G.: Thermography, a tool for reliability and safety. *IEEE Industry Application Magazine*, 1999, s. 28–36.
- [39] Fidali M., Jamrozik W.: The processing of fused infrared and vision images of a welding arc for fault detection. *Proceedings of QIRT Conference*, 2012.
- [40] Fidali M., Jamrozik W., Fidali M., Bzymek A., Timofiejczuk A.: Segmentation of welding arc images for purposes of welding diagnostics. *Diagnostyka*, nr 1, 2013, s. 11–18.
- [41] Fidali M.: Method of machine technical state assessment on the basis of joint signal analysis. *Mechanical Systems and Signal Processing*, nr 25, 2011, s. 871 – 883.
- [42] Fidali M., Bzymek A., Timofiejczuk A., Czupryński A., Jamrozik W.: Ocena stanu procesu spawania na podstawie analizy obrazów wizyjnych i termowizyjnych. *XIV Naukowo–Techniczna Krajowa Konferencja Spawalnicza: „Postęp, innowacje i wymagania jakościowe procesów spajania”*, 2008.

- [43] Fidali M., Czupryński A.: Detekcja wybranych niezgodności spawalniczych na podstawie analizy obrazów termowizyjnych. XV Naukowo–Techniczna Krajowa Konferencja Spawalnicza: „Postęp, innowacje i wymagania jakościowe procesów spajania”, s. 175–186, Międzyzdroje 02–04.06.2009, 2009.
- [44] Fidali M., Jamrozik W.: Baza danych termowizyjnego systemu ciągłego monitorowania i diagnostyki maszyn. Bazy Danych – Rozwój Metod i Technologii. Wydawnictwo Komunikacji i Łączności, 2008.
- [45] Figiel A.: Zastosowanie termowizji w diagnostyce zużycia ściernego elementów maszyn. Górnictwo Odkrywkowe, nr 4–5, 2008, s. 185–189.
- [46] Gandhi H., Green D., Kounios J., Clark C., Polikar R.: Stacked generalization for early diagnosis of Alzheimer’s disease. Engineering in Medicine and Biology Society, EMBS’06. 28th Annual International Conference of the IEEE, s. 5350–5353, 2006.
- [47] Gonzales R., Wintz P.: Digital Image Processing. Addison–Wesley Publishing Company, 1987.
- [48] Gonzalez R. C., Woods R. E.: Digital Image Processing. Prentice Hall, 2002.
- [49] Goshtasby A. A., Nikolov S.: Guest editorial: Image fusion: Advances in the state of the art. Information Fusion, nr 8, 2007, s. 114–118.
- [50] Hall D. L., Llinas J.: An introduction to multisensor data fusion. Proceedings of the IEEE, nr 85, 2002, s. 6–23.
- [51] Han D., Han C., Yang Y.: Multiple classifiers fusion based on weighted evidence combination. Automation and Logistics, 2007 IEEE International Conference on, s. 2138–2143, Aug. 2007.
- [52] Hojjatoleslami S., Kittler J.: Region growing: a new approach. IEEE Transactions on Image Processing, nr 7(7), 1998, s. 1079–1084.
- [53] Hots N.: Uncertainty budget of radiation thermometry. Materiały IX Krajowej Konferencji Termografia i Termometria w Podczerwieni TTP, 2011.
- [54] Huang Y., Suen C.: A method of combining multiple experts for the recognition of unconstrained handwritten numerals. Pattern Analysis and Machine Intelligence, IEEE Transactions on, nr 17, 1995, s. 90–94.
- [55] Ibarra-Castaneda C., Bendada A., Maldague X.: Thermographic image processing for NDT. IV Conferencia Panamericana de END, Buenos Aires, October 2007.
- [56] IEEE: Application guide for AC high–voltage circuit breakers rated on a symmetrical current basis. <http://ieeexplore.ieee.org/servlet/opac?punumber=7006>, 2000.
- [57] Infrasppection Institute: Level–II certified infrared thermographer reference manual. Infrasppection Institute Reference Manual.
- [58] Infrasppection Institute: Standard for infrared inspection of electrical systems & rotating equipment. Infrasppection Institute Standard, 2008.
- [59] ISO/IEC: Uncertainty of measurement – part 3: Guide to the expression of uncertainty in measurement. ISO/IEC Guide 98-3, 2008.
- [60] ISO/IEC: Uncertainty of measurement – part 1: Introduction to the expression of uncertainty in measurement. ISO/IEC Guide 98-1, 2009.
- [61] Jacobs R. A., Jordan M. I., Nowlan S. J., Hinton G. E.: Adaptive mixture of local experts. Neural Computation, nr 3, 1991, s. 79–87.
- [62] Jain A. K., Duin R. P., Mao J.: Statistical pattern recognition: A review. IEEE Trans. on Pattern Analysis and Machine Intelligence, nr 22, 2000, s. 4–37.
- [63] Jamrozik W., Fidali M.: Evaluation of the suitability of ir and tv image aggregation algorithms for purposes of welding process assessment. Proceedings of QIRT Conference.
- [64] Jamrozik W., Fidali M.: Metody dopasowania termogramów i obrazów wizyjnych do dynamicznie zmieniającej się struktury obserwowanej sceny. Pomiary Automatyka Kontrola, nr 9, 2011, s. 993–996.

- [65] Jamrozik W., Fidali M.: Zastosowanie fuzji obrazów wizyjnych i termowizyjnych do monitorowania i diagnozowania procesu spawania. *Przegląd Spawalnictwa*, nr 1, 2011, s. 27–36.
- [66] Jamrozik W.: An example of surface fault estimation on the basis of super-resolution approach. *Diagnostyka*, nr 54, 2010, s. 59–64.
- [67] Jamrozik W.: Metoda diagnozowania procesów przemysłowych z wykorzystaniem fuzji danych. Praca doktorska. Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, 2012.
- [68] Jezior Ł., Ludwiczuk R.: Algorytm Otsu i jego modyfikacje w segmentacji obrazów metodą wieloprogowania. *Polskie Towarzystwo Informatyczne*, Lublin, 2006.
- [69] John H., Kohavi R., Peger K.: Irrelevant features and the subset selection problem. *International Conference on Machine Learning*, 1994.
- [70] Kaplan H.: *Practical Applications of Infrared Thermal Sensing and Imaging Equipment*. SPIE, 2007.
- [71] Kim Y., Lee J., Ra J.: Multi-sensor image registration based on intensity and edge orientation information. *Pattern recognition*, nr 41, 2008, s. 3356–3365.
- [72] Klösger W., Zytow J. M.: Techniques and applications of KDD (abstract). *PKDD*, s. 394, 1997.
- [73] Kohavi R., John G.: Wrappers for features subset selection. *Artificial Intelligence*, nr 97, 1997, s. 273–324.
- [74] Koprowski R., Wróbel Z.: Przetwarzanie obrazów termograficznych. *Materiały VI Krajowej Konferencji Termografia i Termometria w Podczerwieni*, s. 43–60, 2004.
- [75] Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W. (red.): *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*. WNT, Warszawa, 2002.
- [76] Korendo Z., Florkowski M.: Thermography based diagnostics of power equipment. *Power Engineering Journal*, nr 15, 2001, s. 33–42.
- [77] Kulikowski J. L.: Ropoznawanie obrazów. [w:] Chmielewski L., Kulikowski J. L., Nowakowski A. (red.): *Obrazowanie biomedyczne*, s. 193–237. *Akademicka Oficyna Wydawnicza EXIT*, 2003.
- [78] Kwaśny W., Poloszczyk S.: Sygnały cieplne obrabiarek w diagnostyce termograficznej. *II Krajowa Konferencja Diagnostyka Procesów Przemysłowych*, 8–11 września 1997.
- [79] Laohasongkram P., Junsiri J., Oupayaso J.: Application of thermal detector by infrared for electrical arch furnaces transformer. *Proceedings of International Conference on Control, Automation and Systems*, 2007.
- [80] Li S., Wang Y.: Multisensor image fusion using discrete multiwavelet transform. *Proceedings of the 3rd International Conference on Visual Computing*, s. 93–103, 2000.
- [81] Liu X., Ma L., Mathew J.: Machinery fault diagnosis based on fuzzy measure and fuzzy integral data fusion techniques. *Mechanical Systems and Signal Processing*, nr 23, 2009, s. 690–700.
- [82] Madura H. (red.): *Pomiary termowizyjne w praktyce*. *Agenda Wydawnicza PAK*, Warszawa, 2007.
- [83] Malczewski K., Stasiński R.: Zwiększanie rozdzielczości przestrzennej obrazów pochodzących z sekwencji obrazów niskiej jakości. *Poznańskie Warsztaty Telekomunikacyjne*, Poznań, 9–10 grudzień 2004.
- [84] Maldague X. P. V.: *Theory and Practice of Infrared Technology for Nondestructive Testing*. John Wiley & Sons, INC., 2001.
- [85] Malina W., Ablameyko S., Pawlak W.: *Podstawy cyfrowego przetwarzania obrazów*. *Akademicka Oficyna Wydawnicza EXIT*, Warszawa 2002.
- [86] Marinetti S., Grinzato E., Bison P., Bozzi E., Chimenti M., Pieri G., Salvetti O.: Statistical analysis of IR thermographic sequences by PCA. *Journal of Infrared Physics & Technology*, nr 46, 2005, s. 85–91.

- [87] Martin A., Osswald C.: A new generalization of the proportional conflict redistribution rule stable in terms of decision. *Advances and applications of DSMT for information fusion: collected works*, nr 2, 2006, s. 69.
- [88] Materka A., Strumiłło P.: *Wstęp do komputerowej analizy obrazów*. Politechnika Łódzka–Instytut Elektroniki, 2007.
- [89] Meinlschmidt P.: Thermographic detection of defects in wood and wood-based materials. *Proceedings of 14th international Symposium of nondestructive testing of wood*, 2005.
- [90] MIMOSA: An operations and maintenance information open system alliance. <http://www.mimosa.org>, Kwiecień 2013.
- [91] Minkina W.: *Pomiary termowizyjne – przyrządy i metody*. Wydawnictwo Politechniki Częstochowskiej, Częstochowa, 2004.
- [92] Minkina W., Dudzik S.: Termografia w podczerwieni – błędy i niepewności. *Materiały IX Krajowej Konferencji Termografia i Termometria w Podczerwieni TTP*, 2011.
- [93] Minkina W., Dudzik S.: *Infrared thermography: errors and uncertainties*. Wiley, 2009.
- [94] Montgomery M. R.: Using IR thermography as a predictive maintenance tool in an electronics manufacturing facility. http://www.irinfo.org/articles/7_1_2010_montgomery.html, 2010.
- [95] Mucciardi A. N., Gose E. E.: A comparison of seven techniques for choosing subsets of pattern recognition properties. *IEEE Trans. on Computers*, nr c–20, 1971, s. 1023–1031.
- [96] National Instruments: *NI Vision Concepts Manual*, June 2008.
- [97] Ng K. C., Abramson B.: Consensus diagnosis: a simulation study. *Systems, Man and Cybernetics, IEEE Transactions on*, nr 22, Sep/Oct 1992, s. 916–928.
- [98] Nguyen S. H., Nguyen H. S.: Discretization methods in data mining. [in:] Polkowski L., Skowron A. (eds.): *Rough Sets in Knowledge Discovery*, s. 451–482. Springer Physica–Verlag, 1998.
- [99] Nishioka T., Shirato H., Karoa T., Watanabe Y., Yamazaki A., Ohmori K., Aoyama H., Shiga T., Tsukamoto E., Hashimoto S., Tsuchiya K., Miyasaka K.: Impact of 18FDG-pet and CT/MRI image fusion in radiotherapy planning of head-and-neck tumors. *International Journal of Radiation Oncology Biology Physics*, nr 48, 2000, s. 260–261.
- [100] Nixon S. M., Aguado S.: *Feature Extraction and Image Processing*. Newnes, 2002.
- [101] Nowakowski A. (red.): *Postępy termografii. Aplikacje medyczne*. Wydawnictwo Gdańskie, 2001.
- [102] Nowakowski A.: Termografia podczerwieni w diagnostyce medycznej. [w:] Chmielewski L., Kulikowski J. L., Nowakowski A. (red.): *Obrazowanie biomedyczne*, s. 476–617. Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2003.
- [103] Olkkonen H., Pesola P.: Gaussian pyramid wavelet transform for multiresolution analysis of images. *Graphical Models and Image Processing*, nr 58, 1996, s. 394–398.
- [104] Omar M., Viti V., Saito K., Liu J.: Self-adjusting robotic painting system. *Industrial Robot*, nr 33, 2006, s. 50–55.
- [105] Osiały J.: Nowe możliwości wykorzystania badań termowizyjnych w przemyśle szklarskim. *Świat Szkła*, nr 7–8, 2010.
- [106] Papp L.: Using Infrared Surveys in DUNAFERR Steelworks Complex Diagnostic System. *Proceedings of Inframation Conference*, 2004.
- [107] Parikh C., Pont M., Barrie Jones N.: Application of Dempster–Shafer theory in condition monitoring applications: a case study. *Pattern recognition letters*, nr 22, 2001, s. 777–785.
- [108] Pawlak Z.: *Rough Sets – Theoretical Aspects of Reasoning about Data*. Kluwer Academic, Dordrecht, 1991.
- [109] Perch-Nielsen T., Sorensen J. C.: Guideline for thermographic inspection in electrical installations. *Proc. SPIE 2245, Thermosense XVI: An International Conference on Thermal Sensing and Imaging Diagnostic Applications*. Danish Technology Institute, 1994.

- [110] Pieczonka L., Szewdo M., Uhl T.: Termograficzne metody detekcji uszkodzeń. *Pomiary Automatyka Kontrola*, nr 55, 2009, s. 699–702.
- [111] Poloszyk S., Różański L.: Termowizyjna diagnostyka maszyn technologicznych. *Pomiary Automatyka Kontrola*, nr 1, 2000, s. 15–18.
- [112] Poloszyk S., Różański L.: Kształtowanie właściwości metrologicznych systemów diagnostyki termograficznej. *Pomiary Automatyka Kontrola*, nr 4, 2002, s. 14–17.
- [113] Pratt W. K.: *Digital Image Processing*. John Wiley & Sons, Inc., 2001.
- [114] Predmesky R., Ruane T.: Using infrared cameras for process control. *Proceedings of Inframation Conference*, 2001.
- [115] Przyszałka P.: Metodyka modelowania neuronowego w diagnostyce procesów z uwzględnieniem elementów teorii chaosu. *Zeszyt nr 141, Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska*, 2009.
- [116] Radosavljevic Z., Durović Z., Kovacevic B.: An approach to the thermo vision image preprocessing. *Scientific–Technical Review*, nr LIV, 2004, s. 11–15.
- [117] Rajic N.: Principal component thermography for flaw contrast enhancement and flaw depth characterisation in composite structures. *Composite Structures*, nr 58, 2002, s. 521–528.
- [118] Ramac L., Uner M., Varshney P., Alford M., Ferris Jr D.: Morphological filters and wavelet-based image fusion for concealed weapons detection. *Proceedings of SPIE*, volume 3376, s. 110, 1998.
- [119] Różański L., Chajda J.: Ocena możliwości wykorzystania techniki termograficznej w diagnostyce termicznej obiektów i urządzeń energetycznych. *Zeszyty Naukowe Politechniki Opolskiej – Elektryka*, 2006, s. 579–584.
- [120] Rockinger O.: Image sequence fusion using a shift-invariant wavelet transform. *International Conference on Image Processing*, 1997. *Proceedings*, volume 3, s. 288–291. IEEE, 1997.
- [121] RSES: Rough set exploration system. [http://alfa.mimuw.edu.pl/~\sim\\$rses/](http://alfa.mimuw.edu.pl/~\sim$rses/).
- [122] Rudowski G.: *Termowizja i jej zastosowanie*. Wydawnictwo Komunikacji i Łączności, 1978.
- [123] Russ J. C.: *The Image Processing Handbook*. CRC Press, 2006.
- [124] Ruta D., Gabrys B.: Classifier selection for majority voting. *Information fusion*, nr 6, 2005, s. 63–81.
- [125] Rząsa M. R., Kiczma B.: *Elektryczne i elektroniczne czujniki temperatury*. Wydawnictwo Komunikacji i Łączności, Warszawa 2005.
- [126] Schürman J.: *Pattern classification*. John Wiley & Sons, 1996.
- [127] Seipel S., Forsberg A. K., Wesslén D.: Enhanced visualizations of thermographic data in process industry. *EUROVIS–Eurographics /IEEE VGTC Symposium on Visualization*, 2006.
- [128] Skowron A., Rauszer C.: The discernibility matrices and functions in information systems. [in:] Słowinski R. (eds.): *Intelligent Decision Support: Handbook of Applications and Advances of Rough Sets Theory*. Kluwer Academic Publisher, Dordrecht 1992, s. 331–362.
- [129] Smets P., Kennes R.: The transferable belief model. *Artificial intelligence*, nr 66, 1994, s. 191–234.
- [130] Snell J.: Improving the results of thermographic electrical inspections. *ASNT Fall Conf. Record*, 1996.
- [131] Snell R.: Problems commonly encountered in quantitative thermographic electrical inspections. *Proceedings of QIRT Conference*, 1994.
- [132] Stąpor K.: *Automatyczna klasyfikacja obiektów*. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2005.
- [133] Strzelecki M., Materka A.: European project Cost B11 – Quantitation of Magnetic Resonance Image Texture. *Zeszyty Naukowe Instytutu Elektroniki Politechniki Łódzkiej – Elektronika*, nr 4, 1999, s. 115–124.
- [134] Szargut J.: *Termodynamika*. Wydaw. Naukowe PWN, 2000.

- [135] Szopa A., Bober J., Patschek K.: Zastosowania termowizji w energetyce. *Energetyka*, nr 9 (555), 2000, s. 130–136.
- [136] Tadeusiewicz R., Korohoda P.: Komputerowa analiza i przetwarzanie obrazów. Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków 1997.
- [137] Thomas R. A.: The thermography monitoring handbook. Machine & systems condition monitoring series. Coxmoor Pub., Oxford, UK, 1999.
- [138] Timofiejczuk A.: Metodyka wnioskowania z uwzględnieniem kontekstu w diagnostyce maszyn. Wydawnictwo Politechniki Śląskiej, Gliwice 2012.
- [139] Toet A.: Image fusion by a ration of low-pass pyramid. *Pattern Recognition Letters*, nr 9, 1989, s. 245–253.
- [140] Toet A., Valeton J., Ruyven L. van: Merging thermal and visual images by a contrast pyramid. *Optical Engineering*, nr 28, 1989, s. 789–792.
- [141] Żółtowski B., Cempel Cz. (red.): Inżynieria diagnostyki maszyn. Instytut Technologi Eksploatacji PIB, 2004.
- [142] Urbanek G.: Zastosowanie algorytmów ewolucyjnych w identyfikacji odwrotnych modeli diagnostycznych. Zeszyt nr 132, Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, 2006.
- [143] Vollmer M., Möllmann K.-P.: Infrared Thermal Imaging: Fundamentals, Research and Applications. Wiley–VCH, 2010.
- [144] Voorbraak F.: On the justification of Dempster’s rule of combination. *Artificial Intelligence*, nr 48, 1991, s. 171–197.
- [145] Więcek B., Jakubowska T., Wysocki M., Peszyński-Drews C., Ring E., Ammer K., Jung A., Murawski P., Zuber J., Zwolenik S., Plassmann P., Jones C., Jones B., Strzelecki M.: Przetwarzanie obrazów termograficznych w zastosowaniach medycznych. *Zeszyty Naukowe Instytutu Elektroniki Politechniki Łódzkiej – Elektronika*, nr 9, 2005.
- [146] Więcek B., May G. D.: Termowizja w podczerwieni. Podstawy i zastosowania. Wydawnictwo PAK, 2011.
- [147] Świdarski W., Vavilov V.: Przetwarzanie termogramów oraz obróbka danych w badaniach nieniszczących metodami termografii w podczerwieni. *Biuletyn naukowy Problemy Techniki Uzbrojenia*, nr 111, 2009, s. 57–82.
- [148] Widodo A., Satrijo D., Prahasto T., Lim G.-M., Choi B.-K.: Confirmation of thermal images and vibration signals for intelligent machine fault diagnostics. *International Journal of Rotating Machinery*, nr 2012, 2012, s. 1–10.
- [149] Wiśniewski T. S.: Diagnostyka termowizyjna w energetyce, ciepłownictwie i budownictwie. *Ciepłownictwo, Ogrzewnictwo, Wentylacja*, nr 10, 2009, s. 36–40.
- [150] Wittchen W.: Wykorzystanie techniki termowizyjnej w hutnictwie żelaza i stali. *Prace Instytutu Metalurgii Żelaza*, nr 1(62), 2010, s. 250–254.
- [151] Wróbel A.: Termowizyjna kontrola budynków mieszkalnych. *Pomiary Automatyka Kontrola*, nr 3, 2006, s. 23–27.
- [152] Wróbel Z., Koprowski R.: Praktyka przetwarzania obrazów w programie Matlab. Akademicka Oficyna Wydawnicza EXIT, 2004.
- [153] Xu L., Krzyzak A., Suen C.: Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, Man and Cybernetics*, nr 22, May/June 1992, s. 418–435.
- [154] Yang B., Kim K.: Application of Dempster-Shafer theory in fault diagnosis of induction motors using vibration and current signals. *Mechanical Systems and Signal Processing*, nr 20, 2006, s. 403–420.
- [155] Yang J., Honavar V.: Feature subset selection using a genetic algorithm. *Intelligent Systems and their Applications, IEEE*, nr 13, Mar/Apr 1998, s. 44–49.

- [156] Yang Y., Han C., Kang X., Han D.: An overview on pixel-level image fusion in remote sensing. IEEE International Conference on Automation and Logistics, 2007.
- [157] Younus A. M., Widodo A., Yang B.-S.: Evaluation of thermography image data for machine fault diagnosis. *Nondestructive Testing and Evaluation*, nr 25, September 2010, s. 231–247.
- [158] Younus A. M., Yang B.-S.: Intelligent fault diagnosis of rotating machinery using infrared thermal image. *Expert Systems with Applications*, nr 39, 2012, s. 2082–2091.
- [159] Zadeh L.: On the validity of Dempster's rule of combination of evidence. *Memo M*, nr 79, 1979, s. 24.
- [160] Zieliński T. P.: *Cyfrowe przetwarzanie sygnałów: od teorii do zastosowań*. Wydawnictwo Komunikacji i Łączności, 2005.
- [161] Ziopaja K., Różański L., Trafarski A.: Detekcja uszkodzeń przy zastosowaniu aktywnej termografii w podczerwieni i dwuwymiarowej dyskretnej transformacji falkowej. VII Krajowa Konferencja: Termografia i termometria w podczerwieni, Ustroń–Jaszowiec, 2006.
- [162] Zitova B., Flusser J.: Image registration methods: a survey. *Image and vision computing*, nr 21, 2003, s. 977–1000.
- [163] Zuva T., Olugbara O., Ojo S., Ngwira S.: Image segmentation, available techniques, developments and open issues. *Canadian Journal on Image Processing and Computer Vision*, nr 2(3), 2011, s. 20–29.

Metodyka termograficznej diagnostyki obiektów technicznych

(Streszczenie)

Głównym zagadnieniem poruszonym w pracy jest diagnostyka termograficzna obiektów technicznych i procesów przemysłowych wsparta nowoczesnymi metodami przetwarzania, analizy i rozpoznawania obrazów. W pierwszej części pracy w syntetyczny sposób przedstawiono zagadnienia dotyczące termografii w podczerwieni i metody przetwarzania, analizy oraz rozpoznawania obrazów. W dalszej części pracy usystematyzowano i sformułowano ogólne reguły postępowania niezbędne do przygotowania i prowadzenia termograficznych badań diagnostycznych obiektów technicznych i procesów przemysłowych. Główną część pracy stanowi opis opracowanej metodyki termograficznego monitorowania i diagnozowania obiektów technicznych i procesów przemysłowych oraz przykłady jej zastosowania. Zaproponowana metodyka zakłada, że diagnozowanie może być prowadzone na podstawie wyników analizy sygnałów diagnostycznych powstałych w efekcie przetwarzania i analizy obrazów termograficznych. W metodyce wykorzystano koncepcję podziału czasu zegarowego na czas „mikro” i czas „makro”, co pozwala na scharakteryzowanie szybkich i wolnych zmian stanu obiektu w czasie eksploatacji. Ponadto sformułowano wielowariantowy algorytm pozwalający na dobór odpowiedniej kombinacji metod przetwarzania, analizy i rozpoznawania obrazów termograficznych i sygnałów diagnostycznych. Metodyka uwzględnia możliwość jej zastosowania w układach ciągłego monitorowania i diagnostyki poprzez zaproponowanie czterech różnych strategii obserwacji termograficznych diagnozowanych obiektów. Sformułowane strategie pozwoliły na opracowanie szczegółowej koncepcji systemu termograficznego monitorowania, i diagnostyki obiektów technicznych i procesów przemysłowych. Zaproponowaną metodykę zweryfikowano wykorzystując dane zarejestrowane w trakcie czynnych eksperymentów diagnostycznych przeprowadzonych w warunkach laboratoryjnych jak również w trakcie biernego eksperymentu diagnostycznego przeprowadzonego w warunkach przemysłowych. Obserwacji termograficznej poddano laboratoryjny model maszyny wirnikowej, proces spawania oraz turbozespół energetyczny. Dane generowane w trakcie eksperymentów pozyskiwano za pomocą samodzielnie wykonanego systemu termograficznego monitorowania i diagnostyki obiektów. W pracy przedstawiono różne scenariusze stosowania zaproponowanej metodyki diagnozowania. Na potrzeby analizy obrazów termograficznych wykorzystywano metody statystyczne, metody oceny cech geometrycznych oraz samodzielnie opracowane metody polegające m.in. na analizie profili temperaturowych. Analizie poddano również reprezentacje obrazów termograficznych powstałe po zastosowaniu transformaty Fouriera, transformaty falkowej oraz analizy składowych głównych (PCA). Cechy obrazów będące efektem analizy termogramów poddawano procesowi ekstrakcji i selekcji w celu utworzenia zbioru cech relewantnych. Na podstawie wektorów cech relewantnych przeprowadzono rozpoznawanie stanu technicznego obiektów z zastosowaniem klasyfikatorów bazujących na sztucznych sieciach neuronowych i metodach odległościowych. W badaniach wykorzystano również metody fuzji obrazów i fuzji klasyfikatorów, które w znaczący sposób zwiększyły skuteczność prawidłowej identyfikacji słabo rozpoznawalnych stanów technicznych. Z wyników przeprowadzonych badań weryfikacyjnych wynika, że zaproponowana metodyka umożliwia skuteczne diagnozowanie stanu obiektów technicznych i procesów przemysłowych. Wszystkie scenariusze stosowania powyższej metodyki pozwoliły uzyskać bardzo wysoką skuteczność rozpoznawania badanych stanów technicznych. Należy dodać, że niektóre z rozpatrywanych stanów były trudne w identyfikacji. Badania wykazały również, że możliwe jest określenie relacji diagnostycznych między cechami stanu a cechami sygnałów diagnostycznych powstałych w wyniku analizy termogramów. Zastosowane w trakcie badań metody selekcji cech oraz fuzji danych pozwoliły ograniczyć redundancję informacyjną i podnieść skuteczność diagnozowania. Ponadto wykazano wyjątkową zaletę zaproponowanej metodyki, polegającą na możliwości termograficznego monitorowania i diagnozowania jednocześnie wielu obiektów będących w polu widzenia urządzenia obrazującego w podczerwieni.

Słowa kluczowe: diagnostyka techniczna, termografia, termowizja, przetwarzanie, analiza, rozpoznawanie, obrazy, sygnały, wzorce, klasyfikacja, stan techniczny.

Methodology of thermographical diagnostics of technical objects

(Abstract)

The main problem considered in this work is thermographical diagnostics of technical objects and industrial processes supported by modern methods of image processing, analysis and recognition. In the first part of the work, fundamentals of infrared thermography, image processing, analysis and pattern recognitions problems have been briefly presented. In the further part of the work general rules necessary for preparation and performing thermographical investigations of technical objects and industrial process have been systematised and formed. The main part of the work is description of the developed methodology of continuous thermographical monitoring and diagnosing of technical objects and industrial processes and examples of its application. The proposed methodology assumes that diagnosing could be conducted on the basis of the results of diagnostic signals analysis created as the result of infrared images processing and analysis. The methodology uses the idea of 'micro' and 'macro' time zones which allows characterising fast and slow changes of object conditions in time of its operation. Additionally, a multi-variant algorithm of selection of appropriate combination of methods of infrared images and diagnostic signals processing has also been proposed. The methodology takes into account possibilities of its application in the systems of continuous monitoring and diagnosing by proposing four different strategies of thermographical observations of diagnosing objects. The formulated strategies allowed developing a detailed conception of thermographical system of monitoring and diagnosing of technical objects and industrial processes. The proposed methodology has been verified using the data acquired during active diagnostic experiments, conducted in laboratory conditions as well as during passive diagnostic experiment performed in industrial conditions. Laboratory model of rotating machinery, welding process and a power energy turbine-generator have undergone termographic observation. The data generated during the experiments has been acquired using self-prepared prototype version of thermographical monitoring and diagnosing system. Different scenarios of application of proposed diagnostic methodology have been presented in the manuscript. For the purposes of the analysis of infrared images statistical, geometrical and originally developed profile methods have been applied. Transformed versions of infrared images have also been analysed. In this case Fourier, wavelet and PCA transformations have been considered. The operations of feature extraction and selection have been performed to the features being the result of infrared images analysis in order to create a relevant feature set. On the basis of vectors of relevant features object conditions have been recognised using classifiers, based on neural networks as well as distance measure methods. The methods of image fusion and classifier fusion have also been used during the research, which in a significant way increased the performance of identification of weakly recognisable conditions of diagnosing objects. From the results of the conducted research it follows that the proposed methodology allows diagnosing of objects and process conditions effectively. All of the considered scenarios of application of the proposed methodology enabled to obtain very high performance of identification of investigated object conditions. It is worth saying that some of the considered states have been weakly recognisable. The conducted research also has proved that it is possible to determine diagnostic relations between features of object conditions and diagnostic signals features obtained on the basis of infrared images analysis. The methods of features selection and data fusion applied during the research allowed to limit data redundancy and increase diagnosing performance. Moreover, it has been shown that the results of the research have a very unique advantage of the proposed methodology, namely, the possibilities of simultaneous monitoring and diagnosing of a few objects being in the field of view of infrared imaging device.

Keywords: technical diagnostics; infrared thermography; processing, analysis, recognition; image; signal; pattern; classification; object condition.