

5. Aplikacja metod sztucznej inteligencji do wspomagania oceny stanu uszkodzenia stali pracujących w warunkach pełzania

Dążenie do potwierdzenia tezy niniejszej monografii, dotyczącej obiektywizacji oceny trwałości materiału pracującego w warunkach pełzania z wykorzystaniem zespołu materiałoznawczych metod i technik badawczych, w tym badań metalograficznych i badań własności mechanicznych, skłoniła autora do poszukiwań możliwości wykorzystania dostępnych metod obliczeniowych do poprawy skuteczności dokonywanych analiz i ocen. Dla prognozowania trwałości resztkowej elementów instalacji energetycznych i opracowania autorskiej metodologii rozwiązania tego problemu, autor podjął współpracę z Zakładem Technologii Procesów Materiałowych, Zarządzania i Technik Komputerowych w Materiałoznawstwie Politechniki Śląskiej w Gliwicach, który od wielu lat jako jeden z licznych ośrodków badawczych wykorzystuje metody sztucznej inteligencji w obszarze inżynierii materiałowej i komputerowej nauki o materiałach, będącej jedną z jej specjalności [491-505]. Sztuczne sieci neuronowe są bowiem efektywnym i uniwersalnym narzędziem [491], stosowanym między innymi do selekcji materiałów inżynierskich [505-509], optymalizacji procesu produkcyjnego i technologicznego zapewniającego pożądany zestaw ich własności [510-522], predykcji tych własności [523-534], oraz do oceny stopnia uszkodzenia materiałów w wyniku eksploatacji [535-538]. Efektem wymienionych prac własnych, wykonanych głównie we współpracy z M. Sroką [60-77], jest opracowanie metodyki zautomatyzowanej komputerowej klasyfikacji stanu wewnętrznych uszkodzeń w materiałach elementów ciśnieniowych instalacji energetycznych pracujących w warunkach pełzania, umożliwiającej zobiektywizowanie, przyspieszenie i poprawę skuteczności prognozowania trwałości resztkowej tych elementów. Źródłem informacji o strukturze materiału i procesach w nim zachodzących są zarejestrowane obrazy struktur metalograficznych w formie elektronicznej, które zapisano w formacie map bitowych o 256 odcieniach szarości, uzyskiwane metodami mikroskopii świetlnej, elektronowej mikroskopii transmisyjnej, a zwłaszcza skaningowej, przekształcone do jednolitego formatu i rozmiaru. Obecność uszkodzeń wewnętrznych w strukturze stali oraz stopień zaawansowania ich rozwoju określa przydatność materiału do dalszej eksploatacji oraz umożliwia wyznaczanie trwałości resztkowej, określającej czas dalszej bezpiecznej eksploatacji elementów instalacji energetycznych. Opracowana metodyka automatycznej klasyfikacji stanu uszkodzeń wewnętrznych w niskostopowych stalach pracujących w warunkach pełzania, z użyciem metod sztucznej

inteligencji i komputerowej analizy obrazu oraz następnej predykcji na tej podstawie czasu dalszej bezpiecznej eksploatacji elementów instalacji energetycznych, zapewnia powtarzalność podejmowanych decyzji, w odróżnieniu od tradycyjnej, lecz z konieczności subiektywnej klasyfikacji tych uszkodzeń przez ekspertów, różniących się zwykle pomimo bardzo dobrej znajomości zagadnienia oraz ich wysokich, lecz zróżnicowanych kwalifikacji i doświadczeń. Sztuczne sieci neuronowe, jako wykorzystane narzędzia sztucznej inteligencji, wykazują przy tym przewagę nad metodami statystycznymi. Podstawą wytkniętego celu były zgromadzone wyniki badań własnych materiałów po długotrwałej eksploatacji w warunkach pełzania, opisanych m.in. w poprzednich rozdziałach niniejszej pracy, a wynikiem jest opracowanie programu komputerowego do klasyfikacji stopnia uszkodzeń wewnętrznych w materiałach eksploatowanych w warunkach pełzania, z wykorzystaniem metod analizy obrazu dla wyodrębnienia obrazu tych uszkodzeń, zidentyfikowanych przy użyciu skaningowego mikroskopu elektronowego. Model klasyfikacji uszkodzeń, uprzednio omówionej w niniejszej pracy i opisanej m.in. w pracach własnych [15, 50, 58, 101], uproszczono do pięciu klas, z których każda odpowiednio charakteryzuje się występowaniem uszkodzeń podanych w tablicy 14. Zarejestrowane obrazy uszkodzeń wewnętrznych w strukturze stali niskostopowych wstępnie ujednolicono pod względem formatu, skali, kontrastu i rozdzielczości, a następnie wykonano kolejno filtrację medianową, binaryzację (przy progu binaryzacji dobranym eksperymentalnie), erozję binarną, indeksację, po czym wyznaczono współczynniki geometryczne i kształtu opisujące uszkodzenia, zestawione w tablicy 15.

Dane uzyskane z obserwacji rzeczywistych uszkodzeń wewnętrznych stanowiły podstawę estymacji przedziałowej w celu oszacowania przedziału, w którym powinny znajdować się

Tablica 14. *Klasyfikacja stopnia uszkodzeń wewnętrznych w materiałach eksploatowanych w warunkach pełzania przyjęta w opracowanym modelu*

Klasa uszkodzeń	Rodzaj uszkodzeń
klasa 0	struktura stanu wyjściowego lub jemu bliska bez widocznych uszkodzeń
klasa A	pojedyncze pustki
klasa B	pustki ukierunkowane, łańcuszki pustek, łączenie pustek, szczeliny międzykrystaliczne
klasa C	mikropęknięcia
klasa D	makropęknięcia

wartości współczynników geometrycznych opisujących poszczególne uszkodzenia materiału mieszczące się w danej klasie, umożliwiające określenie elementów na obrazie, które stanowią uszkodzenia wewnętrzne materiału. Zakładając że wartości współczynników geometrycznych mają rozkład normalny, szacowanie oparto na przedziałach ufności dla wartości średnich poszczególnych współczynników przy użyciu zależności:

$$P\left\{\bar{x} - t_{\alpha} \frac{s}{\sqrt{n}} < \mu < \bar{x} + t_{\alpha} \frac{s}{\sqrt{n}}\right\} = 1 - \alpha \quad (7)$$

gdzie:

$$\bar{x} = \frac{1}{n} \cdot \sum_{i=1}^n x_i$$

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

1 - α – prawdopodobieństwo przyjęte z góry i nazywane współczynnikiem ufności (w zastosowanym modelu przyjęto wartość 1 - $\alpha \geq 0,95$),

Tablica 15. Wyznaczone współczynniki geometryczne i kształtu opisujące uszkodzenia wewnętrzne w strukturze stali po długotrwałej eksploatacji w warunkach pełzania

Oznaczenie	Współczynniki geometryczne i kształtu	Współczynniki geometryczne i kształtu, dla których algorytm genetyczny popelnia najmniejszy błąd
Po	pole	średnie pole
Ob	obwód	średni obwód
Wk	współczynnik kolistości	–
Wm	współczynnik Malinowskiej	średni współczynnik Malinowskiej
Wc1	współczynnik cyrkularności1	średni współczynnik cyrkularności1
Wc2	współczynnik cyrkularności2	średni współczynnik cyrkularności2
MinOdl	minimalna odległość	minimalna odległość
SFpoz	średnica Fereta pozioma	średnica Fereta pozioma
SFpion	średnica Fereta pionowa	średnica Fereta pionowa
Wz	współczynnik zawartości	współczynnik zawartości
MaxOdl	maksymalna odległość	–
Wbb	współczynnik Blaira-Blissa,	–
Wf	współczynnik Fereta	–
Wh	współczynnik Haralicka	–
Ws	współczynnik bezwymiarowy	współczynnik bezwymiarowy

t_α – wartość zmiennej t Studenta z tablic rozkładu Studenta dla $n - 1$ stopni swobody,

$\bar{x}$ – średnia arytmetyczna z próby,

s – odchylenie standardowe obliczone dla poszczególnych współczynników geometrycznych na podstawie uszkodzeń zidentyfikowanych w obrazach.


Wyznaczone współczynniki geometryczne poszczególnych uszkodzeń są wektorami wejściowymi sztucznych sieci neuronowych opracowanych przy użyciu programu Statistica Neural Networks 4.0 F, w których klasy uszkodzeń wewnętrznych w strukturze stali są pięcioma wektorami wyjściowymi. Zbiór danych wejściowych składający się z obliczonych współczynników geometrycznych dla wytypowanych przypadków doświadczalnych podzielono w sposób losowy na trzy podzbiory: uczący (50% wektorów) dla ustalenia wartości wag podczas uczenia sieci, walidacyjny (25% wektorów) do oceny jakości sieci podczas uczenia, testowy (25% wektorów) do oceny jakości modelu po zakończeniu uczenia sieci, w ten sposób, aby do każdego zbioru wektorów zaklasyfikowano przypadki uszkodzenia charakterystyczne dla każdej z klas. W celu opracowania sztucznej sieci neuronowej dobrano typ sieci, liczby warstw ukrytych i neuronów w poszczególnych warstwach, rodzaje i postaci funkcji aktywacji, metody skalowania zmiennych oraz metody i parametry uczenia sztucznej sieci neuronowej. Analizowano ok. 40 sztucznych sieci neuronowych spośród następujących typów: perceptron wielowarstwowy (MLP – multilayer perceptron), probabilistyczne sieci neuronowe (PNN – probabilistic Neural Network), sieci o radialnych funkcjach bazowych (RBF – Radial Neural Network), sieci liniowe (Linear Network). Podstawą oceny jakości sztucznych sieci neuronowych jest udział poprawnych klasyfikacji uszkodzeń dla danej klasy uszkodzeń wewnętrznych w strukturze stali, a zwiększeniu udziału poprawnych klasyfikacji uszkodzeń przez polepszenie jakości ich działania służą algorytmy genetyczne oraz nieparametryczne testy istotności. Do optymalizacji wykorzystano maski określające, które ze współczynników geometrycznych powinny zostać wykorzystane na wejściu sieci. Algorytmy genetyczne dokonują wyboru najlepszych wektorów wejściowych sztucznej sieci neuronowej w oparciu o populację osobników potomnych, które wykorzystują podstawowe cechy swoich rodziców oraz modyfikują własności. Podstawą dokonanej optymalizacji jakości klasyfikacji wektora zmiennych niezależnych jest krzyżowanie porządkowe, w wyniku którego powstają dwa osobniki potomne charakteryzujące się kombinacją cech rodziców oraz mutacja zapewniająca zmianę pojedynczych osobników potomnych. Selekcja kolejnych osobników, będąca podstawą dalszego rozmnażania,

dotyczy tych, które najlepiej klasyfikują uszkodzenia materiału, popełniając najmniejszy błąd. Trenowanie sieci oparte jest na wzorcach uczących, czyli wektorach wejściowych obejmujących współczynniki geometryczne, podane w tablicy 15, dla których algorytm genetyczny popełnia najmniejszy błąd. Minimalizacja błędu sieci, polegająca na wyszukiwaniu minimum sumy kwadratów pomiędzy wartościami rzeczywistymi a obliczonymi przez sieć, jest podstawą ustalenia wag połączeń synaptycznych neuronów. Optymalny sposób uczenia sieci może być dobierany metodami optymalizacji nieliniowej (Lavenberga-Marquardta), radialnych funkcji bazowych, optymalizacji nieliniowej (quasi-Newtona), wstecznej propagacji błędów lub gradientów sprzężonych, co jest podstawą określenia liczby neuronów w warstwie ukrytej sieci.

W tablicy 16 podano parametry sztucznej sieci neuronowej opracowanej na podstawie nieparametrycznych testów istotności, przedziałów ufności i algorytmów genetycznych, której schemat podano na rysunku 127. Sieć neuronowa składa się z 10 wektorów wejściowych zawierających obliczone współczynniki geometryczne dla wytypowanych przypadków doświadczalnych. W tablicy 17 przedstawiono wartości błędu oraz jakości opracowanej sieci neuronowej, natomiast na rysunku 128 porównano poprawne i błędne klasyfikacje w poszczególnych klasach, co pozwala stwierdzić, że opracowana sieć neuronowa umożliwia średnią poprawną klasyfikację uszkodzeń wewnętrznych w strukturze stali niskostopowych po eksploatacji w warunkach pełzania na poziomie 93%, a największy błąd klasyfikacji 8,33% występuje w przypadku klasy B.

Tablica 16. *Charakterystyka sztucznej sieci neuronowej zastosowanej do wstępnej klasyfikacji uszkodzeń*


Parametry sieci	Charakterystyka
Struktura sieci	MLP 10-31-5
Współczynniki geometryczne zastosowane do nauki sieci	pole, obwód, współczynnik Malinowskiej, współczynnik cyrkularności ¹ , współczynnik cyrkularności ² , minimalna odległość, średnica Fereta pozioma, średnica Fereta pionowa, współczynnik zawartości, współczynnik bezwymiarowy
Metoda uczenia	propagacja wsteczna błędów, gradienty sprzężone
Liczba epok treningowych	466



Rysunek 127. Schemat opracowanej sztucznej sieci neuronowej


Tablica 17. Zestawienie wartości błędu oraz jakości opracowanej sztucznej sieci neuronowej

Błąd uczenia	0,01252	Jakość uczenia	0,976
Błąd walidacji	0,02563	Jakość walidacji	0,965
Błąd testu	0,02886	Jakość testu	0,981



Rysunek 128. Wykres poprawnych i błędnych klasyfikacji w poszczególnych klasach dla opracowanej sieci neuronowej [515]


W wyniku wszystkich podjętych działań opracowano program komputerowy do klasyfikacji stopnia uszkodzeń wewnętrznych, którego schemat blokowy przedstawiono na rysunku 129. Opracowany model komputerowo wspomaganey automatycznej klasyfikacji




Rysunek 129. Schemat blokowy opracowanego programu komputerowego

uszkodzeń wewnętrznych w stalach pracujących w warunkach pełzania przy zastosowaniu sztucznych sieci neuronowych, algorytmów genetycznych i analizy obrazów zweryfikowano doświadczalnie na podstawie wyników badań rzeczywistych uszkodzeń zidentyfikowanych w elementach kotłów parowych, węzownic i rurociągów, które nie zostały użyte do opracowania metodyki automatycznej klasyfikacji uszkodzeń.

Oryginalny obraz z uszkodzeniem wewnętrznym struktury, wczytany w oknie programu komputerowego do klasyfikacji stopnia uszkodzeń wewnętrznych, przedstawiono na rysunku 130. Na rysunku 131 przedstawiono przykłady klasyfikacji uszkodzeń za pomocą opracowanego programu. W wyniku porównania przykładowo wyznaczonej klasy uszkodzenia wewnętrznego w stalach ze znormalizowaną klasą uszkodzenia na 35 przypadków stwierdzono, że jedynie w 2 przypadkach automatycznie zidentyfikowana klasa jest wyższą niż ustalona przez eksperta. Rozbieżności pomiędzy klasyfikacją niektórych przypadków uszkodzeń wewnętrznych w strukturze stali, mogą wynikać z niewystarczającej jakości obrazów wyjściowych, co może prowadzić do błędnej analizy obrazu przez program komputerowy.



Rysunek 130. Oryginalny obraz wejściowy [538]



Rysunek 131. Wynik pomiarów cech obiektów wraz z wektorami cech stanowiących wejście sieci neuronowej i wynikiem klasyfikacji – klasa B [538]

Wyniki weryfikacji wskazują jednak na poprawne opracowanie metodyki oceny stopnia uszkodzenia wewnętrznego stali pracujących w warunkach pełzania. Pomimo że opracowany program komputerowy wymaga stałego doskonalenia, już obecnie może być jednak z powodzeniem stosowany do wspomagania podejmowania decyzji diagnostycznych, jako przykład aplikacji metod komputerowej nauki o materiałach.