



## Metoda wspomagania komputerowego w badaniach diagnostycznych łopatek turbin gazowych

MARIUSZ BOGDAN<sup>1</sup>, JÓZEF BŁACHNIO<sup>2</sup>

<sup>1</sup>Politechnika Białostocka, Wydział Mechaniczny, Katedra Automatyki i Robotyki,  
15-351 Białystok, ul. Wiejska 45c

<sup>2</sup>Instytut Techniczny Wojsk Lotniczych,  
01-494 Warszawa, ul. Księcia Bolesława 6

**Streszczenie.** W artykule przedstawiono metodę wspomagania komputerowego do diagnozowania łopatek turbiny gazowej z wykorzystaniem sztucznych sieci neuronowych. Głównym celem prezentacji jest opracowana sieć neuronowa, za pomocą której na podstawie cech obrazów powierzchni łopatek dokonuje się orzekania o ich stanie (element zdatny, element częściowo zdatny, element niezdatny). Opierając się na wnioskach sformułowanych na podstawie badań mikrostruktury, dotyczących oceny stopnia przegrzania (łopatki zdadne i niezdatne do dalszej eksploatacji), przyjęto jako wzorce obrazy powierzchni reprezentujące łopatki w różnych stanach (neuronowa klasyfikacja wzorcowa). Dodatkowo, wiążąc oraz segregując (wg ich przydatności w procesie uczenia sieci) parametry obrazów, uzyskane zarówno z histogramów jak i macierzy zdarzeń, zautomatyzowano i zwiększono wiarygodność (wspomaganie komputerowe) procesu decyzyjnego.

Zastosowanie sztucznej sieci neuronowej umożliwia w większym stopniu odwzorowanie złożonych zależności pomiędzy obrazem łopatki a jej stanem, niż to realizuje diagnosta dotychczasową metodą subiektywną.


**Słowa kluczowe:** łopatki eksploatowane turbiny gazowej, ocena stanu, sztuczne sieci neuronowe

### 1. Wstęp

W procesie eksploatacji turbin gazowych występują uszkodzenia ich elementów i są to uszkodzenia mające różną postać i intensywność. Najtrudniejsze do identyfikacji rodzaju uszkodzenia i klasyfikacji stanu jest przegrzanie materiału łopatek, zwłaszcza niechłodzonych. W diagnostyce stanu łopatek w niektórych

przypadkach oprócz ostrej klasyfikacji „element zdalny–element niezdatny” stosuje się trzecią ocenę stanu „element częściowo zdalny”. Dotyczy to m.in. turbin gazowych zainstalowanych np. w lotniczych silnikach turboodrzutowych. Zatem w obiektach kosztownych, w których relacja: trwałość–koszt eksploatacji powinna być maksymalnie korzystna. W związku z tym w przypadkach, gdy ze względu na stopień przegrzania, rozumiany jako intensywność zmiany barwy, oraz wielkość i położenie obszaru na piórze łopatki, subiektywnie uznanego przez diagnostę, stosuje się trójstopniową ocenę stanu. Jeśli uzna się, że stopień przegrzania łopatki klasyfikuje się do oceny „element częściowo zdalny”, to okresowo diagnozuje się łopatkę aż do osiągnięcia stanu niezdatności. W wyniku tego przedłuża się okres wykorzystania turbiny — żywotność po uszkodzeniu łopatki (kosztownego silnika lotniczego) oraz zmniejsza się koszty jej eksploatacji. Naturalnie w tym przypadku nie można obniżyć poziomu bezpieczeństwa lotów samolotu, w którym wbudowany jest silnik z diagnozowaną turbiną.

Dobór materiału do wytworzenia łopatki turbiny gazowej o wymaganej trwałości musi uwzględniać widmo wymuszeń w strefie działania maksymalnej temperatury spalin. Częstą przyczyną uszkodzeń turbiny gazowej jest przegrzanie materiału, a także zmęczenie cieplne łopatek aparatu dyszowego oraz wirnika, spowodowane zarówno nadmierną temperaturą jak i czasem jej trwania, a także aktywnością chemiczną spalin (rys. 1).



Rys. 1. Turbina gazowa z widocznymi zmianami barwy na powierzchniach łopatek (łopatki w różnym stopniu przegrzania) [2, 3]

W całym okresie procesu eksploatacji obserwuje się zmianę barwy powierzchni piór łopatek. Zmiany barwy, przedstawione na rysunku 1, są wynikiem różnego stopnia przegrzania materiału. Uszkodzenie wynika z przegrzania materiału łopatek prowadzi do wadliwej pracy turbiny gazowej, a niekiedy, jak w przypadku turboodrzutowych silników lotniczych, do tragicznego w skutkach wypadku. Tego typu uszkodzenie usuwa się zawsze przez naprawę główną silnika, co skutkuje ogromnymi kosztami, w lotnictwie około 0,5-1 mln USD — w zależności od typu silnika. Zatem koszty naprawy głównej silnika są od 1000-3000 razy wyższe w porównaniu z wartością

np. łopatki wirnika turbiny. Obecnie decyzję o konieczności naprawy silnika podejmuje diagnosta, który, posługując się metodą wizualną z użyciem wideoskopu, może diagnozować stan elementów trudno dostępnych turbiny. Oceny stanu dokonuje się na podstawie zarejestrowanego obrazu powierzchni diagnozowanego elementu i porównania tego obrazu z wzorcowymi obrazami powierzchni zdalnych i niezdatnych analogicznych elementów łopatek turbiny. Takie kryteria oceny stanu są bardzo nieprecyzyjne. Wzrok diagnosty obarcza bowiem badanie diagnostyczne łopatek (organoleptyczny sposób oceny stanu) elementem subiektywizmu. Ponadto barwa jest zjawiskiem fizykopsychologicznym. Przez to ocena stanu łopatek dokonywana przez diagnostę może być obciążona dużym błędem. Nie opracowano dotychczas obiektywnej i w pełni wiarygodnej metody wykrywania stopnia przegrzania materiału łopatek turbiny w sposób nieniszczący.


Wykorzystanie techniki cyfrowej rejestracji obrazu, połączonej z komputerową analizą oraz komputerowym wspomaganie decyzji (sieci neuronowe) przyczyni się do zwiększenia obiektywizmu i wiarygodności diagnozowania tego elementu turbiny. W ujęciu możliwości diagnozowania stanu łopatek na podstawie obrazu ich powierzchni łopatek, tj. na podstawie parametrów wyznaczonych: z histogramu (informacja o jasności) oraz macierzy zdarzeń (informacja o teksturze — powtarzalności wzorów na powierzchni łopatek) można różne stany techniczne łopatek skorelować z informacją zawartą w zarejestrowanych obrazach cyfrowych. Powierzchnie łopatek dla określonego stanu technicznego mają zbliżoną barwę i chropowatość (teksturę). Na podstawie parametrów wyznaczonych z histogramu oraz macierzy zdarzeń, przy wykorzystaniu sieci neuronowych (klasyfikacja wzorcowa), możliwe stanie się przypisanie obrazu łopatki (zarejestrowanej powierzchni) do określonej klasy reprezentującej dany stan (zdalny, częściowo zdalny, niezdalny).

## 2. Akwizycja obrazów powierzchni łopatek turbiny gazowej

Jako obiekt badań przyjęto zarówno łopatki nowe (po wygrzewaniu w pięciu wartościach temperatury bliskich temperaturze pracy — stop EI-867 WD — łopatki wirnika turbiny gazowej lotniczego silnika odrzutowego) jak i eksploatowane (stop ŻS-6K — łopatki wieńca kierowniczego turbiny gazowej lotniczego silnika odrzutowego). Akwizycji obrazów dokonano na specjalnie zbudowanym stanowisku laboratoryjnym za pomocą cyfrowego aparatu fotograficznego oraz wideoskopu przemysłowego; zapewniając odpowiednią powtarzalność oraz jakość pozyskiwanych obrazów powierzchni [3]. Następnie przeprowadzono badania metalograficzne mające na celu określenie stanu technicznego badanego elementu turbiny. Pod uwagę wzięto parametry mikrostruktury, tj. zmianę grubości aluminiowej powłoki ochronnej oraz zmianę średniej wielkości wydzieleni fazy  $\gamma'$  (fazy umacniającej stop, która w głównej mierze decyduje o własnościach żarowytrzymałości).

W wyniku oddziaływania wysokich wartości temperatury dochodzi do przemian strukturalnych w superstopach. Modyfikacji mikrostruktury jednocześnie towarzyszy zmiana chropowatości powłoki. Stan powłoki wpływa na odbicie i pochłanianie strumienia świetlnego. Wykorzystuje się zależności pomiędzy właściwościami falowymi światła i fizykochemicznymi badanymi powierzchniami, które to decydują o zależnościach kątowych pomiędzy światłem padającym i odbitym oraz pochłanianiu poszczególnych długości fal widma promieniowania elektromagnetycznego. Dodatkowo na podstawie badań składu chemicznego stwierdzono, że w wyniku oddziaływania wysokich temperatur modyfikacji ulega stężenie wagowe pierwiastków tworzących powłokę.

Dzięki badaniom metalograficznym możliwe stało się usystematyzowanie łopatek wg stanów technicznych. Na rysunku 2 pokazano przykład przyjętej klasyfikacji łopatek w różnym stanie technicznym (kryterium materiałowe).



Rys. 2. Akwizycja obrazów powierzchni łopatek: a) wygrzewanych — za pomocą aparatu fotograficznego; b) eksploatowanych — za pomocą wideoskopy

### 3. Sieci neuronowe


Oceny wartości błędu klasyfikowania (lub trafności klasyfikowania) przeprowadza się, opierając się na symulacji zbioru danych testowych na już wytrenowanej sieci. Ponadto dla zbioru danych testowych znana już jest rzeczywista klasyfikacja. Pozwala to porównać decyzję podjętą przez zamodelowaną sieć z rzeczywistą klasyfikacją i stwierdzić czy, i w jakim stopniu, sieć neuronowa trafnie przewiduje przynależność do określonej klasy (grupy). Łączny błąd klasyfikowania (ang. *overall error rate*) definiuje się jako stosunek:

$$\varepsilon_{ov} = \frac{n_{bl}}{n_{test}}, \quad (1)$$

gdzie:  $n_{bl}$  — liczba błędnie sklasyfikowanych danych testowych,  $n_{test}$  — całkowita liczba danych testowych. Miara trafności klasyfikowana (dokładność, sprawność) określona jest jako uzupełnienie do jedynki łącznego błędu klasyfikacyjnego:

$$\eta_{ov} = 1 - \varepsilon_{ov} = 1 - \frac{n_{bl}}{n_{test}} = \frac{n_{popr}}{n_{test}}. \quad (2)$$


Miary te alternatywnie przytacza się w procentach w skali do 100%. Im większa  $\eta_{ov}$  (im mniejsze  $\varepsilon_{ov}$ ), tym skuteczniejsza jest w klasyfikacji „wyuczona” sieć. Obecnie dostępnych jest wiele modeli sieci nadzorowanych, chociaż w rzeczywistości są one wariantami czy odmianami ograniczonej liczby modeli. Wzięto pod uwagę jedynie te, które dały najlepsze rezultaty (sprawdzenie poprawności klasyfikacji na zbiorze danych testowych), tj. perceptron wielowarstwowy (MLP — ang. *Multi-Layer Perceptron*) oraz sieć o radialnych funkcjach bazowych (RBF — ang. *Radial Basis Function*). Przykładowe struktury tych sieci pokazano na rysunku 3, każda z nich składa się z trzech warstw (jedna warstwa wejściowa, ukryta i wyjściowa) o jednakowej liczbie neuronów w każdej z warstw.



Rys. 3. Schemat budowy sieci [5]: a) perceptronu wielowarstwowego; b) sieci o radialnych funkcjach bazowych

W sieci perceptronowej neurony ułożone są tylko pomiędzy kolejnymi warstwami, przy czym przekazywanie sygnałów odbywa się w jednym kierunku od wejścia do wyjścia (sieć jednokierunkowa). Liczba warstw ukrytych może być w zasadzie dowolna, jednak udowodniono, że dwie warstwy są całkowicie wystarczające do dowolnego odwzorowania danych wejściowych w wyjściowe. Uczenie tego typu sieci odbywa się zwykle w trybie z nauczycielem, metodą gradientową pierwszego lub drugiego rzędu, przez minimalizację funkcji błędu. W przypadku perceptronu wielowarstwowego poziom pobudzenia neuronu jest ważoną sumą wejść (plus wartość progowa dodawana jako tzw. bias). Wprowadzenie do neuronu dodatkowego wejścia bias powoduje, że sieć zyskuje większą zdolność (możliwość) uczenia się. Wiąże się to z umożliwianiem przesuwania progów aktywacji

w zależności od wagi biasu. W sieci o radialnych funkcjach bazowych bias jest dołączony jedynie do neuronów w warstwie wyjściowej. Ponadto ten typ sieci stosuje radialne funkcje bazowe, ma zwykle jedną warstwę ukrytą, zawierającą neurony o radialnej funkcji aktywacji. Neurony wyjściowe są zwykle sumą wagową sygnałów pochodzących z neuronów radialnych warstwy ukrytej. Uczenie tego typu sieci polega na doborze wag warstwy wyjściowej oraz parametrów funkcji radialnych Gaussa [1]. Na rysunku 4 pokazano różnice między sieciami w separacji danych wejściowych.



Rys. 4. Separacja danych dla sieci [1]: a) perceptronu wielowarstwowego; b) sieci o radialnych funkcjach bazowych

#### 4. Diagnozowanie stanu łopatek na podstawie klasyfikacji wzorcowej za pomocą sieci neuronowych


Po przetestowaniu co najmniej kilku programów do budowania i modelowania sieci neuronowych wybrano program STATISTICA 8 — Data Miner [1]. Dzięki temu otrzymano lepsze, dokładniejsze i bardziej powtarzalne wyniki. Zastosowany program ma także możliwość łatwej prezentacji graficznej otrzymanych wyników. Celem konstruowanego klasyfikatora neuronowego było opracowanie metody (wspomaganej komputerowo), pozwalającej rozpoznawać stan łopatki na podstawie obrazu (jego cech) jej powierzchni. Rozpatrzono dwa przypadki:

1. Klasyfikacja dwustanowa (łopatki nowe wygrzewane i łopatki eksploatowane):
  - klasa 1: stan zdatny (łopatka nieprzegrzana);
  - klasa 2: stan niezdatny (łopatka przegrzana).
2. Klasyfikacja trójstanowa (łopatki eksploatowane):
  - klasa 1: stan zdatny (łopatka nieprzegrzana);
  - klasa 2: stan częściowo zdatny (łopatka podejrzana o przegrzanie);
  - klasa 3: stan niezdatny (łopatka przegrzana).

Pierwszym etapem było pozyskanie danych, które następnie posłużyły do zamodelowania sieci (dane wejściowe) i do późniejszego jej testowania (badania



zdolności prawidłowej klasyfikacji). W celu redukcji informacji obrazy barwne zamieniono na obrazy monochromatyczne (odcienie szarości, zakres ośmiobitowy 0-255). Następnie wybrano 10 parametrów wejściowych (cech obrazów). Sześć pierwszych parametrów (P1-P6) opisuje histogram, czyli rozkład jasności pikseli dla badanych fragmentów obrazów (rys. 5). Cztery następne parametry (P7-P10) wyznaczono z macierzy zdarzeń (dla odległości równej 1 i kącie  $0^\circ$ ) (tab. 1).



Rys. 5. Przykład pobierania fragmentów obrazów powierzchni łopatek

TABELA 1

Dane wejściowe — wektor cech

Oznaczenie	Wyjaśnienie
P1	wartość maksymalnego nasycenia
P2	wartość średniej jasności
P3	wariacja rozkładu jasności
P4	skośność histogramu
P5	kurtoza histogramu
P6	eksces histogramu
P7	kontrast
P8	korelacja
P9	energia
P10	homogenność

Dzięki badaniom metalograficznym (kryterium materiałowe) stwierdzono, że łopatkę: nowe wygrzewane w temperaturze 1023 K oraz 1123 K mają strukturę prawidłową, gdy te wygrzewane w temperaturze 1323 K oraz 1423 — strukturę przegrzaną. Natomiast w przypadku łopatek eksploatowanych, łopatkę o strukturę prawidłowej to łopatkę ze stanu I i II; łopatkę o strukturę przegrzanej to łopatkę ze stanu IV i V. Dzięki takiemu podziałowi można było przystąpić do modelowania sieci w programie STATISTICA. Etapy modelowania przebiegały w następujących fazach:

1. standaryzacja danych i kodowanie wyjść (klas);
2. podział danych na próbę uczącą i testową (w stosunku 50% do 50%);

3. ustawienie parametrów kreatora sieci neuronowych, takich jak: minimalna i maksymalna liczba warstw ukrytych (dla MLP i RBF), typy funkcji aktywacji zarówno dla neuronów ukrytych jak i wyjściowych (dla MLP), wartość min. i max. redukcji wag dla neuronów ukrytych i dla neuronów wyjściowych (dla MLP).

Sieć została poddana uczeniu na zbiorze danych wejściowych ze względu na małą liczbę obrazów powierzchni, bez bieżącego sprawdzania stopnia uczenia na zbiorze walidacyjnym. W wyniku symulacji, zarówno w trybie uczenia jak i testowania, otrzymano przedstawione w tabeli 2 optymalne modele sieci neuronowych dla przypadku 1 (klasyfikacja dwustanowa łopatek wygrzewanych).

TABELA 2

Modele sieci dla problemu klasyfikacji dwustanowej (diagnozowania) łopatek wygrzewanych

Nrs	Nas	Ju	Jt	Au	Fb	Aku	Aw
1	RBF 10-6-2	88,9	94,4	RBFT	SOS	Gaussa	Liniowa
2	MLP 10-9-2	94,4	88,9	BFGS 24	SOS	Wykładnicza	Wykładnicza
3	MLP 10-7-2	100	88,9	BFGS 25	SOS	Wykładnicza	Logistyczna
4	MLP 10-15-2	94,4	88,9	BFGS 24	SOS	Wykładnicza	Wykładnicza

Objaśnienie skrótów: Nrs — Nr sieci, Nas — Nazwa sieci, Ju — Jakość (uczenie), Jt — Jakość (testowanie), Au — Algorytm uczenia, Fb — Funkcja błędu, Aku — Aktywacja (ukryte), Aw — Aktywacja (wyjściowe)

Pogrubione modele sieci neuronowych (nr = 2, 3, 4) mają stosunkowo dużą jakość (zdolność) uczenia przy zachowaniu wysokiego poziomu jakości testowania 89%. Jednak w dwóch przypadkach łopatek ze stanu niezdatnego uznana została za łopatkę zdatną. Jest to sytuacja niekorzystna z punktu widzenia diagnozowania łopatek turbiny. W celu wyeliminowania tych błędów klasyfikacyjnych przystąpiono do badania przydatności poszczególnych parametrów (P1-P10) na rozróżnialność pomiędzy klasami (stanami). Przeprowadzono test dla dwóch klas (grup) danych, którego celem było porównanie podstawowych statystyk dla 10 zmiennych o liczebności 18 prób w każdej klasie. Zbiór danych uporządkowany był w ten sposób, by każdy przypadek prezentował jedną jednostkę identyfikowaną przez zmienną grupującą (stan). Na podstawie otrzymanych wyników stwierdzono, że parametry P3 i P4 są zbędne, gdyż nie wnoszą pożytecznej informacji do „problemu klasyfikacji”. W tabeli 3 przedstawiono wyniki modelowania sieci neuronowych po redukcji danych wejściowych.

Zdolność odtworzenia zbioru uczącego — miara zdolności zapamiętywania danych uczących wynosi w tym przypadku 100%, natomiast zdolność do generowania właściwych rozwiązań danych należących do zbioru testującego, na których sieć nie była trenowana (miarą zdolności uogólnienia), wynosi 94%.



TABELA 3

Modele sieci po redukcji danych wejściowych dla problemu klasyfikacji (diagnozowania) łopatek wyrzewananych

Nrs	Nas	Ju	Jt	Au	Fb	Aku	Aw
1	MLP 8-10-2	100,0	94,4	BFGS 24	Entropia	Wykładnicza	Softmax
2	MLP 8-11-2	100,0	94,4	BFGS 30	Entropia	Tanh	Softmax

Identyczną metodę postępowania, przy wyznaczaniu modeli sieci neuronowych, zastosowano dla łopatek eksploatowanych. W tabeli 4 przedstawiono wybrane sieci neuronowe dla danych wejściowych pozyskanych z obrazów powierzchni łopatek zarejestrowanych za pomocą wideoskopu amerykańskiego.

TABELA 4

Modele sieci dla problemu klasyfikacji (diagnozowania) łopatek eksploatowanych

Nrs	Nas	Ju	Jt	Au	Fb	Aku	Aw
1	MLP 10-7-2	100,00	100,00	BFGS 23	Entropia	Tanh	Softmax
2	MLP 10-5-2	100,00	100,00	BFGS 21	Entropia	Liniowa	Softmax
3	MLP 10-10-2	100,00	100,00	BFGS 19	SOS	Wykładnicza	Sinus

W przypadku oceny stanu łopatek eksploatowanych przy użyciu klasyfikacji neuronowej uzyskano modele sieci (nr = 1-3), które bezbłędnie uczą się i odwzorowują klasy — trzy modele sieci nie mylą się przy testowaniu.

Podział trójstanowy, z pośrednim stanem zdadności (łopatka podejrzewana o przegrzanie), ma cel praktyczny, gdyż możliwe staje się okresowe dopuszczenie badanego elementu turbiny do dalszej eksploatacji (eksploatacja z „tolerowanym uszkodzeniem”). Po przeprowadzonej symulacji otrzymano wyniki przedstawione w tabeli 5.

TABELA 5

Modele sieci dla problemu klasyfikacji trójstanowej (diagnozowania) łopatek eksploatowanych

Nrs	Nas	Ju	Jt	Au	Fb	Aku	Aw
1	MLP 10-4-3	100,00	83,33	BFGS 47	Entropia	Logistyczna	Softmax
2	MLP 10-7-3	100,00	83,33	BFGS 52	Entropia	Liniowa	Softmax

Dla każdego z opracowanych modeli (nr 1, 2) sieć uczy się bezbłędnie (100%), jednak myli się przy klasyfikacji (tab. 5). Niekorzystne wyniki (rezultaty) klasyfikacji o pojawienie się klasy 3 (stanu przegrzanego) w klasie 1 (sieć nr 2 — MLP 10-7-3), także sytuacja odwrotna, tzn. pojawienie się w klasie 3 klasy 1 (łopatka dobra nie

może być uznana za przegrzaną oraz łopátka przegrzana nie może być uznana za dobrą). Klasa 2 jest stanem pośrednim pomiędzy klasami 1 i 3 (łopátka podejrzewana o przegrzanie). Dlatego klasa 2 może zawierać zarówno klasę 1 jak i 3, a pojawienie się klasy 2 w klasie 3 nie może być traktowane jako błąd punktu widzenia poprawności diagnozowania tego elementu turbiny. Na podstawie otrzymanych wyników wybrano sieć o numerze 1 (tab. 5) (sieć źle klasyfikuje tylko raz, uznając łopatkę ze stanu 5 — klasy 3 — za dobrą; błąd II rodzaju).

## 5. Podsumowanie

Na podstawie otrzymanych wyników stwierdza się, że sieci neuronowe są dobrym narzędziem do oceny stanu łopatek zarówno nowych (po wygrzaniu) jak i eksploatowanych (rys. 5).

Zbudowany neuronowy model klasyfikacyjny (sieć o określonej architekturze) pozwala określać stan łopátki na podstawie cech (parametrów) jej obrazu z zadowalającą wiarygodnością. Dodatkową zaletą tego typu podejścia jest możliwość pełnego zautomatyzowania procesu diagnozowania w warunkach pracy (bez demontażu turbiny), tj. obraz powierzchni badanego elementu turbiny pozyskiwany za pomocą wideoskopu trafia do komputera, w którym za pomocą oprogramowania wydobywane są jego cechy, a na ich podstawie „zamodelowana sieć” (dobrze wytrenowana) trafnie orzeka o stanie technicznym łopátki.

Klasyfikacja trójstanowa rozszerza dodatkowo proces diagnozowania o możliwość dopuszczenia łopátki do dalszej, jednak nadzorowanej, eksploatacji, tj. do okresowej oceny stanu.

*Artykuł wpłynął do redakcji 14.12.2009 r. Zweryfikowaną wersję po recenzji otrzymano w grudniu 2009 r.*

### LITERATURA

- [1] [www.statsoft.pl](http://www.statsoft.pl) — podręcznik elektroniczny Statistica 8.
- [2] J. BŁACHNIO, *The effect of high temperature on the degradation of heat-resistant and high-temperature alloys*, Solid State Phenomena, vol. 147-149, 2009, 744-752.
- [3] M. BOGDAN, *An attempt of evaluation of overheating of gas turbine blades*, Polish Journal of CIMAC — Diagnosis, reliability and safety, 3, 1, Gdańsk, 2008, 25-32.
- [4] K. W. ZIELIŃSKI, M. STRZELECKI, *Komputerowa analiza obrazu biomedycznego*, PWN, Warszawa — Łódź, 2002.
- [5] S. OSOWSKI, *Sieci neuronowe w ujęciu algorytmicznym*, WNT, Warszawa, 1996.

M. BOGDAN, J. BŁACHNIO

### **Computer-aided method of diagnostics of gas turbine blades**

**Abstract.** The article presents a computer-aided method of diagnostics of gas turbine blades with the use of artificial neural networks. The subject of presentation is the developed neural network, with the help of which — on the basis of features of blade surface images — their condition is determined (operable element, partly operable element, inoperable element). Basing on conclusions formulated on the basis of microstructure examinations and concerning evaluation of state of overheating (blades suitable and not suitable for further operation), as patterns assumed were surface images representing blades in various states (neural pattern classification). Additionally, combining and segregating (according to their applicability for the network teaching process) image parameters, acquired from histograms as well as from matrix of events, automated and increased was the credibility (computer aiding) of a decision process. The application of artificial neural network enables better representation of complex relations between blade image and its condition than in the case of subjective methods used currently by diagnosticians.

**Keywords:** operating gas turbine blades, state condition, artificial neural networks

