

Zastosowanie termowizji w badaniach przesiewowych na przykładzie zmian nowotworowych piersi

Application of thermovision in screening examinations on the example of breast carcinoma

Maria Więcek¹, Robert Strąkowski¹, Teresa Jakubowska², Bogusław Więcek¹

¹Institut Elektroniki, Wydział Elektrotechniki, Elektroniki, Informatyki i Automatyki, Politechnika Łódzka, ul. Wólczańska 211/215, 90-924 Łódź, tel. +48 (0) 42 631 26 37, e-mail: wiecek@p.lodz.pl

²Centrum Diagnostyki i Terapii Laserowej Politechniki Łódzkiej, ul. Wólczańska 215, 93-005 Łódź

Streszczenie

W pracy przedstawiono procedurę termowizyjnych badań przesiewowych, w których dokonano selekcji oraz klasyfikacji obrazów za pomocą sieci neuronowych. Metodę zastosowano do badań zmian nowotworowych piersi. Sieć nauczono za pomocą 15 termogramów obrazujących zmiany patologiczne i 15 termogramów z grupy kontrolnej w projekcji przedniej i bocznej. Dodatkowo zastosowano analizę różnicy cech piersi zdrowej i chorej, co zapewniło największą skuteczność klasyfikacji na poziomie 70%. Lepsze wyniki klasyfikacji uzależnione są od wielkości zbioru uczącego.

Słowa kluczowe: termowizja, klasyfikacja, cechy obrazu, sieci neuronowe

Abstract

In this work, the procedure of screening breast pathology based on thermovision examinations was presented. The thermal image features were evaluated and classified by means of neural networks. 15 thermal images representing pathological lesions and 15 images from control group were examined, both from frontal and side positions of a patient. In addition, the differences of features of neoplastic and healthy breasts tissue, were evaluated. The classification efficiency up to 70% was achieved. The better classification can be obtained in case of bigger number of thermal images from both groups: pathological and control ones.

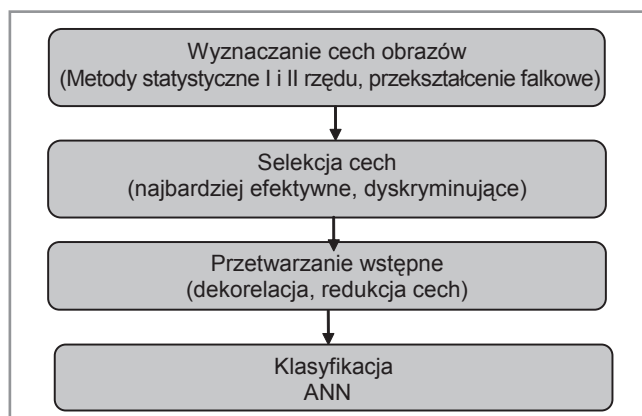
Keywords: thermovision, classification, image features, neural networks

Wprowadzenie

Badania przesiewowe stanów patologicznych piersi, w tym nowotworów, najczęściej wykonywane są za pomocą mammografii lub ultrasonografii. Inną metodą jest nieinwazyjne, bezdotykowe badanie rozkładu temperatury ciała za pomocą kamery termowizyjnej [1-7]. Metoda ta może być badaniem uzupełniającym w stosunku do powszechnie stosowanych badań mammograficznych i ultrasonograficznych.

W Instytucie Elektroniki Politechniki Łódzkiej opracowano procedurę przetwarzania termogramów, umożliwiającą klasyfikację obrazów, w celu zobjektywizowania wyników termowizyjnych badań przesiewowych stanów patologicznych piersi [3, 4, 8]. Procedura polega na wyznaczeniu pewnych cech obrazów termowizyjnych za pomocą

wybranych algorytmów, w tym metod statystycznych I i II rzędu oraz metod transformacyjnych, w tym głównie przekształcenia falkowego [8]. W kolejnym etapie następuje selekcja informacji, uwzględniająca jedynie cechy w niewielkim stopniu skorelowane ze sobą oraz dobrze rozróżniające przypadki patologiczne i fizjologiczne. Ostatnim etapem proponowanej procedury jest klasyfikacja realizowana za pomocą sieci neuronowych (rys. 1).



Rys. 1 Procedura przetwarzania termogramów w badaniach przesiewowych ANN – sztuczna sieć neuronowa (artificial neural network)

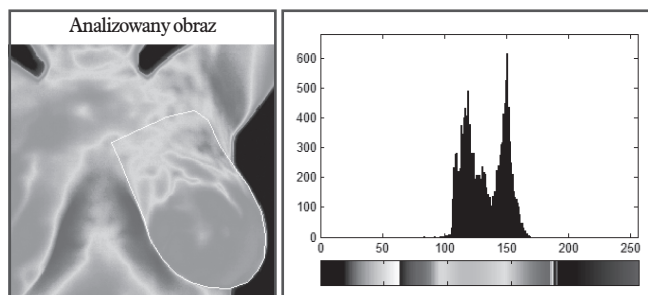
Cechy obrazów termowizyjnych

Cecha obrazu termowizyjnego, zwana także sygnaturą lub indeksem, to wartość liczbową uzyskaną z obrazu termowizyjnego w wyniku przeprowadzenia określonej procedury obliczeniowej. Wśród wielu cech, jakie można wyznaczyć z obrazów termowizyjnych, wyróżniają się cechy statystyczne I i II rodzaju, parametry falkowe, długości ciągów oraz gradientowe [9, 10]. Cechy można wyznaczać zarówno dla całego obrazu, jak i wybranego obszaru zainteresowania.

Parametry I rzędu wyznaczone z histogramu

Parametry statystyczne I rzędu wyznaczone na podstawie histogramu jasności obrazu charakteryzują ogólne cechy obrazu/obszaru zainteresowania. Na podstawie histogramu wyznaczono następujące parametry statystyczne I rzędu:


- wartość oczekiwaną jasności, określającą średnią jasność obrazu termogramów, równoważną średniej temperaturze,
- wariancję, określającą globalną zmienność pikseli rozpatrywanego obrazu,
- skośność histogramu, charakteryzującą stopień asymetrii rozkładu wokół średniej,



Rys. 2 Termogram piersi z nowotworem i histogram zaznaczonego obszaru

Tabela 1 Wartości parametrów I rzędu dla obszaru zainteresowania w termogramie na rys.2

Wartość cechy	Region 1
Wielkość (pix)	14263
Wartość średnia	132.0918
Wariancja	259.782
Skośność	0.049053
Kurtoza	23083.9956
Energia	0.021475
Entropia	5.7141



Rys. 3 Sąsiedztwo punktów w obrazie oraz kierunki analizy: pionowy (7-3), poziomy (5-1), diagonalny (8-4), oraz antydiagonalny (6-2)

- kurtozę, czyli współczynnik skupienia zmiennej losowej, informujący, czy rozkład jest wysmukły czy spłaszczony,
- entropię charakteryzującą globalną złożoność rozkładu jasności,
- energię.

Parametry II rzędu obliczane za pomocą macierzy zdarzeń

Macierz zdarzeń to macierz, której elementami są częstości występowania wartości temperatury i oraz j w odległości d [1-3]. Macierz zdarzeń opisuje przestrzenną strukturę obrazu. Każdy piksel ma ośmiu najbliższych sąsiadów (rys. 3), zatem pary pikseli należy rozważać w czterech kierunkach: poziomym, pionowym, diagonalnym i antydiagonalnym. Sprowadza się to do stworzenia czterech macierzy zdarzeń, odpowiednio dla każdego kierunku.

Z definicji macierzy zdarzeń wynika, że otrzymana macierz jest kwadratowa i symetryczna, a jej rozmiar jest równy ilości poziomów jasności występujących w obrazie. Współrzędne (i, j) w macierzy zdarzeń definiują rozważaną parę pikseli o temperaturze i, j w termogramie w odległości d . Wartość $M(i, j)$ określa licznosc ich występowania w odpowiednim dla danej macierzy zdarzeń kierunku. W celu obliczenia parametrów statystycznych należy tak znormalizować znajdujące się w macierzach częstości występowania par pikseli o określonych jasnościach, aby otrzymać odpowiednie prawdopodobieństwa. W tym celu należy podzielić wszystkie elementy macierzy przez liczbę możliwych w każdym przypadku par. Dla kierunków poziomego i pionowego wynosi ona $2N(M-1)$, a dla kierunków diagonalnych $2(N-1)(M-1)$, gdzie N i M oznaczają odpowiednio liczbę wierszy i kolumn macierzy.

Elementami znormalizowanej macierzy zdarzeń są prawdopodobieństwa $P(i, j)$ występowania w odległości d par pikseli o wartościach temperatury i oraz j [1-3]. Tak skonstruowana macierz zawiera wiele informacji o obrazie. W przypadku gdy prawdopodobieństwa na głównej przekątnej przyjmują wysokie wartości, zmiany temperatury pomiędzy sąsiadującymi pikselami są łagodne, bez znacznych gradientów. Wartości macierzy w prawym górnym rogu i w lewym dolnym informują o poziomie zaszumienia obrazu.

Dla macierzy zdarzeń zostały wyznaczone parametry statystyczne II rzędu, które mogą być użyteczne przy analizie i klasyfikacji obrazów:

- drugi moment zwykły,
- kontrast,
- korelacja,
- suma kwadratów,
- wariancja,
- odwrotny moment różnicowy,
- suma średnich,
- suma wariancji,
- suma entropii,
- entropia,
- wariancja różnicowa,
- entropia różnicowa.

Parametry wyznaczone na podstawie macierzy gradientu

Macierz gradientu określa zmianę jasności w kierunku poziomym i pionowym względem środkowej wartości piksela w masce 3×3 lub 5×5 .

$$\text{Dla maski } 5 \times 5 \quad x(i, j) = \sqrt{(H11 - H15)^2 + (H3 - H23)^2}$$

$$\text{Dla maski } 3 \times 3 \quad x(i, j) = \sqrt{(H8 - H18)^2 + (H12 - H14)^2}$$

gdzie (i, j) oznacza współrzędne w macierzy gradientu, w jakich wpisywana będzie powyżej obliczona wartość. Rozmiar tej macierzy jest równy rozmiarowi obrazu. Z macierzy gradientu wyznacza się typowe parametry statystyczne I rzędu, tj. wartość średnią, wariancję, skośność i kurtozę.

Rys. 4 Maska do wyznaczania macierzy gradientu

H1	H2	H3	H4	H5
H6	H7	H8	H9	H10
H11	H12	H13	H14	H15
H16	H17	H18	H19	H20
H21	H22	H23	H24	H25

Parametry wyznaczone na podstawie macierzy długości ciągów

Macierz długości ciągów R-L (ang. *Run-Length*) wyznaczona jest dla określonego kierunku (tzw. kąta skanowania). Wartość każdego elementu $R(g, i)$ macierzy zawiera informację, ile razy wystąpił ciąg pikseli o tej samej wartości (j – długość ciągu, g – wartość pikseli). Wymiary macierzy wynoszą, więc $L_g \times L_r$, gdzie L_r – to maksymalna długość ciągu, a L_g – to liczba możliwych wartości temperatury w obrazie.

Z macierzy R-L wyznaczamy następujące parametry statystyczne:

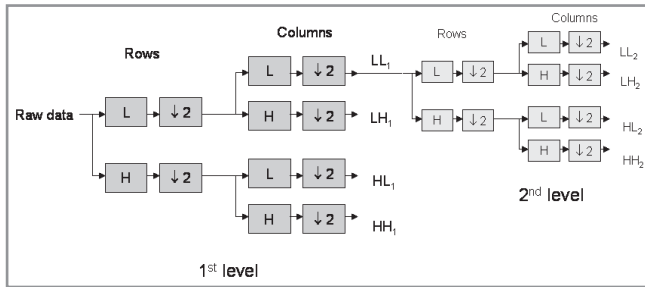
- odwrotny moment uwydatnienia krótkich pasm (*Short run emphasis inverse moment*),
- moment uwydatnienia długich pasm (*Long run emphasis moment*),
- niejednorodność pasm (*Run length nonuniformity*),
- część obrazu w pasmach (*Fraction of image in runs*).

Parametry falkowe

Transformacja falkowa oparta jest na filtracji wierszy i kolumn obrazu z użyciem filtrów dolno- i górnoprzepustowych (rys. 5) [8]. Po każdej filtracji następuje dwukrotna redukcja liczby pikseli w obrazie – decymacja. Procedura ta może być powtarzana do czasu, aż rozmiar obrazu będzie wynosił 1×1 . Praktyczne zakończenie transformacji następuje po 2-4 krokach, a z uzyskanych obrazów wyznaczone są parametry.

Przykładowe wartości cech termogramu piersi chorej i zdrowej

Na rys. 7 oraz w tabelach 2 i 3 przedstawiono przykładowy termogram oraz wartości cech obrazu piersi pacjentki z 4. grupy ryzyka. Prawą pierś zakwalifikowano do dalszej diagnostyki onkologicznej. Na rys. 7 przedstawiono różnice w histogramach obu piersi i wybrane wartości cech z macierzy gradientów (tabela 2) oraz macierzy zdarzeń (tabela 3). Na uwagę zasługuje bardzo wyraźna różnica wartości kurtozy, wyznaczona na podstawie gradientów oraz sumarycznej wariancji dla macierzy zdarzeń.



Rys. 5 Schemat przebiegu transformacji falkowej

Row data – dane pierwotne, Rows – rzędy, Columns – kolumny
1st level – pierwszy poziom, 2nd level – drugi poziom

Tabela 2 Przykładowe wartości cech uzyskane z macierzy gradientów dla piersi chorej (obszar 1) i zdrowej (obszar 2)

Wartość cechy	Region1	Region2
Średni gradient absolutny	2.9595	2,7792
Wariancja gradientu absolutnego	6.0886	5.6242
Skośność gradientu absolutnego	1.1245	3.441
Kurtoza gradientu absolutnego	1.8497	44.3581
Średni gradient absolutny	5.0441	4.5923
Wariancja gradientu absolutnego	18.958	14.1819
Skośność gradientu absolutnego	1.2158	1.6572
Kurtoza gradientu absolutnego	1.7914	7.9563

Tabela 3 Przykładowe wartości cech uzyskane z macierzy zdarzeń dla piersi chorej (obszar 1) i zdrowej (obszar 2), d=1, kierunek poziomy

Wartość cechy	Region1	Region2
Energia	0.0029727	0.0045078
Wariancja	3.365	3.2078
Wariancja różnicowa	3.3541	3.1973
Korelacja	-20020.1665	-129574.1079
Odwrotny moment różnicowy	0.47696	0.49137
Entropia	2.6557	2.4936
Drugi moment kątowy	0.0029727	0.0045078
Kontrast	3.365	3.2078
Suma kwadratów	322.4885	136.2062
Suma średnia	356.4851	383.0447
Sumaryczna wariancja	1286.5888	541.6171
Sumaryczna entropia	2.0918	1.9505
Entropia różnicowa	0.64755	0.6322

Kierunek macierzy zdarzeń

Vertical Horizontal
 Antidiagonal Diagonal

Selekcja cech

Jedną z najczęściej stosowanych metod wyznaczania dyskryminujących cech jest współczynnik Fishera, opisany wzorem (1) [9, 10].

$$F = \frac{D}{V} = \frac{\frac{1}{\sum_{k=1}^K P_k^2} \sum_{k=1}^K \sum_{j=1}^K P_k P_j (\mu_k - \mu_j)^2}{\sum_{k=1}^K P_k V_k} \quad (1)$$

Opisuje on stosunek wariancji pomiędzy klasami do wariancji wewnątrz klasy.

k – jest maksymalną liczbą klas cech,

P_i – jest prawdopodobieństwem wystąpienia i-tej klasy,

μ_i – jest wartością średnią w i-tej klasie,

V_i – wariancją w i-tej klasie.

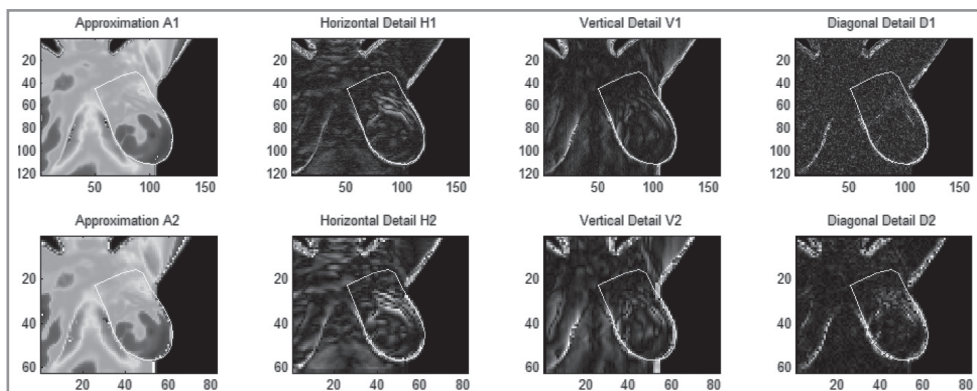
Jeżeli badany parametr może przyjąć szeroki zakres wartości, a wartości wewnątrz jednej klasy mają małą wariancję, to wartość współczynnika Fishera jest duża i dany parametr nadaje się do klasyfikacji. Natomiast jeżeli wartości średnie poszczególnych klas są do siebie zbliżone lub prawdopodobieństwo wystąpienia klasy jest niewielkie, parametr należy odrzucić.

Klasyfikacja obrazów za pomocą sieci neuronowych


Siecią neuronową nazywa się struktury matematyczne, realizujące obliczenia za pomocą elementów zwanych neuronami sieci. Neurony te wykonują pewną podstawową operację opisaną tzw. funkcją aktywacji neuronu. Funkcja aktywacji neuronu przedstawia zależność wartości na wyjściu neuronu od wartości na jego wejściu [4].

Sieć neuronowa może być zbudowana z dowolnej liczby warstw, a każda warstwa może mieć dowolną liczbę neuronów. Na pierwszą warstwę (wejściową) podawane są parametry wejściowe sieci. Wyjścia neuronów ostatniej warstwy dają odpowiedź na postawiony problem. Wszystkie warstwy w środku sieci nazywane są warstwami ukrytymi. Najprostsza sieć bez żadnej warstwy ukrytej zbudowana jest z jednego neuronu i nosi nazwę perceptronu. Funkcją aktywacji neuronu tej sieci jest funkcja skoku jednostkowego. Wyjście perceptronu może więc przybierać tylko dwa stany: 0 lub 1. Tak zaimplementowana sieć nadaje się do rozwiązywania prostych problemów liniowo separowanych. Sieć wielowarstwowa ma dużo większe możliwości i w ogólnym przypadku nadaje się do rozwiązania każdego rodzaju przypadków. Problemem jednak może być dobranie odpowiedniej liczby neuronów w warstwach ukrytych (rys. 8).


Funkcja aktywacji neuronu może być np. skokowa, sigmoidalna, tangens hiperboliczny, liniowa itp. Po zaimplementowaniu sieci przeprowadza się jej trening – uczenie sieci. Polega ono na doborze odpowiednich wag wejść każdego neuronu. Wagi określają udział każdego wejścia neuronu w wyniku, jaki ustali się na jego wyjściu. Są one dobierane na podstawie wektora wejściowego i wyjściowego próbek treningowych. Wartości zawarte w tych wektorach określają żadaną odpowiedź sieci na



Rys. 6 Wynik transformacji falkowej obrazu termograficznego



Rys. 7 Termogram i histogramy obszarów zainteresowania, chora piers – prawa



Rys. 8 Schemat ideowy zaimplementowanej sieci neuronowej z jedną warstwą ukrytą

zadane pobudzenie sieci (wartości próbek wejściowych). Trening sieci najczęściej zachodzi metodą gradientową minimalizacji błędów średniokwadratowych lub za pomocą reguły delty (dla sieci wielowarstwowej: algorytm wstecznej propagacji błędów). Problemem jest możliwość pogorszenia wartości uzyskanych wag, jeżeli wektor gradientu będzie za duży. Jeżeli gradient znajdzie się w minimum lokalnym, to wagi nie zostaną dobrze skorygowane. Następnym etapem jest wprowadzenie do sieci wektora testowego, w celu weryfikacji poprawności doboru wag. Na rys. 8 przedstawiono sieć neuronową, jaka została wykorzystana w badaniach.

Wyniki badań przesiewowych nowotworów piersi

Zmiany nowotworowe po badaniu mammograficznym klasyfikowane są w pięciostopniowej skali ryzyka:

1. brak zmiany,
2. zmiana łagodna,
3. zmiana prawdopodobnie łagodna,
4. zmiana podejrzana,
5. zmiana patologiczna.

*Approximation – przybliżenie
Horizontal – oś pozioma
Vertical – oś pionowa
Diagonal – płaszczyzna diagonalna*

W Centrum Diagnostyki i Terapii Laserowej Politechniki Łódzkiej podczas standardowego badania mammograficznego wykonywane są również zdjęcia termograficzne piersi pacjentek. Na podstawie badania mammograficznego zdjęcia termowizyjne 70 pacjentek zakwalifikowano do 5 grup ryzyka (tabela 4).

Mając do dyspozycji 280 zdjęć piersi 70 pacjentek (po dwa z przodu i z boku), wykonano testy. Testy polegały na odrzuceniu parametrów jednego obrazu ze zbioru danych wejściowych, a potem następowało uczenie jednokierunkowej sieci neuronowej pozostałymi zestawami parametrów. Po nauczaniu sieci neuronowej parametry obrazu odrzuconego podawano na wejście sieci, aby sklasyfikować go do odpowiedniej grupy. W celu zminimalizowania błędów sieci oraz statystycznego uśrednienia wyników proces ten dla każdego przypadku powtórzono od kilku do kilkunastu razy.

Tabela 4 Liczby pacjentek w odpowiednich grupach w termowizyjnych badaniach przesiewowych stanów nowotworowych piersi

Nr grupy	1	2	3	4	5
Liczba pacjentek	35	20	10	5	0

Test pierwszy

Pierwszy test przeprowadzono na grupie 15 kobiet zaklasyfikowanych do 3. i 4. grupy ryzyka. Pod uwagę wzięto termogramy piersi z przodu. Na podstawie współczynnika Fishera wybrano następujące cechy:

- parametry falkowe II rzędu, kierunek poziomy, krok 1., falka Haar – macierz V2 – kontrast,
- parametry falkowe II rzędu, kierunek 135°, krok 1., falka Haar – macierz V2 – suma wariancji,
- parametry II rzędu, kierunek 45°, krok 2. – wariancja różnicowa,
- parametry falkowe I rzędu, falka Haar – macierz H1 – skośność,
- parametry falkowe II rzędu, kierunek 45°, krok 2., falka Haar – macierz V1 – entropia różnicowa,
- parametry falkowe I rzędu, falka Reverse Biorthogonal 3.1 – macierz A2 – kurtoza.

Zbiór uczący składał się z 30 zestawów parametrów. 15 z nich charakteryzowało piersi zdrowe, a 15 – piersi chore. Wyniki klasyfikacji przedstawiono w tabeli 5.

Test drugi

Drugi test przeprowadzono na tej samej grupie kobiet. Pod uwagę wzięto termogramy piersi z boku (rys. 9). Na podstawie współczynnika Fishera wybrano następujące cechy:


- parametry długości ciągu poziome – odwrotny moment uwydatniania krótkich pasm,
- parametry falkowe II rzędu, kierunek 45°, krok 3., falka Haar – macierz V1 – suma entropii,
- parametry falkowe II rzędu, falka Haar – macierz V1 – entropia,

Tabela 5 Wyniki klasyfikacji termogramów piersi z przodu

Lp.	Grupa ryzyka	% poprawnie sklasyfikowanych	Liczba poprawnie sklasyfikowanych	Liczba prób klasyfikacji
1.	3	27,3	3	11
2.	3	81,8	9	11
3.	3	72,7	8	11
4.	3	72,7	8	11
5.	3	63,6	7	11
6.	3	90,9	10	11
7.	3	81,8	9	11
8.	3	63,6	7	11
9.	3	54,5	6	11
10.	3	72,7	8	11
11.	4	72,7	8	11
12.	4	27,2	3	11
13.	4	27,2	3	11
14.	4	18,2	2	11
15.	4	72,7	8	11
16.	1	18,2	2	11
17.	1	0	0	11
18.	1	18,2	2	11
19.	1	100	11	11
20.	1	36,4	4	11
21.	1	36,4	4	11
22.	1	18,2	2	11
23.	1	72,7	8	11
24.	1	63,6	7	11
25.	1	72,7	8	11
26.	1	54,5	6	11
27.	1	81,8	9	11
28.	1	72,7	8	11
29.	1	100	11	11
30.	1	63,6	7	11

Tabela 6 Wyniki klasyfikacji termogramów piersi z boku

Lp.	Grupa ryzyka	% poprawnie sklasyfikowanych	Liczba poprawnie sklasyfikowanych	Liczba prób klasyfikacji
1.	3	63,6	7	11
2.	3	45,5	5	11
3.	3	36,4	4	11
4.	3	81,8	9	11
5.	3	81,8	9	11
6.	3	54,5	6	11
7.	3	63,6	7	11
8.	3	81,8	9	11
9.	3	27,2	3	11
10.	3	9,1	1	11
11.	4	81,8	9	11
12.	4	54,5	6	11
13.	4	45,4	5	11
14.	4	81,8	9	11
15.	4	90,9	10	11
16.	1	18,1	2	11
17.	1	9,1	1	11
18.	1	45,4	5	11
19.	1	0	0	11
20.	1	45,4	5	11
21.	1	9,1	1	11
22.	1	63,6	7	11
23.	1	54,5	6	11
24.	1	45,4	5	11
25.	1	27,2	3	11
26.	1	18,1	2	11
27.	1	54,5	6	11
28.	1	45,4	5	11
29.	1	36,3	4	11
30.	1	27,2	3	11



Rys. 9 Termogramy piersi z boku: a) piers chorego, b) piers zdrowa

- parametry II rzędu, kierunek poziomy, krok 1. – entropia różnicowa,
- parametry gradientowe 3 x 3 – kurtoza,

- parametry falkowe II rzędu, kierunek 135°, krok 3., falka Haar – macierz V1 – entropia różnicowa.

Test trzeci

Trzeci test przeprowadzono na grupie 40 kobiet. 25 kobiet było zdrowych, 15 ze zmianami (grupa ryzyka 3. i 4.). Symulacja polegała na podaniu na wejście sieci różnicy parametrów. Pod uwagę wzięto termogramy piersi z przodu. Na podstawie współczynnika Fishera wybrano następujące cechy:

- parametry falkowe II rzędu kierunek 45°, krok 1., falka Haar – macierz H1 – kontrast,
- parametry falkowe II rzędu kierunek poziomy, krok 1., falka Haar – macierz V2 – difference variance,

Tabela 7 Wyniki klasyfikacji termogramów piersi z przodu ma podstawie różnicy wartości cech piersi chorej i zdrowej

Lp.	Grupa ryzyka	% poprawnie sklasyfikowanych	Liczba poprawnie sklasyfikowanych	Liczba prób klasyfikacji
1.	3	57,1	4	7
2.	3	28,6	2	7
3.	3	85,7	6	7
4.	3	57,1	4	7
5.	3	42,9	3	7
6.	3	85,7	6	7
7.	3	85,7	6	7
8.	3	42,9	3	7
9.	3	71,4	5	7
10.	3	100	7	7
11.	4	100	7	7
12.	4	85,7	6	7
13.	4	85,7	6	7
14.	4	28,6	2	7
15.	4	0	0	7
16.	1	85,7	6	7
17.	1	85,7	6	7
18.	1	71,4	5	7
19.	1	57,1	4	7
20.	1	71,4	5	7
21.	1	71,4	5	7
22.	1	42,9	3	7
23.	1	57,1	4	7
24.	1	42,9	3	7
25.	1	71,4	5	7
26.	1	42,9	3	7
27.	1	28,6	2	7
28.	1	57,1	4	7
29.	1	28,6	2	7
30.	1	0	0	7
31.	1	71,4	5	7
32.	1	0	0	7
33.	1	85,7	6	7
34.	1	57,1	4	7
35.	1	85,7	6	7
36.	1	57,1	4	7
37.	1	71,4	5	7
38.	1	14,3	1	7
39.	1	71,4	5	7
40.	1	0	0	7

Tabela 8 Wyniki klasyfikacji termogramów piersi z boku ma podstawie różnicy wartości cech piersi chorej i zdrowej

Lp.	Grupa ryzyka	% poprawnie sklasyfikowanych	Liczba poprawnie sklasyfikowanych	Liczba prób klasyfikacji
1.	3	57,14	4	7
2.	3	28,57	2	7
3.	3	85,71	6	7
4.	3	57,14	4	7
5.	3	42,86	3	7
6.	3	85,71	6	7
7.	3	85,71	6	7
8.	3	42,86	3	7
9.	3	71,43	5	7
10.	3	100	7	7
11.	4	100	7	7
12.	4	85,71	6	7
13.	4	85,71	6	7
14.	4	28,57	2	7
15.	4	100	7	7
16.	1	85,71	6	7
17.	1	85,71	6	7
18.	1	71,43	5	7
19.	1	57,14	4	7
20.	1	71,43	5	7
21.	1	71,43	5	7
22.	1	42,86	3	7
23.	1	57,14	4	7
24.	1	42,86	3	7
25.	1	71,43	5	7
26.	1	42,86	3	7
27.	1	28,57	2	7
28.	1	57,14	4	7
29.	1	28,57	2	7
30.	1	0	0	7
31.	1	71,43	5	7
32.	1	0	0	7
33.	1	85,71	6	7
34.	1	57,14	4	7
35.	1	85,71	6	7
36.	1	57,14	4	7
37.	1	71,43	5	7
38.	1	14,29	1	7
39.	1	71,43	5	7
40.	1	100	7	7

- parametry falkowe II rzędu kierunek 45°, krok 1, falka Haar – macierz H2 – suma kwadratów,
- parametry falkowe II rzędu kierunek pionowy, krok 2, falka Reverse Biorthogonal 3.1 – macierz H1 – entropia różnicowa,
- parametry falkowe I rzędu, falka Reverse Biorthogonal 3.1 – macierz H2 – wariancja,
- parametry falkowe II rzędu, kierunek 135°, krok 1., falka Reverse Biorthogonal 3.1 – macierz H1 – suma średnich.

Test czwarty

Czwarta symulacja została wykonana dla różnicy parametrów piersi chorej i zdrowej tej samej pacjentki przy zobrazowaniu termalnym z boku. Wybrano następujące parametry:

- parametry falkowe II rzędu, kierunek 45°, krok 1., falka Haar – macierz H1 – kontrast,
- parametry falkowe II rzędu, kierunek poziomy, krok 1., falka Haar – macierz V2 – *difference variance*,
- parametry falkowe II rzędu, kierunek 45°, krok 1., falka Haar – macierz H2 – suma kwadratów,
- parametry falkowe II rzędu, kierunek pionowy, krok 2., falka Reverse Biorthogonal 3.1 – macierz H1 – entropia różnicowa,
- parametry falkowe I rzędu falka Reverse Biorthogonal 3.1 – macierz H2 – wariancja,
- parametry falkowe II rzędu, kierunek 135°, krok 1., falka Reverse Biorthogonal 3.1 – macierz H1 – suma średnich.

Tabela 9 przedstawia zbiorcze wyniki testów. Wynika z niej, że skuteczność rozpoznawania zmian patologicznych jest większa niż rozpoznawanie piersi zdrowych. Ponadto w przypadku badania piersi z boku rozpoznawalność jest większa.

Najlepsze wyniki uzyskano dla testu 4. Rozpoznawalność zmian patologicznych wynosiła 70%, a piersi zdrowych 57%. Jest to najlepszy wynik, jaki udało się uzyskać na tak małej liczbie obrazów patologicznych.

Tabela 9 Sumaryczne wyniki klasyfikacji dla poszczególnych symulacji

	False - positive	True - negative	False - negative	True - positive
Test 1	46	54	40	60
Test 2	67	33	40	60
Test 3	47	53	36	64
Test 4	43	57	30	70

Podsumowanie

Termowizja w podczerwieni może być pomocna w różnych obszarach współczesnej medycyny, wszędzie tam, gdzie obraz termowizyjny jest materiałem diagnostycznym. Użyteczność proponowanej metody potwierdzono na przykładzie badań stanów nowotworowych piersi. Zaproponowano wyznaczenie cech na podstawie różnych danych uzyskanych z termogramów. Na podkreślenie zasługuje to, że w diagnostyce piersi metody transformacyjne, w tym metoda dwuwymiarowego przekształcenia falkowego, prowadzi do wyznaczenia cech, które dobrze rozróżniają stany patologiczne i fizjologiczne. Podstawowym wnioskiem, jaki można wyciągnąć na podstawie przeprowadzonych eksperymentów, jest stwierdzenie, że dla osiągnięcia dużej skuteczności metod klasyfikacji za pomocą sieci neuronowej wymagana jest odpowiednio duża liczba obrazów użytych w procesie jej uczenia. 15 obrazów patologicznych i tyle samo kontrolnych zapewniło skuteczność klasyfikacji na poziomie ok. 50%. Zwiększenie zbioru uczącego z pewnością poprawiłoby skuteczność klasyfikacji.

Należy podkreślić, że proponowana metoda wspomagania diagnostyki przesiewowej stanów nowotworowych piersi jest metodą uzupełniającą do innych obecnie stosowanych, a jej podstawową zaletą jest całkowita nieinwazyjność i bezpieczeństwo pacjenta. ■

Literatura

1. M. Bennett: *Breast cancer screening using high-resolution digital thermography*, Total Health, vol. 22(6), 1985, s. 44.
2. W.C. Amalu, W.B. Hobbs, F.J. Head Elliot: *Infrared imaging of the breast – an overview*, [w:] Medical devices and systems, J.D. Bronzino (red.), CRC Press 2006, rozdz. 25-1 - 25-21.
3. T. Jakubowska, B. Więcek, M. Wysocki, C. Drewno-Peszyński: *Thermal signatures for breast cancer screening – comparative study*, Proc. IEEE EMBS Conf. Cancun, Mexico, Sep 17-21, 2003.
4. B. Więcek, M. Strzelecki, T. Jakubowska, M. Wysocki, C. Drewno-Peszyński: *Advanced thermal image processing*, [w:] Medical devices and systems, J.D. Bronzino (red.), CRC Press, 2006, rozdz. 28-1 - 28-13.
5. E.Y.K. Ng, L.N. Ung, F.C. Ng, L.S.J. Sim: *Statistical analysis of healthy and malignant breast thermography*, Journal of Medical Engineering & Technology, vol. 25(6), 2001, s. 253-263.
6. E.Y.K. Ng, N.M. Sudharsan: *Numerical modelling in conjunction with thermography as an adjunct tool for breast tumour detection*, BMC Cancer, vol. 4(17), 2004, s. 1-26.
7. E.Y.K. Ng: *A review of thermography as promising non-invasive detection modality for breast tumour*, International Journal of Thermal Sciences, 2008, DOI: 10.1016/j.ijthermalsci.2008.06.015.
8. M. Więcek, R. Strąkowski, T. Jakubowska, B. Więcek: *Software for classification of thermal imaging for medical applications*, 9th International Conference on Quantitative InfraRed Thermography QIRT2008, Inżynieria Biomedyczna – Acta Bio-Optica et Informatica Medica, vol. 14, 2008, s. 143.
9. A. Materka, M. Strzelecki, R. Lerski, L. Schad: *Evaluation of texture features of test objects for magnetic resonance imaging*, Infotech Oulu: Workshop on texture analysis in machine vision, June 1999, Oulu, Finland.
10. B.F.J. Manly: *Multivariate statistical method: a primer*, Chapman & Hall, London 1994.
11. E.F.J. Ring, K. Ammer: *The technique of infrared imaging in medicine*, Thermology International, vol. 10, (1) 2000, s. 7-14.

otrzymano / received: 20.12.2009
zaakceptowano / accepted: 30.01.2010