

# Detekcja wad squat w szynach kolejowych

## Detection of squat defects in railway

### Streszczenie

Stan toru kolejowego ma istotny wpływ na bezpieczeństwo ruchu kolejowego. Do tej pory na PKP stan toru był diagnozowany wyłącznie na podstawie badań ultradźwiękowych. Pozwala to na wykrywanie wad znajdujących się wewnątrz szyny. Metoda ta jest jednak zawodna, gdy wady znajdują się na powierzchni szyny lub bezpośrednio pod jej powierzchnią. Wady typu *squat* należą do grupy wad, które nie mogą być wykryte tradycyjną metodą ultradźwiękową. Skłoniło to autora do opracowania wizyjnych algorytmów detekcji tego typu wad. Wykorzystano do tego celu bank filtrów Gabora. W celu określenia najbardziej istotnych cech opisujących te wady wykorzystano technikę selekcji cech zależnych od rodzaju klasyfikatora. Klasyfikacja (detekcja) wad przeprowadzona została wg klasyfikatora SVM. Uzyskano 94% skuteczność klasyfikacji.

**Słowa kluczowe:** squat, detekcja, szyny kolejowe

### Abstract

The state of the railway track has a significant impact on the safety of railway traffic. It is an important topic at the time of a steady increase in speed and the load of railway lines. Until now, the state of rails of the Polish Railway Lines has been verified exclusively by the ultrasonic method. It makes it possible to detect flaws occurring in the cross-section of the rail head. Unfortunately, it is useless when surface flaws are located on or a few millimeters beneath the surface of the rail head. Squat flaws belong to the group of flaws which are not detected by traditional methods. It has led the author to develop and verify algorithms allowing for automatic visual detection of squat flaws. A bank of Gabor filters was used to detect these flaws. In order to select the most informative features describing the squats, sequential feature selection methods based on the wrapper technique were used. Discrimination among areas with squat and areas without squat is performed by an SVM (Support Vector Machine) classifier. In the case of this method, the detection rate was 94%.

**Keywords:** detection, rails


## Wstęp

Stan toru kolejowego, którego elementem są szyny kolejowe, ma istotny wpływ na bezpieczeństwo ruchu pociągów. Z tego względu konieczna jest okresowa kontrola jego stanu. Obecnie w Polsce diagnostyka szynowa jest prowadzona wyłącznie z wykorzystaniem techniki ultradźwiękowej [1]. Wykorzystywany jest do tego celu zautomatyzowany, ultradźwiękowy wagon defektoskopowy. Technika ta umożliwia wykrywanie wad znajdujących się pod powierzchnią główki szyny. Jednak okazuje się ona mało skuteczna w przypadku wad

powierzchniowych szyn. Takimi wadami są wady typu *squat* (rys. 1), występujące na powierzchni główki szyny. Istnieją co prawda techniki oparte na metodach prądów wirowych [2] umożliwiające wykrywanie tego typu wad, jednak ich praktyczne zastosowanie w warunkach, jakie panują na szlaku kolejowym, jest bardzo trudne, a często wręcz niemożliwe. Jak podano w pracy [3], wady *squat* w roku 2011 oraz 2012 były powodem odpowiednio 340 oraz 488 złamań oraz pęknięć szyn kolejowych. Stanowiło to ok. 19% wszystkich złamań i pęknięć powstałych na liniach kolejowych. Zastosowanie technik wizyjnych stanowi alternatywny sposób wykrywania wad tego typu.

Dr hab. inż. Piotr Bojarczak – Uniwersytet Technologiczno-Humanistyczny w Radomiu.

Autor korespondencyjny/Corresponding author: bojarczp@wp.pl



Rys. 1. Postać wad typu squat występująca na powierzchni szyny  
Fig. 1. Example of squat flaw occurring on the rail surface

## Struktura systemu wizyjnego do detekcji wad *squat*

Autor w swoich badaniach, dzięki uprzejmości PKP PLK S.A., wykorzystał pochodzące z bazy zdjęcia toru kolejowego. Zostały one zarejestrowane przez system wizyjny zainstalowany na wagonie defektoskopowym. Obrazy toru kolejowego podlegały wizualnemu sprawdzeniu przez operatora, czy wykryta przez aparaturę defektoskopową wada nie pochodziła np. od złącza szyn. System pełni więc rolę pomocniczą. Składa się on z szybkich, kolorowych kamer klatkowych umiejscowionych na wózku jezdnym wagonu defektoskopowego, ksenonowych źródeł światła doświetlających obszar szyn oraz dwóch komputerów wyposażonych w 1Gb Ethernet, służących do rejestracji obrazów wideo pochodzących od zainstalowanych kamer (każdy z komputerów obsługuje 1 szynę toru). Zarejestrowany przez niego strumień obrazów składa się z ciągu kolejnych niezachodzących na siebie fragmentów toru o długości 0,5 m każdy. Zarejestrowane w ten sposób zdjęcia podlegały automatycznej analizie mającej na celu detekcję wad *squat*. Zaproponowany algorytm ich detekcji składa się z następujących bloków:

- bloku ROI (*Region of Interest*) dla szyny, celem którego jest wyodrębnienie z obrazu fragmentu zawierającego szynę,
- bloku ekstrakcji cech wad *squat*, celem którego jest wyselekcjonowanie najbardziej reprezentatywnych cech opisujących ten typ wady,
- bloku detektora wad *squat*, celem którego jest detekcja obszaru szyny zawierającej tę wadę na podstawie uprzednio wydobytych cech.

Szczegóły dotyczące bloku ROI wykorzystującego dwuwymiarową transformację falkową są przedstawione w [5]. Detekcja wad *squat* może być potraktowana jako proces klasyfikacyjny. Celem tego procesu jest przydzielenie obiektu na podstawie pewnych jego unikalnych cech (u nas występują dwa rodzaje obiektów: obszar szyny z wadą *squat* oraz obszar szyny bez wady *squat*) do jednej z dwóch grup: grupy zawierającej obiekty z wadami *squat* lub grupy obiektów niezawierających takich wad. Proces ten obejmuje dwa etapy: ekstrakcję cech oraz klasyfikację, która w tym przypadku odpowiada detekcji. Zakwalifikowaniu danej przez klasyfikator do pierwszej grupy odpowiada detekcja wady, natomiast zakwalifikowanie danej do drugiej grupy oznacza, że wada nie występuje – brak detekcji wady. Etap ekstrakcji ma na celu wybranie unikalnych cech pozwalających na rozróżnienie między dwoma wyżej wymienionymi grupami obiektów.

## Ekstrakcja cech wad *squat*

Autor, zainspirowany pracami [5, 6] dotyczącymi wykorzystania filtrów Gabora w kontroli materiałów tekstylnych oraz w rozpoznawaniu obiektów, zaproponował ich użycie do ekstrakcji cech wad *squat*. Do ekstrakcji cech został użyty bank  $n$  filtrów Gabora. W tym celu rama (okienko) o stałym rozmiarze 172x132 (172 – długość, w której mieści się największa z rozpatrywanych wad, 132 – szerokość głowki szyny) jest przesuwana z krokiem co jeden punkt po obrazie wycinka szyny uzyskanym w etapie ekstrakcji szyny (blok ROI). Dla każdego położenia rama w obrazie przeprowadzana jest filtracja obrazu znajdującego się pod ramą przez bank  $n$  filtrów Gabora. Następnie każdy z  $n$  wyfiltrowanych obrazów poddawany jest nieliniowemu przekształceniu za pomocą funkcji wartości bezwzględnej jego elementów. W następnym kroku dla każdego z uzyskanych w ten sposób obrazów obliczana jest ich wartość średnia  $\mu_i$  oraz wariancja  $\sigma_i$ . Po obliczeniu wartości  $\mu$  oraz  $\sigma$  dla wszystkich  $n$  obrazów są one podawane na wejście klasyfikatora. Celem jest zaklasyfikowanie obrazu znajdującego się pod aktualnym położeniem rama na podstawie odpowiadających mu  $n$  par  $(\mu_i, \sigma_i)$  jako należącego do grupy obiektów zawierającej wady *squat* (detekcja wady) lub do grupy niezawierającej wad *squat* (wada nie występuje). Kluczowymi kwestiami mającymi decydujący wpływ na jakość procesu detekcji tych wad są: wybór właściwej liczby  $n$  filtrów Gabora, właściwy dobór parametrów dla każdego z filtrów oraz prawidłowy wybór rodzaju klasyfikatora. Filtry Gabora są próbą naśladowania działania komórek wizyjnych ssaków [7]. W przestrzeni dwuwymiarowej pojedynczy 2D (dzwuwymiarowy) filtr Gabora może być opisany następującą zależnością [8]:

$$h(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x'^2}{\sigma_x^2} + \frac{y'^2}{\sigma_y^2}\right)\right] \exp[2\pi jFx'] \quad (1)$$

$$\begin{aligned} x' &= x\cos\Theta + y\sin\Theta \\ y' &= -x\sin\Theta + y\cos\Theta \end{aligned}$$

gdzie:  $j = -1$ ,  $(x', y')$  są współrzędnymi obróconymi,  $\sigma_x$  oraz  $\sigma_y$  są standardowymi odchyleniami obwiedni Gaussa odpowiednio wzdłuż osi X oraz Y,  $F$  jest częstotliwością przestrzennego przebiegu sinusoidalnego, natomiast  $\Theta$  jest jego orientacją względem osi X.

Amplitudowa charakterystyka częstotliwościowa tego filtru może być uzyskana przez zastosowanie do wyrażenia (1) dwuwymiarowej transformacji Fouriera (*two dimensional Discrete Fourier Transform* – 2D DFT) [8]:

$$H(u, v) = \exp\left[-\frac{1}{2}\left(\frac{(u'-F)^2}{\sigma_u^2} + \frac{v'^2}{\sigma_v^2}\right)\right] \quad (2)$$

$$\begin{aligned} u' &= u\cos\Theta + v\sin\Theta \\ v' &= -u\sin\Theta + v\cos\Theta \end{aligned}$$

gdzie:  $\sigma_u = 1/(2\pi\sigma_x)$ ,  $\sigma_v = 1/(2\pi\sigma_y)$ ,  $(u', v')$  są współrzędnymi częstotliwościowymi obróconymi,  $u$  jest częstotliwością oscylacji wzdłuż osi poziomej obrazu (oś X), natomiast  $v$  jest częstotliwością oscylacji wzdłuż osi pionowej obrazu (oś Y).

Wzór (2) przedstawia filtr pasmowy nastrojony na częstotliwość środkową  $F$  o paśmie określonym przez  $\sigma_u$  oraz  $\sigma_v$ . Dzięki czterem parametrom filtru:  $F$ ,  $\Theta$ ,  $\sigma_x$  oraz  $\sigma_y$  możliwe jest dostrojenie filtru do zadanego zakresu częstotliwości, mającego wpływ na rozmiar analizowanych szczegółów w obrazie oraz określenie kierunku występowania szczegółów – parametr  $\Theta$ .

Prawidłowy dobór parametrów filtru ma decydujący wpływ na jakość procesu filtracji. Ponieważ rozmiar oraz położenie (kierunek) analizowanych wad typu *squat* znacząco się zmienia, zastosowano banki (zbiory) filtrów Gabora [9]. Pomimo że funkcje filtrów Gabora nie spełniają precyzyjnie wymagań dotyczących falek, w literaturze często nazywane są falkami Gabora [9]. Jeśli wzór (3) przedstawia postać falki bazowej Gabora [9]:

$$h_{mother}(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right) \exp[2\pi jFx]\right] \quad (3)$$

bank filtrów może być określony w oparciu o następującą zależność:

$$h(p, q) = \alpha^{-p} h_{mother}(x', y')$$

gdzie:

$$x' = \alpha^{-p}(x \cos \Theta_q + y \sin \Theta_q)$$

$$y' = \alpha^{-p}(-x \sin \Theta_q + y \cos \Theta_q)$$

$$\Theta_q = \frac{\pi(q-1)}{L}$$

$$\alpha > 1; \quad p = 1, 2, \dots, S \quad q = 1, 2, \dots, L$$

$p$  jest indeksem skali (rozmiaru) funkcji Gabora,  $q$  indeksem jej orientacji,  $S$  całkowitą liczbą skal, natomiast  $L$  jest całkowitą liczbą orientacji banku filtrów Gabora. Jeżeli nałożymy pewne ograniczenia na  $\alpha$ ,  $\sigma_x$  oraz  $\sigma_y$  [9]:

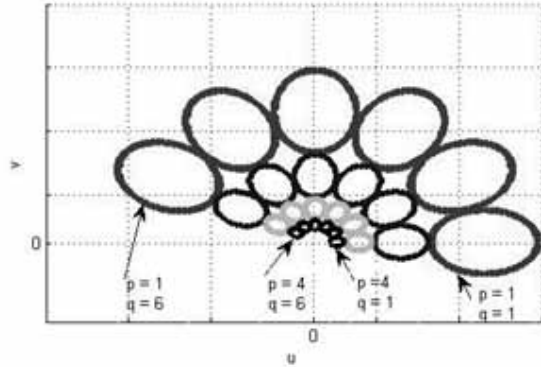
$$\alpha = \left(\frac{F_h}{F_l}\right)^{1/(S-1)}$$

$$\sigma_x = \frac{(\alpha-1)\sqrt{2 \ln 2}}{2\pi(\alpha-1)F_h} \quad (4)$$

$$\sigma_y = \frac{1}{2\pi \tan\left(\frac{\pi}{2L}\right) \sqrt{\frac{F_h^2}{2 \ln 2} - \frac{1}{(2\pi\sigma_x)^2}}}$$

gdzie:  $F_h$  oraz  $F_l$  są odpowiednio maksymalną oraz minimalną częstotliwością obejmowaną przez amplitudowe charakterystyki częstotliwościowe odpowiadające bankowi tych filtrów, wówczas amplitudowe charakterystyki częstotliwościowe sąsiednich filtrów przylegają do siebie w punktach zdefiniowanych przez  $h_{\max(p,q)}$ , gdzie  $h_{\max(p,q)}$  jest wartością maksymalną amplitudowej charakterystyki częstotliwościowej filtru Gabora

określonego przez indeksy  $(p,q)$ . Rysunek 2 przedstawia powyższe charakterystyki określone dla  $F_l = 0,013$ ,  $F_h = 0,1$ ,  $S = 4$  oraz  $L = 6$ .



**Rys. 2.** Przekroje amplitudowych charakterystyk częstotliwościowych dla  $0,5h_{\max(p,q)}$  dla banku filtrów Gabora zdefiniowanych przez  $F_l = 0,013$ ,  $F_h = 0,1$ ,  $S = 4$  oraz  $L = 6$

**Fig. 2.** Half-peak magnitude response of Gabor filters bank for  $F_l = 0,013$ ,  $F_h = 0,1$ ,  $S = 4$  and  $L = 6$

Po przeanalizowaniu wielu obrazów szyn zawierających wady typu *squat* autor zdecydował się użyć banku filtrów Gabora o następujących parametrach:  $F_l = 0,013$ ,  $F_h = 0,1$ ,  $S = 4$  oraz  $L = 6$  jako bazy do poszukiwania optymalnej postaci filtrów Gabora. W wyniku tego uzyskano 24 filtry Gabora o częstotliwościach środkowych pasma przepustowego równych 0,013, 0,042, 0,071, 0,1 oraz orientacjach: 0,  $\pi/6$ ,  $2\pi/6$ ,  $3\pi/6$ ,  $4\pi/6$ ,  $5\pi/6$ . Rysunek 2 przedstawia odpowiadające im przekroje amplitudowych charakterystyk częstotliwościowych uzyskanych dla wartości  $0,5h_{\max(p,q)}$ .

Proces konstrukcji klasyfikatora polega na wygenerowaniu na podstawie dostępnych danych reprezentujących zarówno grupę z wadami, jak i grupę bez wad, hiperpłaszczyzny separującej powyższe dwie grupy w  $m$ -wymiarowej przestrzeni cech. Jeżeli maksymalny wymiar przestrzeni cech oznaczymy jako:

$$M_{\max} = S \cdot L \cdot 2 \quad (5)$$

gdzie:  $S$  jest liczbą skal banku filtrów ( $S = 4$ ),  $L$  jest liczbą orientacji banku filtrów ( $L = 6$ ), natomiast 2 jest liczbą cech –  $(\mu_i, \sigma_i)$  uzyskanych dla każdego filtru Gabora, to zadanie stawiane przed procesem selekcji cech będzie polegało na wyborze ze zbioru  $M_{\max}$  cech podzbioru o możliwie najmniejszej ich liczbie zapewniających najlepszą separację powyższych dwóch grup danych (najmniejszą liczbę źle sklasyfikowanych obszarów szyny).

Algorytmy selekcji cech są często używane w dziedzinie bioinformatyki – stanowią istotne narzędzie diagnostyki medycznej. Wykorzystywane są np. do selekcji genów pozwalających na rozróżnienie tkanek zdrowych i zaatakowanych nowotworem [10]. Można podzielić je na dwie grupy:

– metody wyboru cech pod względem ich indywidualnych właściwości od najlepszej do najgorszej (*filter technique feature selection*) [11] na podstawie

entropii, T-statystyki. Wadą tej metody jest to, że podczas wyboru cech nie uwzględnia ona wzajemnych relacji między nimi,

- metody wyboru cech dla konkretnego typu klasyfikatora (*wrapper technique feature selection*) [11] uwzględniającego jego błąd klasyfikacji (zdefiniowany jako stosunek liczby źle sklasyfikowanych danych do całkowitej ich liczby). Metody te w trakcie wyboru cech uwzględniają wzajemne relacje.

Ze względu na ograniczony zakres artykułu przedstawiona zostanie metoda wyboru cech dla konkretnego typu klasyfikatora. Cechy wybrane zgodnie z tą metodą zapewniają najmniejszy błąd klasyfikacji (najlepszą detekcję wad *squat*). W tym celu z ogromnej ilości zdjęć toru zarejestrowanych przez system wybrano te zawierające wady *squat*, a następnie w sposób ręczny wyodrębniono same wady. Każda z wad mieściła się w obrazie o rozmiarze 172x132 odpowiadającemu rozmiarowi ramki. W wyniku tego uzyskano 600 przykładów obrazów wad. Dodatkowo zarejestrowano również 600 obrazów o rozmiarze 172x32 odpowiadających fragmentom szyn niezawierających wad *squat*. Zgodnie z [11] proces selekcji cech wymaga, aby dane używane w nim były inne od danych użytych do konstrukcji samego klasyfikatora. Z tego względu dane zawierające obrazy wad zostały podzielone w sposób losowy na dwie grupy: 300 danych użytych w procesie selekcji cech oraz 300 danych użytych do konstrukcji klasyfikatora. Również dane zawierające fragmenty szyny bez wad podzielono w ten sam sposób. Za optymalną metodę selekcji cech uznano tę, która zawierała podzbiór o minimalnej liczbie cech zapewniający najmniejszy błąd klasyfikatora, przy czym dane używane do konstrukcji klasyfikatora zawierały cechy wyselekcjonowane przez odpowiedni algorytm selekcji cech. Jako klasyfikator została użyta sieć SVM (*Support Vector Machine*) ze względu na teoretycznie najmniejszy błąd klasyfikacji [12].

Rysunek 3 przedstawia zależność współczynnika klasyfikacji zdefiniowanego jako:


$$\text{współczynnik klasyfikacji} = [1 - \text{bład klasyfikacji}] \cdot 100\% \quad (6)$$

od ilości wybranych cech dla sieci SVM z trzema rodzajami funkcji jąder: liniowym, gaussowskim oraz wielomianu trzeciego stopnia. W tym przypadku jako

**Tablica I.** Sześć najistotniejszych wyselekcjonowanych cech  
**Table I.** Six selected the most important features

Numer cech	Indeks skali filtru - ( $p$ )	Indeks orientacji filtru - ( $q$ )	$\mu$ lub $\sigma$ uzyskane dla filtru Gabora zdefiniowanego przez ( $p, q$ )
3	1	2	$\mu$
8	1	4	$\sigma$
16	2	2	$\sigma$
24	2	6	$\sigma$
26	3	1	$\sigma$
32	3	4	$\sigma$

optymalne rozwiązanie należy uznać sieć SVM z funkcją jądra o postaci wielomianu trzeciego stopnia wraz z sześcioma wyselekcjonowanymi dla niej cechami, dla których współczynnik klasyfikacji był największy.



**Rys. 3.** Zależność współczynnika klasyfikacji sieci SVM od liczby wybranych cech

**Fig. 3.** Classification rate for SVM versus the number of selected features

## Klasyfikator wad *squat*

Jeżeli pojedynczą daną (wycinek szyny) potraktować jako punkt  $x \in \mathbb{R}^M$  w przestrzeni  $M$ -wymiarowej ( $M$  jest liczbą wyselekcjonowanych cech), to celem klasyfikatora będzie stworzenie w oparciu o dostępne dane, czyli zbiór uczący składający się z  $z$  par  $(x_i, d_i)$ ,  $i = 1 \dots z$ , hiperpłaszczyzny separującej powyższe dwie grupy danych. Symbol  $d_i$  jest liczbą (etykieta) przyjmującą wartości  $+1$ , gdy  $x_i$  należy do pierwszej grupy danych, lub  $-1$ , gdy  $x_i$  należy do drugiej grupy danych. W przypadku użytego klasyfikatora opartego na sieci SVM (*Support Vector Machine*) wygenerowana hiperpłaszczyzna separująca przyjmuje położenie optymalne, tzn. zapewniające maksymalny margines separacji [12]. Jest on określany przez maksymalizację odstępów między danymi obu klas położonymi najbliżej siebie. Jeżeli dane nie są separowane liniowo, co oznacza, że nie można poprowadzić hiperpłaszczyzny separującej powyższe dwie grupy danych, przeprowadzane jest nieliniowe rzutowanie  $M$ -wymiarowej przestrzeni wejściowej w  $R$ -wymiarową przestrzeń cech (nie mylić z cechami uzyskanymi z algorytmu selekcji cech) za pomocą funkcji  $\varphi(x)$ , przy czym  $R > M$  [12]. System jest nadal liniowy, przy czym zgodnie z [12] rzutowanie to powiększa wymiar przestrzeni, zwiększając prawdopodobieństwo, że liniowo nieseparowane dane w przestrzeni  $M$ -wymiarowej będą liniowo separowane w nowo uzyskanej przestrzeni. W praktyce zamiast funkcji  $\varphi(x)$  stosuje się tzw. funkcję jądra  $K(x, x_i)$ . Funkcja jądra może przyjmować postać liniową, wielomianową bądź też gaussowską. Przy czym w przypadku jądra liniowego separacja odbywa się w oryginalnej  $M$ -wymiarowej przestrzeni (nie ma zwiększenia jej

wymiaru), natomiast dla pozostałych jąder separacja odbywa się w nowej, zwiększonej przestrzeni cech. Jako klasyfikator wykorzystano sieć SVM z funkcją jądra o postaci wielomianu trzeciego stopnia – dla niej uzyskano największy współczynnik klasyfikacji (rys. 3). Do jej konstrukcji zostały użyte dane nieuczestniczące w procesie wyboru cech. Dane zawierające wady w ilości 300 zostały podzielone w sposób losowy na dwie grupy. Pierwsza grupa zawierająca 153 danych została użyta w procesie uczenia klasyfikatora (konstrukcji hiperpłaszczyzny), natomiast druga grupa zawierająca 147 danych została użyta do testowania działania klasyfikatora po procesie jego uczenia. W podobny sposób podzielono dane bez wad. Każda z podawanych na wejście klasyfikatora danych składała się z wyselekcjonowanych cech przedstawionych w tablicy II.

Poniżej zaprezentowano rezultaty działania klasyfikatora (dla danych testujących, nieuczestniczących w procesie wyboru cech oraz procesie uczenia klasyfikatora).

**Tablica II.** Macierz pomyłek dla klasyfikatora przeprowadzającego detekcję wad *squat*

**Table II.** Confusion matrix for the classifier performing the detection of squat defects

Obszar	Sklassyfikowany jako obszar		Współczynnik klasyfikacji %
	z wadą	bez wady	
z wadą	134	13	94,5
bez wady	4	157	

## Wnioski

Zaprezentowany algorytm może stanowić alternatywny sposób wykrywania wad powierzchniowych typu *squat*. Zastosowanie banków filtrów Gabora wraz z algorytmami selekcji cech umożliwiło zdefiniowanie sześciu reprezentatywnych cech opisujących wady tego typu. Z kolei użyty klasyfikator SVM

umożliwił dyskryminację na podstawie wcześniej określonych reprezentatywnych cech między obszarem szyny zawierającym wadę a niezawierającym jej. Zważywszy na licznie występujące na szynie zabrudzenia, uzyskany 94,5% współczynnik klasyfikacji wydaje się być rezultatem bardzo dobrym.

## Literatura

- [1] P. Lesiak : Mobilna diagnostyka szyn w torze kolejowym; Monografia habilitacyjna, Wydział Transportu Politechniki Warszawskiej, 2008.
- [2] I. Elshafey, L. Lalita Udpa.: A new eddy current imaging system for enhancement of nondestructive evaluation; NDT.net, Vol. 9, 2004, Internet <http://www.ndt.net/article/mendt03/elshaf/elshaf.htm>
- [3] M. Migdal: Istotne czynniki warunkujące wybór strategii szlifowania szyn; VI Konferencja Naukowo-Techniczna INFRA-SZYN, 2013.
- [4] P. Bojarczak : Visual algorithms for automatic detection of squat flaws in railway rails; Insight – Non-Destructive Testing and Condition Monitoring, The Journal of The British Institute of Non-Destructive Testing. Vol. 6 July, 2013.
- [5] K. Jain, N. Ratha, S. Lakshmanan: Object detection using Gabor Filter; Pattern Recognition. Vol. 30, No. 2, (295-309), 1997.
- [6] A. Kumar, GKH. Pang: Defect detection in textured materials using Gabor filters; IEEE Transactions on Industry Applications, Vol. 38, No. 2, (425-440), 2002.
- [7] C. Mandriota, M. Nitti, N. Ancona, A. Distanto: Filter-based feature selection for rail defect detection; Machine Vision and Application, Springer, Vol.15, (179-185), 2004.
- [8] J-K. Kamarainen: Feature Extraction using Gabor filters; PhD dissertation, Lappeenranta University of Technology, Finland, 2003.
- [9] Y. Rubner, C. Tomasi: Perceptual metrics for image database navigation; Kluwer Academic Publishers 2004.
- [10] I. Guyon, J. Weston, S. Barnhill, V. Vapnik: Gene selection for cancer classification using Support Vector Machines; Machine Learning, Kluwer Academic Publishers, (389-422), 2002.
- [11] Y. Saeys, I. Inza, P. Larranaga: A review of feature selection techniques in bioinformatics; Bioinformatics Advance Access, 2007.
- [12] B. Scholkopf, A. Smola: Learning with kernels, Support Vector Machines, regularization, optimization and beyond; MIT Press, Cambridge, Massachusetts, London, 2002.