

Piotr Bojarczak, Piotr Lesiak

Wybrane zagadnienia diagnostyki wizyjnej toru kolejowego

Znaczący rozwój technologii wizyjnych, obejmujący zarówno sprzęt (kamery, serwery), jak również algorytmy obróbki i analizy obrazów, spowodował znaczące zwiększenie zainteresowania zastosowaniem tych technologii w diagnostyce toru kolejowego. Technologie wizyjne są szczególnie przydatne, a nawet niezbędne w przypadku detekcji wad powierzchniowych szyn. Zastosowanie w tym przypadku tradycyjnych metod diagnostycznych, bazujących na technice ultradźwiękowej, przynosi niedoskonałe rezultaty. Dlatego poszukuje się alternatywnych metod pozwalających na detekcje tego typu wad, czego przykładem może być metoda prądów wirowych, stosowana np. na kolejach niemieckich. Jednak jej praktyczne zastosowanie w systemach o znaczących prędkościach badania w trudnych warunkach, jakie panują na szlaku kolejowym, również powoduje określone ograniczenia. Stąd należy dążyć do zastosowania technologii w pełni bezkontaktowych, takich jak metody wizyjne.

Metody te można ponadto wykorzystać do detekcji uszkodzeń lub braku elementów mocujących szynę do podkładu. Zastosowanie tu wyrafinowanych technik bazujących na obróbce i analizie obrazów, wydaje się być jedynym rozwiązaniem pozwalającym na rozwiązanie tego problemu. Również diagnostyka stanu podkładów, obejmująca wykrywanie ich pęknięć, może zostać przeprowadzona na podstawie metod wizyjnych.

Dodatковым atutem tego typu metod jest ich duża szybkość działania, pozwalająca na analizę obrazów w trybie *on-line*. Jest to możliwe dzięki implementacji algorytmów w specjalizowanych procesorach sygnałowych (realizacja programowa algorytmu), bądź też w złożonych układach cyfrowych dużej skali integracji (ang. FPGA – *Field Programmable Gate Array*) – realizacja sprzętowa algorytmu.

Praktyczne wdrożenie metod wizyjnych w diagnostyce toru będzie miało istotny wpływ na poprawę bezpieczeństwa ruchu kolejowego, stąd też obserwuje się coraz większe zainteresowanie tą techniką badań przez zarządy kolejowe na świecie.

Przegląd stanu badań światowych w diagnostyce wizyjnej toru kolejowego

Zagadnieniem wizyjnej diagnostyki toru kolejowego zajmuje się wiele ośrodków badawczych na świecie, do których między innymi należą: University of Central Florida (USA), National Research Centre Bari (Włochy) oraz University of Dalarna (Szwecja) [1, 13, 18, 19, 20, 26]. Prowadzone badania obejmują następujące zagadnienia diagnostyczne:

- oceny powierzchni tocznej główki szyn,
- geometrii szyn (ang. *Measuring Track Gauge*),
- detekcji elementów mocujących szyny do podkładów,
- stanu podkładów,

- stanu podsypki.

W pracach National Research Centre Bari przedstawiono zastosowanie filtrów Gabora oraz transformaty falkowej do detekcji wad typu ang. *corrugation* [18]. Tego typu wady nie stanowią bezpośredniego zagrożenia dla bezpieczeństwa ruchu kolejowego, ale mają znaczący wpływ na jakość świadczonych usług transportowych (wibracje i hałas – „śpiewające szyny”), dlatego zjawiska te stanowią istotny problem badawczy.

Prace University of Central Florida prezentują zastosowanie metod wizyjnych zarówno do określania geometrii szyn, jak również do detekcji elementów mocujących szynę do podkładu [1]. W przypadku pomiaru geometrii szyny (konkretnie rozstawu szyn) wykorzystano metody bazujące na metodach gradientowych oraz transformacji Hough'a. W metodzie detekcji elementów mocujących szynę do podkładu wykorzystano filtry korelacyjne (ang. *template matching*), polegające na określeniu miary podobieństwa między uśrednionym obrazem wykrywanego elementu mocującego (obejmującym przypadki zaszumionej jego postaci) a fragmentami analizowanego obrazu. Przyjęto, że fragment obszaru w analizowanym obrazie, dla którego miara podobieństwa jest największa (przekracza pewien zadany próg), odpowiada położeniu elementu mocującego szynę do podkładu.

Inną metodę detekcji elementów mocujących szynę do podkładu przedstawiono w [19]. Wykorzystuje ona transformatę falkową wraz klasyfikatorem opartym o metodę *k*-najbliższych sąsiadów. Inne rozwiązanie zaproponowano w [20]. Wykorzystuje ona metodę przedstawioną w [21], do ekstrakcji cech na postawie których wykrywany (klasyfikowany) jest element mocujący. Do klasyfikacji wykorzystano prostą funkcję progową. Gdy wartości wyselekcjonowanych cech przekroczą pewien ustalony próg, to obszar charakteryzowany przez te cechy odpowiada wyszukiwanemu elementowi mocującemu.

Prace prowadzone w University of Dalarna dotyczą diagnostyki stanu drewnianych podkładów kolejowych [26]. Obejmują one metodę wykorzystującą filtr entropijny oraz sekwencję operacji morfologicznych wraz z klasyfikatorem opartym o sieć neuronową.


W pracy [13] przedstawiono metodę diagnostyki stanu podsypki. Zastosowano w niej metodę stereowizji (rekonstrukcji obrazu 3-D na podstawie obrazów pochodzących z odpowiednio umiejscowionych kamer 2-D) do określenia profilu podsypki. Na podstawie zmierzonego profilu, przeprowadzana jest diagnostyka stanu podsypki.

Wybrane badania w obszarze diagnostyki wizyjnej toru kolejowego prowadzone na UTH

Obecnie prowadzone na UTH (Uniwersytet Technologiczno-Humanistyczny w Radomiu) badania dotyczące wizyjnej diagnostyki toru kolejowego obejmują następujące zagadnienia:

- detekcję wad podkładów kolejowych [3, 4, 16],

- detekcję i klasyfikację wad powierzchniowych główki szyny typu *squat* oraz *head checking* [14, 15, 17],
 - ocenę stanu elementów mocujących szynę do podkładu [5].
- W artykule ograniczono się do algorytmu detekcji i klasyfikacji wad kontaktowo-naprężeniowych powierzchni tocznej szyny typu *squat*. Algorytm detekcji składa się z dwóch bloków (rys.1):
- ekstrakcji szyny, nazywany również ROI (ang. *Region of Interest*),
 - detekcji wad typu *squat* na podstawie pewnych charakteryzujących je cech.



Rys. 1. Efekt działania bloków ROI oraz detekcji wad typu *squat*

Blok ekstrakcji szyny z obrazu

Ekstrakcję szyny można potraktować, jako proces segmentacji (podziału) obrazu na pewne jego fragmenty (szynę, podkład oraz obszar zajmowany przez podsypkę). Istnieje wiele metod segmentacji [16], które można podzielić na cztery grupy:

- wykrywające krawędzie w obrazie, na podstawie których przeprowadza się segmentację [11], przy czym do wykrywania krawędzi wykorzystuje się najczęściej metody gradientowe;
- bazujące na statystykach pierwszego rzędu [25], w których w celu wyodrębniania w obrazie elementów, bada się rozkład jasności dla pojedynczego punktu z wykorzystaniem wartości średniej, wariancji lub entropii;
- bazujące na statystykach drugiego rzędu (tak zwane miary Haralick'a) [10], w których w celu wyodrębniania z obrazu elementów, bada się zależności między intensywnościami jasności dwóch znajdujących się w stałej odległości od siebie punktów;
- bazujące na analizie obrazu w wielu skalach (ang. *multi-resolution analysis*) [7], wykorzystujące do tego Piramidę Gaussa i Laplace'a lub transformację falkową.

Autorzy przetestowali każdą z tych grup pod kątem ich przydatności do ekstrakcji szyny oraz podkładu. Ze względu na to, że główka szyny może zawierać zarówno zanieczyszczenia, jak i różnych rozmiarów wady powierzchniowe, zastosowanie metod należących do pierwszej grupy nie daje satysfakcjonujących rezultatów. Zastosowanie metody wykorzystującej filtr entropijny (należący do drugiej grupy) do ekstrakcji podkładu przyniosło zadowalające rezultaty, tym niemniej ze względu na jej czasochłonność dla obrazów o dużej rozdzielczości (w analizowanym przypadku 1294×964) postanowiono znaleźć inne rozwiązanie pozwalające na znaczne przyspieszenie algorytmu ROI.

Podobnie, jak w przypadku filtra entropijnego, zastosowanie miar Haralick'a (trzecia grupa algorytmów) dawało zadowalające rezultaty, ale było bardziej czasochłonne od metody z filtrem entropijnym.

Najlepszymi z punktu widzenia zarówno dokładności, jak i szybkości segmentacji okazały się metody oparte o dwuwymiarową dyskretną transformację falkową (ang. *Two Dimensional Discrete Wavelet Transform – 2D DWT*), należące do czwartej grupy [6]. Dzięki tej transformacji istnieje możliwość analizy obrazu w tak zwanych wielu skalach, przy czym obraz o mniejszej skali zawiera elementy o większym rozmiarze niż obraz o większej skali. Własność ta może być wykorzystana do ograniczenia wpływu zabrudzeń oraz wad powierzchniowych występujących we fragmencie szyny, na dokładność procesu jej ekstrakcji.


W wyniku działania dyskretnej jednowymiarowej transformacji falkowej oryginalna funkcja $f(t)$ jest dzielona na dwie części [9]: $f_0(t)$ odpowiadająca przybliżonej postaci oryginalnej funkcji $f(t)$ oraz $g_0(t)$ odpowiadająca komponentowi zawierającemu wyższe częstotliwości, określonemu jako różnica między funkcjami $f(t)$ a $f_0(t)$. Komponent $f_0(t)$ może być ponownie podzielony na dwie części: $f_1(t)$ odpowiadającą przybliżonej postaci funkcji $f_0(t)$ oraz $g_1(t)$ odpowiadający różnicy między $f_0(t)$ a $f_1(t)$. Proces ten może być przeprowadzany w sposób ciągły do dowolnie założonego poziomu. Taki podział nazywany jest też poziomem dekompozycji.

W przypadku dwuwymiarowej dyskretnej transformacji falkowej obrazów, dla każdego poziomu dekompozycji transformacja ta wykonywana jest dwukrotnie: najpierw na wierszach obrazu, a następnie na jego kolumnach [9]. W wyniku tego każdy poziom dekompozycji generuje cztery podobrazy: $f_{LL}(x,y)$, $f_{LH}(x,y)$, $f_{HL}(x,y)$ i $f_{HH}(x,y)$. Podobrazy te reprezentują odpowiednio: podobraz wygładzony, podobraz zawierający drobne szczegóły o orientacji poziomej, podobraz zawierający drobne szczegóły o orientacji pionowej oraz podobraz zawierający drobne szczegóły o orientacji diagonalnej (nachylenie 45° w stosunku do osi poziomej). Dla każdego i -tego poziomu dekompozycji długość oraz szerokość odpowiadających jej podobrazów jest dwukrotnie mniejsza od długości i szerokości podobrazów uzyskanych dla $i-1$ poziomu.

Występującą w obrazie szyna ma orientację poziomą (odchylenie od poziomu $\pm 3^\circ$), stąd do jej ekstrakcji można wykorzystać podobrazy $f_{LH}(x,y)$ lub $f_{HL}(x,y)$. Zasadniczy wpływ na jakość procesu ekstrakcji ma prawidłowy wybór:

- rodzaju podobrazu $f_{LH}(x,y)$ lub $f_{HL}(x,y)$,
- poziomu dekompozycji,
- rodzaju użytej falki.

W celu określenia optymalnych parametrów transformacji falkowej wybrano w sposób losowy 600 zdjęć zawierających zarówno podkłady drewniane, jak i betonowe, częściowo lub całkowicie zasypane podsypką. Przykład zdjęcia zarejestrowanego kamerą zamontowaną na wagonie pomiarowym pokazano na rysunku 2.



Rys. 2. Przykład obrazu zarejestrowanego przez kamerę

Zdjęcia te stanowią podstawę w procesie wyboru parametrów. Po przeanalizowaniu tej grupy zdecydowano się na wybór podobrazu $f_{HL}(x,y)$, czwartego poziomu dekompozycji oraz falki typu bior1.1 [9]. Do określenia położenia szyny wykorzystano rozkład średniej wartości energii obliczonych dla kolejnych wierszy podobrazu $f_{LH}(x,y)$ uzyskanego dla poziomów dekompozycji od pierwszego do czwartego (rys. 3).

Średnia energia i -go wiersza dla podobrazu może być określona na podstawie następującego wyrażenia:

$$\hat{E}_i = \frac{1}{N} \sum_{j=1}^N x_{ij}^2 \quad (1)$$

gdzie:

x_{ij} – j -ty element i -tego wiersza (linii) podobrazu,
 N – długość i -tego wiersza, odpowiadającego długości podobrazu.

Każdy kolejny poziom dekompozycji usuwa szum oraz drobne zanieczyszczenia występujące na szynie, bez wpływu na kształt dużych elementów występujących w obrazie (w tym przypadku szyny). Wykorzystując czwarty stopień dekompozycji (rys. 3g) oraz odpowiadający mu średni rozkład energii wierszy podobrazu (rys. 3h), można określić współrzędne y szyny w tym podobrazie. Do określenia ich wykorzystano funkcję progową z progiem $T = 2100$. Wszystkie wiersze o średniej energii mniejszej od przyjętego progu należą do obszaru szyny.

Po określeniu położenia szyny w podobrazie dla czwartego poziomu dekompozycji, konieczne jest przetransformowanie indeksów wierszy szyny z tego podobrazu do współrzędnych y oryginalnego obrazu. Przekształcenie to zostało przeprowadzone na podstawie zależności:

$$y_{obrazu} = 2 \cdot 4 \cdot I_{wiersza} \quad (2)$$

gdzie:

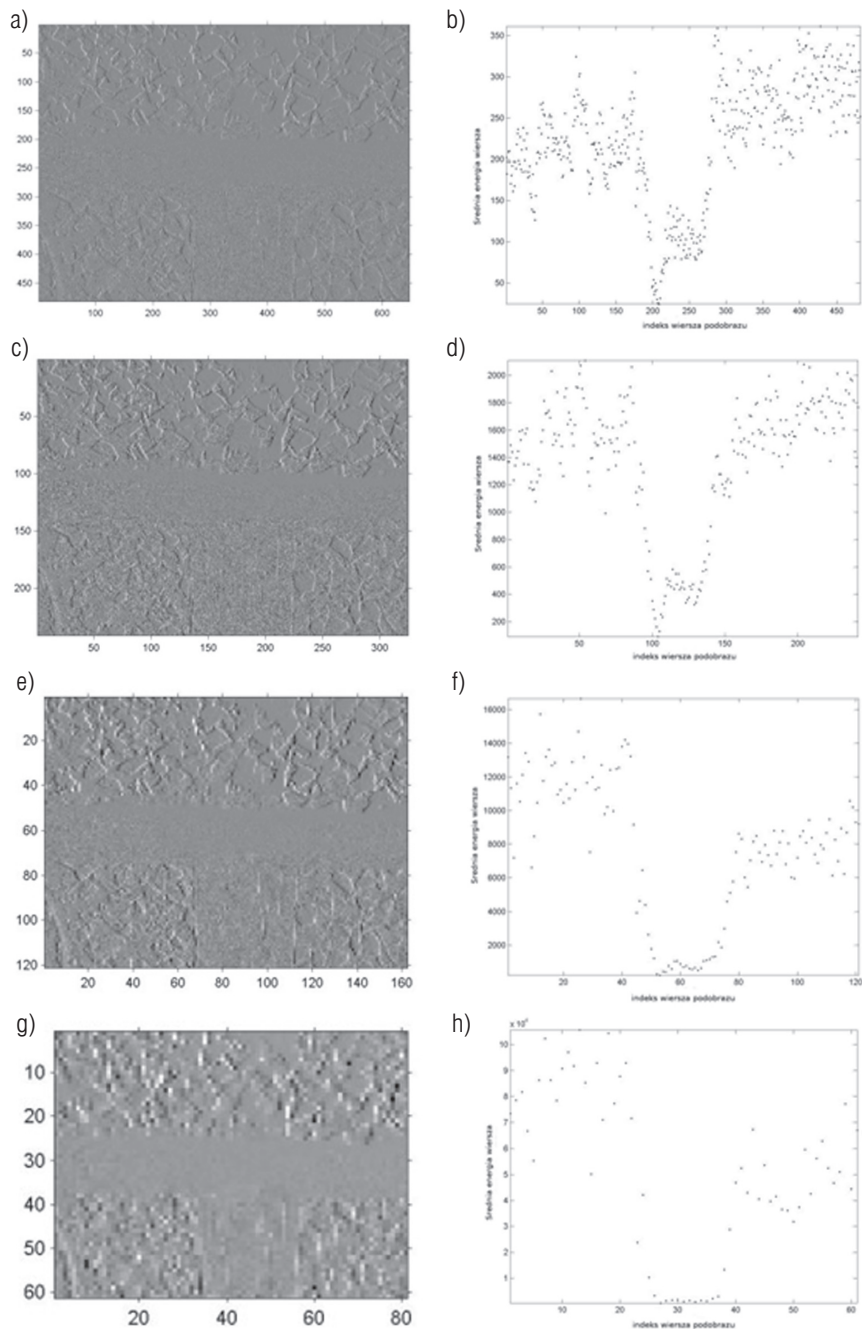
y_{obrazu} – współrzędna obrazu oryginalnego,
 $I_{wiersza}$ – indeks wiersza szyny z podobrazu uzyskanego dla czwartego poziomu dekompozycji,
 4 – czwarty poziom dekompozycji.

W efekcie uzyskano ekstrakcję szyny (rys. 4), gdzie dodatkowo oznaczono jej krawędzie.

Blok detekcji wad typu *squat*

W typowych obrazach, zadowalające rezultaty detekcji uzyskuje się stosując metody oparte na wykrywaniu krawędzi [11, 16], czy też filtry Cannygo [8]. Jednak występujące na szynie zabrudzenia o zmiennym kształcie oraz kierunku powodują, że metody te nie są w tym przypadku skuteczne (przykłady tego typu wad przedstawiono na rys. 5). Toteż zaproponowano algorytm, którego strukturę blokową przedstawiono na rysunku 6.

Detekcja tego typu wad może być potraktowana, jako proces klasyfikacyjny. Celem jego jest przydzielenie obiektu, na podsta-



Rys. 3. Podobrazy $f_{HL}(x,y)$ dla falki bior1.1 wraz z odpowiadającymi im rozkładami średniej energii ich wierszy: a) dla pierwszego poziomu dekompozycji, b) dla drugiego poziomu dekompozycji, c) dla trzeciego poziomu dekompozycji, d) dla czwartego poziomu dekompozycji

wie pewnych unikalnych jego cech, do jednej z dwóch grup: grupy zawierającej obiekty z wadami *squat* lub grupy obiektów nie zawierających takich wad. Proces ten obejmuje dwa etapy: ekstrakcję cech oraz klasyfikację. Etap ekstrakcji ma na celu wybranie unikalnych cech pozwalający na dyskryminację (rozróżnienie) między dwoma wymienionymi grupami obiektów. Do ekstrakcji cech został użyty bank n filtrów Gabora [12]. W tym celu rama (okienko) o stałym rozmiarze 172×132 (172 – długość, w której mieści się największa z rozpatrywanych wad, 132 szerokość główki szyny) jest przesuwana z krokiem, co jeden punkt po obrazie wycinka szyny uzyskanym w etapie ekstrakcji szyny. Dla każdego położenia ramy w obrazie przeprowadzana jest filtracja obrazu znajdującego się pod ramą przez bank n filtrów Gabora. Następnie każdy z n wyfiltrowanych obrazów poddawany jest nie-

liniowemu przekształceniu w postaci funkcji wartości bezwzględnej jego elementów. W następnym kroku dla każdego z uzyskanych w ten sposób obrazów obliczana jest ich wartość średnia μ , oraz wariancja σ . Po obliczeniu wartości μ oraz σ dla wszystkich n obrazów są one podawane na wejście klasyfikatora. Celem jego jest zaklasyfikowanie obrazu znajdującego się pod aktualnym położeniem ramy na podstawie odpowiadających mu n par (μ_i, σ_i) jako należącego do grupy obiektów zawierającej wady *squat* lub do grupy nie zawierającej wad typu *squat*.

Kluczowymi kwestiami mającymi decydujący wpływ na jakość procesu detekcji tych wad jest właściwy wybór:

- liczby n filtrów Gabora,

- parametrów dla każdego z filtrów,
- rodzaju klasyfikatora.

Ze względu na to, że występujące wady *squat* charakteryzują się zmiennym rozmiarem oraz kierunkiem względem osi poziomej, wydaje się, że zastosowanie filtrów Gabora do ekstrakcji cech powinno przynieść zamierzony rezultat. Są to filtry pasmowe umożliwiające wydobycie z analizowanego obrazu elementów (szczegółów) o zadanym rozmiarze oraz orientacji w stosunku do osi poziomej. Zarówno rozmiar analizowanego elementu, jak i jego orientacja może być określona poprzez prawidłowy wybór parametrów filtru Gabora [12].

Ze względu na tę zmienność rozmiaru oraz kierunku wad *squat*, konieczne będzie zastosowanie wielu filtrów do ich detekcji. Autorzy wykorzystali metodę zaprezentowaną w [22] do generacji n filtrów Gabora (nazywanych też bankiem filtrów), umożliwiających szczelne pokrycie zakresu częstotliwości, w jakich potencjalnie znajdują się wykrywane wady (z rozmiarem analizowanego elementu skojarzona jest odpowiadająca mu częstotliwość). Na podstawie tej metody wygenerowano bank 24 filtrów Gabora, pokrywających zakres częstotliwości od $F_l = 0,013$, do $F_h = 0,1$. Na rysunku 7 przedstawiono przekroje amplitudowych charakterystyk częstotliwościowych wyselekcjonowanych 24 filtrów Gabora.

Jeżeli detekcja tych wad zostanie potraktowana jako proces klasyfikacyjny, wówczas jego jakość zależy od prawidłowego doboru zarówno typu, jak i liczby cech charakteryzujących dwie grupy klasyfikowanych obiektów (obszary z wadami *squat* oraz obszary bez wad). Proces konstrukcji klasyfikatora polega na wygenerowaniu, wykorzystując dostępne dane reprezentujące zarówno grupę z wadami, jak i grupę bez wad, hiperpłaszczyzny separującej te dwie grupy w m wymiarowej przestrzeni cech. W tym przypadku maksymalny wymiar przestrzeni cech oznaczono jako:

$$M_{\max} = 24 \cdot 2 \quad (3)$$

gdzie:


24 – liczba filtrów Gabora,

2 – liczba cech (μ, σ) , uzyskanych dla każdego filtru Gabora.


Wówczas zadanie stawiane przed procesem selekcji cech będzie polegało na wyborze ze zbioru M_{\max} cech podzbioru o możliwie najmniejszej ich liczbie, zapewniającego najlepszą separację wymienionych dwóch grup danych (najmniejszą liczbę źle sklasyfikowanych obszarów szyny).

Metody selekcji cech można podzielić na dwie grupy:

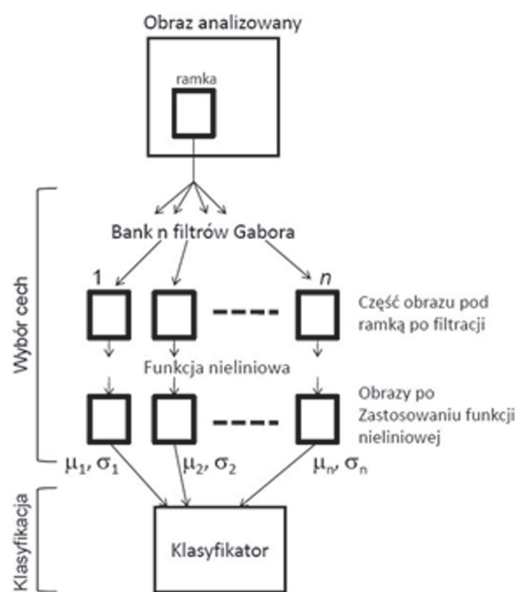
- niezależnych od rodzaju klasyfikatora (ang. *filter technique Feature Selection*) [23], w której stopień „dopasowania” poszczególnych cech do procesu klasyfikacji jest mierzony przy pomocy pewnej funkcji (niezależnej od rodzaju klasyfikatora), przyjmującej postać: entropii, T -statystyki; wadą tej metody jest to, że podczas wyboru cech nie uwzględnia ona wzajemnych relacji między nimi, jak również typu klasyfikatora;
- zależnych od rodzaju klasyfikatora (ang. *wrapper technique Feature Selection*) [27], w której stopień „dopasowania” poszczególnych cech do procesu klasyfikacji mierzony jest dla konkretnego typu klasyfikatora w oparciu o jego błąd klasyfikacji, zdefiniowany jako stosunek liczby źle sklasyfikowanych danych do całkowitej ich liczby; metody te w trakcie wyboru cech uwzględniają wzajemne ich relacje.




Rys. 4. Przykłady realizacji algorytmu ekstrakcji szyny



Rys. 5. Przykłady detekcji wad typu squat



Rys. 6. Schemat blokowy algorytmu detekcji wad typu squat



Rys. 7. Przekroje amplitudowych charakterystyk częstotliwościowych dla banku 24 filtrów Gabora

Autorzy przebadali obydwie grupy metod, ale w artykule przedstawiono jedynie metodę dającą najlepsze wyniki. Jest to metoda wyboru cech zależnych od rodzaju klasyfikatora. W tym przypadku funkcja badająca stopień „dopasowania” poszczególnych cech do procesu klasyfikacji określana jest poprzez błąd klasyfikacji użytego klasyfikatora [27]. Błąd ten jest określany, jako stosunek liczby błędnie sklasyfikowanych danych do całkowitej liczby danych podlegających klasyfikacji. Jako klasyfikator użyto sieci SVM (ang. *Support Vector Machine*) ze względu na teoretycznie najmniejszy błąd klasyfikacji [2, 24]. W procesie wyboru cech użyto 300 przykładów zdjęć fragmentów szyn zawierających wady *squat* oraz 300 przykładów zdjęć fragmentów szyn bez wady typu *squat*.

Na rysunku 8 przedstawiono zależność współczynnika klasyfikacji zdefiniowanego jako:

$$\text{współczynnik klasyfikacji} = (1 - \text{błąd klasyfikacji}) \cdot 100\% \quad (4)$$

od liczby wybranych cech dla sieci SVM z trzema rodzajami funkcji jąder: liniowym, gaussowskim oraz wielomianu trzeciego stopnia. W tym przypadku jako optymalne rozwiązanie należy uznać sieć SVM z funkcją jądra o postaci wielomianu trzeciego stopnia wraz z sześcioma wyselekcjonowanymi dla niej cechami.

Na rysunku 9 przedstawiono natomiast przykładowy obraz główki szyny po filtracji przez sześć filtrów wyselekcjonowanych przez wymieniony algorytm.


Po wyselekcjonowaniu 6 najistotniejszych cech, na podstawie których będzie wykonywana klasyfikacja obszarów szyny, przeprowadzany jest proces konstrukcji (uczenia) klasyfikatora, gdzie użyto sieci SVM. Jest to system przeprowadzający liniową separację w K -wymiarowej przestrzeni cech uzyskanej w wyniku nieliniowego rzutowania N -wymiarowej przestrzeni wejściowej (w przykładzie $N = 6$) za pomocą funkcji $\varphi(x)$. Postać hiperpłaszczyzny separującej uzyskanej w wyniku uczenia może być opisana następującą zależnością [24]:

$$y(x) w^T \varphi(x) + b = \sum_{j=1}^K w_j \varphi_j(x) + b = 0 \quad (5)$$


gdzie:

$w^T = [w_1, w_2, \dots, w_K]^T$ – wagi sieci,
 $\varphi(x) = [\varphi_1(x), \varphi_2(x), \dots, \varphi_K(x)]^T$,
 b – pewna stała.

Jeśli wektor wejściowy x spełnia zależność $y(x) > 0$, to należy do pierwszej grupy (grupy zawierającej obszary z wadą typu *squat*) w przeciwnym przypadku należy do drugiej grupy (zawierają-



Rys. 8. Zależność współczynnika klasyfikacji sieci SVM od liczby wybranych cech



Rys. 9. Efekt filtracji główki szyny filtrami Gabora wyselekcjonowanymi przez algorytm sekwencyjnego wyboru cech zależnych od rodzaju klasyfikatora

a) obraz główki szyny; b), c), d), e), f), g) obrazy po filtracji wyselekcjonowanymi filtrami Gabora

cej obszary bez wad *squat*). W praktyce zamiast funkcji $\varphi(x)$ wykorzystywana jest tak zwana funkcja jądra $K(x, x_i) = \varphi^T(x_i) \varphi(x)$.

Występują trzy jej postacie: liniowe, wielomianowe oraz Gaussowskie (radialne). Ponieważ 6 optymalnych cech uzyskano dla SVM z jądrem wielomianowym trzeciego stopnia, konstruowany klasyfikator będzie wykorzystywał również jądra tego samego typu.

W trakcie procesu uczenia (konstruowania hiperpłaszczyzny separującej) użyto 160 przykładów obszarów zawierających wady *squat* oraz 160 przykładów bez wad. Danych tych nie uwzględniano w procesie wyboru 6 optymalnych cech. Po nauczeniu sieci SVM jej działanie zostało sprawdzone na danych testujących (nieuczestniczących zarówno w wyborze optymalnych cech, jak i procesie uczenia). Dane te składały się z 147 przykładów wad *squat* oraz 161 przykładów bez wad. W tabeli 1, nazywanej też tablicą pomyłek dla klasyfikatora (ang. *Confusion Matrix*), przed-

stawiono liczbę mylnie sklasyfikowanych danych. Współczynnik poprawnie sklasyfikowanych wad dla tego systemu wyniósł 94%.

Tabela 1

Klasyfikator SVM z jądrem wielomianowym 3 stopnia oraz 6 cechami

	Sklasyfikowany jako obszar		Współczynnik klasyfikacji [%]
	z wadą	bez wady	
Obszar z wadą	134	13	94,4805
Obszar bez wady	4	157	

Wnioski

Zastosowanie dwuwymiarowej transformacji falkowej (analizy obrazu w wielu skalach) pozwoliło na precyzyjne określenie położenia szyny niezależnie od stany toru (rodzaju podkładu, stopnia jego pokrycia przez podsypkę), a przez to zwiększyło stopień wykrywalności wad tego typu. Zastosowanie banku filtrów Gabora wraz z algorytmem optymalnego wyboru cech zależnych od rodzaju klasyfikatora pozwoliło na znacząca redukcję ich liczby z 48 do 6, co w połączeniu z zastosowaniem klasyfikatora opartego o sieć SVM (potencjalnie zapewniającego najlepszą klasyfikację) umożliwiło stworzenie optymalnego algorytmu detekcji tego typu wad. Toteż zaproponowany algorytm wizyjnej detekcji wad typu *squat* pozwala na ich wykrywanie z dużym stopniem skuteczności, sięgającym 94%.



Literatura

[1] Babenko P.: *Visual Inspection of Railroad Tracks*. Ph.D dissertation, University of Central Florida, Orlando USA 2009.

[2] Bojarczak P., Lesiak P.: *SVM based classification method of railway's defects*. *Pomiary Automatyka Kontrola* 12/2007, s. 15–17.

[3] Bojarczak P., Lesiak P.: *Application of neural networks into automatic visual diagnostic of railway wooden sleepers*. Międzynarodowa Konferencja Naukowa Transport XXI w. Białowieża 2010. *Logistyka* 4/2010 (płyta CD).

[4] Bojarczak P., Lesiak P.: *Zastosowanie hybrydowej sieci neuronowej do klasyfikacji uszkodzeń drewnianych podkładów kolejowych*. *Prace Naukowe, Transport*, z. 78, s. 23–36, Politechnika Warszawska. Warszawa 2011.

[5] Bojarczak P., Lesiak P.: *Visual system diagnosing the state of elements fastening the rail to the sleepers*. *Pomiary Automatyka Kontrola* 12/2011, s. 1605–1607.

[6] Bojarczak P.: *Application of Wavelet Transform into Precise Localization of Railway Rail Edges in Visual Diagnostic of Track*. *Archives of Transport*, volume 24 issue 1, pp. 5–16. Warszawa 2012.

[7] Byung-Gyu K., Jae-Ick S., Dong-Jo P.: *Fast image segmentation based on multi-resolution analysis and wavelets*. *Pattern Recognition Letters*, vol. 24, pp. 2995–3006, 2003.

[8] Canny J.: *A computation approach to edge detection*. *IEEE Trans PAMI* vol. 8, pp. 679–698, 1986.

[9] Daubechies I.: *Ten lectures on wavelets*. SIAM Press, 1988.

[10] Haralick R.M., Shanmugam K., Dinstein I.: *Textural features for image classification*. *IEEE Trans. on Systems, Man and Cybernetics*, Vol. SMC-3, No 6, pp. 610–621, 1973.

[11] Jain A. K., Dubuisson M-P.: *Segmentation of X-Ray and C-Scan Images of Fiber Reinforced Composite Materials*. *Pattern Recognition*, vol. 25, no. 3, pp. 257–270, 1992.

[12] Kumar A., Pang G.K.H.: *Defect detection in textured materials using Gabor filters*. *IEEE Transactions on Industry Applications*, v.38, pp. 425–440, 2002.

[13] Labarile A., Stella E., Ancona N., Distance A.: *Ballast 3D Reconstruction by Matching Pursuit Based Stereo Matcher*. *IEEE Intelligent Vehicles Symposium Parma*, pp. 653–657. Italy, June 2004.

[14] Lesiak P., Bojarczak P.: *Application of wavelets and fuzzy sets to the detection of head-checking defects in railway rails*. *Transport Systems Telematics, 10th Conference, TST 2010. Communications in Computer and information Science* 104, pp. 327–334. Springer 2010.

[15] Lesiak P., Szumiata T.: *Skaterometria laserowa wad head checking w szynach kolejowych*. *Pomiary Automatyka Komputery w Gospodarce i Ochronie Środowiska* 2/2010, s. 25–28.

[16] Lesiak P., Bojarczak P.: *Przetwarzanie i analiza obrazów w wybranych badaniach defektoskopowych*. *Monograficzna seria wydawnicza Biblioteka Problemów Eksploatacji*. ITE Radom 2012, s. 185.

[17] Lesiak P., Wlazło M.: *Model optyczny skaterometrii laserowej wzorców wad powierzchniowych szyn kolejowych*. *Autobusy, Technika, Eksploatacja, Systemy Transportowe* 3/2013 (płyta CD).

[18] Mandriota C., Nitti M., Ancona A., Stella E., Distanto A.: *Filter base feature selection for rail defect detection*. *Machine Vision and Applications*, Springer-Verlag, pp. 179–185, 2004.

[19] Mazzeo P., Nitti M., Stella E., Distanto A.: *Visual recognition of fastening bolts for railroad maintenance*. *Pattern Recognition Letters*, vol 25, pp. 669–677, Elsevier 2004.

[20] Yang J., Tao W., Liu M., Zhang Y., Zhang H., Zhao H.: *An Efficient direction field-based method for detection of fasteners on high-speed railways*. *Sensors* vol. 11, pp. 7364–7381, 2011.

[21] Rao A.R., Jain R. C.: *Computerized Flow Field Analysis: Oriented Texture Fields*. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, vol 14, No 7, pp. 693–709, July 1992.

[22] Rubner Y., Tomasi C.: *Perceptual Metrics for image database navigation*. *Kluwer Academic Publishers*. Boston, 2000.

[23] Saeys Y., Inza I., Larranaga P.: *A review of feature selection techniques in bioinformatics*. *Bioinformatics Advance Access*, vol. 23, pp. 2507–2517, 2007.

[24] Scholkopf B., Smola A.: *Learning with Kernels, Support Vector Machines, Regularization, Optimization and Beyond*. MIT press, Cambridge, Massachusetts. London, England, 2002.

[25] Yanowitz S. D., Bruckstein A.M.: *A New Method for Image Segmentation*. *Journal of Computer Vision*. *Graphics and Image Processing*, vol. 46, pp. 82–95, 1989.

[26] Yella S., Dougherty M., Gupta N.K.: *Condition monitoring of wooden railway sleepers*. *Transportation Research Part C*, vol. 17, pp. 38–55, Elsevier 2009.

[27] Yu L., Liu H.: *Efficient feature selection via analysis of relevance and redundancy*. *Journal of Machine Learning Research*, 5(Oct), pp.1205–1224, 2004.

Piotr Bojarczak

Wydział Transportu i Elektrotechniki Uniwersytetu Technologiczno-Humanistycznego im. Kazimierza Pułaskiego w Radomiu

Piotr Lesiak

Wydział Transportu i Elektrotechniki Uniwersytetu Technologiczno-Humanistycznego im. Kazimierza Pułaskiego w Radomiu