

## DETEKCJA ZNAKÓW DROGOWYCH I KOLEJOWYCH NA ZDJĘCIACH I W CHMURZE PUNKTÓW – PRZEGLĄD ISTNIEJĄCYCH ALGORYTMÓW\*

### TRAFFIC AND RAILROAD SIGNS DETECTION IN IMAGES AND IN POINT CLOUD – OVERVIEW OF EXISTING ALGORITHMS

**Agnieszka Moskal, Elżbieta Pastucha**

AGH Akademia Górniczo-Hutnicza w Krakowie, Wydział Geodezji Górniczej i Inżynierii Środowiska,  
Katedra Geoinformacji, Fotogrametrii i Teledetekcji Środowiska

**Słowa kluczowe: znaki drogowe, znaki kolejowe, rozpoznawanie wzorca, detekcja znaków,  
klasyfikacja znaków**

Keywords: traffic signs, railroad signs, template recognition, sign detection, sign classification

## Wstęp

W ciągu ostatnich piętnastu lat automatyczna detekcja znaków, przede wszystkim na zdjęciach, ale i w chmurze punktów pozyskanej ze skaningu laserowego, stała się przedmiotem wielu badań. Opracowane algorytmy są najczęściej wykorzystywane do celów inwentaryzacyjnych oraz w systemach wspomagania kierowców. Wraz z szybkim rozwojem technologii pomiarowych i informatycznych można zaobserwować coraz więcej nowych, bardziej skutecznych rozwiązań.

Systemy wspomagania kierowców tworzone są w celu poprawy bezpieczeństwa uczestników ruchu. Informacje o ograniczeniach prędkości oraz o miejscach wymagających większej uwagi, takich jak: przejścia dla pieszych, przejazdy kolejowe lub oblodzenie na drogach, zwiększają komfort jazdy, który ma bezpośredni wpływ na obniżenie poziomu stresu kierowcy. Jednakże nadrzędnym celem takich systemów jest zminimalizowanie ludzkich błędów, które stanowią główne przyczyny wypadków. Ponieważ systemy te ostrzegają kierowcę o bezpośrednich zagrożeniach, powinny one pracować w czasie rzeczywistym. Niezbędne więc jest, aby działały szybko, na małym i możliwie niedrogim sprzęcie. Ponadto zebrane dane nie mogą zajmować zbyt dużo przestrzeni dyskowej. Podczas, gdy istniejące systemy

---

\*Prace zrealizowane w tym artykule zostały wykonane w ramach grantów dziekańskich: 15.11.150.129 oraz 15.11150.244, a także projektu badawczego nr 5.5.150.219.

wspomagania kierowców zawierają zazwyczaj jedną średniorozdzielczą kamerę, systemy do celów inwentaryzacyjnych mogą składać się z kilku precyzyjnych sensorów, takich jak: wysokorozdzielcze kamery bądź skanery laserowe. Systemy do inwentaryzacji tworzone są w celu kontrolowania stanu znaków drogowych i kolejowych oraz ich braku w wyznaczonym miejscu trasy. Oczywiście, wykorzystanie różnorodnych sensorów prowadzi zwykle do otrzymania dużej liczby danych i podniesieniu ich dokładności. W związku z tym, wymagają one urządzeń o dużej mocy obliczeniowej oraz przetwarzania danych w trybie *offline*.

Istnieje kilka problemów związanych z charakterystyką systemów opisanych powyżej. Z racji tego, iż obrazy pozyskiwane są na otwartej przestrzeni, ich jakość może być niska ze względu na różnorodne warunki pogodowe oraz zmienność oświetlenia. Dodatkowo, nagłe przesunięcia pojazdu pomiarowego wywołują gwałtowne zmiany jasności, które nie są wystarczająco szybko uwzględniane w parametrach automatycznej ekspozycji kamer. Należy wziąć również pod uwagę utrudnienia w detekcji, spowodowane przysłonięciem oraz skręceniem znaków w trakcie ruchu pojazdu, ich stanem: uszkodzeniem, zabrudzeniem czy zmianą kolorystyki związaną z upływem czasu.

Prawie każdy opracowany algorytm opiera się na charakterystycznych, wybranych cechach znaków, odróżniających je od innych obiektów. Do atrybutów tych należą proste geometryczne kształty oraz podstawowe kolory.

Rozwiązanie problemu detekcji znaków zależy od wielu czynników. Należy do nich typ urządzeń wykorzystanych do rejestracji danych, kategorie wykrywanych znaków oraz matematyczne rozwiązania zaimplementowane w algorytmie detekcji. Metody różnią się w zależności od celu jaki postawił przed sobą jego autor, typu znaków wziętych po uwagę oraz możliwego poziomu wszechstronności procedury.

## **Detekcja, rozpoznanie i klasyfikacja znaków – schemat postępowania**

Cały proces, mający na celu wykrycie znaków zarówno na obrazach, jak i w chmurze punktów, można podzielić na dwa zasadnicze etapy. Pierwszy prowadzi do wskazania prawdopodobnego położenia znaku oraz rozpoznania jego przynależności do odpowiedniej kategorii obiektów. Etapem drugim jest klasyfikacja, która pozwala określić rodzaj znaku wewnątrz grupy. Etapy te są oczywiście poprzedzane pozyskaniem danych. Nie jest to integralną część całego procesu, jednak typ zebranych informacji i ich liczba wpływa znacząco na kształt tworzonych algorytmów.

### **Pozyskanie danych**

Większość systemów opisanych w niniejszym artykule wykorzystuje niskorozdzielcze obrazy z kamery cyfrowej (Zakoluta et al., 2012; Gao et al., 2006; Ruta et al., 2009; Fang et al., 2004) lub kamery wideo zamontowanej w przedniej części pojazdu (Marmo et al., 2006). Można też spotkać wykorzystanie danych pochodzących z bardziej rozbudowanych systemów pomiarowych (Timofte et al., 2009; Arnoul et al., 1996; Chen et al., 2006).

Jeden z bardziej złożonych systemów pozyskiwania danych składał się z ośmiu kamer cyfrowych zamontowanych na dachu samochodu oraz jednostek GPS i INS (Timofte et al.,

2009). Liczba wykorzystanych sensorów oraz ich układ pozwolił na uzyskanie kompletnej informacji o otoczeniu drogi oraz o przestrzennym położeniu wykrytego znaku. Inny system (Chen et al., 2006) pozwalający na określenie lokalizacji znaków, składał się z kamery cyfrowej, dwóch skanerów laserowych oraz jednostki pozycjonującej. Pierwszy skaner profilował w zakresie 360°, drugi był skierowany do tyłu, rejestrując tylko powierzchnię drogi. Kamera cyfrowa została zamontowana na dachu pojazdu i skierowana zgodnie z kierunkiem jazdy. Georeferencję wynikom pomiaru zapewniał system GPS/IMU. Innym rozwiązaniem było zastosowanie sensorów, pozwalających na łatwiejszą identyfikację znaków przez wykorzystanie ich specyficznych cech. Przykładem jest posłużenie się właściwością silnego odbijania światła nocą przez znaki pokryte powłoką odbłaskową (Arnoul et al., 1996). Opisany system pomiarowy składa się z kamery cyfrowej, kamery NIR, halogenu promieniowania podczerwonego oraz systemu nawigacyjnego.

W przypadku tworzenia mechanizmu wykrywania znaków dla celów inwentaryzacji (w odróżnieniu od systemów wspomagania kierowców), określenie położenia przestrzennego obiektów jest niezbędnym elementem całego procesu. Jednak wyznaczenie georeferencji spotykane jest stosunkowo rzadko. Przykładem są trzy systemy opisane powyżej.

## **Detekcja znaku i określenie jego przynależności do grupy funkcyjnej**


Istnieje wiele sposobów określenia położenia znaku na zdjęciu, a następnie jego powiązania z daną grupą znaków. Najbardziej powszechnym jest dwuetapowa analiza bazująca na głównych cechach znaków: ich barwach oraz prostych geometrycznych kształtach. W przypadku obrazów cyfrowych, proces wykrywania rozpoczyna się od wyboru przestrzeni kolorów. Podstawą detekcji jest zwykle model RGB (Zakoluta et al., 2012; Timofte et al., 2009; Ninot et al., 2010). Ponieważ jest on wrażliwy na modyfikacje oświetlenia wywołane przez zmiany jasności oraz pojawianie się cieni, wykorzystywany jest także model HSV (Ruta et al., 2009) oraz model HSI (Fang et al., 2003; Marmo et al., 2006). Innym sposobem wykluczenia błędów, spowodowanych zmianami oświetlenia, jest zastosowanie modeli wizyjnych, które posłużyły Gao (Gao et al., 2006) do zbudowania deskryptorów kolorów. Autor w celu przejścia z przestrzeni kolorów CIE XYZ do LCH (*Lightness, Chroma, Hue*) użył modelu CIECAM97.

W następnym kroku przeprowadzany jest proces segmentacji, który przez dobór odpowiednich przedziałów progowania, pozwala ograniczyć przestrzeń poszukiwań do miejsc prawdopodobnego położenia znaku. Segmentacji może zostać poddany każdy ze składowych kanałów reprezentacji barw, pojedynczy kanał (Fang et al., 2003), kombinacja kanałów lub obraz uzyskany w wyniku relacji między wybranymi kanałami, gdzie jeden kolor wybierany jest jako referencyjny (de la Escalera et al., 1997). Niekiedy dokonuje się wzmocnienia koloru przez użycie filtrów chromatycznych i morfologicznych (Zakoluta et al., 2012), jak i transformacji kolorów (Ruta et al., 2009). Istnieje również metoda wykorzystująca drzewa czwórkowe (Gao et al., 2006). Inny sposób to automatyczny dobór odpowiednich progów segmentacji na podstawie histogramów (Marmo et al., 2006) lub wręcz zestawu progów przetwarzających iteracyjnie (Timofte et al., 2009). Jako wynik powyższych działań otrzymuje się dla każdego wybranego koloru obraz binarny.

Kształt i kolor znaku są ściśle związane z jego funkcją. Relacja kształtu i funkcji oraz uprzednio wyznaczone obrazy binarne dla wybranych kolorów, umożliwiają zakwalifikowanie znaku do określonej kategorii. Aby to wykonać wykorzystuje się kilka różnych metod. Jedną z nich opiera się na wykrywaniu wierzchołków znaków (de la Escalera et al., 1997). Rozpoznanie wykonywane jest przez analizę obrazu segmentacji zestawem masek, odrębnych dla każdej kategorii znaku. Na podstawie rezultatów wyodrębnienia wierzchołków oraz bazując na cechach geometrycznych znaków, wpasowane zostają odpowiednie kształty. Innym interesującym rozwiązaniem może być zastosowanie map krawędzi (Ruta et al., 2009). Zostają one utworzone przez przetworzenie obrazu prostym filtrem różnicowym, którego wynik poddany zostaje progowaniu. Dla każdego piksela, budującego krawędź na uzyskanej mapie, obliczane są wartości gradientu kierunkowego. Tak utworzona para: mapa krawędzi oraz mapa gradientów kierunkowych, zostaje przeanalizowana przez odpowiednie detektory regularnych poligonów. W wyniku przeprowadzonych operacji otrzymuje się zbiór kształtów znaków w predefiniowanych skalach. Kolejną metodą pozwalającą wykrywać kształty opiera się na histogramach zorientowanych gradientów wykorzystywanych jako deskryptory cech (Zakoluta et al., 2012). Technika ta zlicza wystąpienia zmian orientacji gradientu w określonych fragmentach obrazu. Deskryptory są następnie wykorzystane do uczenia liniowych klasyfikatorów SVM (Maszyna Wektorów Nośnych), każdy dla innej grupy znaków. SVM wymaga przygotowania treningowego zestawu danych. Jest to model uczenia nadzorowanego, stosowany do analizy danych pod kątem rozpoznawania wzorców. Tak przygotowane detektory pracują tylko w miejscach określonych przez maskę, weryfikując obecność odpowiedniego kształtu. Inne metody wykrycia kategorii znaku opierają się na obliczaniu histogramów orientacji i porównywaniu z wzorcowymi (Gao et al., 2006) lub prostym dopasowaniem wzorca (Marmo et al., 2006). Wykorzystanie dopasowania wzorca może być zastosowane jedynie w wysoko regularnym środowisku pomiarowym. Przykładem tego rodzaju środowiska jest torowisko kolejowe, gdzie zarówno ułożenie znaku jak i położenie systemu pomiarowego względem osi toru jest ściśle określone.

Inna, bardziej skomplikowana metoda wykrywania kształtu bazuje na kombinacji klasyfikatorów binarnych opartych na algorytmie Viola-Jones (Timofte et al., 2009). W algorytmie tym analiza wykonywana jest kaskadowo, najpierw jest realizowane przetwarzanie za pomocą klasyfikatorów AdaBoost, potem wykorzystywana jest maszyna wektorów nośnych (SMV) operująca na znormalizowanych kanałach RGB, następnie piramidy histogramów zorientowanych gradientów (HOG) i na końcu cechy Haar'a, wyodrębnione na podstawie AdaBoost (rys. 1). Proces powinien zakończyć się przyporządkowaniem każdego znaku do jednej z sześciu podstawowych klas. Interesującą w tej metodzie jest dodatkowa weryfikacja wykrytych znaków przez formułowanie hipotez przestrzennych. W oparciu o znaną orientację zewnętrzną każdego obrazu, wykryte obrazy znaków grupowane są według hipotezy, że przedstawiają ten sam obiekt. W kolejnej metodzie wykrywania znaków stosuje się sieci neuronowe (Fang et al., 2003). Wykorzystywane są one dwukrotnie, po raz pierwszy do stworzenia obrazu uwypuklającego miejsca zainteresowań na podstawie koloru, a następnie do obliczenia obrazu prezentującego hipotetyczne środki znaków na podstawie gradientów. W obu przypadkach użyte są sieci dwuwarstwowe, których warstwy na wejściu i wyjściu są obrazami o tym samym rozmiarze. Wyniki przetwarzania łączone są ze sobą w jeden obraz poprzez wnioskowanie rozmyte. Następnie na takiej mapie wyszukiwane są maksima, które zostają poddane progowaniu.

Metoda dwuetapowa jest jednym z podejść do problemu wykrywania znaków, jednak inne metody nie są już tak łatwe do sklasyfikowania. Można wyróżnić algorytmy wykorzystujące jedynie parametry kształtu, między innymi algorytm bazujący na wykorzystaniu obrazów gradientów (Loy et al., 2004). Cały proces opiera się na założeniu, że wszystkie obiekty posiadają regularny, symetryczny kształt. W pierwszym kroku obliczane są gradienty każdego piksela obrazu. Następnie obraz jest progowany tak, aby usunąć piksele o niskich wartościach. Każdy pozostawiony piksel „oddaje głos” na położenie środka znaku w odległości ‘r’ (rys. 4). Powstały w ten sposób obraz głosowania oraz obraz stworzony po znormalizowaniu kątów gradientów, po złączeniu tworzą obraz odpowiedzi, którego maksima wskazują położenie znaku. Wykrywanie przeprowadzane jest osobno dla serii promieni ‘r’ i serii poszukiwanych kształtów. Ponieważ znaki mogą być zarówno jaśniejsze jak i ciemniejsze od otoczenia, brane są pod uwagę gradienty z wartościami dodatnimi, jak i ujemnymi. Dodatkowo, w celu usunięcia obiektów liniowych, w zależności od poszukiwanego kształtu, wprowadzana jest wartość maksymalna długości linii.



**Rys. 4.** Proces „głosowania” pikseli o wysokich gradientach na położenie środka znaku (źródło: Loy et al., 2004)

Inne ciekawe podejście zakłada użycie algorytmu SIFT (*Scale – Invariant Feature Transform*) (Nassu et al., 2010). W metodzie wydobywania lokalnych cech na obrazach w odcieniach szarości, algorytm SIFT wykorzystany został do ekstrakcji rejonów o kształcie kolistym, jaśniejszych lub ciemniejszych niż ich otoczenie, dla jednego typu znaków kolejowych (rys. 2). Proces rozpoczyna się od gaussowskiego wygładzenia oraz uszeregowania obrazów w oktawy różniące się skalą. Następnie, jako wynik odjęcia sąsiadujących ze sobą obrazów, tworzona jest mapa odpowiedzi. Wskazywane są na niej lokalne ekstrema oraz przypisywane wartości orientacji gradientów, dla których budowane są deskryptory. Otrzymane w ten sposób elementy łączone są w klastry, wiązane następnie w jeden model. Podczas przetwarzania danych, cechy SIFT są wyodrębniane ze zdjęć i dopasowywane do zbiorów cech w modelu (rys. 2). Rozpoznawanie znaku odbywa się na podstawie podobieństwa rozmieszczenia punktów charakterystycznych na obrazach wzorcowych oraz na zestawie obrazów wykonanych w terenie.

Istnieje wiele koncepcji, których nie udało się zakwalifikować do grup powyżej wymienionych. Analizy mogą opierać się wyłącznie na kolorze, tak jak w metodzie wykorzystującej charakterystyczną wysoką odbliaskowość znaków (Arnoul et al., 1996). Oprócz klasycznej segmentacji po kolorze, wykonywana jest w niej również segmentacja dodatkowo pozyskanych obrazów NIR. Dzięki zastosowaniu halogenu NIR znaki powinny odznaczać się wysokimi wartościami jasności.

Niewiele algorytmów do wykrywania znaków przetwarza chmury punktów pozyskane ze skaningu laserowego. Jeden z nich wykorzystuje charakterystyczną, tablicową budowę znaków i ich położenie bezpośrednio nad jezdnią, bądź blisko jej krawędzi (Chen et al., 2006).

Detekcja poprzedzona jest wydzieleniem powierzchni drogi (na podstawie charakterystycznych nieciągłości występujących na jej krawędziach). Następnie wykonywane jest klasteryzacja punktów, leżących w bezpośrednim sąsiedztwie drogi, pod kątem przynależności do osobnych obiektów. Aby z powstałych w ten sposób grup wydobyć znaki, przeszukiwany jest rzut chmury na płaszczyznę XY. Ponieważ znaki jako elementy płaskie ustawione są pionowo, wykrywane są krótkie odcinki prostych uwidocznione w tym rzucie. Dalsza weryfikacja potencjalnych znaków wykonywana jest poprzez projekcję punktów na zdjęcia. Inna metoda, w której nie da się wydzielić poszczególnych etapów, wykorzystuje detektor Viola–Jones (Bahlmann et al., 2005). Składa się on z dwóch komponentów: wrażliwych na zmianę kolorów falków Haar’a oraz algorytmu AdaBoost. Drugi ze składników pełni podwójną rolę. Łączy kilka słabych klasyfikatorów przypisując im wagi w jeden silny, będący liniową kombinacją zwagowanych, słabych klasyfikatorów. Drugim zadaniem jest zbudowanie potencjalnych klasyfikatorów Haar’a. Dla każdego typu znaków konieczna jest budowa osobnego zestawu klasyfikatorów. Parametry klasyfikatorów: współrzędne względnego położenia, wysokość, szerokość, zapisywane są w postaci wektora. Dodatkowo do zestawu własności dodano cechę koloru będącą konkretnym kanałem przestrzeni kolorów RGB, obrazem mającym wartości znormalizowane lub obrazem w odcieniach szarości. Następnie algorytm AdaBoost tworzy jeden klasyfikator, który analizuje wszystkie obrazy. Wynikiem pracy tego detektora są przybliżone współrzędne położenia znaku oraz skala.

Ciekawe podejście do detekcji znaków wykorzystuje analogię do modelu rozpoznawania człowieka (Fang et al., 2004). Proces podzielony został na trzy etapy: sensoryczny, percepcyjny i koncepcyjny. Detekcja i rozpoznanie kategorii znaku wykonywane jest w pierwszych dwóch etapach. Na początku tworzony jest obraz podobieństwa poszczególnych pikseli do wzorcowych kolorów znaków. Jest on następnie przetwarzany przez sieć neuronową STA w celu utworzenia obrazu uwagi (*attention image*). Kombinacja obrazu oryginalnego i obrazu podobieństwa tworzy obraz krawędziowy. Dodatkowe ograniczenie przeszukiwania wprowadzane jest (na podstawie położenia kamery w pojeździe i typowego położenia znaku wobec jezdni) poprzez obraz preatencji (*preattention image*) (rys. 3).

Połączenie obrazów: krawędziowego, uwagi i preatencji, tworzy obraz zawierający jedynie kandydatów (rys. 3), wokół których tworzone są obrisy prostokątów, wskazujące na znak. Ponieważ znajdują się one często w bezpośrednim sąsiedztwie, ważne jest ich rozdzielanie. W tym celu piksele obrazu dzielone są na dwie kategorie: 1) plan – dla typowych kolorów znaków, 2) tło – dla pozostałych. Ze względu na typową budowę znaku (kolorowa obwódka i białoczarne wnętrze) weryfikacja hipotezy znaku i rozdzielanie grup następuje



Rys. 5. Rozdzielenie znaków w rejonach zainteresowań (źródło: Fang et al., 2004)

przez wydzielenie znaków jedynie w miejscach, gdzie piksele pierwszego planu otaczają piksele tła (rys. 5).


Rozpoznanie kategorii znaku wykonywane jest przez sieć neuronową CART. W pierwszym kroku wyodrębniane są cechy kategoryzujące wykryte znaki. Wskazują one na kolor i kształt znaku (z wykluczeniem wnętrza znaku). Cechy kategoryzujące wprowadzane są do sieci CART (kombinacja sieci ART2 z pamięcią długotrwałą LTM). W uproszczeniu, sieć neuronowa ciągle przystosowuje się do wprowadzanych danych, a LTM jest przeszukiwana pod względem wcześniej utworzonych wzorców. Znaki przyporządkowywane są do odpowiednich kategorii na podstawie odnalezionych szablonów.

## Klasyfikacja

Klasyfikacja to proces przypisania znaku do danego rodzaju w grupie funkcyjnej, na podstawie ideogramu. Istnieje wiele sposobów pozwalających poprawnie sklasyfikować wykryty znak. Część metod wykorzystuje wpasowanie wzorca (Chen et al., 2006), drzewa decyzyjne (Zakoluta et al., 2012; Paclík et al., 2000), znormalizowaną korelację krzyżową (Loy et al., 2004). Innym sposobem jest kombinacja przestrzennej lokalizacji obiektu i jego specyficznych atrybutów (Marmo et al., 2006). Podejście to jednak może być wykorzystane tylko w niewielkiej liczbie przypadków.

Drzewa decyzyjne są szeroko wykorzystywaną techniką klasyfikacji. W procesie tym stawiane są odpowiednio dobrane pytania dotyczące atrybutów zbioru elementów, które należy zakwalifikować do poszczególnych grup. Pytania zadawane są w węzle drzewa powodując rozgałęzienia, które symbolizują prawdopodobne odpowiedzi. Po każdej uzyskanej odpowiedzi zadawane jest kolejne pytanie do momentu, gdy będzie można określić przynależność obiektu do konkretnej klasy. Jedną z metod klasyfikacji znaków wykorzystuje K-wymiarowe drzewa decyzyjne i drzewa losowe (Zakoluta et al., 2012). Drzewo losowe to klasyfikator, który składa się z wielu małych drzew decyzyjnych. Drzewo rośnie, wykorzystując podzbiór próbek treningowych, wybranych w sposób przypadkowy. Również losowo dobierane są atrybuty w każdym węzle drzewa, które wraz z przedziałami progowania oraz maksymalnym współczynnikiem przyrostu informacji, dzielą zbiór danych na dwa podzbiory. Inna metoda wykorzystująca drzewa decyzyjne implementuje klasyfikatory Laplace'a w węzłach struktury (Paclík et al., 2000). Nieznane gęstości warunkowane przez klasy w twierdzeniu Bayes'a, stosowane w tradycyjnym podejściu, zastąpiono wartościami funk-

**Rys. 6.** Wydobywanie cech obiektu za pomocą modelu FOSTS:  
a – siatka modelu,  
b – obliczona orientacja segmentów  
(źródło: Gao et al., 2006)



cji gęstości na zamkniętym przedziale, które uzyskane są z niezależnego zestawu danych treningowych.

Klasyfikację można również wykonać z wykorzystaniem opisu cech kształtu za pomocą modelu FOSTS (rys. 6) (Gao et al., 2006). Na początku wyznaczany jest środek znaku na podstawie jego barwnej obwódki. Następnie tworzona jest siatka, składająca się z szesnastu półprostych i trzech okręgów o różnym promieniu, wszystkie o wspólnym początku, bądź z środkiem w centrum znaku. Powstaje w ten sposób 49 punktów przecięcia, w których obliczana jest orientacja opisujących obiekt segmentów. Na podstawie tych danych tworzone są wektory opisujące cechy kształtu znaku. Ostatecznie otrzymany wektor porównywany jest z wzorcem przetrzymywanym w bazie. Na podstawie podobieństwa znak zostaje sklasyfikowany.

Inny sposób powiązania potencjalnego znaku z rodzajem wewnątrz grupy funkcyjnej wykorzystuje obrazy 2-bitowe o barwach dyskretnych (Ruta et al., 2009). Fragmenty zdjęć zawierające prawdopodobny znak, otrzymane w wyniku detekcji, służą do utworzenia zestawu danych szablonowych. Są one odpowiednio przetwarzane do momentu uzyskania obrazów 2-bitowych. Zestaw badanych obrazów poddawany jest transformacji odległościowej w oparciu o cechę koloru. Jej celem jest stworzenie szablonu, uwzględniającego różnorodność wyglądu znaków, do porównywania wzorcowych obrazów znaków z analizowanymi. Następnie definiowane są lokalne rejony, dla których określa się stopień niepodobieństwa poszczególnych pikseli, przez uzyskanie uśrednionej odległości. Jej wskazanie możliwe jest przez analizę znormalizowanych wartości piksela obrazu poddanego transformacji odległościowej, w odniesieniu do atrybutu koloru dla tego samego piksela na obrazie o kolorach dyskretnych. Wskazanie regionów najlepiej charakteryzujących dany znak odbywa się przez maksymalizację sum otrzymanych lokalnych niepodobieństw.

Często wykorzystywaną metodą klasyfikacji obiektów jest sieć neuronowa. Jedną z takich metod wykorzystuje sieć CHAM (Fang et al., 2004). Na początku tworzony jest zestaw cech, który później zostaje wprowadzony do sieci. Wnętrze wykrytego znaku zostaje poddane binaryzacji na dwa sposoby. Pierwszy, w którym jasne kolory przyjmują wartość 1, a pozostałe 0, i drugi odwrotny. Oba obrazy wprowadzane są do sieci. Sieć CHAM składa się z dwóch warstw. Warstwa wejściowa jest macierzą 2D, której neurony są w pełni połączone z neuronami warstwy wyjściowej, będącej wektorem. Warstwa wyjściowa jest warstwą typu *winner take it all* i decyduje o klasyfikacji znaku. W tej metodzie konieczne jest stworzenie i wytrenowanie tylu sieci neuronowych ile jest branych pod uwagę kategorii znaków.

## Wnioski

Niniejszy artykuł prezentuje przegląd wybranych metod wykrycia, rozpoznania i klasyfikacji znaków drogowych oraz kolejowych. Na przestrzeni ostatnich 15 lat często zajmowano się tym problemem, a w wielu przypadkach – z sukcesem. W algorytmach zaimplementowano różne matematyczne i informatyczne rozwiązania o zróżnicowanym stopniu skomplikowania. Wybór taki wiązał się z problemem uniwersalności systemu lub też jego przeznaczeniem tylko dla wykrycia określonych znaków. Większość opisanych rozwiązań pomija aspekt położenia przestrzennego obiektów oraz jego dokładności. Jest to poniekąd skutek wykorzystania niskorozdzielczych sensorów podczas pobierania danych. Analizując powyższe metody nasuwa się wniosek, że w przyszłych badaniach należałoby zwrócić uwagę na



informację o lokalizacji odnalezionego obiektu, przez rozbudowanie istniejących algorytmów lub też stworzenie nowych. Rozwiązanie takie nie tylko pomoże rozwinąć jeszcze mało popularne systemy inwentaryzacji znaków, ale również pozwoli zasilić istniejące bazy danych.

### Literatura


- Aoyagi Y., Asakura T., 1996: A study on traffic sign recognition in scene image using Genetic Algorithms. Proceedings of the 1996 IEEE IECON. 22nd International Conference on Industrial Electronics, Control, and Instrumentation.
- Arnoul P., Viala M., Guerin J.P., Mergy M., 1996: Traffic signs localisation for highways inventory from video camera on board a moving collection van. Intelligent Vehicles Symposium, IEEE Proceedings: 141-146.
- Bahlmann C., Zhu Y., Ramesh V., Pellkofler M., Koehler T., 2005: A system for traffic sign detection, tracking and recognition using colour, shape and motion information. Intelligent Vehicles Symposium, IEEE Proceedings: 255-260.
- Chen Y., Zhao H., Nagai M., Shao X., Shibasaki R., 2006: A novel vehicle-borne system for traffic signs/signals extraction using laser scanners and CCD images. ITS World Congress, London, UK.
- de la Escalera A., Moreno L.E., Salichs M.A., Armingol J.M., 1997: Road traffic sign detection and classification. Industrial Electronics, *IEEE Transactions* vol. 44, issue 6: 848-859.
- Fang C.Y., Chen S.W., Fuh C.S., 2003: Road – sign detection and tracking. Vehicular Technology, *IEEE Transactions* vol. 52, issue 5: 1329-1341.
- Fang C.Y., Fuh C.S., Yen P.S., Cherng S., 2004: An automatic road sign recognition system based on a computational model of human recognition processing. *Computer Vision and Image Understanding* vol. 96, issue 2: 237-268.
- Gao X.W., Podladchikova L., Shaposhnikov D., Hong K., Shevtsova N., 2006: Recognition of traffic signs based on their colour and shape features extracted using human vision models. *Journal of Visual Communication and Image Representation*, vol. 17, issue 4: 675-685.
- Loy G., Barnes N., 2004: Fast shape – based road sign detection for a driver assistance systems. IEEE/R SJ International Conference on Intelligent Robots and Systems (IROS).
- Marmo R., Lombardi L., Gagliardi N., 2006: Railway sign detection and classification. IEEE Intelligent Transportation Systems Conference.
- Nassu B.T., Ukai M., 2010: Automatic recognition of railway signs using SIFT features. Intelligent Vehicles Symposium (IV), IEEE: 348-354.
- Ninot J., Smadja L., Heggarty K., 2010: Road sign recognition using a hybrid evolutionary algorithm and primitive fusion. *ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science* vol. 39, no. 3.
- Paclík P., Novovičová J., Pudil P., Somol P., 2000: Road sign classification using Laplace kernel classifier. *Pattern Recognition Letters*, v. 21 no. 13: 1165-1173.
- Ruta A., Li Y., Liu X., 2009: Real – time sign recognition from video by class – specific discriminative features. *Pattern Recognition*, v. 43, no. 1: 416-430.
- Timofte R., Zimmermann K., van Gool L., 2009: Multi-view traffic sign detection and 3D localisation. Applications of Computer Vision (WACV).
- Zakoluta F., Stanculescu B., 2012: Real-traffic sign recognition in three stages. Robotics and Autonomous Systems.

**Abstract**

*During the last fifteen years, automatic sign recognition in different type of data has become the subject of many studies. Reasons for these works fall into one of two categories: inventory purposes or drivers assistance systems. Depending on the purpose of the systems, various types of sensors, acquiring different type of data, are implemented. Due to their application, drivers assistance systems need small sensors, bringing limited amount of data, while systems for inventory purposes can use complex measuring systems, integrating different types of sensors and providing high accuracy and large volume data. The time is also at issue. Detection and classification of a sign in driver assistance systems has to be done in real time, while processing of data for inventory purposes can be done off-line. Also global positioning of identified signs is significant only in the latter systems. Structures of proposed algorithms vary and use many different concepts, both from math and information processing. In this paper, basic concepts of most important algorithms from the last fifteen years are presented. Data acquisition process and measuring systems are described shortly. Then, data pre-processing, concepts of detection and, finally, concepts of classification are broadly covered.*

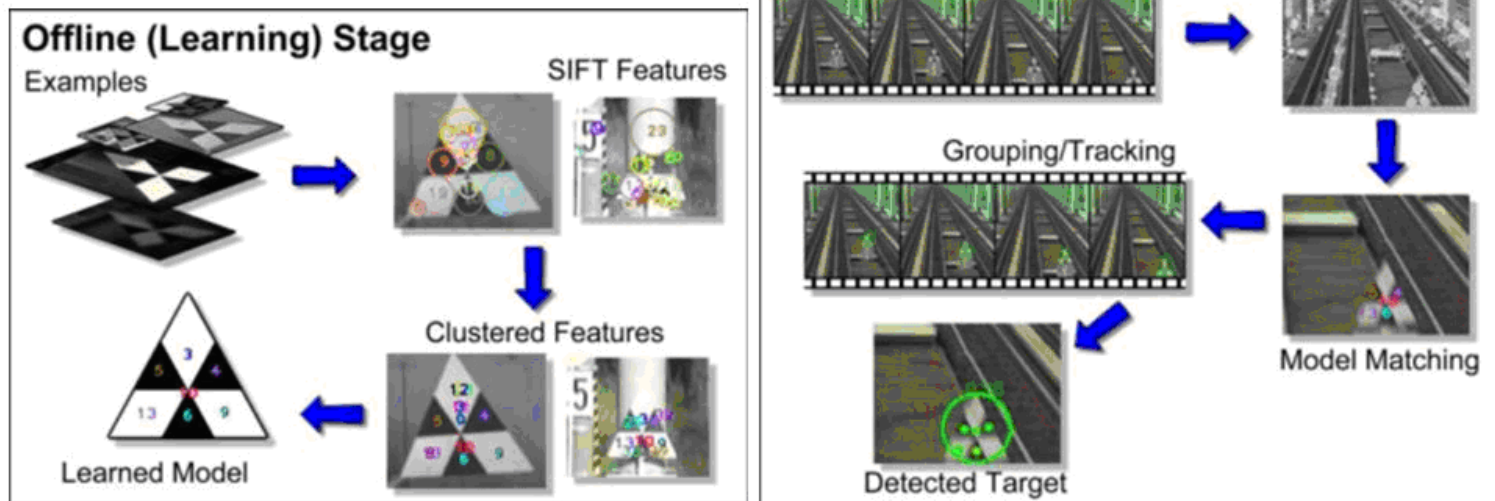
mgr inż. Agnieszka Moskal, doktorantka  
amoskal@agh.edu.pl  
tel. 12 617 3826




mgr inż. Elżbieta Pastucha, doktorantka  
epast@agh.edu.pl  
tel. 12 617 3993



Rys. 1: a - obraz oryginalny, b – obraz po segmentacji, c – łączenie fragmentów, d – wydzielone rejony zainteresowania (źródło: Timofte et al., 2009)

Rys. 2. Schemat proponowanego algorytmu SIFT (źródło: Nassu et al., 2010)





**Rys. 3:** a – obraz oryginalny, b – obraz uwagi, c – obraz zawierający hipotetyczne znaki, d – obraz preatencji, e – obraz uwagi z uwzględnionym obrazem preatencji, f – obraz zawierający hipotetyczne znaki z uwzględnionym obrazem preatencji (źródło: Fang et.al., 2004)