

## NADZOROWANA DETEKCJA TRAS KOMUNIKACYJNYCH Z WYKORZYSTANIEM METOD UCZENIA MASZYNOWEGO

### SUPERVISED ROAD DETECTION USING MACHINE LEARNING METHODOLOGY

Krzysztof Krawiec<sup>1</sup>, Ireneusz Wyczałek<sup>2</sup>

<sup>1</sup> Instytut Informatyki, Politechnika Poznańska

<sup>2</sup> Zakład Geodezji, Politechnika Poznańska

SŁOWA KLUCZOWE: detekcja, klasyfikacja, uczenie się z przykładów, uczenie nadzorowane

STRESZCZENIE: W pracy opisujemy nową metodę wykrywania drogowych tras komunikacyjnych na zobrażowaniu lotniczym lub satelitarnym. Proponowana metoda ma charakter strukturalny i bazuje na koncepcji profilu, rozumianego jako lokalny jednowymiarowy przekrój (rzut) obrazu. Tak rozumiane profile podlegają analizie poprzez ekstrakcję z nich cech zorientowanych na dyskryminowanie punktów reprezentujących drogi od punktów reprezentujących inne obiekty widoczne w obrazie. Cechy analizowane w proponowanej metodzie dobrane zostały do charakterystyki szlaków komunikacyjnych (głównie podłużny kształt); należą do nich m.in. wzajemne podobieństwo blisko zlokalizowanych profili o tej samej orientacji (ciągłość) oraz symetria. Dla polepszenia precyzji, profile obliczane są z wykorzystaniem próbkowania podpunktowego (*sub-pixel sampling*). W dalszych etapach przetwarzania metoda wykorzystuje algorytmy uczenia maszynowego (*machine learning*), w szczególności nadzorowane uczenie się z przykładów. Algorytm uczący się z przykładów dysponuje uczącą próbką pikseli, dla których przynależność do klas decyzyjnych (droga, nie-droga) jest znana. Informacja ta może być wprowadzona przez decydenta (eksperta) poprzez zaznaczenie wybranego obszaru obrazu reprezentującego szlak komunikacyjny, lub pochodzić z odpowiedniego modułu systemu informacji przestrzennej. Algorytm uczenia maszynowego pozyskuje wiedzę ze zbioru uczącego w procesie uczenia indukcyjnego. Wiedza ta jest następnie stosowana do klasyfikowania pozostałych punktów obrazu, dla których informacja ucząca nie jest znana. Ponadto, ponieważ wiedza ta jest wyrażona w dogodnej postaci drzewa decyzyjnego, może być poddana analizie przez eksperta (i potencjalnie skorygowana). Poza prezentacją metody praca zawiera opis jej implementacji komputerowej oraz eksperymentu obliczeniowego przeprowadzonego na rzeczywistym zdjęciu lotniczym terenu zabudowanego. Otrzymane wyniki dowodzą skuteczności proponowanego algorytmu i wskazują na użyteczność podejścia wykorzystującego uczenie maszynowe do analizy zdjęć lotniczych i obrazów satelitarnych.

### 1. WPROWADZENIE

System komunikacyjny traktowany jest często jako podstawowy szkielet topologiczny baz danych topograficznych. Wykorzystanie teledetekcji jako źródła danych do aktualizacji tych baz musi zatem uwzględniać procedury detekcji i wektoryzacji dróg i ulic w sposób

jak najbardziej zautomatyzowany (Heipke *et al.*, 2004). Aktualizacja baz danych nie tylko ma na celu gromadzenie danych o nowych lub zmienionych odcinkach dróg, ale także wykrywanie błędów w istniejących lub nowo tworzonych bazach (Baltsavias, 2004; Klang, 1998).

Aktualny stan prac w tej dziedzinie bazuje coraz częściej na wykorzystaniu obrazów satelitarnych o wysokiej rozdzielczości (Doucette *et al.*, 2004; Gao, Wu, 2004), których zaletą jest możliwość łączenia szczegółowego kanału PAN z kanałami barwnymi R, G, B oraz szczególnie użytecznym kanałem podczerwonym (Zhang, Wang, 2004). Algorytmy wykrywania dróg na tych danych są dopiero w fazie rozwoju i wciąż napotykają na szereg nowych problemów (Zhang *et al.*, 2006). Tradycyjne techniki fotointerpretacyjne bazujące na klasyfikacji nie dają zadowalających rezultatów, głównie z powodu niewielkich różnic spektralnych między nawierzchnią jezdni a piaszczystym lub betonowym poboczem oraz innymi szarymi obiektami w ich sąsiedztwie. Doucette *et al.*, 2004 proponują analizę głównych składowych przed zasadniczą klasyfikacją metodą największego podobieństwa. Coraz częściej jako źródło dodatkowej wiedzy wykorzystuje się istniejące bazy danych (Doucette *et al.*, 2004; Heipke, 2004), a także dane wysokościowe, w tym nowy pomiar lidarowy (Zhang *et al.*, 2006).

Coraz wyraźniej rysuje się taka strategia wykrywania dróg, która łączy tradycyjne metody klasyfikacji z procedurami specjalizującymi się w wykrywaniu krawędzi, obiektów liniowych i ich sieci (Hoverkamp, 2002), maskowaniu niechcianej informacji zakłócającej oraz modelach matematycznych dróg, z uwzględnieniem ich kategoryzacji i związanymi z tym dodatkowymi cechami, jak białe pasy rozdziału i inne znaki sygnalizacji poziomej. Opracowuje się techniki klasyfikacji uwzględniające trzeci wymiar. Znaczące są w tym zakresie osiągnięcia Zhanga C. *et al.*, 2005 oraz Zhanga Q., Couloigner, 2006.

W ramach niniejszej pracy podjęto próbę opracowania własnej techniki wykrywania ulic na wysokorozdzielczym obrazie z sensora QuickBird, na podstawie analizy profili spektralnych. W referacie opisano użytą procedurę i przedstawiono wyniki wstępnych prac.

## **2. PROPONOWANA METODA DETEKЦИИ DRÓG**

Metoda proponowana w niniejszej pracy bazuje głównie na spostrzeżeniu, iż drogi zarejestrowane na obrazie lotniczym lub satelitarnym charakteryzują się podłużnym kształtem, a charakterystyka przekroju poprzecznego drogi nie zmienia się w sposób nagły. Algorytm detekcji, omawiany w szczegółach w dalszej części tej sekcji, polega na systematycznej weryfikacji tej i pokrewnych właściwości dla poszczególnych punktów obrazu.

Działanie metody można podzielić na dwa etapy:


1. W pierwszym z nich, z każdego rozważanego punktu obrazu wyznaczany jest pewien zbiór cech, które w normalnych warunkach są w pewnym stopniu skorelowane z faktem występowania drogi w danej lokalizacji na obrazie.
2. W drugim etapie, cechy obliczone dla każdego punktu odwzorowywane są na decyzje przy pomocy metod uczenia maszynowego.

W kolejnych podsekcjach omówione zostaną odpowiednio oba te etapy.

## 2.1. Wyznaczanie cech z obrazu

Wyznaczenie cech dla pojedynczego punktu obrazu o współrzędnych  $P=(x,y)$  przebiega w sposób zilustrowany na rysunku 1. Wyznaczany jest odcinek  $P_1P_2$  o środku w punkcie  $P$ , długości  $l$  i kącie nachylenia  $\alpha$  względem dodatniego kierunku osi  $X$ . Parametry (jasności) punktów obrazu leżących na odcinku  $P_1P_2$  definiują *profil odniesienia*.

Następnie wyznaczany jest punkt  $Q$ , odległy od  $P$  o  $d$  w kierunku prostopadłym do odcinka  $P_1P_2$  (rys. 1). Punkt  $Q$  staje się podstawą wyznaczenia *profilu badanego*  $Q_1Q_2$ , w sposób analogiczny do tego, w jaki punkt  $P$  jest podstawą wyznaczenia profilu odniesienia. Zarówno kąty nachylenia jak i długości obu profili są takie same (odpowiednio  $\alpha$  i  $l$ ).



Rys. 1. Sposób wyznaczania profilu w proponowanym podejściu

Dalsze działanie metody polega na próbkowaniu rozkładu jasności punktów obrazu leżących pod profilem badanym i porównywaniu go z profilem odniesienia. Z racji dyskretnego charakteru obrazu rastrowego (mapy bitowej), odcinek wyznaczający profil przecina poszczególne punkty obrazu (piksele) w różnym stopniu. W szczególności, jeżeli założymy, że pojedynczy piksel jest kwadratem o boku długości 1, to pododcinek stanowiący część wspólną punktu obrazu i profilu może mieć długość od 0 do  $\sqrt{2}$ . Nieuwzględnienie tego faktu, tj. analizowanie w taki sam sposób wszystkich punktów obrazu, przez które przebiega profil, prowadziłoby do znacznych błędów próbkowania, zwłaszcza biorąc pod uwagę stosunkowo niewielką długość profilu stosowaną (w praktyce najwyżej kilkadziesiąt pikseli). Aby temu zapobiec, proponowana metoda przeprowadza próbkowanie podpunktowe (*sub-pixel sampling*), interpolując wartości profilu na podstawie sąsiednich punktów. Dla uproszczenia, poszczególne próbki profilu pobierane są w odległości 1; zatem profil o długości  $l$  jest wektorem składającym się z  $l$  wartości wypróbkowanych z obrazu.

W wariacie metody prezentowanym w tej pracy profil wyznaczany jest niezależnie dla wszystkich kanałów: czerwonego (R), zielonego (G), i niebieskiego (B). Niech  $r_P$ ,  $g_P$ , oraz  $b_P$ , oznaczają odpowiednio wektory (profile) odniesienia otrzymane w punkcie  $P$  dla kanałów czerwonego, zielonego, i niebieskiego. Analogicznie, profile badane wyznaczone w punkcie  $Q$  oznaczać będziemy odpowiednio  $r_Q$ ,  $g_Q$ , oraz  $b_Q$ . Załóżmy także, że elementy profili indeksowane są liczbami całkowitymi od  $-\lfloor l/2 \rfloor$  do  $\lfloor l/2 \rfloor$ .

Centralnym krokiem metody jest porównywanie profilu badanego  $Q_1Q_2$  z profilem odniesienia  $P_1P_2$ . Miara podobieństwa tych profili zdefiniowana jest następująco:

$$s(P, Q) = \frac{1}{1 + \frac{1}{h} \sum_{i=-\lfloor l/2 \rfloor}^{\lfloor l/2 \rfloor} (|r_{P,i} - r_{Q,i}| + |g_{P,i} - g_{Q,i}| + |b_{P,i} - b_{Q,i}|)} \quad (1)$$

gdzie symbol  $r_{P,i}$  oznacza  $i$ -ty element wektora  $\mathbf{r}_P$ , a  $h$  jest czynnikiem normalizującym dobranym tak aby unormować następujące po nim wyrażenie do przedziału  $[0,1]$ . Wartość  $h$  wynosi 765*l*, co wynika z obecności 3 kanałów i z faktu, że wartości profili na każdym z nich mogą się wahać od 0 do 255 ( $3 \times 255 = 765$ ). Przy powyższej definicji, podobieństwo  $s(P, Q)$  profilu odniesienia wystawionego w punkcie  $P$  oraz profilu badanego wystawionego w punkcie  $Q$  może przyjmować wartości od 0.5 przy ekstremalnie różnych profilach do 1.0 przy profilach identycznych.

Miara  $s$  wykorzystywana jest do pomiaru podobieństwa profili dla różnych kątów  $\alpha$ . Jeśli punkt  $P$  reprezentuje drogę, to, zakładając prawdziwość hipotezy o względnie stałej charakterystyce podłużnej drogi, dla pewnej wartości  $\alpha$  (równej w przybliżeniu lokalnej orientacji drogi pomniejszonej o  $90^\circ$ , patrz rys. 1), podobieństwo  $s(P, Q)$  powinno być znacząco większe od wartości  $s$  uzyskiwanych dla innych kątów. Algorytm porównuje profile dla wybranej liczby  $k$  równo odległych kątów  $\alpha$  ( $\alpha \in [0, 360^\circ)$ ,  $\alpha = 360^\circ i/k$ ,  $i = 0, \dots, k-1$ ) i wyznacza maksymalne podobieństwo profili (*Similarity*) oraz średnie podobieństwo profili (*MeanSimilarity*) dla wszystkich rozważanych wartości  $\alpha$ .

W trakcie prac nad algorytmem zdefiniowano także cechę *symetryczności* profilu. Motywacją dla przyjęcia tej cechy było oczywiste spostrzeżenie, iż w większości przypadków drogi są symetryczne względem osi jezdni. Stopień symetryczności, oznaczany dalej przez *Symmetry*, jest technicznie obliczany również przy pomocy miary  $s$ , poprzez zmierzenie nią podobieństwa profilu odniesienia  $P_1P_2$  i jego symetrycznego odbicia  $P_2P_1$ . Pomiar ten wykonywany jest dla tego kąta  $\alpha$ , dla którego wyznaczono maksymalne podobieństwo (*Similarity*), czyli dla spodziewanej (najbardziej prawdopodobnej) orientacji drogi.

Podsumowując, pełna lista cech obrazu dla badanego punktu  $P$  obejmuje:

- maksymalne podobieństwo profilu (*Similarity*),
- średnie podobieństwo profili dla wszystkich kątów  $\alpha$  (*MeanSimilarity*),
- stopień symetryczności profilu dla kąta  $\alpha$ , dla którego wyznaczono *Similarity* (*Symmetry*),
- średnią barwę profili, tj. średnią wartość składowych  $R$ ,  $G$ , i  $B$  dla próbek profilu (3 cechy).

Kompletny wektor wykorzystywany w tym podejściu składa się zatem z 6 cech.

Opisana wyżej procedura weryfikuje hipotezę obecności drogi w wybranym punkcie obrazu  $P$ . Lokalizacja dróg w całym obrazie wymaga wielokrotnego wywołania tej procedury dla wielu punktów obrazu; w skrajnym, najbardziej dokładnym wariancie, wszystkich punktów. Ponieważ analiza każdego punktu obrazu wymaga obliczenia profili dla wielu kątów  $\alpha$ , realizacja takich obliczeń może być bardzo czasochłonna. W przypadku, gdy czas pracy algorytmu byłby nie do zaakceptowania, możliwy jest kompromis polegający na wywołaniu procedury dla obrazu o zredukowanej rozdzielczości bądź tylko dla punktów w kracie zdefiniowanej przez przecięcia co  $n$ -tego wiersza i co  $n$ -tej kolumny.

Na przykład dla  $n = 2$ , oznacza to rozważanie jedynie punktów leżących na przecięciach, co drugiego wiersza i co drugiej kolumny obrazu; oznacza to orientacyjnie czterokrotne przyspieszenie obliczeń.

Dla zademonstrowania procesu obliczania cech, na rysunku 2 prezentujemy wizualizacje wartości wyżej omawianych cech dla przykładowego obrazu lotniczego. Rysunek zawiera, począwszy od lewej, obraz oryginalny, oraz, kolejno, wizualizacje cech *Similarity*, *MeanSimilarity*, oraz *Symmetry*. Intensywność występowania cechy w danym punkcie odzwierciedlona jest jego jasnością, gdzie kolor czarny odpowiada minimalnej wartości cechy, a kolor biały wartości maksymalnej. Prezentowany wynik został otrzymany dla następujących parametrów:  $l = 15$ ,  $d = 10$ ,  $n = 3$ , oraz  $k = 24$  (rozważane wartości kąta  $\alpha$  próbkowane co  $360^\circ/k = 15^\circ$ ).

## 2.2. Proces decyzyjny wykorzystujący uczenie maszynowe


Analizując przykładowe wyniki prezentowane na rysunku 2 łatwo zauważyć, że każda z obliczanych cech wykazuje pewien stopień korelacji (pozytywnej bądź negatywnej) z obecnością tras komunikacyjnych na obrazie źródłowym. Potwierdza to, zatem formułowane wcześniej hipotezy o przydatności tych cech do detekcji dróg. Z drugiej jednak strony żadna z wyznaczanych cech nie dyskryminuje dróg na tyle dobrze, aby w pojedynkę realizować cały proces decyzyjny. Niezbędna jest zatem pewna fuzja (synergia) cech. Nowatorski charakter niniejszej pracy polega na wykorzystaniu w tym celu podejścia charakterystycznego dla uczenia maszynowego.

Motyacją do zastosowania uczenia maszynowego na tym etapie wnioskowania są trudności, na jakie napotykamy próbując odwzorowywać wartości wyżej zdefiniowanych cech w zmienną decyzyjną metodami tradycyjnymi, np. regresją, w tym:

- znaczne zaszumienie danych wejściowych (wartości cech),
- skomplikowany, najczęściej nieliniowy i jedynie lokalny związek pomiędzy wartościami cech a zmienną decyzyjną,
- brak uniwersalności: ze względu na różną charakterystykę analizowanych zdjęć (warunki oświetleniowe i atmosferyczne, pora dnia, etc.), trudno jest wyznaczyć globalny model decyzyjny który działałby optymalnie dla dowolnych obrazów.

Metody uczenia maszynowego charakteryzują się cechami, które mogą, przynajmniej w pewnym stopniu, zniwelować wymienione tu trudności. Są one wysoce odporne na dane zaszumione i zdolne do modelowania nieliniowych i występujących tylko lokalnie w przestrzeni cech związków pomiędzy cechami a zmienną decyzyjną. Ponadto, dla większości metod, wygenerowanie modelu decyzyjnego (klasyfikatora) nie wymaga wysokich nakładów obliczeniowych. Nic nie stoi zatem na przeszkodzie aby, w skrajnym przypadku, generować model decyzyjny niezależnie dla każdego analizowanego obrazu.

Spośród szerokiego spektrum metodologii dostępnych w uczeniu maszynowym (Bolc *et al.*, 1992; Michalski *et al.*, 1994; Langley 1996; Cichosz 2000; Krawiec *et al.*, 2003), wykorzystaliśmy nadzorowane uczenie się z przykładów jako metodologię najbardziej odpowiednią dla potrzeb realizowanego procesu decyzyjnego. W podejściu tym system uczący się (zwany także algorytmem indukcji) pozyskuje wiedzę z danych reprezentowanych w postaci przykładów.



Rys. 2. Obraz źródłowy (a) oraz wizualizacja wyznaczonych z niego cech *Similarity* (b), *MeanSimilarity* (c), oraz *Symmetry* (d)

Przykładom tym w omawianym podejściu odpowiadają poszczególne punkty obrazu, dla których obliczone zostały cechy według prezentowanej wcześniej procedury. Cechy te

opisują poszczególne przykłady i zwane są w terminologii uczenia maszynowego *atrybutami*.

Paradygmat nadzorowanego uczenia się z przykładów zakłada ponadto obecność dodatkowego, tzw. sygnału uczącego, który w przypadku uczenia się z przykładów oznacza podział przykładów uczących na tzw. klasy decyzyjne. W naszym przypadku rozważane będą dwie klasy decyzyjne: pozytywna (obecność trasy komunikacyjnej) i negatywna (brak trasy). Z praktycznego punktu widzenia, sygnał uczący może być zadany przez eksperta lub pozyskany z modułu selekcji systemu informacji przestrzennej. W obu tych przypadkach, licznosc zbioru uczącego (tj. liczba punktów obrazu, dla których informacja o klasyfikacji jest znana) nie musi być znaczna. Istotniejsze jest natomiast, aby zbiór uczący był *reprezentatywny*, tj. zawierał piksele o charakterystykach zbliżonych do charakterystyce pikseli spoza tego zbioru.


Dla potrzeb niniejszej pracy wybraliśmy generator drzew decyzyjnych C4.5 jako algorytm indukcji (Quinlan, 1993). Ten popularny algorytm sprawdził się w wielu zastosowaniach praktycznych, jest odporny na dane zaszumione i produkuje wiedzę w czytelnej postaci, która może być zrozumiana, zweryfikowana, a nawet potencjalnie skorygowana przez eksperta. Algorytm C4.5 buduje drzewo decyzyjne posługując się metodą „z góry na dół” (*top-down*). W każdym węźle zbiór przykładów uczących dzielony jest na podzbiory stosownie do warunku nakładanego na wartości wybranego atrybutu (zawsze jednego w danym węźle). Wybór atrybutu w węźle odbywa się na podstawie analizy spadku entropii w wyniku partycjonowania przykładów uczących według jego wartości. Spośród dostępnych atrybutów wybierany jest ten, dla którego spadek ten jest największy. Proces budowania drzewa przebiega rekurencyjnie do momentu, gdy dalszy podział węzłów nie prowadzi do spadku entropii. Tak otrzymane drzewo jest następnie nieznacznie upraszczane (*prunning*) z wykorzystaniem pewnej miary statystycznej, ponieważ poszczególne końcowe partie drzewa (zwłaszcza liście) są zazwyczaj wspierane niewielką liczbą przykładów, zatem ich konfiguracja może być w znacznym stopniu przypadkowa, wynikająca z szumów obecnych w zbiorze uczącym. Szczegółowy opis algorytmu znaleźć można w (Quinlan, 1993).

Wnioskowanie na podstawie danych wygenerowanych tą metodą przebiega następująco:

1. Algorytm uczący generuje drzewo decyzyjne na podstawie zbioru uczącego.
2. Drzewo decyzyjne jest stosowane do pozostałych punktów obrazu (spoza zbioru uczącego) i klasyfikuje je.

### 3. EKSPERYMENT

W celu zweryfikowania przydatności niniejszej metody przeprowadzono eksperyment obliczeniowy na rzeczywistym zdjęciu lotniczym. W dalszej części pracy prezentujemy wybrane wyniki. Zostały one otrzymane przy wykorzystaniu autorskiego oprogramowania opartego na publicznie dostępnej bibliotece przetwarzania obrazów i widzenia komputerowego OpenCV (Open, 2001) (implementacja metod przetwarzania obrazu i ekstrakcji cech) oraz pakietu uczenia maszynowego WEKA (implementacja algorytmu C4.5) (Witten *et al.*, 1999). Przedmiotem eksperymentu był obraz prezentowany na rysunku 2.



Rys. 3. Obraz źródłowy z naniesionym przez eksperta zbiorem uczącym (a) oraz wynik detekcji przeprowadzonej proponowaną metodą (b)

Rysunek 3a prezentuje ten sam obraz źródłowy z zaznaczonym zbiorem uczącym wyznaczonym przez eksperta. Zbiór ten obejmuje 1 085 punktów, w tym 201 przykładów pozytywnych (żółte piksele w obrębie dróg) i 884 przykłady negatywne (4 białe prostokąty na pozostałym obszarze).

W dziesięciokrotnej walidacji krzyżowej (*cross-validation*) na zbiorze uczącym, algorytm C4.5 osiąga dla tego obrazu trafność klasyfikowania 98.43 %. W szczególności, popełnianych jest jedynie 1.1 % błędów fałszywie dodatnich (*false-positive errors*) i 3.5 % błędów fałszywie ujemnych (*false-negative errors*).

Rysunek 4 prezentuje, w reprezentacji tekstowej, drzewo decyzyjne wygenerowane algorytmem C4.5 z *wszystkich* przykładów (pikseli uczących) opisanych cechami zdefiniowanymi w sekcji 2.1. Kolejne poziomy drzewa sygnalizowane są wcięciami tekstu. Drzewo składa się z 25 węzłów, w tym 13 liści i wykorzystuje wszystkie zdefiniowane cechy poza składową czerwoną profilu (R). Każdy liść opatrzony jest etykietą klasy decyzyjnej przyznanej przez algorytm indukcji: *P* dla klasy pozytywnej, *N* dla negatywnej.



```

B <= 121.361: N (767)
B > 121.361
| Similarity <= 1.675
| | G <= 138.208
| | | Similarity <= 1.330: N (7)
| | | Similarity > 1.330: P (4)
| | G > 138.208472: N (52/1)
| Similarity > 1.675
| | MeanSimilarity <= 0.021
| | | B <= 139.478: N (21)
| | | B > 139.478
| | | | MeanSimilarity <= 0.016: N (4)
| | | | MeanSimilarity > 0.016: P (2)
| | MeanSimilarity > 0.021
| | | G <= 141.311
| | | | B <= 124.303
| | | | | G <= 132.949: P (14)
| | | | | G > 132.949: N (5)
| | | | B > 124.303: P (139)
| | | G > 141.311
| | | | B <= 131.227: N (26)
| | | | B > 131.227
| | | | | Symmetry <= 0.022: N (3/1)
| | | | | Symmetry > 0.022: P (41/1)
    
```

Rys. 4. Drzewo decyzyjne wygenerowane ze zbioru uczącego

Liczby w nawiasach umieszczone po każdym liściu podają liczbę przykładów uczących (pikseli) wspierających dany liść; opcjonalnie występująca liczba po znaku '/' wskazuje na liczbę przykładów błędnie skierowanych do danego liścia.

Zgodnie z postępowaniem opisanym na końcu sekcji 2, drzewo decyzyjne wygenerowane z przykładów uczących może być następnie zastosowane do pozostałych punktów obrazu. Wynik ewaluacji na zbiorze testującym prezentowany jest na rysunku 3b, gdzie piksele rozpoznane przez drzewo decyzyjne jako droga zostały zabarwione na biało. Uzyskany wynik dowodzi, że proponowane podejście, dzięki zastosowaniu uczenia maszynowego, ma zdolność uogólniania: wykryte zostały nie tylko fragmenty drogi, której części stanowiły zbiór uczący, lecz także inne drogi, o zauważanie innej charakterystyce nawierzchni, np. szeroka droga rozpoczynająca się od lewej krawędzi obrazu.

#### 4. WNIOSKI

W niniejszej pracy zaprezentowano metodę wykorzystującą podejście uczenia maszynowego, w szczególności algorytm indukcji drzew decyzyjnych C4.5, do detekcji dróg w zobrazowaniu lotniczym. Otrzymane wyniki wskazują na przydatność metodyki uczenia maszynowego jako narzędzia umożliwiającego dyskryminację punktów obrazu poprzez fuzję wielu cech.

Ubocznym efektem przeprowadzonych analiz jest dodatkowa informacja o przydatności poszczególnych atrybutów/cech do detekcji dróg. Umieszczenie blisko

korzenia drzewa i/lub częste występowanie w drzewie takich atrybutów jak składowa niebieska (*B*), maksymalne podobieństwo (*Similarity*), składowa zielona (*G*), i średnie podobieństwo (*MeanSimilarity*), wskazują na ich wysoką przydatność w tym zadaniu teledetekcji.

Warto podkreślić iż metoda opisywana w niniejszej pracy nadaje się do wykrywania dowolnych, podłużnych i zachowujących charakterystykę profilu, obiektów w obrazach. Adaptacyjne zdolności algorytmu, które zawdzięcza on wykorzystaniu uczenia maszynowego, umożliwiają niemal natychmiastowe zastosowanie go do, na przykład, wykrywania tras kolejowych i cieków wodnych.

## 5. LITERATURA

- Auclair-Fortier, M. F., Ziou, D., Armenakis, C., and Wang, S., 2001. Automated Correction and Updating of Road Databases from High-Resolution Imagery. *Canadian Journal of Remote Sensing*, Vol. 27 No.1, s. 76-89.
- Baltsavias, E.P., 2004. Objection extraction and revision by image analysis using existing geodata and knowledge: current status and steps towards operational systems. *ISPRS Journal of Photogrammetry & Remote Sensing*, 58, s. 129-151.
- Bolc L., Zaremba P., 1992. *Wprowadzenie do uczenia się maszyn*. Akademicka Oficyna Wydawnicza, Warszawa.
- Cichosz P., 2000. *Systemy uczące się*, WNT, Warszawa.
- Doucette, P., Agouris, P., Stefanidis, A., 2004. Automated Road Extraction from High Resolution Multispectral Imagery. *Photogrammetric Engineering & Remote Sensing*, Vol. 70, No. 12, December 2004, s. 1405-1416.
- Gao, J. and Wu, L., 2004. Automatic Extraction of road networks in urban areas from Ikonos imagery based on spatial reasoning. *Proc. ISPRS XXth Congress*, Istanbul, 12-23.07.2004.
- Haverkamp, D., 2002. Extracting straight road structure in urban environments using Ikonos satellite imagery. *Optical Engineering*, 41(9), s. 2107-2110.
- Heipke, C., Pakzad, K., Willrich, F., Peled, A., 2004. Theme Issue: Integration of Geodata and Imagery for Automated Refinement and Updating of Spatial Databases (Editorial). *ISPRS Journal of Photogrammetry & Remote Sensing*, 58, s. 127-128.
- Klang, D., 1998. Automatic Detection of Changes in Road Databases Using Satellite Imagery. *International Archives of Photogrammetry and Remote Sensing*, Vol. 32, Part 4 "GIS-Between Visions and Applications", Stuttgart, 1998, s. 293-298.
- Krawiec, K., Stefanowski, J., 2003. *Uczenie maszynowe i sieci neuronowe*. Wydawnictwo Politechniki Poznańskiej, Poznań.
- Langley P., 1996. *Elements of machine learning*. Morgan Kaufmann, San Francisco.
- Michalski R.S., Tecuci G. (red) 1994. *Machine learning: a multistrategy approach*, Vol. 4, Morgan Kaufmann, San Francisco.
- Open Source Computer Vision Library: Reference Manual, 2001.
- Quinlan J.R., 1993. *C4.5: Programs for Machine Learning*. Morgan Kaufmann, San Francisco.
- Witten I.H., Frank E., 1999. *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. Morgan Kaufmann, San Francisco.
- Zhang Q., Couloigner I., 2006. Automated road network extraction from High Resolution Multi-spectral Imagery. *Proc. ASPRS Annual Conference*, Reno, Nevada, 1-5.05.2006,

Zhang C., Baltsavias E., O'Sullivan L., 2005. Performance evaluation of ATOMI system for road database updating from aerial film, ADS40, Ikonos and Quickbird orthoimagery. Proc. ISPRS Workshp CMRT 2005 Object Extraction for 3D City Models, Road Databases and Traffic Monitoring - Concepts, Algorithms and Evaluation, Vienna, 29-30.08.2005

Zhang, Y. and Wang, R., 2004. Multi-resolution and Multi-spectral Image Fusion for Urban Object Extraction. *Proceedings of ISPRS XXth Congress*, Istanbul, 12-23.08.2004.

Praca została wykonana w ramach grantu KBN nr 4T12E 016 26 realizowanego w latach 2004-2007.

### **SUPERVISED ROAD DETECTION USING MACHINE LEARNING METHODOLOGY**

**KEY WORDS:** object detection, satellite and aerial imagery, classification, learning from examples, supervised learning

#### **Summary**

This paper presents a novel method of road detection in aerial and satellite imaging. This structural method is based on the concept of *profile*, meant as a local one-dimensional cross-section (cast) of raster image. We acquire such profiles from the image at different orientation angles and extract from them features well discriminating road pixels from non-road pixels. In particular, we use feature definitions tailored to road characteristics (mostly elongation); these include, among others, mutual similarity of close and equally orientated profiles (road continuity) and symmetry. To improve the precision of analysis, the method computes profiles using sub-pixel sampling.

The further part of processing relies on machine learning, in particular, on supervised learning from examples. The algorithm is given a training sample of pixels, for which the decision class assignment (road, non-road) is known. This information may be manually entered by a decision maker (expert) by marking image regions representing road fragments, or alternatively, it may be retrieved from an appropriate module of a geographical information system. Given that information, the algorithm acquires the knowledge from training examples, performing so-called "inductive" learning. That knowledge may be then used to classify the remaining image pixels, for which the decision class assignment is not known. Moreover, the knowledge may be inspected (and potentially corrected) by the decision maker, as it is expressed in a readable form of a decision tree.

The paper presents the algorithm in detail, describes its computer implementation, and demonstrates its application to an aerial image of urban area. The obtained results demonstrate the good performance of the method and indicate the usefulness of machine learning approach in analysis of aerial and satellite imagery.

Dr hab. inż. Krzysztof Krawiec  
e-mail: krawiec@cs.put.poznan.pl  
tel.+61 6652933

Dr inż. Ireneusz Wyczałek  
e-mail: ireneusz.wyczalek@put.poznan.pl  
tel. +61 6652 420