

MAZUREK Przemysław¹
OKARMA Krzysztof¹

Superrozdzielczość ze znanego ruchu kamery do śledzenia ruchu pojazdu z wykorzystaniem algorytmu Spatio-Temporal Track-Before-Detect

Inteligentne Systemy Transportowe,
Wizyjne śledzenie ruchu,
Superrozdzielczość

Streszczenie

W artykule przedstawiono metodę wykorzystania algorytmu superrozdzielczości dla pojedynczej kamery rejestrującej obraz drogi. Pojazdy o rozmiarze mniejszym od jednego piksela pobudzają cały piksel, przez co estymacja ich położenia i prędkości jest utrudniona. Wykorzystanie algorytmu Spatio-Temporal Track-Before-Detect (ST-TBD) pozwala na śledzenie obiektów subpikselowych, jednak istnieją takie trajektorie, dla których estymacja subpikselowa nie jest możliwa. Zaproponowane rozwiązanie bazuje na kamerze, która jest nieznacznie przesuwana w pionie i poziomie w celu rejestracji obrazu sceny pozwalającego na osiągnięcie efektu superrozdzielczości w celu dokonania fuzji danych w przestrzeni stanu. W artykule przeanalizowano konfigurację śledzenia 1D odpowiadającego najgorszej możliwej trajektorii. Dla 40 różnych prędkości obiektu wyznaczono średni błąd położenia bezwzględnego dla systemu z algorytmem ST-TBD oraz z tym samym algorytmem wspomaganym dodatkowym filtrem. Rozwiązanie drugie bazujące na hierarchicznym śledzeniu pozwoliło na ponad dwukrotne zmniejszenie średniego błędu maksymalnego oraz uzyskanie trzykrotnie mniejszego błędu średniego.

SUPER-RESOLUTION FROM KNOWN CAMERA MOTION FOR VEHICLES' TRACKING USING SPATIO-TEMPORAL TRACK-BEFORE-DETECT ALGORITHM

Abstract

In the paper a method for application of the super-resolution algorithm for a single camera recording the road traffic is presented. Vehicles corresponding to the objects with size smaller than a single pixel stimulate the whole pixel, so the estimation of their location and velocity is troublesome. Using the Spatio-Temporal Track-Before-Detect (ST-TBD) algorithm it is possible to track the sub-pixel objects but there are some trajectories for which the sub-pixel estimation is not possible. Proposed solution is based on the slightly moving camera (horizontally and vertically) in order to record the images allowing to obtain the super-resolution effect and data fusion in the state space. In the paper the 1D tracking configuration has been analysed corresponding to the worst possible trajectory. The mean absolute error of location has been calculated for 40 different object's velocities both for ST-TBD algorithm with and without additional filtering. The second solution based on the hierarchical tracking allows for more than double reduction of the average maximum error and three times less average error.

1. WSTĘP

Inteligentne Systemy Transportowe (ITS) wymagają znacznych nakładów finansowych zarówno na ich uruchomienie, jak również utrzymanie. Wykorzystanie kamer wideo [6,9] pozwala na redukcję liczby czujników drogowych oraz umożliwia rezygnację z ingerencji w nawierzchnię drogi. Zasięg pracy tego typu sensorów jest jednak zależny od warunków atmosferycznych oraz wykorzystanych algorytmów. Algorytmy przetwarzania obrazów oraz śledzenia ruchu pozwalają w zależności od ich doboru na pracę w małej, jak też i większej odległości od kamery. Zwiększenie odległości pozwala na efektywniejszą pracę ITS z uwagi na możliwość przewidywania sytuacji, jaka będzie występować w określonym czasie w sąsiedztwie sensora zainstalowanego np. przy skrzyżowaniu, co pozwala na poprawę jego przepustowości. Zastosowanie kamer ograniczone jest zakłóceniami atmosferycznymi, co jest poważną wadą, jednak wykorzystanie algorytmów śledzenia przed detekcją (Track-Before-Detect - TBD) pozwala w pewnym stopniu na zwiększenie zasięgu pracy w porównaniu do istniejących obecnie systemów przetwarzania obrazu wideo. Algorytmy TBD pozwalają na śledzenie sygnału, który jest ukryty w szumie, przy czym szumem tym może być szum przetwornika obrazu lub też zakłócenia obrazu [1,3].

Konwencjonalne systemy śledzenia wykorzystują detekcję i śledzenie, jednak rozwiązanie to nadaje się wyłącznie do sytuacji, gdy sygnał jest powyżej szumu tła. Ponieważ zawsze istnieją zakłócenia, algorytm detekcji będzie wykrywał zbyt dużo poruszających się obiektów. Im niżej będzie ustawiony próg detekcji, z uwagi na niski poziom sygnału obiektu, tym więcej tego typu detekcji będzie miało miejsce. W celu redukcji wpływu fałszywych detekcji oraz zagubienia detekcji prawdziwego obiektu stosowany jest algorytm estymacji ruchu bazujący na predyktorze. Predyktor pozwala

¹ Wyższa Szkoła Techniczno-Ekonomiczna w Szczecinie, Wydział Transportu Samochodowego;
71-244 Szczecin; ul. Klonowica 14. Tel: +48 91 424-08-75, Fax: +48 91 424-08-76 E-mail: mazurek@wste.szczecin.pl, okarma@wste.szczecin.pl

na przewidzenie położenia obiektu na podstawie założonego modelu ruchu, dzięki czemu możliwe jest określenie, która obserwacja po detekcji dotyczy może obiektu. Zwykle stosuje się technikę bramkowania (inaczej okienkowania), które powiązana jest z przewidywanym położeniem. Pozwala to na redukcję poszukiwań do mniejszego obszaru i tym samym eliminację dużej liczby fałszywych detekcji. Algorytmy śledzenia, takie jak np. filtr Kalmana, pozwalają dodatkowo na dynamiczną zmianę obszaru okienka. W wypadku, gdy trzeba śledzić więcej niż jeden obiekt konieczne jest zastosowanie dodatkowego algorytmu przydziału, na ogół współpracującego z algorytmem śledzenia. Obserwacje (detekcje) muszą być przydzielone do właściwych ścieżek (trajektorii) ruchu obiektów. Zadanie to może być bardzo złożone obliczeniowo [2].

Ponieważ konwencjonalne techniki śledzenia nie radzą sobie w wypadku ginięcia sygnału w szumie, konieczne jest zastosowanie jedynej możliwej techniki bazującej na zamianie kolejności operacji. Zamiast wykonywać detekcję a następnie śledzenie, konieczne jest wykonanie najpierw śledzenia, a potem detekcji. Oznacza to, że każdą potencjalną trajektorię należy przyjąć za możliwą i wykonać śledzenie obiektu, a następnie po pewnej liczbie kroków przeanalizować trajektorie pod kątem takich, które mają odpowiednio wysoką wartość prawdopodobieństwa. Zadanie TBD polega w najprostszym przypadku na wykorzystaniu akumulacji wartości sygnału wzdłuż możliwych trajektorii. Największa wartość będzie wówczas odpowiadała najbardziej prawdopodobnej trajektorii. Wielokrotne sumowanie (lub inna liniowa operacja filtracji dolnoprzepustowej) pozwala na redukcję szumu, zatem w wypadku zakłóceń o charakterze gaussowskim, zakłócenia te po uśrednieniu będą miały wartość bliską zero. Obecność sygnału o wartości większej niż zero będzie wykryta poprzez stwierdzenie, że wartość średnia znacznie różni się od zera.

Wadą algorytmów TBD jest jednak gigantyczny koszt obliczeniowy w porównaniu do rozwiązania klasycznego, ponieważ liczba trajektorii jest typowo opisana liczbą pikseli obrazu przemnożoną przez liczbę wektorów ruchu. Dla każdej z tych trajektorii musi być wyznaczona estymata według odpowiedniego wzoru. Dla podejścia konwencjonalnego liczba trajektorii jest równa liczbie obiektów śledzonych.

2. ALGORYTM SPATIO-TEMPORAL TRACK-BEFORE-DETECT

Algorytm ten realizuje wyczerpującą analizę wszystkich trajektorii opisanych macierzą Markowa. Jego postać rekursywna jest przedstawiona za pomocą poniższego pseudo-algorytmu:

Start

$$P(k=0, s) = 0 \quad //inicjalizacja \quad (1a)$$

For $k \geq 1$

$$P^-(k, s) = \int_S q_k(s | s_{k-1}) P(k-1, s_{k-1}) ds_{k-1} \quad //korekcja ruchu \quad (1b)$$

$$P(k, s) = \alpha P^-(k, s) + (1 - \alpha) X(k, s) \quad //korekcja informacji \quad (1c)$$

EndFor

Stop

gdzie:


- k – numer iteracji,
- s – komórka przestrzeni stanów,
- X – dane wejściowe,
- P^- – predykcja przestrzeni stanów,
- P – zaktualizowana przestrzeń stanów,
- α – waga (współczynnik wygładzania),
- $q_k(s | s_{k-1})$ – macierz tranzycji Markowa.

Algorytm ten wykonuje analizę wyczerpującą [4,9], co pozwala na sprawdzenie wszystkich trajektorii. Istnieją co prawda możliwości redukcji liczby trajektorii, jednak wiąże się to z pogorszeniem jakości pracy algorytmu.

Dane wejściowe wprowadzane są w kroku (1c) i służą do aktualizacji przestrzeni stanów. Zwykle przestrzeń stanów jest zdefiniowana w odniesieniu do przestrzeni danych. Oznacza to, że dla obrazu wejściowego przestrzeń stanów jest zdefiniowana współrzędnymi obrazu i jego rozdzielczością. Kolejny wymiar przestrzeni stanów jest określony wektorem ruchu. Liczba wektorów ruchu oraz ich dobór pozwala na określenie precyzji śledzenia. Im większa liczba wektorów ruchu, tym bardziej prawdopodobne jest dobre dopasowanie do trajektorii, dzięki czemu poprawia się jakość pracy algorytmu. Ponieważ zwiększenie liczby wektorów ruchu jest ograniczone ilością pamięci oraz mocą obliczeniową, stosuje się rozwiązanie kompromisowe. Zamiast znacznej liczby wektorów ruchu, stosuje się ich mniejszą liczbę dodając tranzycje między stanami. Tranzycje opisane są macierzą Markowa pozwalając na przejście wartości z jednej trajektorii na sąsiednią. Pozwala to także na śledzenie pojazdu w warunkach wykonywania manewru na drodze.

Macierz Markowa jest macierzą rzadką i oryginalna operacja (1b) jest realizowana w taki sposób, aby nie było konieczności wykonywania mnożenia macierzowego.

Wynikiem działania algorytmu TBD jest albo przestrzeń stanów po predykcji, albo po aktualizacji. W niniejszym artykule stosowane jest podejście pierwsze.



Rys.1. Wektor ruchu, dla którego występuje pobudzenie tego samego punktu dwóch sąsiednich pikseli

Dane wejściowe wprowadzone są w kroku (1c) i podlegają ważeniu z przestrzenią stanów po predykcji. W zależności od wartości współczynnika wagowego występuje ważenie między dwoma procesami całego algorytmu. Wzór (1b) opisuje proces rozmywania a wzór (1c) proces wyostrażania danych. Zwykle dla systemów TBD wartość współczynnika wagowego jest bliska 1, ale nigdy nie osiąga tej wartości.

3. OGRANICZENIA W PRÓBKOWANIU SYNGAŁÓW

Obiekt, który pobudza pojedynczy piksel obrazu znajduje się wewnątrz niego, co oznacza, że jego położenie może zostać wyznaczone z dokładnością ograniczoną rozmiarem piksela. W wypadku ruchu obiektu następuje pobudzenie kolejnych pikseli. Jeśli ruch obiektu charakteryzuje się stałą prędkością, to kolejne pobudzenia pozwalają na wyznaczenie prędkości oraz położenia z rozdzielczością lepszą niż wynika to z rozmiaru pojedynczego piksela. Uzyskuje się wtedy pracę z rozdzielczością subpikselową, jeśli obiekt rozpatrywany jest jako obraz.

Rozwiązanie to nie może być stosowane do obiektów, które się nie poruszają oraz do obiektów, których kolejne położenia znajdują się w tym samym miejscu dla różnych pikseli. Możliwe jest wtedy wyznaczenie prędkości, ale nie położenia.

W rzeczywistości liczba takich trajektorii jest bardzo duża, ponieważ wektor ruchu, którego długość jest nieznacznie większa lub mniejsza od pokazanej na rysunku 1, będzie powodował takie same pobudzenia w dłuższym odcinku czasu. Jediną metodą na uniknięcie tego ograniczenia i uzyskanie śledzenia z rozdzielczością subpikselową jest wykorzystanie algorytmów superrozdzielczości.


Algorytmy superrozdzielczości pozwalają na zwiększenie rozdzielczości, zazwyczaj poprzez wykorzystanie dodatkowych pomiarów [5]. Instalując kilka kamer, tak aby piksele nie pokrywały się między nimi, możliwe jest zwiększenie rozdzielczości optycznej całego systemu. Wadą jest konieczność zastosowania dodatkowych kamer oraz rozbudowy systemu akwizycji i przetwarzania obrazów. Możliwym rozwiązaniem jest wykorzystanie ruchu samego obiektu w celu zwiększenia rozdzielczości [8].

Rozwiązanie proponowane w artykule bazuje na wykorzystaniu znanego przesunięcia kamery realizowanego za pomocą układu mechanicznego sterowanego silnikiem. Przesunięcia powinno być bardzo małe o ułamki rozmiaru piksela. Można do tego celu zastosować także przetworniki piezoelektryczne. Wówczas kamera w trakcie pracy wykonuje drgania losowe sterowane z komputera.


Algorytm realizujący śledzenie z superrozdzielczością wymaga zwiększenie rozmiaru przestrzeni stanów stosownie do pożądanej rozdzielczości [7]. Zamiast bezpośredniego wprowadzania $X(k,s)$ jako pikseli obrazu, konieczna jest wcześniejsza interpolacja obrazu wejściowego z wykorzystaniem algorytmu najbliższego sąsiada. Stopień interpolacji (N) określa zwiększenie liczby komórek w przestrzeni stanów i tym samym rozdzielczości. Dla sygnału 1D jest to wartość N , a dla obrazu 2D jest to $N \times N$.

4. ANALIZA NUMERYCZNA DOKŁADNOŚCI ŚLEDZENIA


Maksymalny błąd wyznaczenia położenia dla systemu bez wykorzystania superrozdzielczości wynosi 1 (rozmiar piksela), jednak maleje on przy zastosowaniu superrozdzielczości. Dalsza redukcja wielkości błędu jest możliwa poprzez użycie filtracji dolnoprzepustowej, która jest stosowana do położenia wykrytego przez algorytm. W przeprowadzonym badaniu symulacyjnym posłużono się przykładem obiektu poruszającego się po trajektorii liniowej, przy czym dla uproszczenia zrealizowano śledzenie 1D. Współczynnik $N=4$ powoduje, że rozdzielczość uzyskiwana z samego systemu TBD jest 4-krotnie większa od początkowej. Współczynnik wygładzania jest równy 0,95, co jest wartością typową dla systemu TBD. Sygnał wejściowy nie był zakłócany, w celu pokazania jakości pracy wynikającej wyłącznie z zastosowania superrozdzielczości. Przesunięcie przetwornika obrazu było sterowane za pomocą generatora o rozkładzie równomiernym. Prędkości obiektu były zmieniane od 0 do 4 z krokiem 0.1. Każdy z testów był powtarzany 10-krotnie w celu zmniejszenia wpływu szumu. Na kolejnych rysunkach przedstawiono wartości średnie błędu bezwzględnego położenia.




Rys.2. Średnia wartość błędu bezwzględnego położenia (linia ciągła dla systemu TBD, linia przerywana dla systemu TBD z dodatkową filtracją) – bez przesunięcia kamery




Rys.3. Średnia wartość maksymalnego błędu bezwzględnego położenia (linia ciągła dla systemu TBD, linia przerywana dla systemu TBD z dodatkową filtracją) – bez przesunięcia kamery




Rys.4. Średnia wartość mediany błędu bezwzględnego położenia (linia ciągła dla systemu TBD, linia przerywana dla systemu TBD z dodatkową filtracją) – bez przesunięcia kamery



Rys.5. Średnia wartość błędu bezwzględnego położenia (linia ciągła dla systemu TBD, linia przerywana dla systemu TBD z dodatkową filtracją) – losowe przesunięcia kamery



Rys.6. Średnia wartość maksymalnego błędu bezwzględnego położenia (linia ciągła dla systemu TBD, linia przerywana dla systemu TBD z dodatkową filtracją) – losowe przesunięcia kamery



Rys.7. Średnia wartość mediany błędu bezwzględnego położenia (linia ciągła dla systemu TBD, linia przerywana dla systemu TBD z dodatkową filtracją) – losowe przesunięcia kamery

System ze statyczną kamerą charakteryzuje się porównywalnymi parametrami dla zwykłego algorytmu TBD, jak z ruchomą kamerą. Zastosowanie filtracji powoduje około dwukrotne zmniejszenie wartości średniego błędu. Najistotniejszy jest fakt, iż dla wektora prędkości 4 błąd znacznie maleje z wartości 3 do około 1,3 wskutek wykorzystania losowych przesunięć kamery. Błąd maksymalny nie jest redukowany przez system z ruchomą kamerą. Mediana zachowuje się podobnie jak średni błąd.

Wprowadzenie filtru powoduje poprawę jakości śledzenia, co jest zgodne z oczekiwaniami. W celach testowych wykorzystano filtr o skończonej odpowiedzi impulsowej (SOI) 31. rzędu typu średnia ruchoma. Dobór filtru jest istotny dla estymacji położenia – wyższy rząd pozwala na lepszą estymację położenia.

5. WNIOSKI

Śledzenie pojazdu znajdujących się w znacznej odległości od kamery jest zadaniem bardzo ważnym dla nowych i rozbudowywanych Inteligentnych Systemów Transportowych.

Zaproponowane rozwiązanie bazujące na ruchomej kamerze powoduje poprawienie sytuacji dla systemu śledzenia zwłaszcza, gdy wektor ruchu obiektu jest wielokrotnością rozmiaru piksela. Redukcja poziomu błędu jest możliwa aż do rzędu rozmiaru subpiksela, co jest istotne do poprawy wyznaczania położenia.

Przesunięcia kamery mogą być realizowane za pomocą prostych środków i nie wymagają rozbudowy systemu akwizycji, jedynie części odpowiadającej za przetwarzanie obrazów. Zwiększenie rozdzielczości jest możliwe technikami programowymi, przy czym istotnym rozwiązaniem jest dodatkowa filtracja położenia, co zastępuje zwiększanie rozmiaru przestrzeni stanów i tym samym kosztu obliczeniowego.

6. BIBLIOGRAFIA

- [1] Barniv, Y.: Dynamic Programming Algorithms for Detecting Dim Moving Targets. In: Bar-Shalom, Y. (ed.): Multitarget-Multisensor Tracking. Artech House 1990.
- [2] Blackman, S., Popoli, R.: Design and Analysis of Modern Tracking Systems. Artech House 1999.
- [3] Boers, Y., Ehlers, F., Koch, W., Luginbuhl, T., Stone, L.D., Streit, R.L.: Track Before Detect Algorithm. EURASIP Journal on Advances in Signal Processing, Hindawi 2008.
- [4] Coue C., Fraichard Th., Bessiere P., Mazer E.: Using Bayesian Programming for Multi-Sensor Multi-Target Tracking in Automotive Applications, International Conference on Robotics and Automation, Taipei, 2003.
- [5] Irani M., Peleg S.: Improving Resolution by Image Registration. Graphical Models and Image Processing, vol. 53, str. 231-239, 1991.
- [6] Klein L.A.: Sensor Technologies and Data Requirements for ITS. Norwood, Massachusetts, Artech House ITS library 2001.
- [7] Mazurek P., Okarma K.: Algorytmy superrozdzielczości w Inteligentnych Systemach Transportowych do śledzenia odległych pojazdów. Logistyka nr 2, str. 255-262, 2010.
- [8] Mazurek P., Okarma K.: Subpikselowe śledzenie ruchu pojazdów na drodze w dużej odległości od kamery. Logistyka nr 3, str. 1815-1824, 2011.
- [9] Williams B.: Intelligent Transport Systems Standards, Artech House Publishers, 2008.

7. PODZIĘKOWANIA

Artykuł powstał dzięki wsparciu w ramach grantu Ministerstwa Nauki i Szkolnictwa Wyższego nr N509 399136 „Estymacja trajektorii ruchu pojazdów z wykorzystaniem analizy bayesowskiej oraz algorytmów cyfrowego przetwarzania obrazów”.