

Bartłomiej PŁACZEK

## WZORCE DIAGNOSTYCZNE DLA SYSTEMÓW WIDEODETEKCJI RUCHU DROGOWEGO

**Streszczenie.** Niniejszy artykuł stanowi raport dotyczący badań, których celem jest opracowanie bazy wzorców diagnostycznych do testowania systemów wideodetekcji i wideorejestracji zdarzeń drogowych. Wzorce diagnostyczne umożliwią sprawdzenie poprawności działania systemów wideo w zakresie detekcji i klasyfikacji pojazdów, rozpoznawania zdarzeń oraz pomiarów parametrów strumieni pojazdów. W artykule omówiono metody stosowane w testowaniu tych systemów oraz miary oceny ich działania. Przedstawiono również model danych opracowany dla zapisu wzorców diagnostycznych.

## DIAGNOSTIC PATTERNS FOR TRAFFIC VIDEO DETECTION SYSTEMS

**Summary.** This paper comprises report of researches, that aimed to develop diagnostic patterns for testing procedures of video detection and surveillance systems. Diagnostic patterns will allow to verify the video systems accuracy in domains of vehicles detection and classification, events recognition and parameters measurements of traffic streams. In the paper applied methods have been discussed for the video systems testing and their performance evaluation metrics have been presented. Data model designed for diagnostic patterns notation has also been introduced.

### 1. WPROWADZENIE

Wdrożenie nowych wideosystemów dla detekcji i nadzoru ruchu drogowego wymaga wcześniejszych, złożonych testów poprawności ich działania. Poprawność informacji uzyskiwanej z takich systemów warunkuje właściwy dobór parametrów sterowania i zarządzania ruchem drogowym. Ewentualne błędy wideosystemów mogą się wiązać ze znacznymi stratami, gdy nie zostaną odpowiednio szybko rozpoznane.

Testy poprawności działania muszą obejmować badania w zróżnicowanych warunkach ruchu, oświetlenia, pory dnia i stanu pogody. Potrzebna jest również ocena rezultatów uzyskiwanych dla różnych konfiguracji systemu (na przykład dobór parametrów i lokalizacji kamery oraz pól detekcji).

Przeprowadzenie odpowiednich badań poprawności działania systemów wideo wymaga wcześniejszego opracowania wzorców diagnostycznych uwzględniających zróżnicowane warunki pracy. Wzorec diagnostyczny zawiera testową sekwencję wideo wraz z opisem rzeczywistego położenia pojazdów, trajektorii ruchu, czasów wystąpienia określonych zdarzeń oraz innych parametrów strumieni pojazdów. Badany system jest uruchamiany dla sekwencji testowej, a uzyskane wyniki porównywane są ze wzorcem, odpowiednie miary błędów pozwalają na ocenę danego systemu. Dzięki opracowaniu bazy wzorców

diagnostycznych możliwa będzie obiektywna ocena i porównywanie różnych systemów wideodetekcji i nadzoru oraz wybór optymalnej konfiguracji systemu.

Układ niniejszego artykułu jest następujący : w rozdziale 2 omówiono metody stosowane w testowaniu systemów wideodetekcji, metody badania poprawności algorytmów śledzenia obiektów oraz rozpoznawania zdarzeń. W rozdziale 3 zawarto przegląd miar błędów, które są stosowane do oceny tych systemów. Rozdział 4 zawiera opis opracowanego modelu danych wzorca diagnostycznego. Przedstawiono format zapisu danych wzorcowych dla sekwencji testowej, które będą wykorzystywane do badań systemów wideo. Rozdział 5 zawiera podsumowanie opracowania oraz określenie dalszych kierunków badań.

## **2. METODY TESTOWANIA SYSTEMÓW WIDEODETEKCJI I NADZORU RUCHU DROGOWEGO**

Do tworzenia testów umożliwiających ocenę poprawności działania systemów wideodetekcji i wideorejestracji zdarzeń drogowych mogą być stosowane różne metody, które podzielono na następujące grupy, uwzględniając rodzaj wykorzystywanego wzorca:

- metody porównywania z wynikami innego typu systemów pod nadzorem człowieka,
- metody wykorzystujące wzorce opracowane przy udziale człowieka,
- metody wykorzystujące pseudosyntetyczne wzorcowe sekwencje wideo,
- metody wykorzystujące sekwencje wzorcowe generowane w pełni komputerowo.

Metoda testowania, polegająca na porównywaniu wyników wideodetekcji z rezultatami działania innego typu detektorów, była stosowana w badaniach niezawodności systemu Autoscope [1]. Pola detekcji dla detektora Autoscope zdefiniowano w taki sposób, aby pokrywały się z pętlami detektorów indukcyjnych zainstalowanymi w nawierzchni jezdni. Sekwencje wideo były zapisywane dla okresów czasu, w których zaistniały znaczące różnice wyników detekcji dla pętli indukcyjnych i wideodetektora. Zarejestrowane fragmenty wideo były następnie szczegółowo analizowane off-line przez człowieka, którego zadaniem było zidentyfikowanie błędów detekcji (wideodetektora lub pętli indukcyjnych) oraz ich przyczyn. Baza danych ze wzorcowymi klatkami wideo oraz informacjami o lokalizacji pojazdów wprowadzonymi przez operatora została zastosowana w opracowaniu [3] do uczenia oraz testowania neuronowego detektora pojazdów. Wzorce gromadzone w bazie danych były opracowywane przez człowieka. Przygotowanie wzorców polegało na zaznaczeniu prostokątną ramką na obrazie lokalizacji pojazdów dla kolejnych klatek sekwencji wideo.

Inna metoda przygotowania wzorcowych sekwencji wideo [4] polega na zastosowaniu algorytmu detekcji obiektów pod nadzorem człowieka, który koryguje wyniki detekcji, korzystając ze specjalnie do tego celu stworzonego interfejsu graficznego. Poprawione przez operatora rezultaty wraz z obrazami źródłowymi stanowią wzorce diagnostyczne dla badania różnych algorytmów segmentacji (detekcji) obiektów.

Dla algorytmów śledzenia obiektów oraz wideonadzoru, wykorzystujących wzorce kształtu opracowany został system umożliwiający automatyzację ich oceny [6]. System ten zawiera graficzny interfejs użytkownika oraz interfejs API umożliwiający dołączanie własnych modułów realizujących śledzenie obiektów. Interfejs graficzny pozwala użytkownikowi wyznaczyć wzorcowe położenie śledzonych obiektów dla badanej sekwencji wideo, obserwować działanie algorytmów oraz wyniki oceny w postaci wykresów miar błędów. Interfejs API daje użytkownikowi możliwość dołączania funkcji, które definiują algorytm śledzenia obiektów, rozpoznawane zdarzenia oraz miary błędów.

Sekwencje testowe oraz narzędzia umożliwiające ocenę on-line algorytmów śledzenia obiektów w sekwencjach wideo udostępniane są w sieci Internet. Serwisy tego rodzaju można

znaleźć między innymi pod adresem [www.vividevaluation.ri.cmu.edu](http://www.vividevaluation.ri.cmu.edu) [10] oraz [www.petsmetrics.net](http://www.petsmetrics.net) [11]. Aby dokonać oceny algorytmu, należy pobrać z serwisu on-line sekwencję testową, przeprowadzić eksperyment i uzyskane wyniki w odpowiednim formacie przesłać na serwer. Na serwerze wyniki śledzenia obiektów porównywane są ze wzorcem i wyznaczane zostają oceny algorytmu zgodnie z przyjętym zestawem miar. Oceny wyznaczone dla testowanego algorytmu zostają opublikowane na stronie [www](http://www), dzięki czemu można bezpośrednio porównać różne algorytmy pod względem poprawności uzyskanych rezultatów dla identycznych danych testowych.

Wzorcowe sekwencje testowe dla systemów detekcji i śledzenia obiektów mogą być także generowane automatycznie jako pseudosyntetyczne wideo. Metoda ta wymaga licznego zbioru zgromadzonych sekwencji wideo wraz z odpowiadającymi im wynikami śledzenia. Sekwencje muszą spełniać odpowiednie wymagania, aby na ich podstawie można było generować pseudosyntetyczne sekwencje testowe [8].

Również w pełni syntetyczne obrazy generowane komputerowo były wykorzystane do oceny algorytmów detekcji pojazdów [9]. Taka metoda tworzenia obrazów testowych pozwala na szybkie wykonanie badań poprawności działania algorytmu detekcji w szerokim zakresie zmian parametrów oświetlenia oraz lokalizacji kamery.

Wzorce syntetyczne jak również pseudosyntetyczne generowane są w oparciu o przyjęte modele, które zakładają pewne uproszczenia rzeczywistości. W związku z tym syntetyczne sekwencje testowe nie są w stanie odzwierciedlić całej złożoności sekwencji rzeczywistych. Dla testów systemów wideo nadzorujących ruch drogowy, których najistotniejszym aspektem jest ocena pracy w zróżnicowanych warunkach rzeczywistych, najbardziej odpowiednie są metody wykorzystujące wzorce opracowane przy udziale człowieka.

### 3. MIARY POPRAWNOŚCI DETEKcji I ŚLEDZENIA POJAZDÓW

W literaturze znajdujemy wiele definicji miar, które umożliwiają ocenę poprawności wideodetekcji, śledzenia obiektów czy rozpoznawania zdarzeń. Typ przyjętej miary zależy od rodzaju algorytmu (np. algorytm rozpoznawania obecności pojazdów lub wyznaczania trajektorii) oraz celu jego zastosowania (np. sterowanie ruchem drogowym lub rejestracja wykroczeń).

Miary efektywności oraz klasy błędów systemów wideodetekcji z uwzględnieniem ich znaczenia dla sterowania ruchem drogowym przedstawiono w pracy [2]. Zaproponowano następujące miary efektywności wideodetektora:

- procent przypadków poprawnej detekcji pojazdu,
- procent zgłoszeń niezgodnych,
- procent ważnych zgłoszeń niezgodnych, które mogą mieć wpływ na sterowanie ruchem drogowym.

Wśród zgłoszeń niezgodnych wyróżniono:

- zgłoszenia fałszywe (detektor wskazuje zajętość, gdy pojazd nie jest obecny w polu detekcji),
- zgłoszenia pominięte (detektor nie wskazuje zajętości, gdy pojazd znajduje się w polu detekcji).

Sklassyfikowano błędy powodujące zgłoszenia niezgodne i określono ich wpływ na powstawanie niepoprawnych stanów w systemie sterowania ruchem drogowym.

Inny zestaw zdarzeń uwzględnianych w procedurach oceny funkcjonowania systemów wideodetekcji pojazdów podano w [5]; są to:

- poprawna detekcja (obecność pojazdu zostaje rozpoznana, gdy wjeżdża on do obszaru detekcji i stan zajętości obszaru pozostaje stały aż do momentu opuszczenia przez pojazd),
- detekcja wydłużona (obecność pojazdu jest stale rozpoznawana, podczas gdy przebywa on w obszarze detekcji, po opuszczeniu obszaru detekcji detektor pozostaje w stanie zajętości przez pewien okres),
- detekcja wielokrotna (obecność pojazdu jest rozpoznana, podczas gdy przebywa on w polu detekcji, lecz przynajmniej raz w tym okresie na krótko zanika stan zajętości detektora),
- błąd detekcji (obecność pojazdu nie zostaje rozpoznana w okresie jego przejazdu przez obszar detekcji),
- utrata detekcji (obecność pojazdu jest początkowo poprawnie rozpoznawana po jego pojawieniu się w polu detekcji, następnie stan zajętości detektora zanika i nie zostaje przywrócony, mimo że pojazd nadal znajduje się w obszarze detekcji),
- połączenie detekcji (luka pomiędzy pojazdami nie zostaje poprawnie rozpoznana – stan zajętości detektora zostaje utrzymany bez przerwy, podczas gdy przez obszar detekcji przejeżdżają kolejne pojazdy w niewielkich odstępach jeden za drugim),
- połączenie z wydłużeniem detekcji (sytuacja jak w przypadku połączenia detekcji, dodatkowo stan zajętości detektora jest utrzymywany przez pewien czas po opuszczeniu obszaru detekcji przez ostatni pojazd w grupie),
- fałszywa detekcja (stan zajętości detektora pojawia się na maksimum 5 sekund, w czasie gdy w polu detekcji nie znajduje się żaden pojazd),
- fałszywa detekcja z wydłużeniem (stan fałszywej detekcji utrzymujący się przez pewien okres czasu, dłuższy niż 5 sekund).

W opracowaniu [4] do oszacowania błędów detekcji zastosowano procedurę porównywania regionów rozpoznanych przez człowieka w klatkach wzorcowych oraz wyznaczonych algorytmem detekcji. Rozróżniono następujące przypadki:

- poprawna detekcja (wykryty region odpowiada dokładnie jednemu regionowi z klatki wzorcowej),
- fałszywy alarm (wykryty region nie odpowiada żadnemu regionowi z klatki wzorcowej),
- błąd detekcji (region z klatki wzorcowej nie posiada odpowiednika w wynikach detekcji),
- połączenie regionów (wykryty region odpowiada kilku regionom z klatki wzorcowej),
- podział regionów (region z klatki wzorcowej odpowiada kilku wykrytym regionom),
- połączenie z podziałem (gdy spełnione są warunki dla dwóch poprzednich przypadków).

Procentowy udział poszczególnych przypadków, które zostały wymienione powyżej, stanowił miarę oceny algorytmów detekcji obiektów.

Obszerny zestaw definicji miar dla oceny algorytmów detekcji i śledzenia obiektów zawarto w [7]. Miary oceny zostały podzielone na dwie grupy: bazujące na analizie obiektów rozpoznanych na pojedynczej klatce oraz uwzględniające trajektorie ruchu obiektów w sekwencji wideo (dla zestawu klatek).


#### 4. MODEL DANYCH WZORCA DIAGNOSTYCZNEGO

Zaproponowany model wzorca diagnostycznego zawiera następujące cztery elementy: testową sekwencję wideo (zapisaną w formacie filmu lub zbioru pojedynczych klatek), opis sekwencji testowej zawarty w bazie danych, maskę wzorca obiektów dla każdej klatki w sekwencji oraz maskę definicji obszarów.


Model zawierający podstawowe elementy bazy danych przechowującej opisy sekwencji testowych przedstawiono w postaci diagramu ER na rysunku 1. Sekwencja testowa posiada



obszarów. Za pomocą jednej bitmapy można zdefiniować maksymalnie 255 obszarów rozłącznych. Jeżeli obszary mają się pokrywać w pewnych fragmentach obrazu, wówczas należy zastosować więcej niż jedną maskę definicji obszarów.



Rys. 2. Przykład obiektów definiowanych maską wzorca dla danej klatki  
Fig. 2. The example of objects defined in frame by the pattern mask



Rys 3. Przykład definicji obszarów dla sekwencji testowej  
Fig. 3. The example of regions definition for testing sequence

W przedstawionym modelu uwzględniono możliwość przechowywania informacji dotyczących klas obiektów oraz występujących zdarzeń. Klasa obiektu może opisywać rodzaj pojazdu (np. osobowy, ciężarowy, autobus, tramwaj). Zdarzenia zapisane we wzorcu testowym mogą być związane między innymi z pojawieniem się nowych obiektów w polu widzenia lub zmianą położenia obiektu, przy zaistnieniu warunków opisanych odpowiednimi atrybutami. Na przykład: zdarzenie parkowanie wystąpi, gdy pojazd zmieni swoje położenie z obszaru 2 do obszaru 1 (rys. 3). Natomiast zdarzenie przejazd na czerwonym świetle wystąpi, gdy pojazd opuści obszar 2 podczas sygnału zabraniającego ruchu. Tak więc zdarzenia mogą być rozpoznawane automatycznie na podstawie danych zapisanych w innych encjach bazy danych.

## 5. PODSUMOWANIE

Przedstawiony w artykule model danych umożliwia zapis wzorców diagnostycznych dla systemów wideodetekcji i wideorejestracji zdarzeń drogowych. Odpowiednio zapisane dane testowe pozwalają na dokonanie oceny algorytmów rozpoznawania pojazdów i zdarzeń, wyznaczania trajektorii ruchu, klasyfikacji oraz pomiaru parametrów strumieni pojazdów.

W procedurach oceny mogą zostać wykorzystane różne miary błędów, których przykłady podano w niniejszym opracowaniu. Przeprowadzono również dyskusję metod stosowanych do przygotowania wzorców diagnostycznych dla systemów analizy wideo.

Dalsze prace będą dotyczyły narzędzi ułatwiających i przyspieszających proces definiowania wzorców dla sekwencji testowych. Badania będą prowadzone dla algorytmów automatycznego rozpoznawania i generowania danych wzorcowych, w których rola człowieka powinna zostać sprowadzona do kontroli poprawności wygenerowanych wzorców oraz dokonywania ewentualnych korekt. Projektowane narzędzia powinny wykorzystywać techniki przetwarzania obrazu i analizy off-line sekwencji wideo oraz metody obróbki obrazów cyfrowych dla stworzenia odpowiedniego interfejsu graficznego, który umożliwi sprawne przygotowanie wzorców diagnostycznych.

## Literatura

1. Michalopoulos P. G., Jacobson R.: Field implementation of the Minnesota video detection system, The 3rd International Conference On Vehicle Navigation & Information Systems, IEEE 1992.
2. Martin P. T., Dharmavaram G., Stevanovic A.: Evaluation of UDOT'S Video Detection Systems, System's Performance in Various Test Conditions, University of Utah Traffic Lab, 2004.
3. A neural network based vehicle detection and tracking system, Proceedings of the 27th Southeastern Symposium on System Theory (SSST'95), IEEE Computer Society Washington 1995.
4. Nascimento J., Marques J. S.: Performance evaluation of object detection algorithms for video surveillance, IEEE Transactions on Multimedia, Accepted for publication, 2005.
5. MacCarley A.: City of Anaheim/Caltrans/FHWA advanced traffic control system field operational test evaluation: Task C: video traffic detection system, California Path Program, Institute of Transportation Studies, University of California, Berkeley 1998.
6. Jaynes C., Webb S., Matt Steele R., Xiong Q.: An Open Development Environment for Evaluation of Video Surveillance Systems, Proceedings of the Third International Workshop on Performance Evaluation of Tracking and Surveillance (PETS'2002).

7. Bashir F., Porikli F.: Performance Evaluation of Object Detection and Tracking Systems, IEEE International Workshop on Performance Evaluation of Tracking and Surveillance 2006 (PETS 2006).
8. Black J., Ellis T., Rosin P.: A novel method for video tracking performance evaluation. In International Workshop on Visual Surveillance and Performance Evaluation of Tracking and Surveillance, 2003.
9. Moon H., Chellappa R.: Performance Analysis of a Simple Vehicle Detection Algorithm, Elsevier Preprint 2001.
10. Collins R., Zhou X., Teh S. K.: An Open Source Tracking Testbed and Evaluation Web Site, IEEE International Workshop on Performance Evaluation of Tracking and Surveillance (PETS 2005), 2005.
11. Young D., Ferryman J.: PETS Metrics: On-line Performance Evaluation Service. The Second Joint IEEE International Workshop on Visual Surveillance and Performance Evaluation of Tracking and Surveillance (VS-PETS 2005), 2005.

Recenzent: Dr hab. inż. Romuald Szopa  
Profesor Politechniki Częstochowskiej

*Praca wykonana w ramach badań własnych: BW 422/RT5/2006*