



Jan PURCZYŃSKI

PORÓWNANIE SKUTECZNOŚCI WYBRANYCH METOD ESTYMACJI PRĘDKOŚCI POJAZDU W WARUNKACH SILNYCH ZAKŁÓCEŃ LOSOWYCH

Streszczenie

W pracy porównano skuteczność wybranych metod estymacji prędkości pojazdu w warunkach silnych zakłóceń. Rozpatrzono następujące metody: aproksymacji parabolicznej, funkcji interkorelacji, wygładzania wykładniczego oraz wstępnego uśrednienia sekwencji obrazów. W wyniku przeprowadzonych symulacji komputerowych ustalono, że najlepsze efekty (najmniejszy błąd średniokwadratowy) uzyskano stosując metodę średniej ruchomej oraz wygładzania wykładniczego poprzedzone wstępnym uśrednieniem sekwencji obrazów.

WSTĘP

W niniejszej pracy zostaną rozpatrzone zagadnienie estymacji prędkości pojazdów na podstawie obrazu zarejestrowanego przez kamerę wideo. W przypadku niskiego poziomu zakłóceń stosuje się metodę polegającą na odejmowaniu kolejnych klatek obrazu, co pozwala zidentyfikować poruszające się obiekty. Przykładem może być algorytm zaproponowany przez Lucas B.D i Kanade T. [2]. Jedną z wersji tego algorytmu przewiduje wykorzystanie pochodnej obrazu. Wykonanie operacji różniczkowania sygnału w obecności zakłóceń losowych może być przyczyną dużych błędów [3]. W przypadku wysokiego poziomu zakłócenia metoda odejmowania kolejnych sekwencji obrazu staje się nieprzydatna, ponieważ prowadzi do wzrostu poziomu zakłócenia- następuje sumowanie wariancji szumu.

W niniejszej pracy, gdzie uwzględnia się silne zakłócenia losowe, przyjęto, że dla poszczególnych klatek estymuje się położenie obiektu, natomiast prędkość wyznacza się na podstawie sekwencji obrazów (10 lub 20).

Przyjęto, że przed uruchomieniem pomiaru prędkości została zarejestrowana dostateczna liczba obrazów tła (np. 1000), na podstawie której dokonano uśrednienia, co pozwoliło określić charakterystyczne cechy tła. Zakłada się, że uśredniony obraz tła jest odejmowany od kolejnych, zarejestrowanych obrazów z poruszającym się obiektem. W efekcie, przyjmuje się, że tło posiada poziom równy zero i jest zakłócanie szumem gaussowskim identycznie jak pojazd. W celu uproszczenia rozważań rozpatruje się pojazdy w uproszczonej skali szarości: pojazdowi jasnemu przyporządkowana jest liczba 0,5, natomiast pojazdowi ciemnemu- liczba - 0,5. Zakładając, że prędkość pojazdu wynosi 90km/godz. oraz kamera rejestruje 25 klatek na sekundę, stwierdza się, że dwie kolejne klatki odpowiadają drodze 1m przebytego przez pojazd. Zakładając, że kamera ma rozdzielczość 320 pikseli oraz obraz obejmuje drogę

o długości 320m, stwierdza się, że odległość dwóch sąsiadujących pikseli w obrazie odpowiada odległości 1m na drodze. Zakłada się, że ruch pojazdu, o długości 6m, odbywa się na jednym pasie ruchu a kamera umieszczona jest z boku drogi.

Model pojazdu, tzn. prostokąt o podstawie 6 pikseli został rozmyty za pomocą filtru średniej ruchomej przyjmując postać trapezu.

Model pojazdu został zakłócony szumem gaussowskim.

W dalszych rozdziałach zostaną porównane wyniki estymacji prędkości pojazdu z wykorzystaniem następujących metod:

- aproksymacji parabolicznej,
- funkcji interkorelacji,
- wygładzania wykładniczego,
- wstępnego uśrednienia sekwencji obrazów.

Powyższe metody zostały wykorzystane we wcześniejszych pracach autora [4,5,6,7].

1. ESTYMACJA Z WYKORZYSTANIEM APROKSYMACJI PARABOLICZNEJ [4]

W pracy [4] zastosowano metodę estymacji maksimum współczynnika $a0_i$ (oznaczonej jako wariant I) oraz jej modyfikację, polegającą na poszukiwaniu wartości maksymalnej iloczynu L kolejnych współczynników $a0_i$ (wariant II).

Algorytm estymacji prędkości pojazdu jest następujący. Dla kolejnych (np. 10-ciu) obrazów wyznacza się wartości pikseli dla których wystąpiło maksimum współczynnika $a0_i$ oraz ich medianę. Wartości pikseli, których odległość od mediany przekracza $P=20$ zostają zastąpione wartością średnią sąsiadów. W przypadku, gdy dotyczy to pikseli skrajnych (pierwszy lub ostatni) dokonuje się ekstrapolacji liniowej wartości dwóch najbliższych pikseli. Dla uzyskanego zestawu wyznacza się trend liniowy, którego współczynnik kierunkowy prostej określa prędkość pojazdu.

W pracy [4] rozpatrzono grupę trzech pojazdów, dla których wyznaczano wartość średnią grupy pojazdów.

Prędkość grupy pojazdów wyznaczono jako średnią wyników dla poszczególnych pojazdów uzyskanych dla kolejnych symulacji komputerowych.

Symulacje komputerowe polegały na wykonaniu $K=400$ powtórzeń i wyznaczeniu na tej podstawie błędu estymacji.

Następnie wyznaczano wartość błędu RMSE (Root Mean- Squared Error):

$$RMSE = \sqrt{\frac{1}{K} \sum_{k=1}^K (\hat{v}_k - v_d)^2} \quad (1)$$

gdzie: \hat{v}_k - oszacowanie prędkości w k -tej symulacji

v_d - wartość dokładna prędkości

a także błąd RRMSE (Relative Root Mean- Squared Error):

$$RRMSE = \sqrt{\frac{1}{K} \sum_{k=1}^K \left(\frac{\hat{v}_k - v_d}{v_d} \right)^2} \quad (2)$$

gdzie oznaczenia jak we wzorze (1).

Przy poczynionych założeniach, prędkość pojazdu $v_d = 90 \frac{km}{godz.}$ odpowiadała przemieszczeniu modelu pojazdu o jeden piksel w ciągu jednej sekundy, tzn. położenie pojazdu w dwóch kolejnych obrazach różni się o jeden piksel. Oznacza to, że we wzorze (2) należy przyjąć $v_d = 1$, czyli wzór (2) prowadzi do tych samych wyników, co wzór (1).

Wyniki obliczeń zamieszczono w rozdziale 2 pracy.

2. ESTYMACJA Z WYKORZYSTANIEM FUNKCJI INTERKORELACJI [5]

W pracy [5], do estymacji położenia pojazdu, zastosowano funkcję interkorelacji:

$$\Phi_n = \sum_{i=0}^N y_i x(i-n) \quad (3)$$

gdzie: y_i - zarejestrowany sygnał ; $i = 1, 2, \dots, N$;

x_i - założony model pojazdu

Jako założony model obrazu pojazdu x_i przyjęto trapez, który wyraża się wzorem:

$$x(i-n) = A \begin{cases} 1 & \text{dla } |i-n| \leq d \\ \frac{D-|i-n|}{D-d} & \text{dla } d < |i-n| \leq D \\ 0 & \text{dla } |i-n| > D \end{cases} \quad (4)$$

gdzie: $2D$ – dolna (dłuższa) podstawa trapezu

$2d$ - górna (krótsza) podstawa trapezu.

Zostały rozpatrzone szczególne przypadki wzoru (4): $D = d$ – prostokąt oraz $d = 0$ – trójkąt.

Proponowana metoda estymacji położenia pojazdu polega na wyznaczeniu wartości funkcji Φ_n i określeniu punktu n_{\max} występowania maksimum funkcji interkorelacji – metodę tę oznaczono jako MI. Uwzględniając trzy modele pojazdu, zastosowano następujące oznaczenia pierwszej metody: MPI – prostokąt, MTI – trapez oraz $M\Delta I$ - trójkąt. Rozpatrzono również modyfikację metody MI polegającą na poszukiwaniu wartości maksymalnej iloczynu L kolejnych wartości funkcji Φ_n - MII oraz odpowiednio MPII, MTII i $M\Delta II$.

W przypadku pojazdu ciemnego reprezentowanego przez liczbę $-0,5$, należy poszukiwać minimum funkcji korelacji wzajemnej- algorytm wyznaczał niezależnie obydwie ekstrema, a porównanie wyników końcowych jednoznacznie ustalało zaistniały wariant.

Algorytm estymacji prędkości pojazdu jest następujący. Dla kolejnych (np. 10-ciu) obrazów wyznacza się wartości pikseli, dla których wystąpiło maksimum funkcji Φ_n oraz ich medianę. Obserwacje, dla których odległość wartości pikseli od mediany przekraczają P zostają usunięte – nie uwzględnia się ich w dalszych obliczeniach. Dla uzyskanego zestawu wyznacza się trend liniowy, którego współczynnik kierunkowy prostej określa prędkość pojazdu.

Obliczenia wykonano dla sekwencji 30 obrazów, przy czym, omówioną procedurę estymacji prędkości pojazdu stosowano oddzielnie dla każdej sekwencji 10-ciu obrazów.

Jako wynik końcowy przyjmowano średnią arytmetyczną z trzech sekwencji.

W tabeli 1 zamieszczono błędy wyników estymacji prędkości pojazdu uzyskane na drodze symulacji komputerowych ($K=400$). Kolejne kolumny zawierają: odchylenie standardowe zakłócenia σ , wartość oszacowania prędkości \hat{v} , obciążenie estymatora $b(\hat{v})$ oraz błąd średnio kwadratowy RMSE.

Ponadto, w tabeli 1 zamieszczono wyniki estymacji prędkości pojazdu z wykorzystaniem aproksymacji parabolicznej (rozdz.1) oznaczone jako metoda PI i PII.

Porównując wyniki estymacji prędkości metodą MI (MPI, MTI, $M\Delta I$) stwierdza się najmniejsze wartości błędów RMSE dla metody MTI (okno trapezowe), które są porównywalne z wartościami błędów RMSE metody PI. Odnosnie metody MII, najmniejsze wartości błędów zapewniają metody $M\Delta II$ (okno trójkątne) i MTII (okno trapezowe), które okazują się dokładniejsze, niż metoda PII.

Z tabeli 1 wynika, że metoda MII prowadzi do mniejszych wartości błędów niż metoda MI, zarówno co do błędu RMSE, jaki błędu obciążenia $b(\hat{v})$. Ponadto stwierdza się, że wartości błędu obciążenia $b(\hat{v})$ są wielokrotnie mniejsze, niż wartości błędu RMSE. Oznacza to, że zasadniczym źródłem błędów jest wariancja estymatora $V(\hat{v})$.

Z danych zawartych w tabeli 1 wynika, że najlepsze wyniki uzyskano dla metod $M\Delta II$ i $MTII$. Jednakże stosowanie okna trapezowego jest uciążliwe, ponieważ wymaga określenia dwóch parametrów (długości podstaw).

Tab. 1. Błędy wyników estymacji prędkości pojazdu

σ	Metoda MPI			Metoda MPII		
	\hat{v}	$b(\hat{v})$	RMSE	\hat{v}	$b(\hat{v})$	RMSE
0,25	0,9945	-0,0055	0,0641	1,0027	0,0027	0,0577
0,30	0,9877	-0,0123	0,0849	1,0009	0,0009	0,0721
0,35	0,9756	-0,0244	0,1117	0,9917	-0,0083	0,0947
	Metoda MTI			Metoda MTII		
0,25	0,9972	-0,0028	0,0546	1,0015	0,0015	0,0539
0,30	0,9930	-0,0070	0,0743	1,0002	0,0002	0,0683
0,35	0,9856	-0,0144	0,1083	0,9926	-0,0074	0,0893
	Metoda $M\Delta I$			Metoda $M\Delta II$		
0,25	1,0016	0,0016	0,0659	1,0012	0,0012	0,0546
0,30	0,9985	-0,0015	0,0851	1,0048	0,0048	0,0676
0,35	0,9864	-0,0136	0,1162	0,9951	-0,0049	0,0884
	Metoda PI			Metoda PII		
0,25	0,9970	-0,0030	0,0650	0,9983	-0,0017	0,0554
0,30	0,9908	-0,0092	0,0833	0,9938	-0,0062	0,0726
0,35	0,9773	-0,0227	0,1056	0,9835	-0,0165	0,1011

Źródło: opracowanie własne

Z tego powodu należy zarekomendować metodę $M\Delta II$, gdzie w wyniku zastosowania kryterium odległości od mediany, określa się tylko jeden parametr (długość podstawy). Za stosowaniem okna trójkątnego przemawia dodatkowo fakt, że w przypadku silniejszego rozmycia obrazu pojazdu, model pojazdu jeszcze bardziej upodobni się do trójkąta.

3. ESTYMACJA Z WYKORZYSTANIEM METODY WYGŁADZANIA WYKŁADNICZEGO BROWNA [6]

W rozdziale tym zostanie omówiona estymacja położenia pojazdu wykorzystująca metodę wygładzania (wyrównywania) wykładniczego Browna [9]:

$$y_{w_{i+1}} = a \cdot y_{i+1} + (1-a)y_{w_i} \quad (5)$$

gdzie: y_i - zarejestrowany sygnał ; $i = 1, 2, \dots, N$;
 yw_i - sygnał wygładzony wykładniczo ; $yw_1 = y_1$.

W pracy [6] zaproponowano dwustronną metodę wygładzania opisaną wzorem:

$$yw2_j = a \cdot yw_{j+1} + (1-a)yw2_j ; \quad j = N, N-1, \dots, 1; \quad (6)$$

gdzie: yw_j - sygnał wygładzony zgodnie ze wzorem (12) ;

$yw2_j$ - sygnał wygładzony dwustronnie ; $yw2_N = yw_N$. $j = N, N-1, \dots, 1$;

Proponowana metoda estymacji położenia pojazdu polega na wyznaczeniu wartości $yw2$ i określeniu punktu i_{\max} występowania maksimum tej funkcji – metodę tę oznaczono jako WW.

Algorytm estymacji prędkości pojazdu jest następujący. Dla kolejnych (np. 10-ciu) obrazów wyznacza się wartości pikseli dla których wystąpiło maksimum funkcji $yw2$ oraz ich medianę. Obserwacje, dla których odległość wartości pikseli od mediany przekraczają P zostają usunięte – nie uwzględnia się ich w dalszych obliczeniach. Dla uzyskanego zestawu wyznacza się trend liniowy, którego współczynnik kierunkowy prostej \hat{v}_1 określa prędkość pojazdu. Postępowanie powtarzamy dla kolejnych trzech sekwencji 10-ciu obrazów, a następnie wyznaczamy wartość średnią współczynników kierunkowych:

$$\hat{v} = \frac{1}{3}(\hat{v}_1 + \hat{v}_2 + \hat{v}_3) \quad (7)$$

Zaproponowaną metodę oznaczono jako WWI.

Należy zauważyć, że omówiona w rozdziale 3 metoda interkorelacji dla modelu prostokątnego pokrywa się z metodą średniej ruchomej (Moving Average):

$$YS_i = \frac{1}{2M+1} \sum_{k=-M}^M y_{i+k} \quad (8)$$

Metoda została oznaczona jako MAI.

Ponadto, zastosowano aproksymację paraboliczną - metodę tę oznaczono jako PARI.

Obliczenia wykonano dla sekwencji 30 obrazów, przy czym, omówioną procedurę estymacji prędkości pojazdu stosowano oddzielnie dla każdej sekwencji 10-ciu obrazów. Jako wynik końcowy przyjmowano średnią arytmetyczną z trzech sekwencji.

W pierwszej kolejności ustalono wartość P , decydującą o rezultatach testu odległości piksela od mediany – w wyniku testu obserwacja była odrzucana, bądź też uwzględniona. Dla wszystkich trzech metod: WWI, PARI, MAI wyznaczono wartość optymalną wynoszącą $PI=7$, która zapewniła minimalną wartość błędu średniokwadratowego.

Omówione metody bazowały na wzorze (7), tzn. wyznaczano wartość średnią dla trzech kolejnych sekwencji 10-ciu obrazów.

W trakcie obliczeń sprawdzono inny wariant polegający na uwzględnieniu sekwencji 30 obrazów bez rozbijania na segmenty 10-cio elementowe. Wyznaczona wartość optymalna – ze względu na najmniejszą wartość błędu RMSE- odległości wartości piksela od mediany wyniosła $PII=17$ dla wszystkich trzech metod oznaczonych: WWI, PARI, MAI.

W tabeli 2 zamieszczono błędy oszacowania prędkości pojazdu uzyskane na drodze symulacji komputerowych. Kolejne kolumny zawierają: odchylenie standardowe

zakłócenia σ , wartość oszacowania prędkości \hat{v} , obciążenie estymatora $b(\hat{v})$ oraz błąd średnio kwadratowy RMSE.

Oprócz wartości MI oraz MII, które wyznaczono wspólnie dla trzech metod, określono wartości dalszych parametrów, oddzielnie dla poszczególnych metod. Jako kryterium optymalności przyjęto minimum wartości błędu średniokwadratowego.

Z tabeli 2 wynika, że niezależnie od rozpatrywanej metody, wariant II prowadzi do błędu RMSE niemal dwukrotnie mniejszego niż błąd RMSE metody I. Oznacza to, że nie należy wyznaczać wartości średniej dla trzech sekwencji 10-ciu obrazów (wzór(7)), lecz prowadzić obliczenia dla całej sekwencji 30-tu obrazów. W związku z powyższym, dalsze porównania wyników zostaną ograniczone do trzech ostatnich kolumn tabeli 2 (wariant II).

Istotną sprawą jest złożoność obliczeniowa algorytmu.

Tab. 2. Błędy oszacowania prędkości pojazdu

σ	Metoda WWI			Metoda WWII		
	\hat{v}	$b(\hat{v})$	RMSE	\hat{v}	$b(\hat{v})$	RMSE
0,25	0,9906	-0,0094	0,0739	0,9948	-0,0052	0,0304
0,30	0,9723	-0,0277	0,0963	0,9837	-0,0163	0,0501
0,35	0,9516	-0,0484	0,1222	0,9651	-0,0349	0,0805
0,40	0,9151	-0,0849	0,1944	0,9347	-0,0653	0,1223
	Metoda PARI			Metoda PARII		
0,25	0,9909	-0,0091	0,0649	0,9965	-0,0035	0,0259
0,30	0,9838	-0,0162	0,0793	0,9858	-0,0142	0,0459
0,35	0,9629	-0,0371	0,1048	0,9625	-0,0375	0,0791
0,40	0,9143	-0,0857	0,2265	0,9258	-0,0742	0,1335
	Metoda MAI			Metoda MAII		
0,25	0,9934	-0,0066	0,0616	0,9978	-0,0022	0,0219
0,30	0,9985	-0,0015	0,0851	1,0048	0,0048	0,0676
0,35	0,9639	-0,0361	0,1072	0,9637	-0,0363	0,0820
0,40	0,9346	-0,0654	0,1582	0,9344	-0,0654	0,1188

Źródło: opracowanie własne

Dla wszystkich trzech metod, wspólną częścią algorytmu jest poszukiwanie maksimum – w związku z czym nie będzie brane pod uwagę.

Uwzględniając wzory (5) i (6) stwierdza się, że złożoność obliczeniowa dwustronnej metody wygładzania wykładniczego wynosi $ZW = 6 \cdot N$.

Ze wzorów zamieszczonych w pracy [4] wynika, że złożoność obliczeniowa metody aproksymacji parabolicznej wynosi $ZP = 5 \cdot N \cdot (M + 1)$, gdzie $2M+1$ szerokość okna (liczba elementów uwzględnianych w algorytmie). Ze wzoru (8) otrzymuje się złożoność obliczeniową metody średniej ruchomej $ZMA = 2M \cdot N$. Biorąc pod uwagę optymalne wartości $M=6$ dla aproksymacji parabolicznej oraz $M=3$ dla metody średniej ruchomej, uzyskuje się następujące wielkości:

$$ZW = 6 \cdot N, ZP = 35 \cdot N, ZMA = 6 \cdot N \quad (9)$$

Zdecydowanie najgorzej wypada metoda aproksymacji parabolicznej. Pozostałe dwie metody wykazują jednakową złożoność obliczeniową – dzieje się tak, ponieważ we wzorze (8) podstawia się $M=3$. Dla $M > 3$ złożoność metody MA będzie większa, niż złożoność metody dwustronnego wygładzania.

Uwzględniając wartości błędu średniokwadratowego (tabela 2) oraz złożoność poszczególnych algorytmów (wzór (9)), należy polecić metodę dwustronnego wygładzania wykładniczego oraz metodę średniej ruchomej.

4. ESTYMACJA WYKORZYSTUJĄCA WSTĘPNE UŚREDNIANIE SEKWENCJI OBRAZÓW [7]

Zgodnie z ostatnią uwagą zawartą w rozdziale 3, w niniejszym rozdziale zostaną uwzględnione metody : średniej ruchomej oraz wygładzania wykładniczego.

W przypadku każdej z tych metod rozpatrzono dwa oddzielne podejścia bazujące na sekwencji 20 obrazów. W pierwszym obliczenia wykonuje się dla dwóch sekwencji 10-ciu obrazów a następnie wyznaczamy wartość średnią współczynników kierunkowych:

$$\hat{v} = \frac{1}{2}(\hat{v}_1 + \hat{v}_2) \quad (10)$$

Postępowanie to oznaczono w odniesieniu do metody średniej ruchomej jako MA1 dla 10-ciu pierwszych obrazów, MA2 dla kolejnych 10-ciu obrazów oraz MAS dla średniej (wzór (10)). Analogicznie dla metody wygładzania wykładniczego zastosowano oznaczenia: W1 (10 obrazów), W2 (10 kolejnych obrazów) , WS (wzór (10)).

W niniejszym rozdziale zastosowanie powyższych metod zostanie poprzedzone wstępną obróbką sygnału polegającą na uśrednianiu sekwencji obrazów. Operacja uśrednienia zmniejsza poziom zakłócenia, jednocześnie wprowadzając błąd polegający na rozmyciu poruszającego się pojazdu. W związku z tym powstaje problem określenia optymalnej liczby kolejnych obrazów podlegających uśrednieniu. W pracy [7] rozpatrzono zmieniającą się liczbę uwzględnionych obrazów od $M=3$ do $M=7$.

W trakcie symulacji komputerowych wykonanych dla poziomu zakłócenia $\sigma=0,4$ ustalono, że minimum błędu średniokwadratowego uzyskuje się dla $M=5$ (optymalna liczba obrazów podlegających wstępnemu uśrednieniu).

W ramach symulacji komputerowych uwzględniano następujące zestawy danych: 10 pierwszych obrazów (MA1U,W1U), 10 kolejnych obrazów (MA2U, W2U) oraz wartość średnią (wzór (10)) dla dwóch sekwencji obrazów (MASU, WSU).

W trakcie obliczeń sprawdzono drugi wariant polegający na uwzględnieniu sekwencji 20 obrazów bez rozbijania na segmenty 10-ciu elementowe oznaczony: MAMU, WMU.

W tabeli 3 zamieszczono błędy wyników estymacji prędkości pojazdu uzyskane na drodze symulacji komputerowych ($K=400$) dla odchylenia standardowego zakłócenia $\sigma = 0,4$. Kolejne kolumny zawierają: zastosowaną metodę, wartość oszacowania prędkości \hat{v} , obciążenie estymatora $b(\hat{v})$ oraz błąd średnio kwadratowy RMSE.

Cztery pierwsze wiersze tabeli 3 zawierają wyniki metody proponowanej w niniejszym rozdziale - ze wstępnym uśrednianiem danych. Dwa ostatnie wiersze zawierają wyniki zamieszczone w tabeli 2, przy czym rozpatrzono tam sekwencję 30 obrazów. Metoda MAS (WS) oznacza wyniki średniej trzech sekwencji 10-ciu obrazów uzyskanych metodą średniej ruchomej (metodą wygładzania wykładniczego). Odpowiednio, MAM (WM) oznacza wyniki dla sekwencji 30-tu obrazów uzyskanych metodą średniej ruchomej (metodą wygładzania wykładniczego).

Tab. 3. Błędy wyników estymacji prędkości pojazdu dla poziomu zakłócenia $\sigma = 0,4$

Metoda	\hat{v}	$b(\hat{v})$	RMSE	Metoda	\hat{v}	$b(\hat{v})$	RMSE
MA1U	0,9832	-0,0168	0,0914	W1U	0,9896	-0,0104	0,0984
MA2U	0,9824	-0,0176	0,1125	W2U	0,9934	-0,0066	0,0970
MASU	0,9830	-0,0170	0,0717	WSU	0,9844	-0,0156	0,0725
MAMU	1,0026	0,0026	0,0344	WMU	1,0022	0,0022	0,0407
MAS	0,9346	-0,0654	0,1582	WS	0,9151	-0,0849	0,1944
MAM	0,9344	-0,0654	0,1188	WM	0,9347	-0,0653	0,1223

Źródło: opracowanie własne

Z tabeli 3 wynika, że obciążenie estymatora $b(\hat{v})$ jest kilkakrotnie mniejsze od wartości RMSE – analogicznie jak dla tabeli 1. Oznacza to, że ocenę błędu metody można ograniczyć do wartości RMSE. Porównując błędy metod: MASU (7,17%) oraz MAMU (3,44%) stwierdza, że nie należy wyznaczać wartości średniej dla dwóch sekwencji 10-ciu obrazów (wzór(10)), lecz prowadzić obliczenia dla całej sekwencji 20-tu obrazów. Analogiczny wniosek można wyciągnąć dla metody wygładzania wykładniczego, gdzie błędy wynoszą: dla WSU (7,25%) oraz dla WMU (4,07%).

Proponowana w rozdz. 3 metoda prowadziła dla metody średniej ruchomej do następujących wartości błędów: 9,14% dla sekwencji 10-ciu pierwszych obrazów (MA1U); 11,25% dla 10-ciu następnych obrazów (MA2U) oraz 7,17% dla wartości średniej (MASU ,wzór(10)). Błąd metody MASU zmalał, w przybliżeniu, $\sqrt{2}$ razy w stosunku do wartości błędu metody MA1U (MA2U). Jest to zgodne z teorią, ponieważ wzór (10) prowadzi do dwukrotnie mniejszej wariancji, a w konsekwencji, do $\sqrt{2}$ razy mniejszego odchylenia standardowego. Podobna sytuacja zaistniała w metodzie wygładzania wykładniczego, gdzie wzór (10) prowadził do błędu 7,25% (MASU), przy wartościach wyjściowych 9,84% (W1U) oraz 9,7% (W2U).

PODSUMOWANIE

W pracy dokonano porównania skuteczności wybranych metod estymacji prędkości pojazdu w warunkach silnych zakłóceń losowych. Najmniej przydatną okazała się metoda bazująca na aproksymacji parabolicznej opisana w rozdz.1. Spośród omówionych w rozdz.2 metod wykorzystujących funkcję interkorelacji, należy polecić metodę średniej ruchomej (wzór (8)). Porównywalne z metodą Moving Average wyniki zapewnia metoda dwustronnego wygładzania wykładniczego (wzory (5) i (6)) zaprezentowana w rozdz.3. Najlepsze efekty uzyskuje się jeżeli stosując wymienione dwie metody, poprzedzi się je wstępnym uśrednieniem sekwencji obrazów (rozd.4).

Mianowicie, zgodnie z tabelą 3, dla proponowanej w rozdz.3 metody MA uzyskano błąd 15,82% (MAS), podczas gdy dla proponowanej metody błąd wynosi 7,17%, przy niekorzystnej liczbie uwzględnionych sekwencji obrazów (dwie sekwencje). Analogiczna uwaga dotyczy metody wygładzania (rozd.3)- błąd 19,44% (WS) w porównaniu z błędem 7,25% (WSU). Jeszcze większe dysproporcje występują dla metody wspólnej mediany dla pełnego zestawu obrazów. Dla metod z rozdz.3 uzyskano błędy: 11,88% (MAM) oraz 12,23% (WM). Natomiast proponowana w rozdz.4 metoda zapewnia następujące wartości błędów: 3,44% (MAMU) oraz 4,07% (WMU). Najmniejsze wartości błędów odnotowano dla metody wstępnego uśredniania z wyznaczeniem wartości mediany dla całego zestawu obrazów: 3,44% (MAMU) oraz 4,07% (WMU).

Podsumowując należy polecić metody średniej ruchomej (MA) oraz wygładzania wykładniczego (WW) poprzedzone wstępnym uśrednieniem sekwencji obrazów (rozd. 4), przy czym wartość mediany wyznacza się dla pełnego zestawu obrazów (nie stosuje się wzorów (7) lub (10)).

EFFICIENCY COMPARISON OF SELECTED METHODS OF ESTIMATING A VEHICLE VELOCITY IN STRONG RANDOM NOISE CONDITIONS

Abstract

In the paper the efficiency of selected methods of estimating a vehicle velocity in strong random noise conditions was compared. The following methods were examined: parabolic approximation, intercorrelation function, exponential smoothing and initial averaging of an image sequence. As a result of computer simulations it was concluded that the most effective (i.e. yielding the smallest mean squared error) proved the moving average method and exponential smoothing preceded by initial averaging of an image sequence.

BIBLIOGRAFIA

1. Krzyśko M.: *Statystyka matematyczna. Cz.II*, Poznań UAM 1997
2. Lucas B.D. Kanade T.: *An iterative image registration technique with an application to stereo vision*, Proceeding of Imaging understanding workshop 1981, pp.121—130
3. Purczyński J.: *Algorithms for differentiation of signals with random noise*. Computer Applications in Electrical Engineering, Poznań 2009 , pp. 21-31
4. Purczyński J.: *Estimation of the Mean Velocity of a Group of Vehicles in Strong Random Noise Conditions*, Series: Communications in Computer and Information Science No 104, TST, Springer- Verlag Berlin Heidelberg 2010, pp.168-174
5. Purczyński J.: *Estymacja prędkości pojazdu w warunkach silnych zakłóceń losowych z wykorzystaniem funkcji interkorelacji*, Logistyka nr 6/2010 str. 2839-2846 (CD-ROM)
6. Purczyński J.: *Estymacja prędkości pojazdu w warunkach silnych zakłóceń losowych metodą wygładzania wykładniczego Browna*, Logistyka nr 6/ 2011 str.3529-3536 (CD-ROM).
7. Purczyński J.: *Estymacja prędkości pojazdu w warunkach silnych zakłóceń losowych metodą uśredniania sekwencji obrazów*. Referat wygłoszony na Konferencji LogiTrans2012 – Szczyrk 17-20. 04.2012r.
8. Szabatin J.: *Podstawy teorii sygnałów*, Warszawa, WKiŁ 2000
9. Zeliaś A., Pawełek B., Wanat S.: *Prognozowanie ekonomiczne Teoria, Przykłady, Zadania*, Wydawnictwo Naukowe PWN, Warszawa 2003

Praca finansowana ze środków Ministerstwa Nauki i Szkolnictwa Wyższego (Projekt badawczy Nr N N509 399136 „Estymacja trajektorii ruchu pojazdów z wykorzystaniem analizy bayesowskiej oraz algorytmów cyfrowego przetwarzania obrazów”).

Autor:

Prof. dr hab. inż. Jan PURCZYŃSKI – Wyższa Szkoła Techniczno-Ekonomiczna w Szczecinie