

# Modelowanie sygnału z kamery termowizyjnej na potrzeby badania algorytmów optical-flow

Grzegorz Bieszczad, Krzysztof Sawicki, Andrzej Ligienza, Mariusz Mścichowski, Sławomir Gogler  
Wojskowa Akademia Techniczna, Instytut Optoelektroniki, ul. gen. Sylwestra Kaliskiego 2, 00-908 Warszawa

**Streszczenie:** W artykule przedstawiono sposób modelowania sygnału pochodzącego od kamery termowizyjnej, pozwalający na wykonanie analizy porównawczej algorytmów wyznaczania tak zwanego przepływu optycznego. Sposób modelowania powstał na potrzeby rozwoju czujnika inercyjnego, wyznaczającego przesunięcie pojazdu na podstawie analizy obrazu z kamery termowizyjnej. W ramach prac rozwojowych niezbędnym okazało się dokonanie wyboru rodzaju algorytmu wyznaczania przepływu optycznego oraz optymalizację parametrów algorytmu. Syntetyczny model sygnału pozwolił na szybkie prototypowanie algorytmów i automatyczną optymalizację jego parametrów. W artykule przedstawiono przykładowe wyniki porównania efektywności algorytmów SAD oraz Farnebäcka w kontekście zastosowania dla obrazów termowizyjnych.

**Słowa kluczowe:** termowizja, śledzenie, analiza obrazu, przepływ optyczny, nawigacja

## 1. Wprowadzenie

W artykule przedstawiono metodę testowania algorytmów wyznaczania przepływu optycznego z zastosowaniem opracowanego modelu numerycznego obrazu z kamery termowizyjnej. Nowy sposób testowania został opracowany na potrzeby realizacji projektu nowego czujnika nawigacyjnego do pojazdu BSP (Bezzałogowy Statek Powietrzny). Obecnie jako czujniki nawigacyjne dla pojazdów bezzałogowych stosowane są czujniki GPS, czujniki barometryczne, akcelerometry i żyroskopy. W pojazdach tych występują czujniki położenia bezwzględne takie jak GPS, dalmierze itp. oraz czujniki wyznaczające dynamikę ruchu jak akcelerometry i żyroskopy. Służą one zarówno do orientowania pojazdu w przestrzeni, jak i do sterowania jego automatyką, a jednocześnie, uzupełniając się, tworzą redundantny zbiór danych zwiększających dokładność i niezawodność urządzenia. Czujniki, które czerpią informacje o położeniu z ruchu względnego, przyspieszenia lub momentu pędu, są powszechnie nazywane czujnikami bezwładnościowymi lub inercyjnymi. Okazuje się jednak, że powszechnie instalowane na pojazdach typu BSP kamery mogą być również bogatym źródłem informacji o ruchu względnym pojazdu, na którym są zainstalowane. Coraz powszechniejsze stają się czujniki świadomości sytuacyjnej, które są przeznaczone do wykrywania przeszkód i unikania

kolizji [1]. Takie systemy są często tworzone przy użyciu algorytmów przetwarzania obrazu i uczenia maszynowego do analizy sygnału na przykład z kamer stereoskopowych [2], kamer typu „time of flight” [3] i innych. Czujniki wizyjne wyposażone w odpowiednie metody przetwarzania danych mogą dostarczyć dodatkowych informacji do systemu nawigacyjnego, zwiększając w ten sposób precyzję szacowania pozycji BSP. Takie systemy często wykorzystują kamery pracujące w widzialnej części widma promieniowania elektromagnetycznego. Jednym z pierwszych udanych wdrożeń takiego czujnika jest PX4FLOW [4].

Termowizyjny, inercyjny czujnik, który został opracowany w Wojskowej Akademii Technicznej, to nowy typ czujnika pozycjonującego, który ma na celu nie tylko zwiększenie dokładności i niezawodności systemu nawigacyjnego, ale dodatkowo umożliwia akwizycję obrazów termowizyjnych, jako danych uzupełniających świadomość sytuacyjną. Obrazowanie termowizyjne umożliwia nawigację w całkowitej ciemności, trudnych warunkach pogodowych lub w pomieszczeniach. Urządzenie nawigacyjne, dla którego opracowano narzędzie w postaci modelu sygnału z kamery, zainstalowane na pojeździe latającym, pozwala wnioskować o względnym przesunięciu pojazdu latającego na podstawie analizy obrazu z kamery termowizyjnej. Tak opracowany czujnik stanowi dodatkową informację w wieloczułkowym systemie nawigacji i świadomości sytuacyjnej nowoczesnego drona. Aby prawidłowo testować czujnik tego typu, bez potrzeby przeprowadzania testów na modelu fizycznym pojazdu latającego, został opracowany model syntetyczny sygnału z kamery termowizyjnej zainstalowanej na tego typu pojeździe wykonującym zadany ruch. Dodatkowo opracowany model sygnału pozwala dokonać lepszego wyboru odpowiedniego algorytmu wyznaczania przepływu optycznego oraz optymalizację parametrów wybranego algorytmu ze względu na skuteczność śledzenia punktów na obrazie termowizyjnym oraz na złożoność obliczeniową.

### Autor korespondujący:

Grzegorz Bieszczad, grzegorz.bieszczad@wat.edu.pl

### Artykuł recenzowany

nadesłany 17.07.2023 r., przyjęty do druku 15.01.2024 r.



Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 3.0

Przedstawiono tu zatem sposób modelowania sygnału pochodzącego od kamery termowizyjnej pozwalający na wykonanie analizy porównawczej wybranych algorytmów wyznaczania przepływu optycznego: algorytmu Sum-of-Absolute-Differences (SAD) [5] oraz algorytmu Farnebäck [6]. Syntetyczny model sygnału pozwolił na szybkie prototypowanie algorytmów i automatyczną optymalizację jego parametrów.

## 2. Opis przedmiotu badania – wybrane algorytmy przepływu optycznego


### 2.1. Algorytm przepływu optycznego

Niezależnie od użytego źródła obrazu, możliwe jest wyodrębnienie ruchu punktów na obrazie za pomocą algorytmów przepływu optycznego. Algorytmy przepływu optycznego wyznaczają ruch każdego lub wybranych punktów obrazu, analizując ich przesunięcie w kolejnych ramkach obrazu. Dla każdego takiego punktu wyznaczany jest wektor przesunięcia punktu na obrazie. Na podstawie takiej informacji możliwe jest wyznaczenie ruchu kamery za pomocą względnych zależności geometrycznych kamery i obserwowanego obiektu, np. powierzchni ziemi.

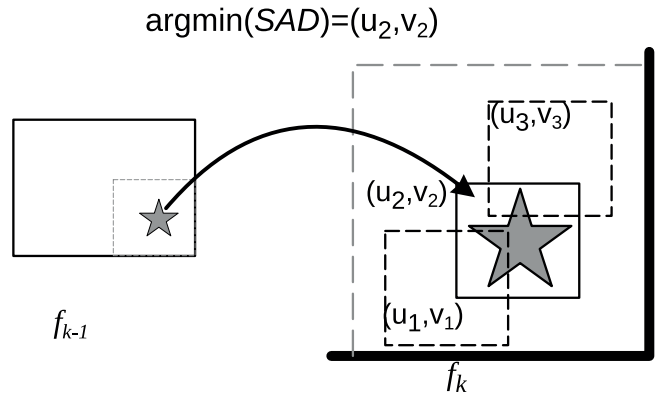
Do badań wytypowano dwa algorytmy wyznaczania przepływu optycznego — jeden z rodziny algorytmów tzw. gęstych, wyznaczających przepływ optyczny dla każdego piksela w obrazie, a drugi rzadki — w wyznaczonych miejscach obrazu. Są to odpowiednio algorytmy Farnebäck i SAD.

#### 2.1.1. Algorytm Farnebäck

W badaniu zastosowano implementację algorytmu Farnebäck występującą w udostępnionej publicznie bibliotece OpenCV [7]. Metoda Farnebäck polega na lokalnej aproksymacji obrazu odniesienia oraz aktualnie analizowanego, za pomocą odpowiednich dwuwymiarowych wielomianów trzeciego stopnia, a następnie analitycznym obliczeniu przesunięcia między funkcjami wielomianowymi. Lokalne aproksymacje są dokonywane dla otoczenia każdego piksela na obrazie. W wyniku przeprowadzenia obliczeń metodą Farnebäck powstaje tak zwane gęste pole wektorowe przepływu optycznego, to znaczy, dla każdego piksela w obrazie przypisany jest dokładnie jeden wektor przesunięcia. Przykładowe pole wektorowe uzyskane dla obrazu termowizyjnego z czujnika inercyjnego zainstalowanego na pojeździe latającym zaprezentowano na rys. 1.



Rys. 1. Wyznaczone pole wektorowe metodą Farnebäck dla wybranej ramki obrazu z sekwencji obrazów termowizyjnych  
Fig. 1. Farnebäck vector field for selected image frame obtained from a sequence of thermal images



Rys. 2. Lokalizowanie obiektu poprzez odnajdywanie obszaru, dla którego współczynnik SAD jest najmniejszy  
Fig. 2. Locating an object by finding the area for which the SAD is the smallest

#### 2.1.2. Algorytm SAD

Algorytmy gradientowe, takie jak SAD, oceniają położenie obiektu przez analizę różnic między dwiema kolejnymi klatkami obrazu. Zmiany położenia obiektu są szacowane poprzez znajdowanie gradientów w przestrzeni i w czasie. Algorytm śledzenia oparty na metodzie Sum-of-Absolute-Differences wykrywa przesunięcie obiektu obliczając dla fragmentów obrazu miarę podobieństwa z fragmentem obrazu z poprzedniej chwili, zapamiętanego w pamięci procesora obliczeniowego. Współczynnik SAD określa różnicę między dwoma fragmentami obrazu, co zobrazowano na rys. 2.


Oba porównywane fragmenty muszą mieć te same wymiary i najczęściej są prostokątami. Przyjmując, że dwa fragmenty obrazu (nazywane tutaj oknem) mają wymiar  $(2h + 1)$  na  $(2h + 1)$ , oraz że są one wycentrowane w punktach  $(x, y)$  oraz  $(u, v)$ , można dla nich określić współczynnik SAD korzystając ze wzoru:

$$SAD = \sum_{i,j \in \{-h,h\}} |f_{k-1}(x+i, y+j) - f_k(u+i, v+j)| \quad (1)$$

gdzie:  $i \in \{-h, h\}$ ,  $j \in \{-h, h\}$  – iteratory obszaru podobieństwa;  $h$  – rozmiar obrazu do porównania,  $f_k$  – pojedyncza ramka –  $k$ -ty obraz,  $k$  – numer ramki,  $f_k(m, n)$  – wartość piksela obrazu w  $m$ -tym wierszu i  $n$ -tej kolumnie,  $(x, y)$  – położenie śledzonego obiektu na poprzedniej ramce,  $(u, v)$  – położenie fragmentu obrazu, z którym następuje porównanie.

W algorytmie przeszukane zostają obszary znajdujące się w odległości nie większej od poprzedniego położenia obiektu, niż pewna ustalona wartość. Ta ustalona wartość nazwana została zasięgiem śledzenia. Jeśli założymy, że śledzony obiekt znajduje się na obrazie  $f_{n-1}$  i jest wycentrowany w punkcie  $(x, y)$ , to znalezienie obiektu na kolejnej klatce obrazu polega na znalezieniu takiego  $(u, v)$ , dla którego SAD przyjmuje minimum. Punkt  $(u, v)$  oznacza środek poszukiwanego obiektu na obrazie  $f_k$ . Sytuację, w której fragment obrazu jest przeszukiwany piksel po pikselu zobrazowano na rys. 3, gdzie czerwonym prostokątem zaznaczono położenie obiektu na poprzedniej ramce, niebieskimi prostokątami przykładowe fragmenty obrazu do porównania, natomiast strzałkami schemat skanowania obszaru wokół pierwotnego położenia obiektu.

Wymiary obszaru poszukiwań zależą od założonej wcześniej dynamiki zmian obrazu. W praktyce należy wyznaczyć, w jakim zakresie obiekt będzie zmieniał swoje położenie na obrazie z ramki na ramkę. Maksymalne przesunięcie obiektu na obrazie, wyrażone w pikselach, powinno odpowiadać zasię-



Rys. 3. Kolejne obszary porównania obszarów obrazów za pomocą metody SAD

Fig. 3. Successive areas of comparison of image areas using the SAD method

gowi śledzenia, czyli odległości od środka obszaru śledzenia do jego krawędzi. Zwiększenie obszaru śledzenia niesie za sobą konieczność dokonywania większej liczby obliczeń, gdyż trzeba dokonać większej liczby porównań fragmentów obrazów. Aby zminimalizować liczbę porównywanych obszarów, należałoby zapewnić warunki, w których przesunięcie obiektu między kolejnymi ramkami obrazów byłoby jak najmniejsze. Zakładając stałe warunki obserwacji obiektu oraz jego właściwości dynamiczne, można zmniejszyć przesunięcia obiektu z obrazu na obraz, poprzez zwiększenie liczby rejestrowanych ramek obrazu w jednostce czasu.

### 3. Model sygnału z kamery termowizyjnej

#### 3.1. Niejednorodność resztkowa

Matryce mikrobolometryczne i detektory fotonowe wykazują zróżnicowaną reakcję detektorów na równomierne promieniowanie podczerwone, które pada na ich powierzchnię. Przyczyną tego zjawiska są niedoskonałości produkcyjne indywidualnych detektorów oraz układu odczytowego, które wynikają z zastosowanego procesu technologicznego. Nierównomierność w rozmiarze detektorów prowadzi do powstania losowej nieregularności w ich czułości oraz generuje losowe napięcie niezrównoważenia. Niedoskonałość wykonania ślepych bolometrów i wzmacniaczy całkujących powoduje powstanie charakterystycznego kolumnowego wzoru na odczytywanym z detektora obrazie. W wyniku różnorodnych niedoskonałości w matrycy detektorów, kamera termowizyjna generuje nieregularny obraz z nałożonym szumem o stałym wzorze FPN (ang. *Fixed Pattern Noise*), nawet przy oświetleniu równomiernym promieniowaniem podczerwonym. W celu eliminacji stałego wzorca szumu stosowane są różnego rodzaju algorytmy korekcji niejednorodności [8–11]. Mimo zastosowania najbardziej wyszukanych metod korekcji niejednorodności, zawsze występuje w obrazie niejednorodność resztkowa, która objawia się szczególnie podczas dynamicznych zmian temperatury własnej matrycy detektorów [12]. Dynamiczne zmiany warunków środowiskowych, występujące w pojazdach UAV istotnie wpływają na jakość zobrazowania w zainstalowanych na nich kamerach termowizyjnych, szczególnie w kamerach z niechłodzonymi detektorami bolometrycznymi. Zjawisko stałego wzorca szumu resztkowego powinno być więc, w tym kontekście zastosowania, uwzględnione w modelu szumowym.

#### 3.2. Szum czasowy

Szum czasowy detektora jest fluktuacją wartości napięcia detektora, występującą mimo ustalonych warunków jego pracy i stałej wartości padającego promieniowania. Szum czasowy detektora pogarsza jego rozdzielczość temperaturową, wyrażoną na przykład parametrem NETD (ang. *Noise Equivalent Temperature Difference*), czyli wartością różnicy temperatury obserwowanego obiektu równoważnej szumom własnym detektora. Poziom szumów detektora określa się najczęściej wartością skuteczną napięcia tego szumu. Wartość tego parametru określany dla całej kamery zależy również od parametrów układu optycznego, z którym pracuje detektor. Na ogół parametr NETD dla detektorów mikrobolometrycznych mierzy się w układzie optycznym o aperturze względnej  $F/\# = 1$  i dla określonej temperatury otoczenia.

#### 3.3. Wpływ układu optycznego

W kamerze termowizyjnej tylko część docierającego do matrycy detektorów promieniowania stanowi sygnał użyteczny pochodzący z obserwowanej sceny. Duża część energii padającej na detektory i wpływającej na ich temperaturę pochodzi od takich źródeł jak obudowa układu optycznego kamery czy obudowa i podłoże detektora. Składowa udziału energii ze sceny, w stosunku do ilości energii z obudowy kamery i innych źródeł, zależy od współczynnika konfiguracji optycznej detektorów (*View Factor*) i układu optycznego oraz właściwości spektralnych okna transmisyjnego matrycy. Przykładowo, współczynnik konfiguracji optycznej detektora z obiektywem kamery można przybliżyć schematem powierzchni jednostkowej, znajdującej się w danej odległości do równoległego dysku, o zadanym promieniu odpowiadającym aperturze układu optycznego i środkiem przechodzącym przez normalną do powierzchni detektora. W zależności od konstrukcji obiektywu, współczynnik konfiguracji optycznej może różnić się między detektorami w matrycy o kilka procent [13].

Zmiana temperatury otoczenia ma również wpływ na moc sygnału padającego na detektory, pochodzącego z elementów mechanicznych mocowania oraz soczewek obiektywu. Jeśli wpływ tego sygnału jest nierównomierny względem położenia detektorów w matrycy, powoduje on zwiększenie niejednorodności obrazu termowizyjnego na promieniowanie ze sceny i objawia się w postaci charakterystycznych wzorów w obrazie [12]. Prawidłowo skonstruowany układ optyczny nie powinien wprowadzać dodatkowego sygnału z własnego promieniowania w sposób nierównomierny, jednak w praktyce nie jest to zawsze możliwe. Przykładowy obraz termowizyjny uzyskany za pomocą kamery, w której zjawiska te były zauważalne, zaprezentowano na rys. 4. Na rysunku widoczny jest charakterystyczny wzór w postaci jaśniejszego okręgu na obrzeżach obrazu, co wynika z nierównomiernego promieniowania elementów mechanicznych na powierzchnię matrycy.

W ramach zastosowanego modelu, zjawisko promieniowania pasożytniczego od układu optycznego przybliżono za pomocą funkcji cosinusowej, w której argumentem była odległość od środka powierzchni matrycy, co przedstawiono za pomocą wzoru 2.

$$L_{x,y} = A \cdot \cos \left[ \pi \cdot \sqrt{\left(x - \frac{X}{2}\right)^2 + \left(y - \frac{Y}{2}\right)^2} \cdot f \right] \quad (2)$$

gdzie:  $X = 640$  – rozdzielczość pozioma matrycy,  $Y = 480$  – rozdzielczość pionowa matrycy,  $f = 0, 5$  – współczynnik geometryczny efektu winietowania,  $A$  – współczynnik amplitudowy efektu winietowania.



**Rys. 4. Efekt wpływu promieniowania elementów konstrukcyjnych kamery na obraz sceny**  
 Fig. 4. The effect of radiation of camera structural elements on the image of the scene

Współczynniki  $f$  oraz  $A$  dobiera się do sytuacji pomiarowej, przy czym współczynnik geometryczny  $f$  jest charakterystyczny dla modelowanego układu optycznego i dobiera się go raz dla danej kamery, natomiast współczynnik  $A$  może zmieniać się w czasie, co odpowiada zmianom temperatury układu optycznego. W pracach badawczych dotyczących projektowanego czujnika inercyjnego zbudowanego w oparciu o kamerę termowizyjną współczynnik  $f$  ustalono na wartość 0,5, co w wystarczającym stopniu przybliżało zachowanie układu optycznego. Istnieją bardziej wyszukane sposoby modelowania powyższego efektu [14, 15], jednak dla tego zastosowania nie były one konieczne.

### 3.4. Uproszczony model sygnału z obserwowanego terenu

Do kamery termowizyjnej realizującej zadanie śledzenia terenu dociera sygnał użyteczny w postaci obrazu termograficznego terenu znajdującego się bezpośrednio pod pojazdem latającym. W ogólności jest to obraz o skomplikowanej strukturze, jednak w modelu przyjęto uproszczone założenie, że obraz terenu jest sygnałem losowym o przestrzennej gęstości widmowej, skoncentrowanej wokół niskich częstotliwości. Wygenerowanie sygnału

terenu sprowadza się do wygenerowania odpowiednio dużej macierzy liczb losowych z rozkładu normalnego, a następnie przetworzenie macierzy za pomocą odpowiednio dobranego dolnoprzepustowego filtra przestrzennego. Z takiej macierzy można wybrać w procesie kadrowania fragment odpowiadający aktualnie obserwowanemu obszarowi. Ruch kamery obserwującej teren będzie odpowiadał zmianie obszaru, z którego wybierany jest bieżący kadr, przy czym rozmiar kadrowanego terenu odpowiada wysokości, na której symulowany jest przełot pojazdu. W przypadku kiedy rozmiar kadrowanego obszaru jest stały, mamy do czynienia z wyidealizowanym przypadkiem przełotu na stałej wysokości. W obecnym modelu przyjęto właśnie takie założenie upraszczające – przełotu na stałej wysokości.

### 3.5. Syntetyczny model szumowy

Do modelowania sygnału ze sceny dla danego zastosowania uwzględnione zostały powyższe zjawiska i ich odwzorowujące sygnał użyteczny ze sceny oraz szum pomiarowy:

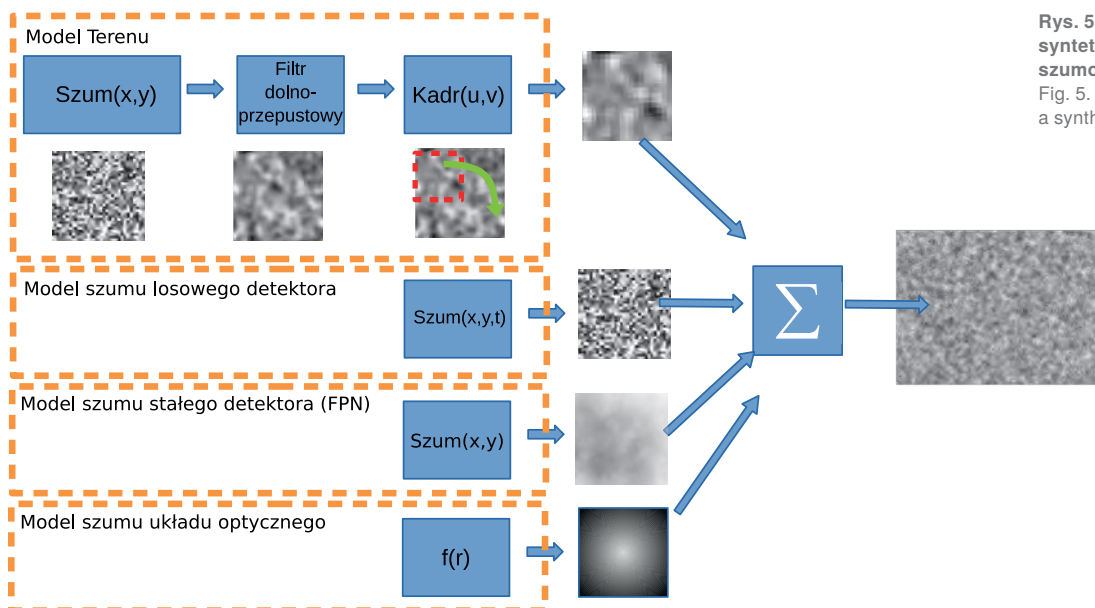
- Sygnał użyteczny
  - Stały wzorzec terenu
- Składowe stałe (błędy systematyczne pomiaru)
  - Składowe stałe w czasie, losowe w  $(x, y)$  — FPN
  - Składowe stałe w czasie, ustalone w  $(x, y)$  :  $u = f(x, y)$ 
    - układ optyczny
- Składowe losowe (błędy przypadkowe pomiaru)
  - Składowe losowe w czasie i przestrzeni — szum czasowy macierzy.

Składniki modelu są ze sobą algebraicznie sumowane z wagami odpowiadającymi wpływowi danego składnika szumowego (rys. 5).

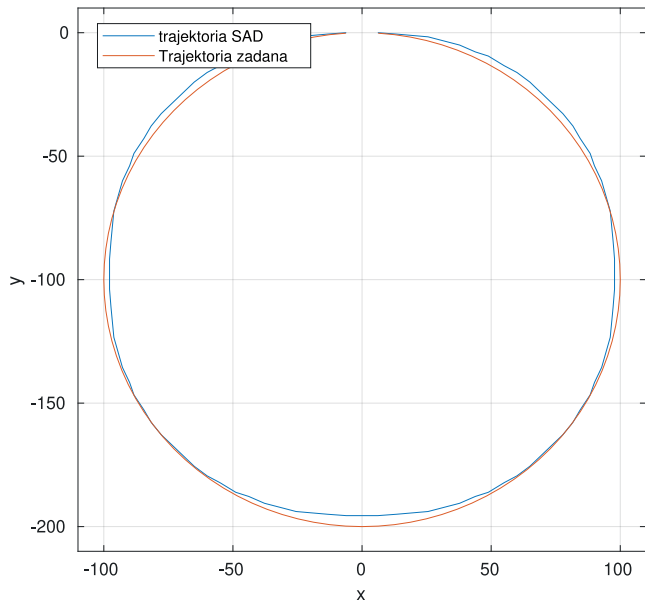
Kod źródłowy modelu, napisany w języku MATLAB, został udostępniony publicznie [16].

## 4. Badanie wybranych algorytmów

W modelu uwzględniono parametryzowany wpływ poszczególnych składników szumowych, dzięki czemu można zbadać wpływ zjawisk występujących w kamerze termowizyjnej na skuteczność śledzenia wybranym algorytmem wyznaczania przepływu optycznego. W szczególności można porównać wpływ szumu czasowego i przestrzennego o różnym natężeniu



**Rys. 5. Schemat blokowy syntetycznego modelu szumowego**  
 Fig. 5. Block diagram of a synthetic noise



**Rys. 6. Przykładowa trajektoria obrazu wyznaczona algorytmem SAD wraz z referencyjną trajekcją zadaną w modelu**  
 Fig. 6. Example image trajectories determined by the SAD algorithm with a modeled reference trajectory

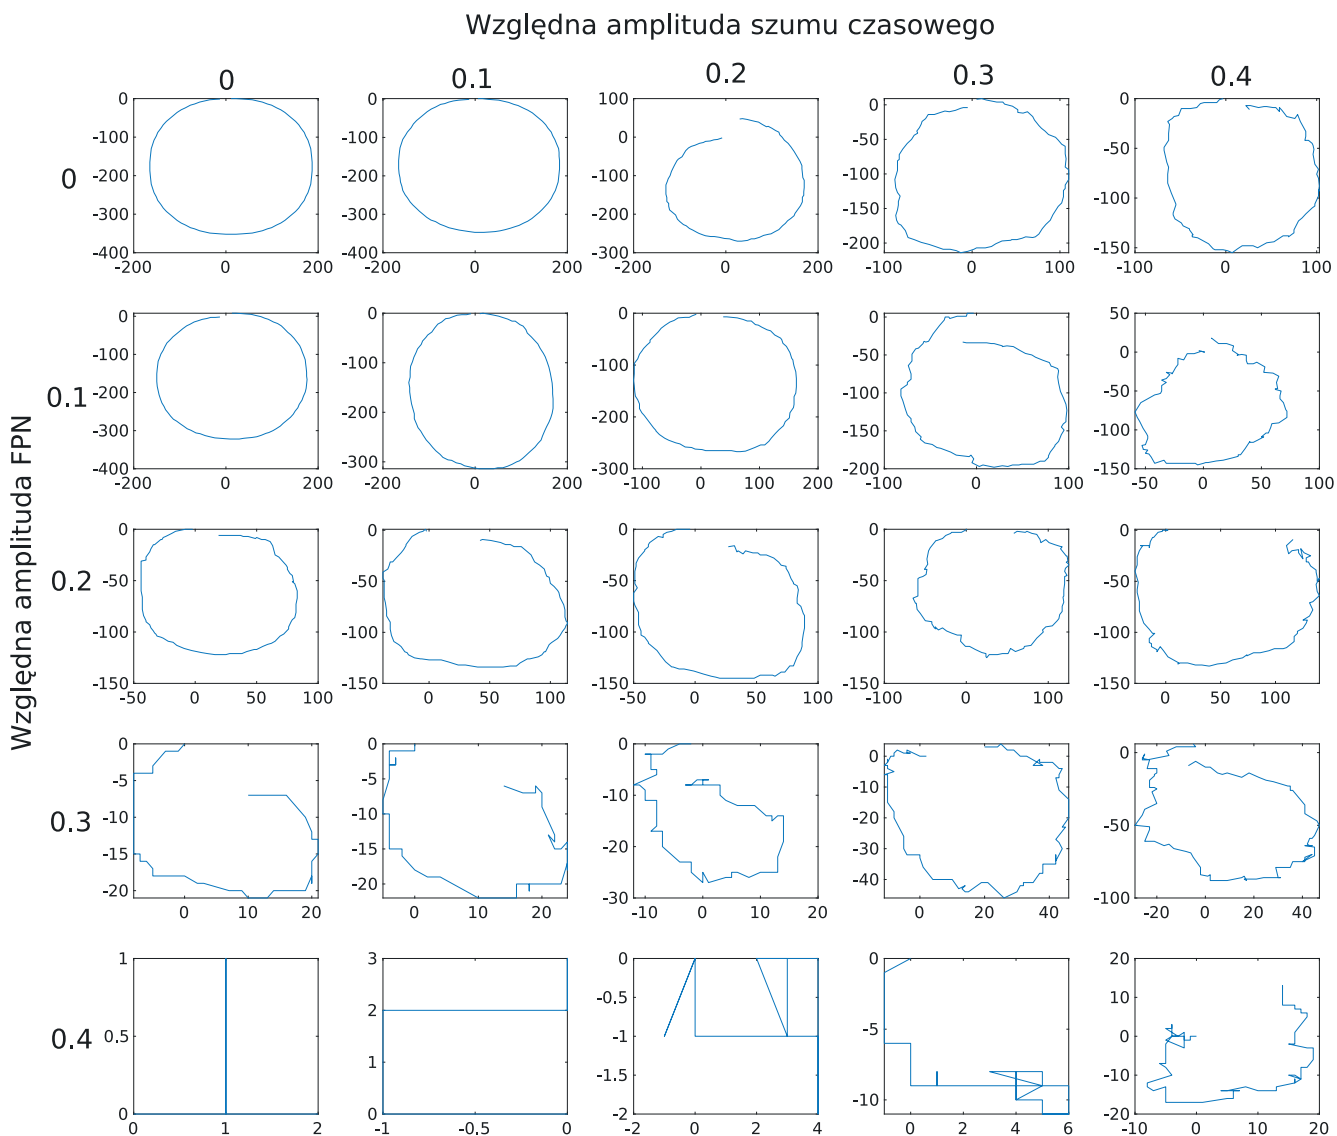
na model skuteczność śledzenia. Zadany wektor przesunięcia w modelu sygnału może być porównany z uśrednionym wektorem przesunięcia wyznaczonym, dla pola gęstego według wzoru 3, badanym algorytmem optical-flow.

$$\bar{V}_{xy} = \frac{1}{X \cdot Y} \sum_1^X \sum_1^Y V_{xy} \tag{3}$$

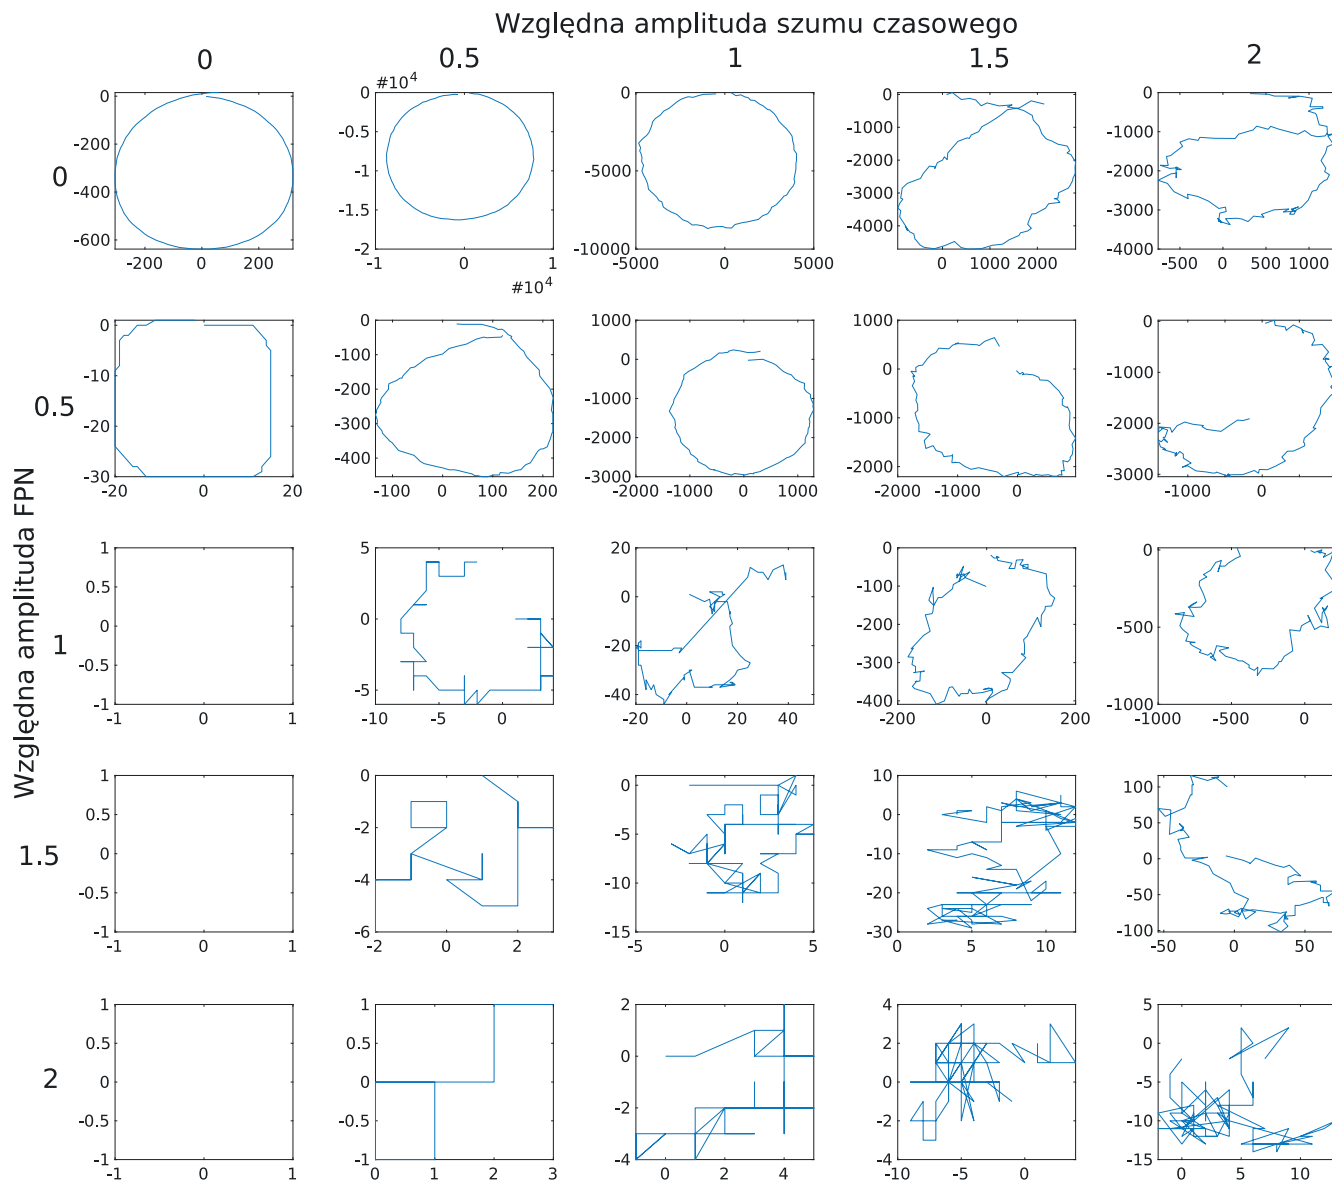
gdzie:  $V_{xy}$  – składnik pola wektorowego wyznaczony algorytmem optical-flow dla danej współrzędnej obrazu.

Tak wyznaczony wektor przesunięcia całego obrazu można wyznaczyć dla każdej ramki obrazu w sekwencji, tworząc trajektorię przesunięcia obrazu. Porównując trajektorię zadaną i wyznaczoną odpowiednim algorytmem optical-flow, można ocenić skuteczność odpowiedniego algorytmu. Przykładową trajektorię wyznaczoną za pomocą algorytmu SAD, wraz z trajekcją referencyjną wprowadzoną do modelu, przedstawiono na rys. 6.

Do badania algorytmów posłużono się sekwencją wygenerowanych obrazów o zadanej amplitudzie sygnału użytecznego ze sceny oraz zadanej względnej amplitudzie szumu czasowego i szumu FPN. Amplitudę szumów ustalano w zakresie



**Rys. 7. Zestaw wybranych trajektorii ruchu dla różnych parametrów szumu czasowego i szumu FPN dla algorytmu SAD**  
 Fig. 7. A set of selected motion trajectories for different parameters of time noise and FPN noise for the SAD algorithm



Rys. 8. Zestaw wybranych trajektorii ruchu dla różnych parametrów szumu czasowego i szumu FPN dla algorytmu Farnebacka  
 Fig. 8. A set of selected motion trajectories for different parameters of time noise and FPN noise for the Farneback algorithm

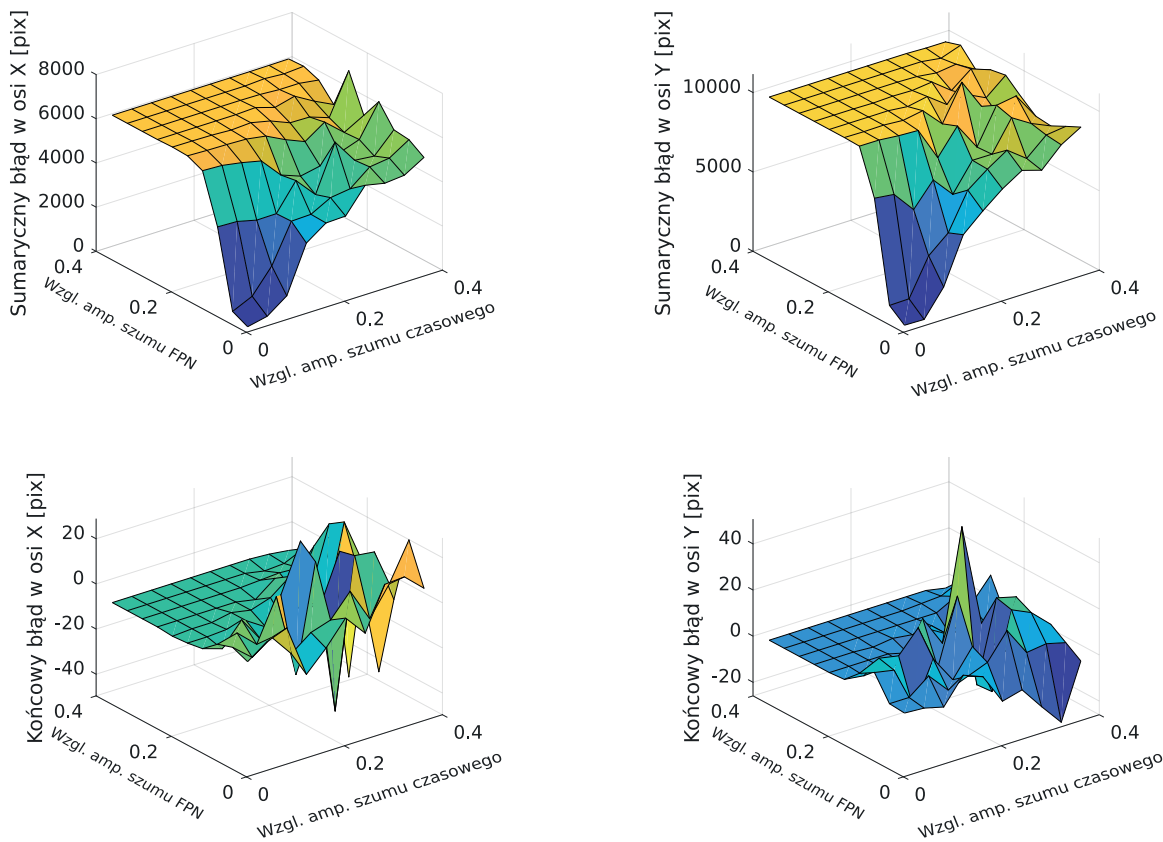
od 0 do 2 względem amplitudy sygnału użytecznego. Pozwalało to na zbadanie algorytmów śledzenia w warunkach, w których amplituda sygnału użytecznego była niższa niż amplituda szumu. Do badania algorytmów śledzenia skonfigurowano model sygnału tak, aby sygnał użyteczny odtwarzał kołowy ruch pojazdu w taki sposób, aby promień koła na obrazie zatoczył okrąg o promieniu 100 pikseli. Przedstawiony przykład z rys. 6 został uzyskany dla sygnału o znikomym poziomie szumów czasowych i FPN, dzięki czemu wyznaczona trajektoria i trajektoria zadana pokrywają się niemal całkowicie. Niewielkie odstępstwa między trajektoriami występują najprawdopodobniej z powodu występowania niewielkich błędów numerycznych.

Wyznaczone trajektorie ruchu z zaszumionych obrazów są przedstawione na rys. 7 (metoda SAD) oraz rys. 8 (metoda Farnebacka). Przedstawione zbiory obrazów zostały zestawione dla różnych kombinacji amplitudy odpowiednich rodzajów szumów FPN i czasowego.

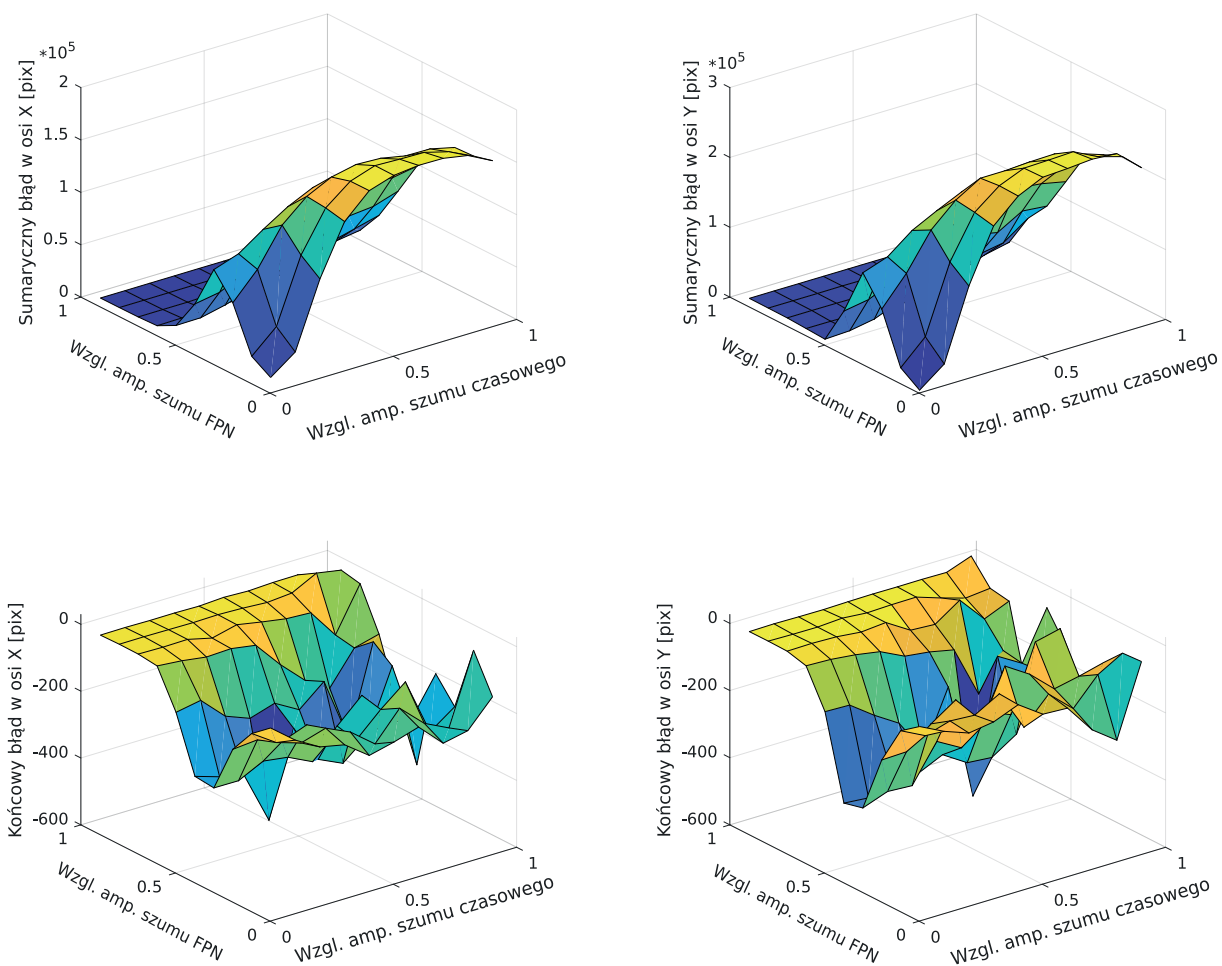
Wyraźnie daje się zauważyć, że dla niskich wartości szumów metoda SAD sprawdza się znacznie lepiej, ponieważ kształty wyznaczonych trajektorii są podobne w większym stopniu do zadanego pierwotnie okręgu. Dla metody Farnebacka ist-

nieje możliwość pracy z większymi poziomami szumów niż dla metody SAD, ale z istotnymi ograniczeniami. O ile w metodzie Farnebacka kierunek ruchu jest wyznaczany prawidłowo, o tyle amplituda ruchu jest obciążona istotnym błędem. Powoduje to istotną zmianę skali wyznaczonych przesunięć, często nawet o kilka rzędów wielkości, mimo zachowania zbliżonego kształtu trajektorii. Wynika to między innymi z większego zasięgu poszukiwania zadanego dla tego algorytmu, niż w metodzie SAD i tym samym możliwości wystąpienia większych błędów maksymalnych.

Do oceny skuteczności śledzenia opracowano miarę, która uwzględniała dokładność wyznaczonych wektorów przesunięcia na obrazie z klatki na klatkę. Dla odpowiednio długiej sekwencji ruchu można obliczyć sumę kolejnych błędów, wyliczonych dla każdej kolejnej klatki sekwencji obrazów. Wyniki pomiarów błędów dla obu algorytmów przedstawiono na rys. 9 dla algorytmu SAD i na rys. 10 dla algorytmu Farnebacka. Górne wykresy przedstawiają błąd wyznaczenia trajektorii odpowiednio dla współrzędnych  $x$  oraz  $y$  w funkcji amplitudy szumu czasowego i szumu FPN. Dodatkowo przedstawiono odległość między końcowym punktem wyznaczonej trajektorii i trajektorii referencyjnej odpowiednio na wykresach dolnych.

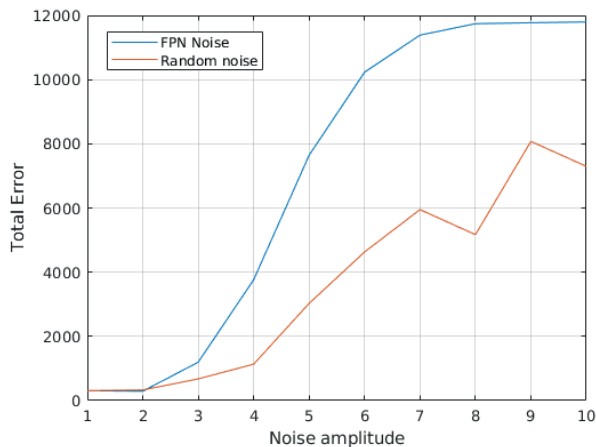


**Rys. 9. Zależność błędu trajektorii w funkcji natężenia szumów czasowych i FPN dla algorytmu SAD**  
 Fig. 9. Trajectory error dependence as a function of time noise intensity and FPN for the SAD algorithm



**Rys. 10. Zależność błędu trajektorii w funkcji natężenia szumów czasowych i FPN dla algorytmu Farnebacka**  
 Fig. 10. Trajectory error dependence as a function of time noise intensity and FPN for Farneback algorithm

Istotny jest fakt narastania błędu wyznaczenia trajektorii dla szumu FPN i szumu czasowego w niejednakowy sposób. Ogólnie oba algorytmy wyznaczania przepływu optycznego przedstawiają większą czułość na szum typu FPN niż na szum czasowy. Wiele wskazuje na to, że algorytmy wyznaczania przepływu optycznego charakteryzuje pewnego rodzaju zysk stosunku sygnału do szumu, związany z przetwarzaniem obrazu



Rys. 11. Zależność błędów trajektorii w funkcji natężenia szumów czasowych i FPN dla algorytmu SAD

Fig. 11. Trajectory error dependency as a function of time noise intensity and FPN for SAD

z otoczenia piksela. Jeżeli założymy, że szum czasowy między pikselami jest nieskorelowany, to może występować tu efekt uśrednienia szumu w procesie przetwarzania otoczenia piksela. Jednocześnie szum FPN może mieć dokładnie odwrotny skutek, zwiększając autokorelację przestrzenną sygnału z matrycy detektorów, tym samym powodując tendencję algorytmu do wykazywania największego podobieństwa obszaru między ramkami w dokładnie tym samym punkcie przestrzeni – odpowiadającemu zerowemu przesunięciu. Efekt ten jest wyraźniejszy, jeśli zestawimy wyniki pomiaru błędów, zmierzonych niezależnie dla obu typów szumów, co przedstawiono na rys. 11. Dla obu analizowanych algorytmów wpływ szumu FPN jest silniejszy niż wpływ szumu czasowego.

## 5. Wnioski

Czułość termiczną kamery termowizyjnej określa się najczęściej parametrem NETD. Parametr ten określa jak małe różnice temperatury sceny kamera jest w stanie rozróżnić. W praktyce pomiarów terenowych, w różnych warunkach środowiskowych i pogodowych oraz różnych porach roku wynika, że dla większości warunków spotykanych w polskim klimacie, kontrast termiczny podłoża jest rzędu 100 mK. Jest to wartość porównywalna z parametrem NETD kamer termowizyjnych nawet o przeciętnej jakości. Można więc założyć, że dla większości kamer termowizyjnych instalowanych na pojazdach typu UAV, stosunek sygnału do szumu czasowego powinien być zdecydowanie większy od jedności. Czułość termiczna może mieć znaczenie dla działania czujnika w trudnych warunkach pogodowych jak te, które występują późną, deszczową jesienią i zimą, kiedy to kontrast termiczny gruntu jest bardzo wyrównany z powodu opadów deszczu lub mokrego śniegu i niskiego nasłonecznienia. Jak wynika z przeprowadzonej analizy typowe parametry kamer termowizyjnych spotykanych w praktyce pomiarów

są wystarczające do realizacji przedstawionych algorytmów optical-flow.

Jak wynika z modelowania, ważnym parametrem wpływającym na zadanie śledzenia obrazu jest występowanie niejednorodności resztkowej, wynikającej z niedoskonałego usuwania FPN, która może powodować tendencję algorytmu śledzenia zmian na obrazie do błędnego traktowania stałego wzorca niejednorodności resztkowej jako nieruchomej sceny. Należy zapewnić, by niejednorodność resztkowa kamery w trakcie realizacji zadania wyznaczania optical-flow, na przykład na potrzeby nawigacji, była porównywalna lub mniejsza od NETD kamery. Zwykle niejednorodność resztkową mierzy się za pomocą modelu trójwymiarowego szumu, którego pomiar pozwala na porównanie odpowiednich wartości szumu przestrzennego (RNU) z szumem czasowym (NETD). W tego typu zadaniach pomiar szumów 3D nabiera istotnego znaczenia.

Należy zaznaczyć, że zaawansowane techniki śledzenia przesunięć na obrazie mogą powodować efekt w postaci zysku przestrzennego, wynikającego z jednoczesnej analizy dużego obszaru obrazu, powodując tym samym minimalizację wpływu szumu czasowego NETD na zasadzie podobnej do efektu uśredniania. O ile dla pewnych algorytmów wyznaczania przesunięcia obrazów, parametr NETD może mieć pomijalne znaczenie, o tyle wpływ niejednorodności resztkowej jest trudny do wyeliminowania.

Sposoby modelowania jak przedstawione w niniejszym artykule mogą zyskiwać znaczenie szczególnie w nowych metodach przetwarzania obrazu z zastosowaniem uczenia maszynowego. W tego typu metodach przetwarzania mogą występować nieoczywiste zależności czasowe i przestrzenne które mogą nie być w praktyce poznawalne w sposób analityczny, a być osiągalne jedynie na drodze symulacji lub eksperymentu. Należy zaznaczyć, że wartości błędów generowanych przez algorytmy optical-flow analizowane w artykule, są bardzo wysokie i wynikają wprost z dobranych skrajnych wartości szumu, co powoduje pracę na granicy skuteczności algorytmów. Metody implementujące metody optical-flow w rzeczywistych urządzeniach muszą zapewnić odpowiedni margines bezpieczeństwa dla wartości SNR, jednak nie zmienia to faktu, że testowanie algorytmów tego typu ujawnia największą wartość poznawczą właśnie w warunkach granicznych.

Na obecnym etapie rozwoju modelu istnieje możliwość symulowania ruchu pojazdu UAV na stałej wysokości. Istnieje możliwość rozszerzenia modelu pozwalając na uwzględnienie zmiany wysokości lotu poprzez modyfikację funkcji kadrującej ten fragment sygnału który odpowiada za generację terenu. Idąc dalej można funkcję kadrującą poprzedzić odpowiednim przekształceniem perspektywicznym, w ten sposób uzyskując dodatkowe stopnie swobody dla symulowanego pojazdu latającego. Jednocześnie tego typu rozwiązanie mogłoby skomplikować proces testowania i wyciągania wniosków.

## Bibliografia

1. Gageik N., Benz P., Montenegro S., *Obstacle Detection and Collision Avoidance for a UAV With Complementary Low-Cost Sensors*, "IEEE Access", Vol. 3, 2015, 599–609, DOI: 10.1109/ACCESS.2015.2432455.
2. Ruf B., Monka S., Kollmann M., Grinberg M., *Real-time on-board obstacle avoidance for UAVs based on embedded stereo vision*, "International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences", Vol. 42, No. 1, 2018, 363–370, 2019, DOI: 10.5194/isprs-archives-XLII-1-363-2018.



3. Masiero A., Sofia G., Tarolli P., *Quick 3D with UAV and ToF camera for geomorphometric assessment*, “International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences”, Vol. 43, No. 1, 2020, 259–264, DOI: 10.5194/isprs-archives-XLIII-B1-2020-259-2020.
4. Mazal J., *Self-localization of Unmanned Aerial Vehicles Based on Optical Flow in Onboard Camera Images*, “Lecture Notes in Computer Science”, Vol. 10756, Switzerland: Springer International Publishing AG, 2018, 106–132, DOI: 10.1007/978-3-319-76072-8\_8.
5. Aziz M.Z.A., Ibai P.S.A., Adnan S.F.S., Rohmad M.S., Makhtar A.K.B., Ghani M.A.A., *Accelerated Optical Flow Function Algorithm Using Compute Unified Device Architecture*, “Procedia Engineering”, Vol. 41, 2012, 1343–1352, 2012, DOI: 10.1016/j.proeng.2012.07.320.
6. Wu H., Zhao R., Gan X., Ma X., *Measuring surface velocity of water flow by dense optical flow method*, “Water”, Vol. 11, No. 11, 2019, DOI: 10.3390/w11112320.
7. Farneback G., *Two-Frame Motion Estimation Based on Polynomial Expansion*, Proceedings of the 13<sup>th</sup> Scandinavian Conference on Image Analysis, 2003, 363–370, DOI: 10.1007/3-540-45103-X\_50.
8. Olbrycht R., Więcek B., Mey G.D., *Thermal drift compensation method for microbolometer thermal cameras*, “Applied Optics”, Vol. 51, No. 11, 2012, 1788–1794, DOI: 10.1364/AO.51.001788.
9. Krupiński M., Bieszczad G., Sosnowski T., Madura H., Gogler S., *NonUniformity Correction in Microbolometer Array with Temperature Influence Compensation*, “Metrology and Measurement Systems”, Vol. 21, No. 4, 2014, 709–718, DOI: 10.2478/mms-2014-0050.
10. Perry D.L., Dereniak E.L., *Linear theory of nonuniformity correction in infrared staring sensors*, “Optical Engineering”, Vol. 32, No. 8, 1993, 1854–1859, DOI: 10.1117/12.145601.
11. Olbrycht R., Więcek B., *New approach to thermal drift correction in microbolometer thermal cameras*, “Quantitative InfraRed Thermography Journal”, Vol. 12, No. 2, 2015, 184–195, DOI: 10.1080/17686733.2015.1055675.
12. Felczak M., Sosnowski T., Strąkowski R., Bieszczad G., Gogler S., Stępień J., Więcek B., *Electrothermal analysis of a TEC-less IR microbolometer detector including self-heating and thermal drift*, “Quantitative InfraRed Thermography Journal”, 2023, DOI: 10.1080/17686733.2023.2179280.
13. Timus D., Prata M., Kalla S., Abbas M., Oner F., Galiano E., *Some further analytical results on the solid angle subtended at a point by a circular disk using elliptic integrals*, “Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment”, Vol. 580, No. 1, 2007, 149–152, 2007, Proceedings of the 10<sup>th</sup> International Symposium on Radiation Physics, DOI: 10.1016/j.nima.2007.05.055.
14. Sosnowski T., Bieszczad G., Gogler S., Madura H., Felczak M., Strąkowski R., *Radiacyjny model obudowy chłodzonego matrycowego detektora podczerwieni*, „Pomiary Automatyka Robotyka”, R. 25, Nr 4, 2021, 67–76, DOI: 10.14313/PAR\_242/67.
15. Gogler S., Bieszczad G., Krupiński M., Zarzycka A., *Metoda wyznaczania czułości napięciowej detektorów podczerwieni z uwzględnieniem właściwości układu optycznego*, „Przegląd Elektrotechniczny”, R. 89, Nr 10, 2013, 65–68.
16. Bieszczad G., *irnoisemodel – Model sygnału z kamery termowizyjnej do testowania algorytmów optical flow*, <https://github.com/gbieszczad/irnoisemodel>, 2023.
17. Kowalski P., Nowak Z., *Zastosowania termometru*, „Kwartalnik termiczny” – wydanie specjalne, Nr 5, 1999, 205–218.
18. Marinetti S., Bison P., Grinzato E., Muscio A., *Thermal diffusivity measurement of stainless steel by periodic heating technique*, Proceedings of 5<sup>th</sup> AITA Workshop, Vol. 5, 1999, 205–218.
19. Bieszczad G.T., Gogler S., Krupiński M., Ligienza A., Sawicki K., *The concept of thermovision sensor supporting the navigation of unmanned aerial platforms*, Measurement Automation Monitoring, Vol. 65, No. 1, 2019, 15–18.

## Modeling of the Thermal Imaging Camera Signal for Optical-Flow Algorithms Evaluation

**Abstract:** The article presents a method of modeling the signal coming from a thermal imaging camera that allows to perform a comparative analysis of algorithms for determining the so-called optical-flow. The modeling method was created for the development of an inertial sensor determining the displacement of the vehicle based on the analysis of the image from a thermal imaging camera. As part of the development work, it was necessary to select the type of optical flow algorithm and optimize its parameters. The synthetic signal model allowed for quick prototyping and automatic optimization of its parameters. The article presents exemplary results of comparing the efficiency of SAD and Farneback algorithms in the context of application for thermal imaging.

**Keywords:** thermal imaging, tracking, image analysis, optical flow, navigation

### dr inż. Grzegorz Bieszczad

grzegorz.bieszczad@wat.edu.pl  
ORCID: 0000-0001-8048-2609

Ukończył w 2008 r. Wojskową Akademię Techniczną na Wydziale Elektroniki. Stopień doktora otrzymał w 2012 r. Obecnie zajmuje się zagadnieniami związanymi z projektowaniem systemów cyfrowych, programowaniem mikroprocesorów i układów FPGA związanych z cyfrowym przetwarzaniem obrazu, w tym obrazów termicznych.



### dr inż. Krzysztof Sawicki

krzysztof.sawicki@wat.edu.pl  
ORCID: 0000-0002-1368-3854

Ukończył Wydział Elektroniki Wojskowej Akademii Technicznej w 2009 r.; rozprawa doktorska z tematyki steganografii w sieciach bezprzewodowych obroniona w WAT w 2019 r.; jego zainteresowania skupiają się na sieciach bezprzewodowych, bezpieczeństwie teleinformatycznym, steganografii i systemach wbudowanych.



### dr inż. Sławomir Gogler

slawomir.gogler@wat.edu.pl  
ORCID: 0000-0002-3002-6362

Ukończył Politechnikę Warszawską w 2011 r. na Wydziale Mechatroniki. W 2020 r. uzyskał tytuł doktora nauk technicznych w Wojskowej Akademii Technicznej. Zajmuje się zagadnieniami konstrukcji układów optycznych oraz modelowaniem matematyczno-fizycznym.



### mgr inż. Andrzej Ligienza

andrzej.ligienza@wat.edu.pl  
ORCID: 0000-0002-5789-8531

Tytuł inżyniera otrzymał w 2014 r. po ukończeniu kierunku mechatronika ze specjalizacją inżynierii systemów mechatronicznych. Tytuł magistra otrzymał w 2016 r. po ukończeniu kierunku optoelektronika ze specjalizacją inżynieria systemów optoelektronicznych. W 2018 r. objął stanowisko starszego inżyniera w Zakładzie Techniki Podczerwieni i Termowizji Instytutu Optoelektroniki WAT.



### Mariusz Mścichowski

mariusz.mscichowski@student.wat.edu.pl  
ORCID: 0000-0002-0079-1960

Student Wydziału Elektroniki Wojskowej Akademii Technicznej. Jego zawodowe zainteresowania skupiają się na cyfrowych pomiarowych układach elektronicznych oraz szybkim prototypowaniu FDM.

