

KANIEWSKI Piotr¹

ADAPTACYJNY FILTR KALMANA ODBIORNIKA GNSS

W odbiornikach systemów nawigacji satelitarnej GNSS zwykle stosowane są algorytmy filtracji Kalmana. Z reguły stosuje się rozszerzone filtry Kalmana (EKF) zaprojektowane przy założeniu stałej dokładności pseudoodległości. W praktyce pseudoodległości mają zmienną dokładność i dodatkowo mogą być okazjonalnie obciążone błędami znacznie przekraczającymi typowe wartości (błędami anomalnymi). Z tego względu wskazane jest estymowanie w filtrze macierzy kowariancji błędów pomiarowych, zamiast zakładania jej stałej wartości. W niniejszej pracy zaprezentowano, opracowany przez autora, adaptacyjny filtr Kalmana odbiornika GNSS (ADKF), w którym macierz ta jest na bieżąco estymowana, przez co filtr dostosowuje swoje wagi do zmieniającej się dokładności pomiarów. Podano model projektowy i algorytm filtru oraz przedstawiono wybrane wyniki jego badań.

ADAPTIVE KALMAN FILTER OF GNSS RECEIVER

Contemporary GNSS receivers usually employ Kalman filtering algorithms. Typically, they are Extended Kalman Filters (EKF), designed under assumption of constant accuracy of pseudoranges. In practice, pseudoranges have variable accuracy and occasionally they can contain errors significantly exceeding their typical values (so called anomaly errors). For this reason, estimation of the measuring covariance matrix, instead of assuming its constant value, seems a justified and advantageous approach. The paper presents an Adaptive Kalman Filter for GNSS receiver, proposed and designed by the author. The filter estimates the measuring covariance matrix and this way adjusts its weights to variable accuracy of measurements. The design model and the algorithm of the filter, as well as chosen simulation results are included.

1. WSTĘP

Nawigacyjne odbiorniki GNSS (*Global Navigation Satellite System*) określają położenie metodą odległościową [3, 6, 12]. Wielkościami mierzonymi są różnice czasu pomiędzy momentami wysłania i odbioru sygnałów radiowych transmitowanych przez satelity nawigacyjne. Sygnały satelitów zawierają w tzw. depezy nawigacyjnej między innymi informacje niezbędne do wyznaczenia ich położenia oraz czasu transmisji sygnału. Odbiornik GNSS wykorzystując własny zegar określa czas odbioru sygnałów. Przeliczona

¹ Wojskowa Akademia Techniczna, Wydział Elektroniki, Instytut Radioelektroniki, ul. Kaliskiego 2, 00-908 Warszawa, Tel. +4822 6839224, E-mail: Piotr.Kaniewski@wat.edu.pl

na ekwiwalent odległościowy różnica między czasem odbioru a czasem nadania jest nazywana pseudoodległością, ze względu na fakt, że zegar odbiornika GNSS nie jest wstępnie zsynchronizowany z czasem satelitarnego systemu nawigacyjnego [12].

Określenie położenia wymaga wyznaczenia przynajmniej czterech pseudoodległości i rozwiązania czterech nieliniowych równań o postaci [2, 6, 12]:

$$\Psi_i = \sqrt{(X_i - x)^2 + (Y_i - y)^2 + (Z_i - z)^2} + c\Delta t = R_i + b \quad (1)$$

gdzie: Ψ_i – pseudoodległość do i -tego satelity,

R_i – odległość do i -tego satelity,

X_i, Y_i, Z_i – położenie i -tego satelity obliczane na podstawie depezy nawigacyjnej,

x, y, z – położenie pojazdu,

c – prędkość światła,

Δt – błąd synchronizacji zegara odbiornika GNSS,

b – odległościowy ekwiwalent błędu synchronizacji zegara odbiornika GNSS.

Pseudoodległości wyznaczone w odbiornikach GNSS mają zmienną dokładność i mogą być okazjonalnie obciążone błędami znacznie przekraczającymi typowe wartości, zwanymi dalej błędami anomalnymi [5, 7]. Błędy anomalne występują w wielu radiotechnicznych urządzeniach nawigacyjnych, które są podatne na zakłócenia spowodowane między innymi tłumieniem sygnału w ośrodku transmisyjnym, odbiciami sygnałów od pobliskich obiektów (wielodrożnością) oraz interferencją sygnałów użytecznych z sygnałami pochodzącymi od innych źródeł promieniowania fal radiowych.

Tymczasem we współczesnych odbiornikach GNSS zwykle są stosowane rozszerzone filtry Kalmana EKF (*Extended Kalman Filter*), zaprojektowane przy założeniu stałej dokładności pseudoodległości [3, 12]. W niniejszej pracy zaproponowano zastąpienie takiego filtru adaptacyjnym filtrem Kalmana ADKF (*Adaptive Kalman Filter*) [7].

Idea adaptacyjnej filtracji Kalmana jest znana z literatury [3, 9, 11]. Istnieją również niezbyt liczne publikacje opisujące praktyczne wykorzystanie różnych wariantów adaptacyjnego filtru Kalmana w odbiornikach GNSS i w systemach zintegrowanych INS/GNSS [4, 5, 8, 10]. Autorzy wymienionych opracowań wykorzystywali cztery zasadnicze typy rozwiązań adaptacyjnych, tj. skalowanie macierzy kowariancji zakłóceń procesu w zależności od wyników testów statystycznych innowacji, wielomodelową estymację adaptacyjną MMAE (*Multiple Model Adaptive Estimation*), estymację i adaptacyjną zmianę macierzy kowariancji zakłóceń procesu i macierzy kowariancji błędów pomiarowych oraz wagowe przetwarzanie reszt pomiarowych podczas aktualizacji pomiarów w filtrze Kalmana odbiornika GNSS.

Przedstawiony w niniejszym opracowaniu algorytm filtracji odbiornika GNSS oparto na ogólnych równaniach adaptacyjnego filtru Kalmana, zaczerpniętych z publikacji [11]. Założono jednak, że model dynamiki systemu jest poprawnie modelowany i nie ma konieczności estymacji macierzy kowariancji zakłóceń procesu. Ze względu na możliwość wystąpienia w pomiarach błędów anomalnych oraz ze względu na zmienność dokładności pomiarów pseudoodległości, realizowana jest natomiast estymacja elementów macierzy kowariancji błędów pomiarowych.

2. MODEL ODBIORNIKA GNSS

2.1 Model dynamiki

Podczas projektowania algorytmów filtracji Kalmana dla urządzenia lub systemu nawigacyjnego należy sformułować jego opis matematyczny, składający się z modelu dynamiki i modelu obserwacji. Najbardziej przydatny jest opis metodą przestrzeni stanów. W opisie tym zakłada się, że pełną informację o systemie w chwili t zawiera wektor stanu $\mathbf{x}(t)$. Zbiór możliwych wartości wektora stanu stanowi przestrzeń stanów [2, 3, 7, 9].

W filtrach Kalmana odbiorników GNSS, model dynamiki opisuje zmiany w czasie położenia użytkownika i jego pochodnych oraz błędów zegara odbiornika [2]. W zależności od kategorii użytkownika (pieszy, pojazd lądowy, obiekt pływający, statek powietrzny) charakter ruchu, a tym samym sposób jego modelowania jest nieco inny.

W prezentowanym filtrze przyjęto model dynamiki określany w literaturze jako PVA (*Position-Velocity-Acceleration*) [1, 2, 7], który opisuje zmiany w czasie składowych położenia (x, y, z), prędkości (v_x, v_y, v_z) i przyspieszenia (a_x, a_y, a_z) pojazdu w układzie współrzędnych ECEF (*Earth-Centered Earth-Fixed*) [7]. Model PVA jest stosowany w przypadku pojazdów silnie manewrujących i jest odpowiedni do modelowania ruchu pojazdów lądowych (zwłaszcza podczas jazdy miejskiej), ponieważ ruch ten charakteryzuje się częstymi zmianami prędkości i kierunku. Zmiany w czasie i związki pomiędzy zmiennymi stanu w modelu PVA wynikają z newtonowskich równań ruchu i w wersji dyskretnej mogą być zapisane następująco [1, 2, 7]:

$$\begin{bmatrix} x(k+1) \\ v_x(k+1) \\ a_x(k+1) \\ y(k+1) \\ v_y(k+1) \\ a_y(k+1) \\ z(k+1) \\ v_z(k+1) \\ a_z(k+1) \end{bmatrix} = \begin{bmatrix} 1 & T & T^2/2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & T & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & T & T^2/2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & T & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & T & T^2/2 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & T \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x(k) \\ v_x(k) \\ a_x(k) \\ y(k) \\ v_y(k) \\ a_y(k) \\ z(k) \\ v_z(k) \\ a_z(k) \end{bmatrix} + \begin{bmatrix} w_x(k) \\ w_{vx}(k) \\ w_{ax}(k) \\ w_y(k) \\ w_{vy}(k) \\ w_{ay}(k) \\ w_z(k) \\ w_{vz}(k) \\ w_{az}(k) \end{bmatrix} \quad (2)$$

przy czym $w_x, w_y, w_z, w_{vx}, w_{vy}, w_{vz}, w_{ax}, w_{ay}$ i w_{az} stanowią zakłócenia procesu (ciągi gaussowskie o zerowej wartości oczekiwanej i stałej wariancji), reprezentujące niepewność występującą w modelu ruchu pojazdu, natomiast T stanowi okres dyskretyzacji modelu, tj. przedział czasu pomiędzy chwilami $(k-1)T$ i kT .

Model ten należy uzupełnić o model błędów zegara odbiornika GNSS, ponieważ brak synchronizacji tego zegara ze skalą czasu GNSS jest przyczyną występowania bardzo dużych błędów odległości wyznaczanych przez odbiornik od centrum anteny do satelitów systemu, tzw. pseudoodległości [6, 12]. Typowy model błędów zegara zawiera dwie zmienne stanu, z których jedną jest odległościowy ekwiwalent błędu synchronizacji zegara b , zaś drugą dryf zegara d . Dyskretny model tych błędów jest następujący [2]:

$$\begin{bmatrix} b(k+1) \\ d(k+1) \end{bmatrix} = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} b(k) \\ d(k) \end{bmatrix} + \begin{bmatrix} w_b(k) \\ w_d(k) \end{bmatrix} \quad (3)$$

przy czym w_b i w_d stanowią zakłócenia procesu (ciągi gaussowskie o zerowej wartości oczekiwanej i stałej wariancji) w modelu błędów zegara odbiornika GNSS.

Łącząc model dynamiki pojazdu z modelem błędów zegara odbiornika, uzyskuje się następujące równanie dynamiki systemu [7]:

$$\underbrace{\begin{bmatrix} x(k+1) \\ v_x(k+1) \\ a_x(k+1) \\ y(k+1) \\ v_y(k+1) \\ a_y(k+1) \\ z(k+1) \\ v_z(k+1) \\ a_z(k+1) \\ b(k+1) \\ d(k+1) \end{bmatrix}}_{\mathbf{x}(k+1)} = \underbrace{\begin{bmatrix} 1 & T & T^2/2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & T & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & T & T^2/2 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & T & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & T & T^2/2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & T & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & T \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}}_{\Phi(k+1,k)} \cdot \underbrace{\begin{bmatrix} x(k) \\ v_x(k) \\ a_x(k) \\ y(k) \\ v_y(k) \\ a_y(k) \\ z(k) \\ v_z(k) \\ a_z(k) \\ b(k) \\ d(k) \end{bmatrix}}_{\mathbf{x}(k)} + \underbrace{\begin{bmatrix} w_x(k) \\ w_{vx}(k) \\ w_{ax}(k) \\ w_y(k) \\ w_{vy}(k) \\ w_{ay}(k) \\ w_z(k) \\ w_{vz}(k) \\ w_{az}(k) \\ w_b(k) \\ w_d(k) \end{bmatrix}}_{\mathbf{w}(k)} \quad (4)$$

Powyższe równanie ma postać zgodną z następującym, ogólnym zapisem liniowego równania stanu systemu stacjonarnego [2, 3, 7, 9]:

$$\mathbf{x}(k+1) = \Phi \mathbf{x}(k) + \mathbf{w}(k) \quad (5)$$

przy czym \mathbf{x} reprezentuje wektor stanu, \mathbf{w} stanowi wektor zakłóceń procesu, zaś Φ jest macierzą tranzycyjną. W teorii filtracji Kalmana zakłada się następujące własności statystyczne wektora \mathbf{w} :

$$E[\mathbf{w}(k)] = \mathbf{0} \quad (6)$$

$$E[\mathbf{w}(k)\mathbf{w}^T(l)] = \mathbf{Q}(k)\delta(k,l) \quad (7)$$

przy czym $\mathbf{Q}(k)$ stanowi macierz kowariancji dyskretnych zakłóceń procesu $\mathbf{w}(k)$, zaś $\delta(k,l)$ oznacza funkcję delty Kroneckera.

2.2 Model obserwacji

Model obserwacji w odbiorniku GNSS jest dany następującym równaniem, w którym dla poprawy czytelności pominięto zależność zmiennych od indeksu czasu k [2]:

$$\underbrace{\begin{bmatrix} \Psi_1 \\ \Psi_2 \\ \vdots \\ \Psi_m \end{bmatrix}}_{\mathbf{z}(k)} = \underbrace{\begin{bmatrix} \sqrt{(X_1 - x)^2 + (Y_1 - y)^2 + (Z_1 - z)^2 + b} \\ \sqrt{(X_2 - x)^2 + (Y_2 - y)^2 + (Z_2 - z)^2 + b} \\ \vdots \\ \sqrt{(X_m - x)^2 + (Y_m - y)^2 + (Z_m - z)^2 + b} \end{bmatrix}}_{\mathbf{h}[\mathbf{x}(k)]} + \underbrace{\begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_m \end{bmatrix}}_{\mathbf{v}(k)} \quad (8)$$

gdzie: Ψ_i – pseudoodległość do i -tego satelity,
 X_i, Y_i, Z_i – położenie i -tego satelity,
 x, y, z – położenie pojazdu,
 b – odległościowy ekwiwalent błędu synchronizacji zegara odbiornika GNSS,
 v_i – błąd pomiarowy i -tej pseudoodległości.

Model obserwacji jest nieliniowy ze względu na nieliniowość zależności wiążących pseudoodległości i współrzędne położenia użytkownika. Odpowiada on postaci ogólnego nieliniowego równania obserwacji [2, 3, 7, 9]:

$$\mathbf{z}(k) = \mathbf{h}[\mathbf{x}(k), k] + \mathbf{v}(k) \quad (9)$$

przy czym \mathbf{x} jest wektorem stanu, \mathbf{z} stanowi wektor pomiarowy, \mathbf{v} jest wektorem błędów pomiarowych, a \mathbf{h} stanowi nieliniową funkcję wektorową. W teorii filtracji Kalmana zakłada się następujące własności statystyczne wektora \mathbf{v} :

$$\mathbf{E}[\mathbf{v}(k)] = \mathbf{0} \quad (10)$$

$$\mathbf{E}[\mathbf{v}(k)\mathbf{v}^T(l)] = \mathbf{R}(k)\delta(k, l) \quad (11)$$

przy czym $\mathbf{R}(k)$ reprezentuje macierz kowariancji błędów pomiarowych $\mathbf{v}(k)$.

Ze względu na zmieniającą się w czasie działania odbiornika liczbę obserwowanych satelitów GNSS, wektor pomiarowy \mathbf{z} i wektor błędów pomiarowych \mathbf{v} mają zmienne rozmiary, zależne od liczby m śledzonych satelitów. Oznacza to również zmienność rozmiarów macierzy kowariancji błędów pomiarowych \mathbf{R} , która na diagonalnej zawiera wariancje błędów pseudoodległości σ_ψ^2 [2]:

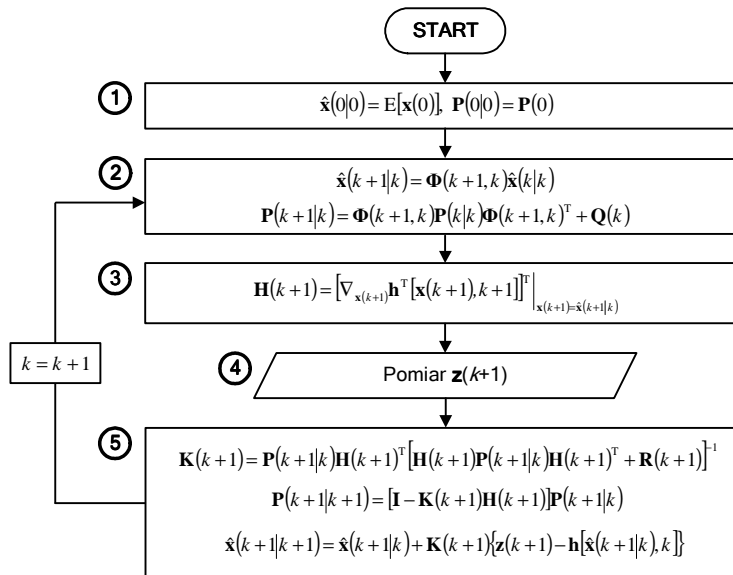
$$\mathbf{R} = \text{diag}(\sigma_\psi^2, \sigma_\psi^2, \dots, \sigma_\psi^2) \quad (12)$$

3. ALGORYTMY FILTRACJI ODBIORNIKA GNSS

3.1 Rozszerzony filtr Kalmana (EKF)

Ze względu na fakt, że model odbiornika GNSS jest nieliniowy i zawiera addytywne, gaussowskie zakłócenia procesu oraz błędy pomiarowe, do estymacji wektora stanu jest w nim zwykle stosowany filtr rozszerzony (EKF), odpowiedni dla systemów o podanych cechach [7]. Schemat blokowy algorytmu EKF przedstawiono na rys. 1.

Algorytm filtracji EKF składa się z jednorazowej inicjalizacji (1), predykcji wektora stanu i macierzy kowariancji błędów (2), obliczenia macierzy pomiarowej \mathbf{H} (3), realizacji pomiaru (4) oraz korekcji estymowanego wektora stanu z wykorzystaniem ostatnio wykonanego pomiaru (5). Kroki (2)-(5) algorytmu są wykonywane rekursywnie.



Rys.1. Algorytm EKF odbiornika GNSS

gdzie: $\hat{\mathbf{x}}(k|k)$ – estymata wektora stanu w chwili kT – wynik filtracji,

$\hat{\mathbf{x}}(k+1|k)$ – estymata wektora stanu w chwili $(k+1)T$ – wynik predykcji,

$\mathbf{P}(k|k)$ – macierz kowariancji błędów filtracji w chwili kT ,

$\mathbf{P}(k+1|k)$ – macierz kowariancji błędów predykcji w chwili $(k+1)T$,

$\mathbf{K}(k)$ – macierz wzmocnień Kalmana w chwili kT ,

\mathbf{I} – macierz jednostkowa.

Występujące w równaniach filtru EKF macierze Φ , \mathbf{Q} i \mathbf{R} są niezmiennie w czasie i pochodzą z podanego uprzednio modelu systemu, natomiast macierz pomiarowa $\mathbf{H}(k+1)$ jest zmienna i musi być obliczana podczas pracy filtru, jako macierz pochodnych cząstkowych nieliniowej funkcji \mathbf{h} po elementach wektora stanu \mathbf{x} [7]:

$$\mathbf{H}(k+1) = \begin{bmatrix} \frac{\partial \Psi_1}{\partial x} & 0 & 0 & \frac{\partial \Psi_1}{\partial y} & 0 & 0 & \frac{\partial \Psi_1}{\partial z} & 0 & 0 & 1 & 0 \\ \frac{\partial \Psi_2}{\partial x} & 0 & 0 & \frac{\partial \Psi_2}{\partial y} & 0 & 0 & \frac{\partial \Psi_2}{\partial z} & 0 & 0 & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{\partial \Psi_m}{\partial x} & 0 & 0 & \frac{\partial \Psi_m}{\partial y} & 0 & 0 & \frac{\partial \Psi_m}{\partial z} & 0 & 0 & 1 & 0 \end{bmatrix}_{\mathbf{x}=\hat{\mathbf{x}}(k+1|k)} \quad (13)$$

przy czym:

$$\frac{\partial \Psi_i}{\partial x} = \frac{-[X_i - \hat{x}(k+1|k)]}{\sqrt{[X_i - \hat{x}(k+1|k)]^2 + [Y_i - \hat{y}(k+1|k)]^2 + [Z_i - \hat{z}(k+1|k)]^2}} \quad \text{dla } i=1\dots m \quad (14)$$

$$\frac{\partial \Psi_i}{\partial y} = \frac{-[Y_i - \hat{y}(k+1|k)]}{\sqrt{[X_i - \hat{x}(k+1|k)]^2 + [Y_i - \hat{y}(k+1|k)]^2 + [Z_i - \hat{z}(k+1|k)]^2}} \quad \text{dla } i=1\dots m \quad (15)$$

$$\frac{\partial \Psi_i}{\partial z} = \frac{-[Z_i - \hat{z}(k+1|k)]}{\sqrt{[X_i - \hat{x}(k+1|k)]^2 + [Y_i - \hat{y}(k+1|k)]^2 + [Z_i - \hat{z}(k+1|k)]^2}} \quad \text{dla } i=1\dots m \quad (16)$$

3.2 Adaptacyjny filtr Kalmana (ADKF)

Stosowanie stałej macierzy kowariancji błędów pomiarowych \mathbf{R} w filtrze EKF stanowi znaczne uproszczenie modelu systemu w przypadku, gdy pseudoodległości posiadają zmienną dokładność. Z tego względu w niniejszej pracy zaproponowano użycie w odbiorniku GNSS filtra adaptacyjnego (ADKF), który przetwarza pomiary z wagami zależnymi od ich dokładności [7]. Miarą dokładności pomiarów jest estymowana na bieżąco macierz kowariancji błędów pomiarowych $\hat{\mathbf{R}}$.

Dzięki dostosowywaniu się wag filtru do aktualnej dokładności pseudoodległości, filtr ADKF redukuje również wpływ błędów anomalnych na dokładność pozycjonowania, ponieważ błędy anomalne można uznać za specyficzny przypadek zmiennej dokładności pomiarów, która zmienia się skokowo pomiędzy dwoma skrajnymi stanami.

Równania predykcji i korekcji w algorytmie ADKF nie różnią się od zależności występujących w filtrze EKF (rys. 1). Dodatkowymi lub zmodyfikowanymi elementami algorytmu są następujące operacje wprowadzone pomiędzy krokami (4) i (5) EKF [7]:

$$\mathbf{e}(k+1) = \mathbf{z}(k+1) - \mathbf{h}[\hat{\mathbf{x}}(k+1|k), k] \quad (17)$$

$$\hat{\mathbf{R}}_e(k+1) = (1 - \mu)\hat{\mathbf{R}}_e(k) + \mu\mathbf{e}(k+1)\mathbf{e}(k+1)^T \quad (18)$$

$$\hat{\mathbf{R}}(k+1) = \hat{\mathbf{R}}_e(k+1) - \mathbf{H}(k+1)\mathbf{P}(k+1|k)\mathbf{H}(k+1)^T \quad (19)$$

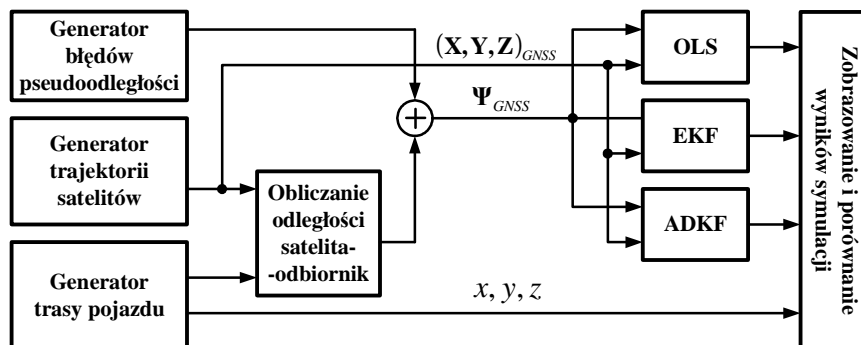
przy czym \mathbf{e} stanowi wektor reszt pomiarowych, czyli różnicę pomiędzy faktycznym a przewidywanym wektorem pomiarowym \mathbf{z} , zaś $\hat{\mathbf{R}}_e$ jest estymowaną macierzą kowariancji innowacji (macierzą kowariancji reszt pomiarowych) [2, 7].

Współczynnik $\mu \in (0,1)$ stanowi stałą uśredniania macierzy kowariancji reszt pomiarowych, decydującą o długości efektywnego okna czasowego obliczanej średniej. W celu szybkiej detekcji błędów anomalnych wskazane jest stosowanie krótkiego okna czasowego, co występuje przy $\mu \rightarrow 1$, natomiast uzyskanie wysokiej dokładności oszacowania macierzy $\hat{\mathbf{R}}$ wymaga stosowania $\mu \rightarrow 0$.

Wybór współczynnika μ jest zwykle wynikiem kompromisu, uwzględniającego spodziewany charakter błędów anomalnych i pożądane własności filtru, np. szybkość reakcji na wystąpienie tych błędów [7].

4. WYNIKI BADAŃ SYMULACYJNYCH


Opisane algorytmy filtracji EKF i ADKF odbiornika GNSS zbadano metodą symulacji komputerowej. Badania, przeprowadzone zgodnie z metodyką wyjaśnioną na rys. 2, miały na celu porównanie dokładności obu filtrów Kalmana oraz algorytmu pozycjonowania metodą najmniejszych kwadratów OLS (*Ordinary Least Squares*) [12].



Rys.2. Metodyka badań symulacyjnych odbiornika GNSS

Pierwszy etap badań polegał na sprawdzeniu wpływu zmiennej dokładności pseudoodległości na dokładność estymowanego położenia. W tym celu czas symulacji wynoszący 600 sekund podzielono na dwa odcinki po 300 sekund każdy. W pierwszym odcinku wygenerowane błędy pseudoodległości miały odchylenia standardowe $\sigma_{\psi} = 7,5$ m, które przyjęto na podstawie budżetu błędów systemu GPS, przedstawionego w literaturze jako parametr UERE (*User Equivalent Range Error*). Według jednego z najnowszych oszacowań parametr UERE w systemie GPS wynosi 7,5 m [6].


W kolejnych 300 sekundach, błędy te znacznie zwiększono, dodając do każdego z nich gaussowski ciąg losowy o zerowej wartości oczekiwanej i odchyleniu standardowym wynoszącym 100 m. Uzyskane błędy położenia pojazdu wzdłuż wybranej osi lokalnego horizontalnego układu współrzędnych ENU (osi wschodniej) przedstawiono na rys. 3. Błędy pozycjonowania wzdłuż pozostałych osi układu ENU mają podobny charakter i z tego względu nie zostały zamieszczone.



Rys.3. Sładowa wschodnia błędów pozycjonowania – zmienna dokładność pomiarów

Kolejny etap badań polegał na sprawdzeniu działania i porównaniu dokładności algorytmów OLS, EKF i ADKF w warunkach występowania błędów anomalnych. Badania przeprowadzono dla dwóch różnych scenariuszy symulacji. Oba badania trwały po 600 sekund, a zastosowane w nich odchylenia standardowe błędów pseudoodległości wynosiły 7,5 m. W pierwszym badaniu, do jednej z wygenerowanych pseudoodległości dodano błąd o charakterze impulsowym, trwający od 200 do 400 s i posiadający amplitudę 100 m. W drugim badaniu, dodany do wybranej pseudoodległości błąd miał charakter błędu rampowego, rozpoczynającego się w 200 s symulacji i posiadającego nachylenie zbocza (prędkość narastania) wynoszące 1 m/s.

Wyniki badań przeprowadzonych według obu scenariuszy przedstawiono na rys. 4. Przedstawiają one błędy pozycjonowania za pomocą algorytmów OLS, EKF i ADKF wzdłuż wybranej osi układu współrzędnych ENU (osi wschodniej). Błędów pozostałych współrzędnych położenia nie zamieszczono, ze względu na ich podobny charakter.



Rys.4. Sładowa wschodnia błędów pozycjonowania – błąd impulsowy i rampowy

5. WNIOSKI

Na podstawie wyników pierwszej części badań można stwierdzić, że w przypadku normalnej sytuacji pomiarowej (czas symulacji 0-300 s), w której dokładność

pseudoodległości jest stała i stosunkowo wysoka, a parametry filtrów Kalmana są dopasowane do rzeczywistej dokładności pomiarów, najdokładniejszym algorytmem estymacji położenia jest EKF. Algorytm ADKF ma porównywalną, chociaż nieco niższą dokładność niż EKF, natomiast najmniej dokładny jest algorytm OLS.

Przy zwiększonych błędach pseudoodległości GNSS (czas symulacji 300-600 s), najdokładniejszym rozwiązaniem jest filtr ADKF, który adaptacyjnie dopasowuje macierz R , dostrajając się do zwiększonych błędów pseudoodległości.

Z przedstawionych wyników drugiej części badań algorytmu ADKF i z porównania błędów tego filtru z błędami filtru EKF wynika, że filtr ADKF posiada istotną przewagę nad EKF. Błędy pozycjonowania w odbiorniku GNSS wyposażonym w EKF znacznie wzrastają w przypadku wystąpienia błędów anomalnych jednej z mierzonych pseudoodległości, natomiast w odbiorniku z filtrem ADKF dokładność pozycjonowania praktycznie nie ulega zmianie. Wnioski takie wypływają zarówno z analizy przypadku błędu anomalnego o charakterze krótkotrwałego, stałego przesunięcia wartości pseudoodległości (błędu impulsowego), jak i z analizy przypadku błędu anomalnego o charakterze narastającym ze stałą prędkością (błędu rampowego).

6. BIBLIOGRAFIA

- [1] Bar-Shalom Y., Li X.R., Kirubarajan T.: *Estimation with Applications to Tracking and Navigation Theory Algorithms and Software*, John Wiley & Sons, USA, 2001.
- [2] Brown R.G., Hwang P.Y.C.: *Introduction to random signals and applied Kalman filtering*, Wiley, UK, 1992.
- [3] Grewal M.S., Weill L.R., Andrews A.P.: *Global Positioning Systems, Inertial Navigation and Integration 2nd Edition*, John Wiley & Sons, USA, 2007.
- [4] Hide C., Moore T., Smith M.: *Adaptive Kalman Filtering Algorithms for Integrating GPS and Low Cost INS*, PLANS 2004, s. 227-233, 2004.
- [5] Jang C., Juang J., Kung F.: *Adaptive Fault Detection in Real-Time GPS Positioning*, IEE Proceedings Radar, Sonar and Navigation, Vol.147, No.5, s. 254-258, 2000.
- [6] Januszewski J.: *Systemy satelitarne GPS, Galileo i inne*, PWN, Warszawa, 2006.
- [7] Kaniewski P.: *Struktury, modele i algorytmy w zintegrowanych systemach pozycjonujących i nawigacyjnych*, Wyd. WAT, 2010.
- [8] McBurney P.W.: *A robust approach to reliable real-time Kalman filtering*, IEEE PLANS'90, s. 549-556, 1990.
- [9] Minkler G., Minkler J.: *Theory and Application of Kalman Filtering*, Magellan Book Company, USA, 1993.
- [10] Rao K., Swamy M., Plotkin E.: *GPS Navigation with Increased Immunity to Modeling Errors*, IEEE Transactions on Aerospace and Electronic Systems, Vol.40, No.1, 2004.
- [11] Salychev O.: *Inertial Systems in Navigation and Geophysics*, Bauman MSTU Press, Moscow, Russia, 1998.
- [12] Spilker J. & Parkinson B., Eds., *Global Positioning System: Theory and Applications*, Vol. I, American Institute of Aeronautics and Astronautics, USA, 1996.