

# Optymalizacja wzmocnienia obserwatora Luenbergera w układzie predykcyjnego sterowania systemem aktywnego zawieszenia

Grzegorz Maślak, Przemysław Orłowski

Zachodniopomorski Uniwersytet Technologiczny, al. Piastów 17, 70-310 Szczecin

**Streszczenie:** Układy sterowania wykorzystujące regulatory predykcyjne bardzo często wymagają wprowadzenia do ich struktury mechanizmów umożliwiających estymację niedostępnego pomiarowo stanu obiektu. Zależnie od przypadku nieosiągalne mogą być informacje o różnej liczbie zmiennych stanu. Szeroko stosowanymi układami pozwalającymi na uzyskanie niezbędnych informacji o stanie obiektu są obserwator Luenbergera oraz różnego typu filtry Kalmana. Autorzy proponują metodę syntezy obserwatora Luenbergera opartą na optymalizacji wzmocnienia owego obserwatora, przy czym wyznacznik jakości uzyskanego wzmocnienia wykorzystywanego przez optymalizator stanowi ogólna jakość regulacji układu sterowania z regulatorem predykcyjnym. Opracowana metoda pozwala na uzyskanie, z punktu widzenia przyjętego kryterium, obserwatora o właściwościach lepszych niż analogiczny układ, którego syntezę przeprowadzono przy wykorzystaniu równania Sylwestera oraz klasycznego filtra Kalmana, mimo występowania zakłóceń. Metoda zaprezentowana zostanie na przykładzie układu predykcyjnego sterowania systemem aktywnego zawieszenia.

**Słowa kluczowe:** obserwator stanu, sterowanie predykcyjne, optymalizacja obserwatora, zawieszenie aktywne

## 1. Wprowadzenie

Dla potrzeb sterowania układami, zwłaszcza wielowymiarowymi, regulatory predykcyjne często są bardzo dobrym wyborem, zapewniającym zadowalającą jakość regulacji dzięki możliwości ujęcia w ich strukturze zarówno przewidywania zachowania obiektu oraz ograniczeń, jak również zakłóceń. Co więcej, sygnał sterujący wyznaczany jest w sposób optymalny z punktu widzenia przyjętego przez projektanta kryterium. Jednocześnie, z uwagi na to, że zazwyczaj tego typu regulatory bazują na stanie obiektu, a ten zwykle nie jest w pełni dostępny pomiarowo, bądź jego pomiar byłby problematyczny, estymator stanu staje się nieodzownym elementem układu z MPC. Przykłady tego typu układów z obserwatorem można znaleźć w [2, 7, 4]. Alternatywą, równie popularną metodą estymacji jest filtracja Kalmana. Oba mechanizmy wymagają dopasowania parametrów estymatora celem uzyskania możliwie najlepszej estymacji wektora stanu. Wymaga to wiedzy o samym obiekcie oraz jego otoczeniu. Oczywiście

istnieją powszechnie znane metody, takie jak wykorzystanie równań Sylwestera w przypadku obserwatora Luenbergera oraz bezpośredni pomiar kowariancji szumu lub jego oszacowanie w przypadku filtra Kalmana. Korzystając z podstawowych równań macierzowych wynikowe wzmocnienie Luenbergera nie jest jednak optymalne w przypadku występowania zakłóceń, natomiast niezbędne do poprawnego działania filtra Kalmana kowariancje mogą być problematyczne w oszacowaniu, czy pomiarze. Dlatego autorzy proponują metodę doboru wzmocnienia obserwatora bazującą na optymalizacji dokonywanej dla funkcji kosztu zbliżonej do tej, którą wykorzystuje MPC.

Opracowana metoda nawiązuje do podejścia prezentowanego w [1], gdzie nieznaną kowariancję wykorzystywaną przez filtr Kalmana dobrano za pomocą metody najmniejszych kwadratów oraz [10], gdzie rozwiązując układ równań macierzowych poszukiwano optymalnego wzmocnienia filtra. Metodę projektowania optymalnego obserwatora Luenbergera dla obiektów nieliniowych, w oparciu o programowanie matematyczne, zaproponowano w [8]. Część wspólną wszystkich wymienionych publikacji stanowi ujęcie problemu syntezy narzędzia pozwalającego na estymację stanu obiektu w formie zadania optymalizacji dowolnego typu. Uściślając problem do grupy estymatorów współpracujących z regulatorami predykcyjnymi, dobór estymatora można rozumieć także jako element autotuningu MPC, co przekrojowo zaprezentowano w [11], natomiast metoda autotuningu bazująca na optymalizacji algorytmem rojowym przedstawiona została w [9]. Korzystając z idei optymalizacji oraz przyjmując za wyznacznik optymalności całościową jakość regulacji na wzór autotuningu, opracowano nową metodę doboru wzmocnienia obserwatora Luenbergera, w której to funkcją kosztu jest kopia

### Autor korespondujący:

Grzegorz Maślak, mg38657@zut.edu.pl

### Artykuł recenzowany

nadesłany 15.11.2020 r., przyjęty do druku 31.05.2021 r.



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

funkcji zawartej w pracującym w badanym układzie sterowania regulatorze predykcyjnym, a co za tym idzie, optymalizator, zamiast minimalizować błąd estymacji, maksymalizuje jakość regulacji przez poszukiwanie minimalnej wartości obranego kryterium.

Dodatkowo w przyjętym przykładzie występuje stochastyczny szum procesowy pod postacią nierówności drogi oraz zakłócenia od urządzeń pomiarowych, co dodatkowo utrudnia dobranie odpowiedniego wzmocnienia obserwatora.

## 2. Model obiektu oraz zakłóceń

W artykule rozważany jest typowy model ćwiartki samochodu, tzw. quarter car model, o dwóch stopniach swobody. W skład modelu wchodzi dwie bryły sztywne z określonymi własnymi masami, między którymi umieszczono sprężynę, element tłumiący oraz nastawny element generujący siłę. Między powierzchnią drogi a umieszczoną niżej masą zamodelowano kolejną sprężynę. Odpowiednio,  $M_s$  reprezentuje masę resorowaną,  $M_{us}$  masę nieresorowaną,  $k_s$  oraz  $\beta_s$  odpowiadają stałej sprężyny oraz tłumieniu zastosowanego amortyzatora,  $k_{us}$  odzwierciedla stałą sprężystości opony, natomiast  $f$  oznacza siłę, z jaką oddziałuje element aktywny. Model oraz jego opis matematyczny zapożyczono z [3]. Tak zamodelowany układ opisują cztery zmienne stanu:

- $x_1$  – odkształcenie opony,
- $x_2$  – prędkość masy nieresorowanej,
- $x_3$  – wychylenie zawieszenia,
- $x_4$  – prędkość masy resorowanej.

Przy założeniu liniowości sprężyny oraz tłumienia amortyzatora i opony, stan układu wyrażony jest wzorem:

$$\dot{x} = Ax + B\bar{f} + B_\omega\omega$$

gdzie:

$$x^T = [x_1 \ x_2 \ x_3 \ x_4]$$

Za wyjście obrano pierwszą pochodną prędkości masy resorowanej  $x_4$ , czyli przyspieszenia, na jakie wystawione jest nadwozie pojazdu i opisano je wzorem:

$$y = Cx + Du$$

Za wejście układu przyjęto znormalizowaną, nastawną siłę  $\bar{f}$  reprezentującą oddziaływanie silownika hydraulicznego bądź silnika liniowego na układ zawieszenia. Macierze wykorzystywane do modelu zadane zostały następującymi zależnościami:

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ -\omega_{us}^2 & -2\rho\xi\omega_s & \rho\omega_s^2 & 2\rho\xi\omega_s \\ 0 & -1 & 0 & 1 \\ 0 & 2\xi\omega_s & -\omega_s^2 & -2\xi\omega_s \end{bmatrix}$$

$$B = \begin{bmatrix} 0 \\ \rho \\ 0 \\ -1 \end{bmatrix} \quad B_\omega = \begin{bmatrix} -1 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

$$C = [0 \quad 2\xi\omega_s \quad -\omega_s^2 \quad -2\xi\omega_s]$$

$$D = [0]$$

gdzie:

$$\rho = \frac{M_s}{M_{us}} \quad \omega_{us} = \sqrt{\frac{k_{us}}{M_{us}}} \quad \omega_s = \sqrt{\frac{k_s}{M_s}}$$

$$\xi = \frac{\beta_s}{2\sqrt{k_s M_s}} \quad \bar{f} = \frac{f}{M_s}$$

Parametry, które przyjęto na potrzeby symulacji zestawiono w Tabeli 1.

Tabela 1. Parametry modelu

Table 1. Model parameters

$T_s$	10 ms
$\omega_s$	1,5 Hz
$\omega_{us}$	10 Hz
$\rho$	10
$\xi$	0,05

Tak opisany model poddano dyskretyzacji.

Nierówności drogi pokonywanej przez pojazd zamodelowano w postaci niemierzalnego zakłócenia  $\omega$  oddziałującego bezpośrednio na pierwszą zmienną stanu. Przyjęto zakłócenia od drogi w formie szumu białego o rozkładzie normalnym:

$$N(0, \sigma)$$

i odchyleniu standardowym zadanym wzorem:

$$\sigma = \sqrt{\frac{2\pi v A_{road}}{T_s}}$$

gdzie:  $T_s$  – czas próbkowania w sekundach,  $v$  – prędkość pojazdu w km/h,  $A_{road}$  – stała zakłóceń pochodzących od drogi.

Przy generowaniu zakłóceń zastosowano standardową dopuszczalną prędkość poza terenem zabudowanym, tj. 90 km/h, a zgodnie z [3], przyjęto stałą zakłóceń pochodzących od drogi równą 4,9e-6.

Na obiekt oddziaływały także zakłócenia od wyjścia o rozkładzie normalnym, pochodzące z czujników przyspieszenia, których rozkład opisano wzorem:

$$N(0, \sigma_y)$$

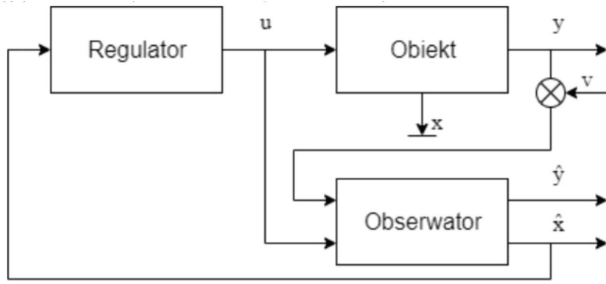
dla  $\sigma_y = 0,0008 \text{ m/s}^2$ .

## 3. Regulator predykcyjny

W skład analizowanego układu regulacji wchodził omówiony wcześniej obiekt, obserwator stanu oraz regulator predykcyjny. Schemat ideowy układu sterowania przedstawiono na rys. 1.

Przy syntezy regulatora oraz wszelkich symulacjach układu sterowania wykorzystywane były narzędzia wchodzące w skład środowiska MATLAB wzbogacone o przedstawiony w [5] pakiet narzędzi dedykowanych pracy z regulatorami predykcyjnymi, optymalizacji parametrycznej i geometrii obliczeniowej, MPT3. Funkcja kosztu regulatora użytego w układzie korzystała z norm kwadratowych i przyjmowała następującą postać:

$$J[x(0), U_0] = x_N^T P x_N + \sum_{k=0}^{N-1} x_k^T Q_x x_k + y_k^T Q_y y_k + \Delta u_k^T S \Delta u_k$$



Rys. 1. Schemat układu regulacji  
Fig. 1. Control system diagram

Przyjęto następujące macierze wagowe funkcji kosztu:

$$Q_x = \begin{bmatrix} 1000 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 100 & 0 \\ 0 & 0 & 0 & 500 \end{bmatrix}, \quad Q_y = 500$$

$$P = \begin{bmatrix} 1000 & 0 & 0 & 0 \\ 0 & 1000 & 0 & 0 \\ 0 & 0 & 1000 & 0 \\ 0 & 0 & 0 & 1000 \end{bmatrix}, \quad S = 50$$

Horyzont sterowania  $N$  ustalono na 50 kroków. Czas próbkowania wynosił 10 milisekund. Wynikowy regulator przyjął postać prawa sterowania w formie PWA.

## 4. Algorytm optymalizacji wzmocnienia Luenbergera

W przypadku obserwatora Luenbergera, za pośrednictwem macierzy  $L$ , nazywanej wzmocnieniem obserwatora, możliwa jest zmiana jego dynamiki i to właśnie od jej doboru zależy jakość estymacji stanu obiektu. Jak już wspomniano, autorzy zaproponowali metodę opartą na optymalizacji, a co za tym idzie, zdefiniowano następujący problem programowania nieliniowego:

$$J^*(L) = \min \sum_{k=j}^n x_k^T Q_x x_k + y_k^T Q_y y_k$$

dla  $k = 0, T_s, 2T_s, \dots, t$  i ograniczeń równościowych korespondujących z równaniami stanu obiektu:

$$x_{k+1} = A_d x_k + B_d u_k + B_\omega \omega_{k+1}$$

$$y_k = C_d x_k + D_d u_k$$

dla  $j = 2/T_s$  i z równaniami obserwatora stanu:

$$\hat{x}_{k+1} = A_d \hat{x}_k + B_d u_k + L(y_k + v_k - \hat{y}_k)$$

$$\hat{y}_k = C_d \hat{x}_k$$

oraz wejściem skojarzonym z prawem sterowania PWA i błędami estymacji:

$$u_k = f_0^*(\hat{x}_{k-1}),$$

$$U = u_j, u_{j+1}, \dots, u_n,$$

$$e_x = \sum_{k=j}^n |x_k - \hat{x}_k|,$$

$$e_y = \sum_{k=j}^n |y_k - \hat{y}_k|$$

a także ograniczeniami nierównościami dla wektora wejść:

$$\|U\|_2 \leq 9,5$$

oraz dla błędów estymacji:

$$\begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \end{bmatrix} \leq \begin{bmatrix} 50 \\ 50 \\ 10 \\ 20 \end{bmatrix}$$

$$e_y \leq 10$$

przy czym  $Q_x$  oraz  $Q_y$  są macierzami diagonalnymi wag określającymi wpływ poszczególnych zmiennych stanu oraz wyjścia na wartość funkcji celu, a  $e_x = [e_1 \ e_2 \ e_3 \ e_4]^T$  oznacza wektor dopuszczalnych błędów estymacji poszczególnych zmiennych stanu.

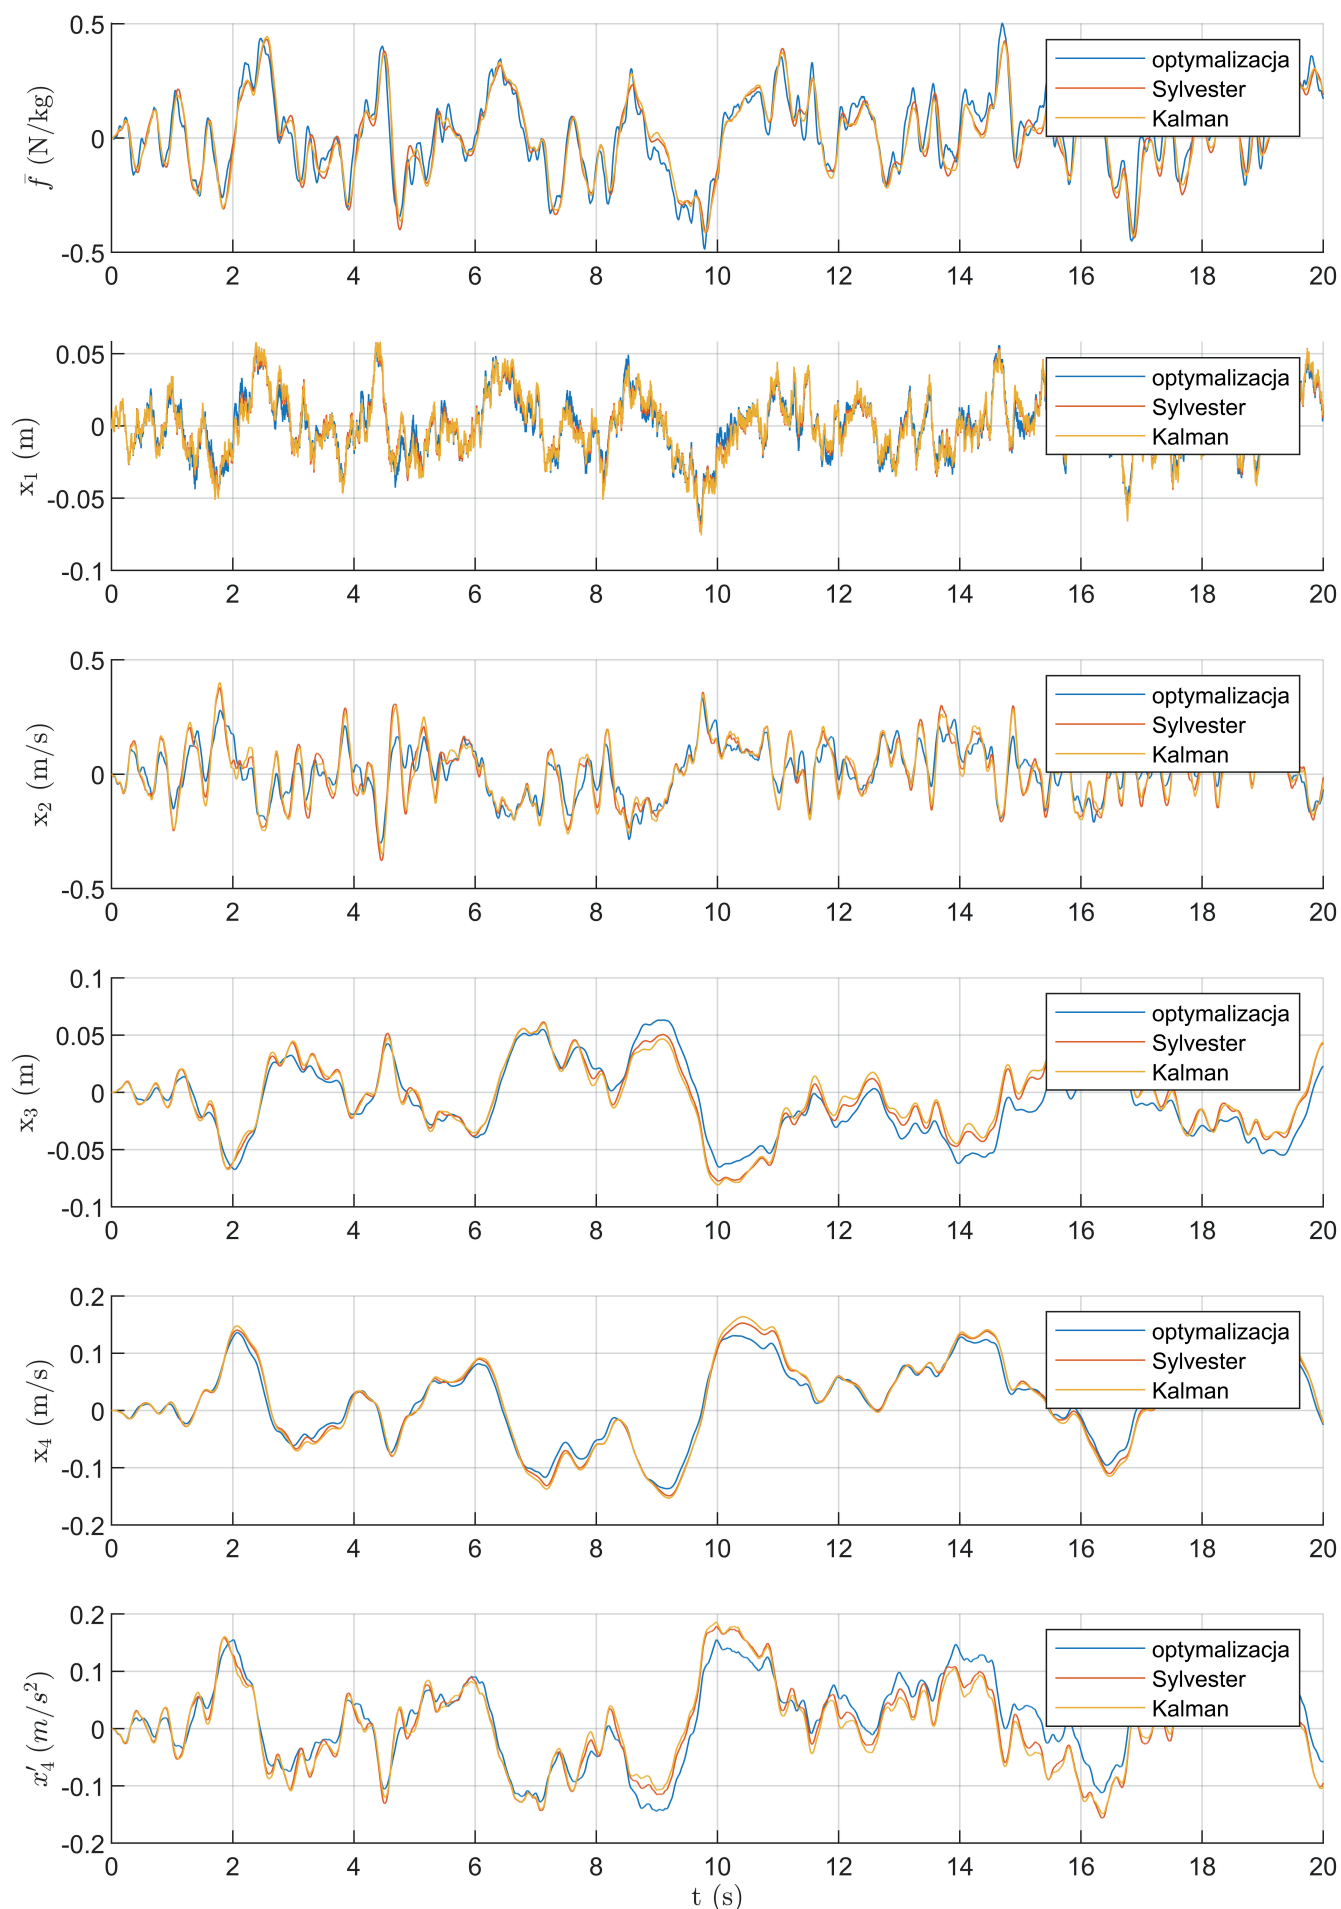
Nie brano pod uwagę dwóch pierwszych sekund każdej symulacji tak, by obserwator mógł dogonić obiekt. Co więcej, pierwsze dwie sekundy po uruchomieniu pojazdu są czasem pomijalnie małym w stosunku do czasu jazdy. Wykorzystywano macierze wagowe  $Q_x$  oraz  $Q_y$  korespondujące z macierzami wykorzystywanymi w funkcji kosztu regulatora predykcyjnego sterującego obiektem. Zastosowane ograniczenia stanowiły dodatkowe narzędzie pozwalające naprowadzić algorytm na odpowiednie rozwiązanie przez bezpośrednią ocenę błędów estymacji oraz niedopuszczenie do korzystania ze zbyt dużych wartości sygnału sterującego. Z uwagi na fakt, iż wynik optymalizacji wybraną metodą w znacznym stopniu zależy od punktu startowego, algorytm startował z dobrze rokującego punktu wyznaczonego za pomocą metody Kalmana.

Skorzystano tu z faktu, iż zarówno filtr Kalmana, jak i obserwator Luenbergera, mają podobne wektory wzmocnień. Metoda ta pozwalała, po podaniu kowariancji szumu procesowego oraz pomiarowego, na szybkie, zgrubne dobranie początkowego wzmocnienia. Tak zdefiniowane zadanie optymalizacji rozwiązano za pomocą metody interior-point zaimplementowanej w środowisku MATLAB. Szczegółowa dokumentacja wykorzystanej funkcji znajduje się w [6]. Z uwagi na znaczną złożoność czasową obliczania wartości funkcji celu, wymagającej każdorazowego dokonania symulacji, dużą zależność od punktu początkowego, powtarzalność i możliwość sprecyzowania dodatkowych ograniczeń uznano algorytm tego typu za najlepszy wybór.

## 5. Rezultaty

Otrzymany zgodnie z opisaną procedurą układ sterowania testowano w sposób symulacyjny w środowisku MATLAB. W pierwszej kolejności sprawdzono zachowanie układu w warunkach identycznych pod kątem zakłóceń jak w procesie optymalizacji wzmocnienia obserwatora Luenbergera. Przebiegi oraz jakość regulacji porównywano z układami z takimi samymi regulatorami i nieco innymi mechanizmami estymacji stanu obiektu, tj. obserwatorem Luenbergera o wzmocnieniu wyliczonym w oparciu o równanie Sylwestera oraz filtrem Kalmana. Uzyskane przebiegi przedstawiono na rys. 2.

Jak można zauważyć (rys. 2), obserwator otrzymany z metody Sylwestera oraz filtr Kalmana przekładają się na zbliżone przebiegi stanu oraz wyjścia obiektu. Układ korzystający z estymatora otrzymanego przy wykorzystaniu metody prezentowanej



Rys. 2. Zestawienie odpowiedzi obiektu dla zakłóceń identycznych z zakłóceniami wykorzystanymi w trakcie procesu optymalizacji wektora wzmocnień L

Fig. 2. System responses comparison, same disturbances as during L gain optimization

przez autorów pozwolił na uzyskanie mniejszej amplitudy przyspieszeń nadwozia oraz zmniejszenie prędkości masy resorowanej. Zauważalnie zmalały także prędkości masy nieresorowanej, które jednak nie były brane pod uwagę w ocenie jakości regulacji. Co więcej, obserwator wyznaczony na bazie optymalizacji skłonił regulator do generowania sygnałów sterujących o wyższych wartościach. Wartości kryterium jakości regulacji, które wykorzystano także w procesie optymalizacji wektora  $L$ , dla układu badanego oraz układów porównawczych zgromadzone w Tabeli 2.

**Tabela 2. Wartości przyjętego kryterium jakości regulacji dla zakłóceń identycznych z zakłóceniami wykorzystanymi w trakcie procesu optymalizacji wektora wzmocnień  $L$**

Table 2. Performance index values, same disturbances as during  $L$  gain optimization

metoda	optymalizacja	Sylvester	Kalman
$J^*$	113725,39	124398,73	127149,01

Z tabeli jasno wynika, iż uzyskany estymator zapewnia najlepszą jakość regulacji w świetle przyjętego kryterium. Kolejną fazę badania otrzymanego układu stanowiły testy dla zakłóceń losowych, różnych od tych, które wykorzystano w procesie optymalizacji. Jednocześnie zachowano prezentowane wcześniej odchylenia standardowe zakłóceń od drogi oraz pochodzących z czujnika przyspieszeń karoserii. W procesie generacji zakłóceń korzystano z dostępnego w środowisku MATLAB generatora liczb pseudolosowych pozwalającego na ustalenie konkretnych ziaren, co wykorzystano w dwojaki sposób, tj. w procesie optymalizacji możliwe było utrzymanie zawsze tego samego scenariusza zakłóceń, a w procesie weryfikacji wyników możliwe było generowanie niepowtarzalnych zakłóceń dla każdej z prób. Celem uzyskania miarodajnych wyników przeprowadzone zostało sto prób. Tego typu podejście miało na celu przede wszystkim sprawdzenie czy optymalizacja wzmocnienia nie nastąpiła jedynie dla jednostkowego scenariusza zakłóceń wykorzystanego w procesie optymalizacji. Uzyskany rozkład wartości kryterium jakości regulacji przedstawiono na rys. 3.


Analizując powyższe histogramy można zauważyć, iż układ korzystający z obserwatora wyznaczonego na drodze optymalizacji zdecydowanie częściej, w porównaniu do filtra Kalmana oraz obserwatora otrzymanego z wykorzystaniem równania Sylwestera, uzyskiwał niższe wartości przyjętego kryterium  $J^*$ . Dominanta dla uzyskanego obserwatora znajduje się w przedziale od 0,7 do 0,8, natomiast dla pozostałych estymatorów jest to przedział od 0,8 do 0,9. Dodatkowe dane statystyczne korespondujące z oboma histogramami zgromadzone w Tabeli 3.

**Tabela 3. Porównanie wartości miar statystycznych wyznaczonych na podstawie danych zebranych na przestrzeni stu prób dla układów z różnego typu estymatorami stanu**

Table 3. Comparison of statistical information based on data from 100 experiments and for different methods of state estimation

	min $J^*$	max $J^*$	$\bar{J}^*$	$\sigma_{J^*}$
$J_{opt}^*$	40 292,18	134 277,87	75 500,18	16 871,51
$J_S^*$	45 802,65	157 950,42	83 052,49	19 023,28
$J_K^*$	47 283,32	162 977,99	84 907,05	19 702,26

Proponowany estymator zapewnił niższe wartości skrajne oraz średnie przyjętego kryterium i jednocześnie utrzymał najniższe odchylenie standardowe, co świadczy o powtarzalności wyników. Uzyskano minimalne wartości  $J^*$  mniejsze o 12 % w stosunku do układu z obserwatorem wyznaczonym w oparciu o równanie Sylwestera oraz o 14,8 % niższe w stosunku do układu z filtrem Kalmana.



**Rys. 3. Histogramy przedstawiające rozkład wartości przyjętego kryterium jakości regulacji uzyskane na przestrzeni stu prób dla różnych zakłóceń**

Fig. 3. Histograms showing distribution of control performance index for 100 experiments with random noise

Jeśli chodzi o wartości maksymalne, uzyskano wyniki lepsze odpowiednio o 15 % oraz o 17,6 %. Biorąc pod uwagę wartość uśrednioną, udało się uzyskać o 9,1 % wyższą jakość regulacji w stosunku do układu z obserwatorem wyznaczonym w oparciu o równanie Sylwestera oraz o 11,1 % wyższą w stosunku do filtra Kalmana.

## 6. Podsumowanie

Zaprezentowana metoda syntezy obserwatora oparta na optymalizacji zapewniła poprawę ogólnej jakości regulacji względem filtra Kalmana oraz obserwatora otrzymanego z wykorzystaniem równania Sylwestera. Jednocześnie utrzymano prostotę obserwatora Luenbergera. Co więcej, synteza tego typu estymatora stanu nie wymaga szczegółowych informacji o występujących w układzie zakłóceń. Dodatkowo rezultaty pokazały, iż otrzymane optymalne wzmocnienie obserwatora nie zostało zoptymalizowane pod kątem konkretnego scenariusza, a w sposób ogólny, co jest szczególnie ważne z uwagi na losowy charakter nierówności nawierzchni drogi.

Należy jednak zaznaczyć, iż zaproponowana nowa metoda została opracowana dla konkretnego układu, tj. układu aktywnego zawieszenia. Nie wyklucza to jednak jego zdolności do zastosowania w podobnych układach z racji jej przyjętego podejścia polegającego na zapożyczeniu funkcji kosztu regulatora predykcyjnego. Sprawdzenie zdolności tego typu sposobu syntezy obserwatora dla szerszej grupy układów może stanowić przedmiot dalszych badań.

## Bibliografia

1. Akesson B., Jørgensen J., Jørgensen S., *A Generalized Auto-covariance Least-Squares Method for Covariance Estimation*, [In:] Proceedings of the American Control Conference (July 2007), 3713–3714, DOI: 10.1109/ACC.2007.4282878.
2. Gallego A.J. et al., *Observer-based Model Predictive Control of a parabolic-trough field*, "Solar Energy", Vol. 97, 426–435, DOI: 10.1016/j.solener.2013.09.002.
3. Giorgetti N. et al., *Hybrid Model Predictive Control Application Towards Optimal Semi-Active Suspension*, [In:]

- Proceedings of the IEEE International Symposium on Industrial Electronics*, ISIE 2005. 391–398, DOI: 10.1109/ISIE.2005.1528942.
4. Houssemeddine Gouta et al., *Generalized predictive control for a coupled four tank MIMO system using a continuous-discrete time observer*, "ISA Transactions", Vol. 67, 2016, 280–292, DOI: 10.1016/j.isatra.2016.11.021.
  5. Herceg M. et al., *Multi-Parametric Toolbox 3.0*, [In:] Proc. of the European Control Conference. [http://control.ee.ethz.ch/~mpt]. Zurich, Switzerland, July 2013, 502–510, DOI: 10.23919/ECC.2013.6669862.
  6. Inc. MathWorks. *Dokumentacja programu MATLAB 2020a*. www.mathworks.com/help/optim/ug/fmincon.html. 2020.
  7. Mayne D.Q. et al. *Robust Output Feedback Model Predictive Control for Constrained Linear Systems under Uncertainty Based on Feed Forward and Positive Invariant Feedback Control*, [In:] Proceedings of the 45th IEEE Conference on Decision and Control, 2006, 6618–6623, DOI: 10.1109/CDC.2006.376851.
  8. Mohan S., Liu J., Vasudevan R., *Synthesizing the optimal luenberger-type observer for nonlinear systems*. [In:] IEEE 56th Annual Conference on Decision and Control (CDC), 2017, 3658–3663, DOI: 10.1109/CDC.2017.8264197.
  9. Suzuki R. et al., *Automatic Tuning of Model Predictive Control Using Particle Swarm Optimization*, [In:] IEEE Swarm Intelligence Symposium, 2007, 221–226, DOI: 10.1109/SIS.2007.367941.
  10. Takeuchi Y., *Optimization of Continuous-Time Observations for the Stationary Kalman-Bucy Filter*, [In:] Proceedings of the ISCIE International Symposium on Stochastic Systems Theory and its Applications, 2015, 22–29, DOI: 10.5687/sss.2015.22.
  11. Waschl H., Alberer D., del Re L., *Automatic Tuning Methods for MPC Environments*, [In:] EUROCAST 2011, 41–48, DOI: 10.1007/978-3-642-27579-1\_6.

## Luenberger Observer Gain Optimization in Model Predictive Control System for Car Active Suspension

**Abstract:** MPC Driven control systems very often are requiring the introduction of a mechanism predicting the state of the object unavailable for measurements. Depending on the case, a different number of state variables will be unobtainable. Widely used systems to obtain essential data of the condition of an object are Luenberger state observer and different types of Kalman filters. The authors propose a new method of Luenberger observer synthesis based on Luenberger gain optimization using performance index corresponding to generalized system performance. The developed method allows us to obtain better-performing observer from the point of view of the adopted criterion, compared to similar estimators derived from the Sylvester equation and classic Kalman filters, even despite the occurrence of disturbances. The developed method will be presented on an example of an active suspension system with MPC.

**Keywords:** state observer, model predictive control, observer optimization, active suspension

**inż. Grzegorz Maślak**  
mg38657@zut.edu.pl  
ORCID: 0000-0003-4631-9423

Student studiów magisterskich na kierunku Automatyka i Robotyka na Wydziale Elektrycznym Zachodniopomorskiego Uniwersytetu Technologicznego w Szczecinie. Zainteresowania naukowe obejmują zagadnienia związane ze sterowaniem predykcyjnym, optymalizacją oraz układami hybrydowymi.



**dr hab. inż. Przemysław Orłowski, prof. ZUT**  
Przemyslaw.orlowski@zut.edu.pl  
ORCID: 0000-0001-6407-9668

Profesor nadzwyczajny w Katedrze Automatyki i Robotyki Zachodniopomorskiego Uniwersytetu Technologicznego w Szczecinie. Główne kierunki badań naukowych to analiza i synteza układów sterowania, w szczególności układy dyskretne, układy hybrydowe, układy niepewne, optymalizacja jedno i wielokryterialna, metody sztucznej inteligencji.

