



**POLITECHNIKA
GDAŃSKA**

WYDZIAŁ
ELEKTROTECHNIKI
I AUTOMATYKI



Imię i nazwisko autora rozprawy: Krzysztof Jaroś
Dyscyplina naukowa: automatyka, elektronika, elektrotechnika i technologie kosmiczne

ROZPRAWA DOKTORSKA

Tytuł rozprawy w języku polskim: Sterowanie predykcyjne i fuzja danych w systemie dynamicznego pozycjonowania statku

Tytuł rozprawy w języku angielskim: Model predictive control and data fusion in the dynamic positioning vessel system

Promotor	Promotor pomocniczy
<i>podpis</i>	<i>podpis</i>
prof. dr hab. inż. Roman Śmierchalski	dr hab. Anna Witkowska

Podziękowania

Na powstanie i ostateczny kształt mojej pracy doktorskiej miało wpływ wiele osób, którym chciałbym w tym miejscu podziękować.

W sposób szczególny jednak dziękuję Prof. dr hab. inż. Romanowi Śmierchal-skiemu i za opiekę promotorską, za Jego pracę włożoną w obecny kształt niniejszej rozprawy, ale przede wszystkim za umiejętność stawiania wymagań, oceniania pracy, wyrozumiałość oraz poświęcony czas.


Chciałbym również bardzo podziękować Pani dr hab. Annie Witkowskiej, która zawsze pomagała mi ze wszystkimi problemami, które napotykałem na swojej drodze, oraz służyła dobrą radą, wsparciem merytorycznym, uwagami oraz za poświęcony czas.

Osobne, równie ważne, podziękowania składam na ręce mojej żony Karoliny, na którą zawsze mogłem liczyć, wspierała mnie i wykazywała ogromną wyrozumiałość co do mojej pracy naukowej.

Streszczenie

Głównym zadaniem systemu dynamicznego pozycjonowania (DP) na statkach jest utrzymywanie ich pozycji i kursu za pomocą jedynie własnego układu napędowego. Funkcja ta ma szczególne zastosowanie w morskim przemyśle wydobywczym, który na przestrzeni lat badał złoża znajdujące się pod powierzchnią dna morskiego oraz rozwijał technologie do ich wydobycia. Podstawowym problemem przy wydobywaniu złóż z dna morskiego jest utrzymanie położenia platformy, statku z określoną dokładnością. Pierwszymi technologiami wykorzystywanymi do pozycjonowania statku były systemy kotwiczne i pomostowe. Są one jednak ograniczone głębokością dna oraz rodzajem podłoża w przypadkach, dla których budowa odpowiedniej infrastruktury jest nieuzasadniona ekonomicznie. Konieczne było stworzenie alternatywnego sposobu utrzymywania pozycji i kursu statku, w którym do zadania pozycjonowania wykorzystano by wyłącznie napędy i stery zainstalowane na statku. Zaprojektowany zestaw połączonych funkcjonalnie urządzeń nazwano systemem dynamicznego pozycjonowania. Statki z systemem dynamicznego pozycjonowania znajdują również zastosowanie w nowych obszarach, np. przy serwisie farm wiatrowych, układaniu rur i przewodów oraz w przeładunku na morzu. Nowe zastosowania funkcjonalne statków DP wraz z wprowadzeniem nowych technologii wymagają prowadzenia dalszych prac nad tymi systemami.

Podstawowym zadaniem systemu dynamicznego pozycjonowania jest sterowanie statkiem w celu minimalizacji błędów położenia i kursu. System dynamicznego pozycjonowania wykorzystywany jest do utrzymywania statku w zadanym położeniu i kursie lub do sterowania statkiem po zadanej trajektorii z małą prędkością, zwykle nieprzekraczającą 2 m/s . Zadanie to musi być realizowane z określoną dokładnością.



Rys. 1: System dynamicznego pozycjonowania statkiem

System dynamicznego pozycjonowania przedstawiony schematycznie na rys. 1 składa się z następujących podsystemów:

- napędowego statku – wytwarzającego siły i momenty potrzebne do realizowania zadania dynamicznego pozycjonowania;
- elektroenergetycznego – odpowiedzialnego za dostarczanie energii elektrycznej i zarządzanie mocą na statku;
- pomiarowego – odpowiedzialnego za pomiar położenia, kursu, prędkości statku oraz warunków środowiskowych potrzebnych do oszacowania sił działających na statek od zakłóceń środowiskowych;
- obróbki sygnałów pomiarowych – odpowiedzialnego za fuzję danych wykorzystywaną do obliczania estymacji położenia, kursu statku, prędkość obrotową śrub napędowych oraz zakłócenia środowiskowe;
- sterowania – odpowiedzialnego za określenie wielkości sterujących w postaci sił i momentów, jakie wymagane są do realizacji zadania dynamicznego pozycjonowania;
- alokacji i kontroli napędów – odpowiedzialnego za obliczenie nastaw dla poszczególnych napędów i sterów zainstalowanych na statku.

Wartością wejściową do systemu dynamicznego pozycjonowania jest zadane położenie, kurs lub trajektoria. Podsystem sterowania na podstawie wartości zadanych i informacji z podsystemu obróbki sygnałów pomiarowych oblicza siły i momenty, jakie muszą zostać wytworzone przez podsystem napędowy, aby zrealizować zadanie dynamicznego pozycjonowania. Za określenie aktualnych wartości pomiarowych potrzebnych do sprzężenia zwrotnego odpowiedzialny jest podsystem pomiarowy. Podsystem obróbki sygnałów oblicza wartości estymowane potrzebne dla zadania dynamicznego pozycjonowania, archiwizuje



dane z podsystemów i nadzorując ich pracę. Zadana wartość sił sterujących przekazywana jest do podsystemu alokacji i kontroli napędów, który przelicza odpowiednie nastawy napędów i położenie sterów statku. Podsystem elektroenergetyczny dostarcza energię elektryczną zasilającą napędy i stery do realizacji zadania sterowania statkiem.

Istotnym problemem dla statków z systemem dynamicznego pozycjonowania są awarie. Awaria urządzeń systemu dynamicznego pozycjonowania może spowodować nieakceptowalne straty materialne, zagrożenie dla załogi i środowiska. Towarzystwa klasyfikacyjne – Lloyd’s Register of Shipping, Det Norske Veritas (DNV), Polski Rejestr Statków – na podstawie rezolucji IMO Martine Safety Committee Circular 645 w przepisach opisują kryteria dotyczące projektowania, wyposażenia i testów urządzeń w systemie dynamicznego pozycjonowania. W celu zmniejszenia skutków awarii podzespołów, przepisy dla statków DP w zależności od klasy statku wymagają stosowania nadmiarowych podsystemów pomiarowych, komputerowych, sterowania i elektroenergetycznych, spełniających odpowiednie parametry.

Głównymi problemami badawczymi w systemach dynamicznego pozycjonowania są metody sterowania statkiem DP i przetwarzanie sygnałów pomiarowych. W pracy przedstawiono dwa kierunki badań. Pierwszy dotyczy zadania fuzji danych z wykorzystaniem nadmiarowej struktury pomiarowej dokonującej pomiaru położenia, kursu i prędkości w celu estymacji tych wielkości i zakłóceń środowiskowych. Drugi kierunek badań dotyczy poprawy jakości sterowania statkiem z wykorzystaniem nieliniowego modelu statku w sterowaniu predykcyjnym. Celem fuzji danych jest obliczenie estymowanych wartości zakłóceń środowiskowych, stanów statku oraz parametrów niemierzalnych z wykorzystaniem matematycznego modelu statku. W poniższej pracy do przetwarzania sygnałów pomiarowych wykorzystano algorytm kaskadowego połączenia filtru cząsteczkowego i rozszerzonego filtru Kalmana. Zaprojektowany algorytm porównano z rozszerzonym filtrem Kalmana, nieliniowym obserwatorem i filtrem cząsteczkowym w czasie wykonywania zadania pozycjonowania i sterowania wzdłuż trajektorii z małą prędkością. W celu porównania filtrów przeprowadzono badania symulacyjne z wykorzystaniem kilku scenariuszy. Scenariusze podzielono na badania dotyczące jakości estymacji filtrów w zależności od wykonywanego zadania i niezawodności układu pomiarowego. Na podstawie badań wykazano, że zastosowany algorytm fuzji danych utrzymuje wysoką jakość estymacji zmienionych oraz poprawia jakość estymacji w sytuacjach awaryjnych. W badanych scenariuszach przyjęto następujące sytuacje awaryjne:

- dryft czujników pomiarowych,
- czasowy brak aktualizacji pomiaru z czujników pomiarowych,
- uszkodzenie czujników pomiarowych, skutkujące wskazaniem pomiarów z dużym błędem pomiarowym.

W celu poprawy jakości systemu sterowania zaimplementowano regulator predykcyjny z wykorzystaniem nieliniowego modelu statku, który został porównany z



regulatorem backstepping i nieliniowym regulatorem PID. Algorytmy przebadano pod względem zadania utrzymania położenia i kursu statku oraz sterowania statkiem do wartości zadanej położenia i kursu statku. W pracy wykazano, że zaproponowany algorytm nieliniowego sterowania predykcyjnego ma lepsze własności dynamiczne od pozostałych algorytmów.

W ostatniej części pracy badano efektywność działania przedstawionych algorytmów i połączono algorytm fuzji danych z algorytmami sterowania. W badaniach symulacyjnych sprawdzono wpływ dokładności estymacji na jakość sterowania regulatora predykcyjnego, regulatora backstepping i regulatora PID dla zadania utrzymywania stałej pozycji i kursu oraz w procesach przejściowych podczas skokowej zmiany wartości zadanej. Wyniki badań symulacyjnych wykazały, że zaproponowany system fuzji danych poprawia odporność systemu na większość prezentowanych scenariuszy awaryjnych oraz utrzymuje zbliżone wyniki dla scenariuszy ze sprawnie działającym układem pomiarowym. Porównanie zaproponowanego algorytmu sterowania z pozostałymi algorytmami wykazało, że cechuje się on lepszymi właściwościami dynamicznymi i statycznymi.

Abstract

The main task of a dynamic positioning (DP) system on vessels is to maintain their position and heading. This function has particular applications in the offshore mining industry, which over the years has explored deposits beneath the seabed and developed technologies to extract them. The main problem in seabed mining is to maintain the position of the platform/vessel with a certain accuracy. The first technologies used for vessel positioning were anchor and bridge systems. However, they are limited by the depth of the bottom and the type of substrate in cases for which the construction of adequate infrastructure is not economically justified. An alternative means of maintaining the vessel's position and heading had to be developed, in which only the drives and rudders installed on the vessel would be used for the positioning task. The designed set of functionally connected devices was called the dynamic positioning system. Vessels with dynamic positioning systems are also being used in new areas such as wind farm servicing, pipe and cable laying and offshore transshipment. New functional applications of DP vessels with the introduction of new technologies require further work on these systems.

The primary task of a dynamic positioning system is to steer the vessel to minimize position and heading error. A dynamic positioning system is used to keep a vessel on a predefined position and heading or to steer a vessel along a predefined trajectory at low speed, usually not exceeding 2 m/s . This task must be performed with a specific accuracy.

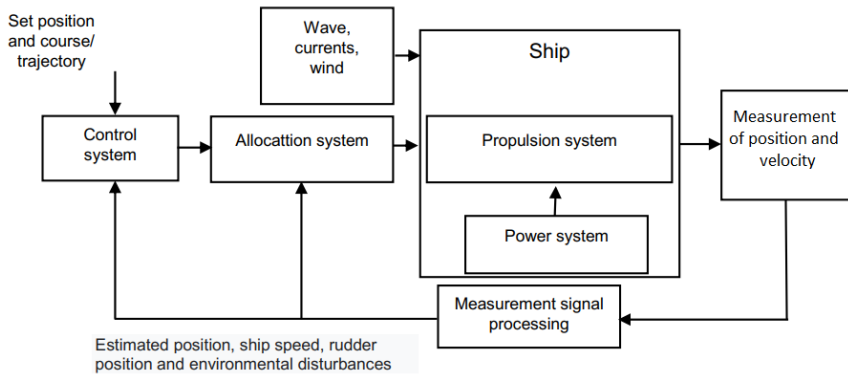


Fig. 2: Dynamic positionig vessel system

The dynamic vessel positioning system shown schematically in fig 2 consists of the following subsystems:

- the vessel's propulsion system - which generates the forces and torques needed to perform the dynamic positioning task;
- power - responsible for electrically powering the vessel and performing vessel power management
- measuring - responsible for measuring the vessel's position, heading, speed and environmental conditions needed to estimate the forces on the vessel from environmental disturbances;
- measurement signal processing - responsible for data fusion used to calculate estimates of position, heading, propeller speed and environmental disturbances;
- control - responsible for determining the control quantities in the form of forces and torques that are required to perform the dynamic positioning task;
- allocation system - responsible for calculating presets for individual propulsion units and rudders installed on the shvesselip.

The input value to a dynamic positioning system is a preset position, heading or trajectory. The steering subsystem calculates the forces and torques that must be produced by the drive subsystem to accomplish the dynamic positioning task, based on the presets and information from the measurement signal processing subsystem. The measurement subsystem is responsible for determining the actual measurement values needed for feedback. The signal processing subsystem calculates the estimated values needed for the dynamic positioning task, archives the data from the subsystems, and supervises their operation. The set value of the steering forces is transmitted to the propulsion allocation and steering



subsystem, which recalculates the appropriate propulsion settings and rudder position of the vessel. The electrical power subsystem provides the electrical energy to power the drives and rudders for the vessel steering task.

A constant problem for vessels with dynamic positioning systems is failures. Failure of the dynamic positioning system equipment can result in unacceptable property damage, crew and environmental hazards. Classification societies - Lloyd's Register of Shipping, Det Norske Veritas (DNV), Polish Register of Shipping - on the basis of IMO Resolution Maritime Safety Committee Circular 645 describe in regulations the criteria for design, equipment and testing of devices in the dynamic positioning system. To reduce the effects of component failures, DP vessel regulations, depending on the class of vessel, require redundant measurement, computer, steering, and electrical power subsystems that meet the appropriate parameters.

The main research problems in dynamic positioning systems are methods of steering DP vessels and measurement signal processing. The paper presents two lines of research. The first addresses the task of data fusion using a redundant measurement structure that measures position, heading and velocity to estimate these quantities and environmental disturbances. The second line of research deals with improving the quality of vessel steering using a nonlinear vessel model in predictive steering. The purpose of data fusion is to calculate estimated values of environmental disturbances, vessel states, and unmeasurable parameters using a mathematical model of the vessel. In the following work, a cascaded algorithm combining a particle filter and an extended Kalman filter is used to process the measurement signals. The designed algorithm was compared with an extended Kalman filter, a nonlinear observer, and a particle filter when performing a positioning and steering task along a trajectory at low speed. Simulation studies using several scenarios were conducted to compare the filters. The scenarios were divided into studies on the quality of filter estimation depending on the task at hand and the reliability of the measurement system. Based on the study, it was shown that the applied data fusion algorithm maintains high quality of variable estimation and improves the quality of estimation in contingencies. The following contingencies were assumed in the scenarios studied:

- drift of measurement sensors,
- temporary lack of measurement updates from the measurement sensors,
- damage of measurement sensors, resulting in measurements with a large measurement error.

To improve the quality of the steering system, a predictive controller was implemented using a nonlinear vessel model, which was compared with a backstepping controller and a nonlinear PID controller. The algorithms were tested for the task of maintaining the vessel's position and heading and steering the vessel to the vessel's position and heading setpoint. This paper shows that the proposed nonlinear predictive steering algorithm has better static and dynamic properties than the other algorithms.



In the last part of the paper, the efficiency of the presented algorithms is studied and the data fusion algorithm is combined with the steering algorithms. In the simulation studies, the effect of estimation accuracy on the steering quality of the predictive controller, backstepping controller and PID controller was checked for the task of maintaining a constant position and heading and in transient processes during a step change of the setpoint. The results of the simulation studies showed that the proposed data fusion system improves the robustness of the system to most of the presented failure scenarios and maintains similar results for scenarios with a well-functioning measurement system. Comparison of the proposed steering algorithm with the other algorithms showed that it has better dynamic and static properties.

Spis treści

Podziękowania	iii
Streszczenie	v
Abstract	ix
Spis treści	xiii
Spis rysunków	xv
Spis tabel	xxvii
Lista symboli	xxxii
1 Wstęp	1
1.1 Cel i teza pracy	5
1.2 Układ pracy	6
2 Model matematyczny statku	7
2.1 Kinematyka	10
2.2 Dynamika	10
3 Fuzja danych	17
3.1 Algorytm fuzji danych	20
3.2 Filtr Kalmana	22
3.3 Rozszerzony filtr Kalmana	24
3.4 Nieliniowy obserwator	26
3.5 Filtr cząsteczkowy	28
3.6 Fuzja danych w badaniach systemu DP	33
4 Sterowanie	39
4.1 PID	40
4.2 Regulator backstepping	42
4.3 Sterowanie predykcyjne	44
4.4 Realizacja sterowania predykcyjnego w badaniach symulacyjnych	47
5 Badania symulacyjne algorytmów fuzji danych	51
5.1 Opis i założenia dotyczące badania symulacyjnego estymacji stanu i fuzji danych	51



Spis treści

5.2	Badania symulacyjne estymacji i fuzji danych	58
5.3	Wnioski	119
6	Badania symulacyjne algorytmów sterowania	123
6.1	Założenia dotyczące badań algorytmów sterowania	123
6.2	Wnioski	146
7	Podsumowanie	149
	Bibliografia	153

Spis rysunków

1	System dynamicznego pozycjonowania statkiem	vi
2	Dynamic positioning vessel system	x
2.1	Ruchy statku o 6 stopniach swobody.	7
2.2	Stopnie swobody uwzględnione w systemie dynamicznego pozycjonowania	9
2.3	Stopnie swobody pomijane w systemie dynamicznego pozycjonowania	9
2.4	Układy współrzędnych stosowane do opisu matematycznego modelu statku	10
3.1	Podział fuzji danych według JDL	18
3.2	Scentralizowana architektura systemu	19
3.3	Zdecentralizowana architektura systemu	19
3.4	Rozproszona architektura systemu	19
3.5	Schemat blokowy nieliniowego pasywnego obserwatora	28
4.1	Schemat układu sterowania PID ze sprzężeniem zwrotnym od przyspieszenia	41
4.2	Schemat blokowy regulatora backstepping	44
4.3	Wykres zależności czasowych dla sterowania predykcyjnego [96]	45
4.4	Wykres realizowanego kroku predykcji dla projektowanego algorytmu MPC	48
5.1	Siły od zakłóceń działające na statek dla scenariuszy	52
5.2	Położenie i kurs statku w układzie współrzędnym NED w czasie wykonywania manewru	53
5.3	Prędkości statku w układzie związanym ze statkiem w czasie wykonywania manewru	53
5.4	Położenie i kurs statku w układzie współrzędnym NED podczas stabilizacji	54
5.5	Prędkości statku w układzie związanym ze statkiem podczas stabilizacji	54
5.6	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - manewr	60
5.7	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - manewr	60
5.8	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - manewr	60



5.9	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - manewr	61
5.10	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - manewr	61
5.11	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o -stabilizacja	62
5.12	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o -stabilizacja	62
5.13	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - stabilizacja	63
5.14	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - stabilizacja	63
5.15	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - stabilizacja	63
5.16	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - różna złożoność modelu obiektu podczas manewru	65
5.17	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - różna złożoność modelu obiektu podczas manewru	66
5.18	Błąd średniokwadratowy $RMSE(k)$ kursu ψ - różna złożoność modelu obiektu podczas manewru	66
5.19	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej u - różna złożoność modelu obiektu podczas manewru	66
5.20	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej v - różna złożoność modelu obiektu podczas manewru	67
5.21	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - nadmiarowa konfiguracja czujników podczas manewru	68
5.22	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - nadmiarowa konfiguracja czujników podczas manewru	69
5.23	Błąd średniokwadratowy $RMSE(k)$ kursu ψ - nadmiarowa konfiguracja czujników podczas manewru	69
5.24	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej u - nadmiarowa konfiguracja czujników podczas manewru	69
5.25	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej v - nadmiarowa konfiguracja czujników podczas manewru	70
5.26	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - nadmiarowa konfiguracja czujników podczas stabilizacji	71
5.27	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - nadmiarowa konfiguracja czujników podczas stabilizacji	71
5.28	Błąd średniokwadratowy $RMSE(k)$ kursu ψ - nadmiarowa konfiguracja czujników podczas stabilizacji	71
5.29	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej u - nadmiarowa konfiguracja czujników podczas stabilizacji	72
5.30	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej v - nadmiarowa konfiguracja czujników podczas stabilizacji	72
5.31	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - porównanie różnej konfiguracji czujników podczas manewru . . .	73



5.32	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - porównanie różnej konfiguracji czujników podczas manewru . . .	73
5.33	Błąd średniokwadratowy $RMSE(k)$ kursu ψ - porównanie różnej konfiguracji czujników podczas manewru	74
5.34	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - - porównanie różnej konfiguracji czujników podczas manewru .	74
5.35	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - - porównanie różnej konfiguracji czujników podczas manewru	74
5.36	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - uszkodzenie 1 z 3 czujników położenia podczas manewru	76
5.37	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 1 z 3 czujników położenia podczas manewru	76
5.38	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 1 z 3 czujników położenia podczas manewru	77
5.39	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 1 z 3 czujników położenia podczas manewru	77
5.40	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 1 z 3 czujników położenia podczas manewru . .	77
5.41	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji	78
5.42	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji	78
5.43	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji	79
5.44	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji . . .	79
5.45	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji . .	79
5.46	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - uszkodzenie 1 z 3 czujników prędkości podczas manewru	80
5.47	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 1 z 3 czujników prędkości podczas manewru	80
5.48	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 1 z 3 czujników prędkości podczas manewru	81
5.49	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 1 z 3 czujników prędkości podczas manewru	81
5.50	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 1 z 3 czujników prędkości podczas manewru . . .	81
5.51	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji	82
5.52	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji	82
5.53	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji	83
5.54	Błąd średniokwadratowy $RMSE(k)$ prędkość wzdłużnej statku u - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji . . .	83



5.55	Błąd średniokwadratowy prędkości poprzecznej statku v - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji	83
5.56	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X - uszkodzenie 2 z 3 czujników położenia podczas manewru	85
5.57	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 2 z 3 czujników położenia podczas manewru	85
5.58	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 2 z 3 czujników położenia podczas manewru	85
5.59	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 2 z 3 czujników położenia podczas manewru	86
5.60	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 2 z 3 czujników położenia podczas manewru . .	86
5.61	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - uszkodzenie 2 z 3 czujników prędkości podczas manewru	87
5.62	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 2 z 3 czujników prędkości podczas manewru	87
5.63	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 2 z 3 czujników prędkości podczas manewru	87
5.64	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 2 z 3 czujników prędkości podczas manewru	88
5.65	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 2 z 3 czujników prędkości podczas manewru . . .	88
5.66	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru	89
5.67	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru	90
5.68	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru . . .	90
5.69	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru	90
5.70	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru	91
5.71	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji	91
5.72	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji	92
5.73	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji . .	92

5.74	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji	92
5.75	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji	93
5.76	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru	93
5.77	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru	94
5.78	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru . . .	94
5.79	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru	94
5.80	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru	95
5.81	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji	95
5.82	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji	96
5.83	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji . .	96
5.84	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji	96
5.85	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji	97
5.86	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru	98
5.87	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru	98
5.88	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru . . .	98
5.89	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru	99



5.90	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru	99
5.91	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji	100
5.92	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji	100
5.93	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji	100
5.94	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku ψ - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji	101
5.95	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji	101
5.96	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas manewru	102
5.97	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji 2 z 3 czujników prędkości podczas manewru	102
5.98	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi ψ - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas manewru	102
5.99	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas manewru	103
5.100	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji 2 z 3 czujników prędkości podczas manewru	103
5.101	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas stabilizacji	104
5.102	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas stabilizacji	104
5.103	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas stabilizacji	104
5.104	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji 2 z 3 czujników prędkości podczas stabilizacji	105
5.105	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas stabilizacji	105
5.106	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - dryft 1 z 3 czujników położenia podczas manewru	106



5.107	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - dryft 1 z 3 czujników położenia podczas manewru	107
5.108	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 1 z 3 czujników położenia podczas manewru	107
5.109	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 1 z 3 czujników położenia podczas manewru	107
5.110	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku w osi v - dryft 1 z 3 czujników położenia podczas manewru . . .	108
5.111	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - dryft 1 z 3 czujników położenia podczas stabilizacji	108
5.112	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 1 z 3 czujników położenia podczas stabilizacji	109
5.113	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 1 z 3 czujników położenia podczas stabilizacji	109
5.114	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 1 z 3 czujników położenia podczas stabilizacji	109
5.115	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku w osi X_o - dryft 1 z 3 czujników położenia podczas stabilizacji .	110
5.116	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - dryft 1 z 3 czujników prędkości podczas manewru	110
5.117	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - dryft 1 z 3 czujników prędkości podczas manewru	111
5.118	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 1 z 3 czujników prędkości podczas manewru	111
5.119	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 1 z 3 czujników prędkości podczas manewru	111
5.120	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - dryft 1 z 3 czujników prędkości podczas manewru	112
5.121	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - dryft 2 z 3 czujników położenia podczas manewru	113
5.122	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - dryft 2 z 3 czujników położenia podczas manewru	113
5.123	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 2 z 3 czujników położenia podczas manewru	114
5.124	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 2 z 3 czujników położenia podczas manewru	114
5.125	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - dryft 2 z 3 czujników położenia podczas manewru	114
5.126	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - dryft 2 z 3 czujników prędkości podczas manewru	115
5.127	Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - dryft 2 z 3 czujników prędkości podczas manewru	115
5.128	Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 2 z 3 czujników prędkości podczas manewru	115
5.129	Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 2 z 3 czujników prędkości podczas manewru	116



5.130	Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - dryft 2 z 3 czujników prędkości podczas manewru	116
5.131	Błąd średniokwadratowy $RMSE(k)$ zakłuceń wolnozmiennych w osi X_o - podczas manewru	117
5.132	Błąd średniokwadratowy $RMSE(k)$ siły zakłuceń wolnozmiennych w osi Y_o - podczas manewru	117
5.133	Błąd średniokwadratowy $RMSE(k)$ momentu zakłuceń wolnozmiennych w okół osi Z_o - podczas manewru	118
5.134	Błąd średniokwadratowy $RMSE(k)$ zakłuceń wolnozmiennych w osi X_o - podczas manewru	118
5.135	Błąd średniokwadratowy $RMSE(k)$ siły zakłuceń wolnozmiennych w osi Y_o - podczas manewru	119
5.136	Błąd średniokwadratowy $RMSE(k)$ momentu zakłuceń wolnozmiennych w okół osi Z_o - podczas manewru	119
6.1	Styczne i dynamiczne parametry sterowania	125
6.2	Położenie statku w osi X_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	126
6.3	Położenie statku w osi Y_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	126
6.4	Kurs ψ statku podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	127
6.5	Prędkość wzdłużna statku u podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	127
6.6	Prędkość poprzeczna statku v podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	127
6.7	Położenie statku w osi X_o podczas badania parametrów algorytmów sterowania w stanie ustalony, - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	129
6.8	Położenie statku w osi Y_o podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	129



6.9	Kurs statku ψ podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	129
6.10	Prędkość wzdłużna statku u podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	130
6.11	Prędkość poprzeczna v podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe	130
6.12	Położenie statku w osi X_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	131
6.13	Położenie statku w osi Y_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	131
6.14	Kurs statku ψ podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	132
6.15	Prędkość wzdłużna statku u podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	132
6.16	Prędkość poprzeczna statku v podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	132
6.17	Położenie statku w osi X_o podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	134
6.18	Położenie statku w osi Y_o podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	134
6.19	Kurs statku ψ podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	134



6.20	Prędkość wzdłużna statku u podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	135
6.21	Prędkość poprzeczna v podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	135
6.22	Położenie statku w osi X_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	136
6.23	Położenie statku w osi Y_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	137
6.24	Kurs statku ψ podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	137
6.25	Prędkość wzdłużna statku u podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	137
6.26	Prędkość poprzeczna statku v podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	138
6.27	Położenie statku w osi X_o podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	139
6.28	Położenie statku w osi Y_o podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	139



6.29	Kurs statku ψ podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	140
6.30	Prędkość wzdłużna statku u podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	140
6.31	prędkość poprzeczna statku v podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	140
6.32	Położenie statku w osi X_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	141
6.33	Położenie statku w osi Y_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	142
6.34	Kurs statku ψ podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	142
6.35	Prędkość wzdłużna statku u podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	142
6.36	Prędkość poprzeczna statku v podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	143
6.37	Położenie statku w osi X_o podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	144
6.38	Położenie statku w osi Y_o podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	144
6.39	Kurs statku ψ podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	145



6.40	Prędkość poprzeczna statku u podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	145
6.41	Prędkość wzdłużna statku v podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	145

Spis tabel

2.1	Zapis oznaczeń wykorzystywanych do opisu stopni swobody ruchu statku [83].	8
2.2	Współczynniki dla statku Northern Clipper	14
5.1	Konfiguracje czujników pomiarowych	55
5.2	Wartość uśredniona błędu średniokwadratowego estymacji dla manewru statku.	61
5.3	Wartość uśredniona błędu średniokwadratowego estymacji dla stabilizacji położenia i kursu statku.	64
5.4	Wartość uśredniona błędu średniokwadratowego estymacji podczas manewru z wykorzystaniem różnej złożoności modelu obiektu.	67
5.5	Wartość uśredniona błędu średniokwadratowego estymacji podczas manewru przy nadmiarowej konfiguracji czujników.	70
5.6	Wartość uśredniona błędu średniokwadratowego estymacji podczas stabilizacji przy nadmiarowej konfiguracji czujników.	72
5.7	Porównanie średniego błędu średniokwadratowego estymacji dla dwóch różnych konfiguracji czujników pomiarowych.	75
6.1	Parametry algorytmów sterowania	124
6.2	Statyczne i dynamiczne parametry algorytmu sterowania dla kryterium odpowiedzi skokowej (zmiana położenia z [0 m, 0 m, 0 rad] do [100 m, 100 m, 0.5 rad]) - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe.	128
6.3	Statyczne i dynamiczne parametry algorytmu sterowania dla kryterium odpowiedzi skokowej (zmiana położenia z [0 m, 0 m, 0 rad] do [100 m, 100 m, 0.5 rad]) - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe.	133
6.4	Statyczne parametry algorytmu sterowania podczas badania kryterium sterowania w stanie ustalonym - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	135
6.5	Statyczne i dynamiczne parametry algorytmu sterowania dla kryterium odpowiedzi skokowej (zmiana położenia z [0 m, 0 m, 0 rad] do [100 m, 100 m, 0.5 rad]) - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe.	138



6.6	Statyczne parametry algorytmu sterowania podczas badania kryterium sterowania w stanie ustalonym - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe	141
6.7	Statyczne i dynamiczne parametry algorytmu sterowania dla kryterium odpowiedzi skokowej (zmiana położenia z [0 m, 0 m , 0 rad] do [100 m, 100 m, 0.5 rad]) - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe.	143
6.8	Statyczne parametry algorytmu sterowania podczas badania kryterium sterowania w stanie ustalonym - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe	146

Spis algorytmów

1	Filtr Kalmana	24
2	Rozszerzony filtr Kalmana	25
3	Pasywny nieliniowy obserwator	27
4	Filtr cząsteczkowy	32
5	Kaskadowe połączenie filtra cząsteczkowego i rozszerzonego filtra Kalmana	34
6	Pasywny nieliniowy obserwator wykorzystywany w symulacjach	36
7	Schemat procedury fuzji danych	36

Lista symboli

- \mathbf{A}_D – macierz stanu w równaniach stanu dla wektora stanu \mathbf{x}_k^D ,
 \mathbf{A}_K – macierz stanu w równaniach stanu dla wektora stanu \mathbf{x}_k^K ,
 \mathbf{A}_k – macierz stanu uzyskana w procesie linearyzacji modelu $\mathbf{f}_{nl}(\mathbf{x}_{k-1}, \mathbf{v}_{k-1})$,
 \mathbf{B}_D – macierz wejść sterowania w równaniach stanu dla wektora stanu \mathbf{x}_k^D ,
 \mathbf{B}_K – macierz sterowania w modelu przestrzeni stanu, opisująca kinematyczne zależności modelu statku,
 \mathbf{b} – wektor reprezentujący wolnozmiennie zakłócenia środowiskowe,
 b – siła od zakłóceń środowiskowych dla modelu sprężyny z tłumieniem,
 $\mathbf{b}_{k|k}$ – wektor estymowanych zakłóceń wolnozmiennych dla chwili k ,
 $\mathbf{C}(\mathbf{v})$ – macierz Coriolisa zawierająca siły dośrodkowe,
 $\mathbf{C}_{RB}(\mathbf{v})$ – macierz Coriolisa opisująca siły dośrodkowe oddziałujące na bryłę sztywną,,
 $\mathbf{C}_A(\mathbf{v})$ – macierz Coriolisa opisującą siły dośrodkowe oddziałujące na masy dodane,
 \mathbf{C}_l – jest liniowa macierz wyjścia,
 $\mathbf{D}(\mathbf{v})$ – macierz związana z hydrodynamicznymi siłami tłumiącymi,
 \mathbf{D}_L – macierz uwzględniająca liniową część hydrodynamicznych sił tłumiących,
 $\mathbf{D}_{NL}(\mathbf{v})$ – macierz uwzględniająca nieliniową część hydrodynamicznych sił tłumiących,
 d – współczynnik tłumienia dla modelu sprężyny z tłumieniem,
 \mathbf{F}_l – liniowa macierz stanu,
 \mathbf{F}_c – funkcja celu w sterowaniu predykcyjnym,
 $\mathbf{f}_{nl}(\mathbf{x}_{k-1}, \mathbf{v}_{k-1})$ – wektor nieliniowych funkcji opisująca przejście pomiędzy stanem w chwili $k-1$ do k z wykorzystaniem wektora stanu \mathbf{x}_{k-1} i szumu procesu \mathbf{v}_{k-1} ,
 \mathbf{H}_k – macierz wyjścia uzyskana w procesie linearyzacji modelu $\mathbf{h}_{nl}(\mathbf{x}_k, \mathbf{n}_k)$,
 $\mathbf{h}_{nl}(\mathbf{x}_k, \mathbf{n}_k)$ – wektor nieliniowych funkcji opisująca model pomiaru w chwili k z wykorzystaniem wektora stanu \mathbf{x}_k i szumu pomiarowego \mathbf{n}_k ,
 $h_m(s)$ – filtr dolnoprzepustowy w pętli sprzężenia zwrotnego przyspieszenia,
 \mathbf{I} – macierz jednostkowa,
 \mathbf{I}_K – wektor innowacji w filtrze Kalmana,
 I_z – moment bezwładności w osi Z_b ,
 K – moment obrotowy wokół osi wzdluznej X_b ,
 K_d – wzmacnienie członu różniczkującego regulatora PID,
 K_i – wzmacnienie członu całkującego regulatora PID,
 \mathbf{K}_k – macierz wzmacnień Kalmana,
 K_m – wzmacnienie w pętli sprzężenia zwrotnego przyspieszenia w regulatorze PID,
 K_p – wzmacnienie członu proporcjonalnego regulatora PID,



- k – wzmocnienie sprzężenia zwrotnego dla modelu sprężyny z tłumieniem,
 k – dyskretna chwila czasu,
 $\mathbf{k}_1, \mathbf{k}_2, \mathbf{k}_2$ – wzmocnienia nieliniowego obserwatora,
 M – moment obrotowy wokół osi poprzecznej Y_b ,
 \mathbf{M} – macierz bezwładności statku,
 \mathbf{M}_A – macierzą hydrodynamicznych współczynników masy dodanej i wody tworzącej,
 \mathbf{M}_{RB} – macierz bezwładności bryły sztywnej,
 m – masa statku,
 m – współczynnik bezwładności dla modelu sprężyny z tłumieniem,
 $m_{k|k}$ – estymowana wartość oczekiwana dla chwili k
 $m_{k|k-1}$ – predykcja wartość oczekiwana dla chwili k
 $m_{k-1|k-1}$ – estymowana wartość oczekiwana dla chwili $k - 1$
 N – moment obrotowy wokół osi pionowej Z_b ,
 $\mathbf{N}(U_o)$ – macierz reprezentująca sumę sił Coriolisa i tłumienia zależna od prędkości wypadkowej statku,
 $\mathcal{N}(x, m, P)$ – rozkład gaussowski o argumentach x , wartości średniej m , kowariancji P ,
 N_c – liczba nadmiarowych czujników.
 N_k – liczba chwil czasowych w jednej symulacji.
 N_s – liczba cząstek (próbek losowych) przypadających na jedną chwilę czasową w filtrze cząsteczkowym,
 \mathbf{n}_k – wektor szumu procesu opisanym przez kowariancję modelu (\mathbf{R}_K),
 \mathbf{n}_{pom} – wektorem szumu pomiaru/ niepewność pomiarowa,
 $\mathbf{P}_{k|k}$ – estymowana macierz kowariancji stanu dla chwili k ,
 $\mathbf{P}_{k|k-1}$ – predykcja macierz kowariancji stanu dla chwili k ,
 p – prędkość kątowna statku wokół osi X_b ,
 $p(x_k|y_{1:k})$ – funkcja rozkładu prawdopodobieństwa a posteriori czyli rozkładu prawdopodobieństwa wystąpienia stanu x_k przy zbiorze pomiarów $y_{1:k}$,
 $p(x_k|y_k)$ – funkcja rozkładu prawdopodobieństwa a posteriori czyli rozkładu prawdopodobieństwa wystąpienia stanu x_k przy pomiarze y_k ,
 $p(x_k|y_{1:k-1})$ – funkcja rozkładu prawdopodobieństwa a priori czyli wystąpienia stanu x_k przy zbiorze pomiarów $y_{1:k-1}$,
 $p(x_k|x_{0:k-1})$ – funkcja rozkładu prawdopodobieństwa dołączenia stanu x_k do zbioru stanów $x_{0:k-1}$,
 $p(x_k|x_{k-1})$ – funkcja rozkładu prawdopodobieństwa przejścia stanu x_{k-1} do stanu x_k ,
 $p(y_k|x_k)$ – funkcja rozkładu prawdopodobieństwa otrzymania pomiaru y_k dla stanu x_k ,
 $p(y_k|y_{1:k-1})$ – funkcja rozkładu prawdopodobieństwa otrzymania pomiaru y_k dla serii pomiarów $y_{1:k-1}$,
 $p(x_0)$ – początkowy rozkład prawdopodobieństwa a posteriori,
 $p(y_k|x_{0:k}, y_{1:k-1})$ – rozkład prawdopodobieństwa wystąpienia pomiaru y_k dla zbioru stanów $x_{0:k}$ i zbioru pomiarów $y_{1:k-1}$,
 $p(x_{0:k}|y_{1:k-1})$ – rozkład prawdopodobieństwa zbioru stanów $x_{0:k}$ przy zbiorze pomiarów równym $y_{1:k-1}$,



$p(y_k|y_{1:k-1})$ – rozkład prawdopodobieństwa wystąpienia pomiaru y_k dla zbioru pomiarów y_{k-1} .

\mathbf{Q}_K – macierz kowariancja niepewności modelu stanu,

\mathbf{Q}_{MPC} – macierz wag w funkcji celu,

q – prędkość kątowna statku wokół osi Y_b ,

$\mathbf{R}(\psi)$ – macierz rotacji zależna od kursu statku,

\mathbf{R}_K – macierz kowariancji niepewności modelu pomiaru,

\mathbf{R}_{MPC} – macierz wag w funkcji celu,

r – prędkość kątowna statku wokół osi Z_b ,

\mathbf{S}_K – macierz kowariancji innowacji,

T_c – horyzont sterowania,

T_p – horyzont predykcji,

Δt – przyrost czasu pomiędzy kolejnymi chwilami k ,

U_o – prędkość wypadkowa statku w układzie 2D.

u – prędkość statku wzdłuż osi X_b ,

u_s – wektor sterowania,

$\bar{\mathbf{u}}_k$ – zbiór kolejnych wektorów sterowań w funkcji celu,

\mathbf{v} – wektor prędkości dla układu związanego ze statkiem,

$\mathbf{v}_{k|k}$ – wektor estymowanych prędkości dla układu związanego ze statkiem dla chwili k

v – prędkość statku wzdłuż osi Y_b ,

\mathbf{v}_k – wektor szumu modelu opisanym przez kowariancję modelu (\mathbf{Q}_K),

\mathbf{v}_{pro} – szum procesu/niepewność modelu procesu,

w – prędkość statku wzdłuż osi Z_b ,

\mathbf{w}_b – wektor zmiennych losowych o rozkładzie normalnym,

\mathbf{w}_s – wektor sił zakłóceń środowiskowych,

w_k^i – waga i -tej cząstki filtru cząsteczkowego,

\tilde{w}_k^i – znormalizowana waga i -tej cząstki filtru cząsteczkowego,

X – siła działająca wzdłuż statku skierowana na dziób,

X_b – oś wzdłużna statku, skierowana na dziób,

X_o – oś określająca kierunek północ/południe,

\mathcal{X} – macierz punktów sigma z przypisanymi im wagami $\{\mathcal{X}_i, \mathcal{W}_i\}$,

x_G – odległość punktu środka ciężkości statku od punktu GC,

x_o – położenie statku w osi X_o ,

\mathbf{x} – wektor stanu,

x – stan obiektu,

\mathbf{x}_k^D – wektor stanu statku dla chwili k składający się z $[\boldsymbol{\eta}_k, \mathbf{b}_k, \dot{\boldsymbol{\eta}}_k, \dot{\mathbf{b}}_k]^T$,

\mathbf{x}_k^K – wektor stanu statku składający się z $[\boldsymbol{\eta}, \dot{\boldsymbol{\eta}}, \ddot{\boldsymbol{\eta}}]^T$,

\mathbf{x}_k – dyskretny wektor stanu dla chwili k ,

$x_{0:k-1}$ – zbiór stanów obiektu do chwili $k-1$,

$x_{0:k}$ – zbiór stanów obiektu do chwili k ,

x_k – stan obiektu w chwili k ,

$\mathbf{x}_{k|k-1}$ – predykcja wektora stanu,

$\mathbf{x}_{k|k}$ – estymowana wartość wektora stanu,

$\mathbf{x}_{0:k}$ – zbiór estymowanych stanów do chwili k ,

$\mathbf{x}_{0:k}^i$ – i -ta cząstka/próbka zawierająca wektora stanu w filtru cząsteczkowego,



- $\bar{\mathbf{x}}_k$ – zbiór kolejnych wektorów stanów w funkcji celu,
 Y – siłą działającą w poprzek statku skierowana na prawą burtę,
 Y_b – oś poprzeczna statku skierowana na prawą burtę,
 Y_o – oś określające kierunek wschód/zachód,
 y_o – położenie statku w osi Y_o ,
 \mathbf{y}_k – wektor pomiaru z czujników dla chwili k ,
 $y_{1:k-1}$ – zbiór pomiarów do chwili $k-1$,
 $y_{1:k}$ – zbiór pomiarów do chwili k ,
 y_k – pomiar w chwili k ,
 y_k^i – pomiar z i -tego czujnika pomiarowego
 $\tilde{\mathbf{y}}_k$ – różnica pomiędzy pomiarem a wartością estymowaną,
 $\mathbf{y}(\mathbf{x}_k^D)$ – wektor funkcji wyjścia dla wektora stanu \mathbf{x}_k^D ,
 $\mathbf{y}(\mathbf{x}_k^K)$ – wektor funkcji wyjścia dla wektora stanu \mathbf{x}_k^K ,
 Z – siła działająca wzdłuż pionowej osi statku skierowana do dołu,
 Z_b – oś pionowa skierowana do centrum Ziemi,
 Z_o – oś określające wysokość,
 z – wektor wyjściowy,
 z_k – wektor pomiaru dla chwili k obliczonym z wykorzystaniem modelu \mathbf{h}_{nl} ,
 z_D – wektor pomiarowym dla stanu \mathbf{x}_D ,
 z_K – wektor pomiarowym dla stanu \mathbf{x}_K ,
 z_o – położenie statku w osi Z_o ,
 $z(k)$ – dyskretny wektor wyjścia dla chwili k ,
 z_k – jest obliczoną wartością pomiaru,
 z_k – wektor pomiarów z m nadmiarowych czujników,
 z_k^i – pomiar z pojedynczego czujnika,
 ψ – miara orientacji statku wokół Z_o (kurs),
 $\boldsymbol{\eta}$ – wektor opisujący położenie i kurs statku,
 $\tilde{\boldsymbol{\eta}}$ – uchyb sterowania,
 $\boldsymbol{\eta}_d$ – zadany wektor stanu,
 $\boldsymbol{\eta}_{k|k}$ – wektor estymowanego dla chwili k ,
 $\boldsymbol{\tau}$ – wektor sił X , Y i momentu N ,
 $\boldsymbol{\tau}_c$ – siły wytworzone przez napędy i stery statku,
 $\boldsymbol{\tau}_{PID}$ – wektor sił obliczonych przez regulator PID,
 $\boldsymbol{\gamma}(\mathbf{x}_k^D)$ – wektor funkcji wyjścia dla wektora stanu \mathbf{x}_k^D ,
 $\boldsymbol{\gamma}(\mathbf{x}_k^K)$ – wektor funkcji wyjścia dla wektora stanu \mathbf{x}_k^K ,
 $\boldsymbol{\Omega}$ – macierz opisującą amplitudę zakłóceń środowiskowych,
 $\lambda(\mathbf{x}_k, \mathbf{u}_k)$ – funkcja kary za przekroczenie ograniczeń w sterowaniu predykcyjnym,
 $x_k \sim q(x_{0:k-1} | y_{1:k-1})$ – oznacza wylosowanie stanu x_k z rozkładu prawdopodobieństwa $q(x_{0:k-1} | y_{1:k-1})$,



Rozdział 1

Wstęp

Statki od zawsze odgrywały istotną rolę w historii ludzkości jako środek transportu. Nie jest znany dokładny czas, w którym człowiek po raz pierwszy skonstruował łódź czy statek, ale transport morski stanowił znaczący element zmian politycznych, odkryć geograficznych i handlu. Sterowanie i nawigacja statkiem od zawsze były skomplikowanymi i złożonymi zadaniami. Podróże morskie i oceaniczne wymagały precyzyjnego planowania tras. Mapy oraz przyrządy pomiarowe umożliwiające określenie położenia statku były jego podstawowym wyposażeniem. Ważną umiejętnością gwarantującą dotarcie do planowanego miejsca było utrzymywanie statku na z góry założonym kursie. Koncepcja automatycznego sterowania kursem statku powstała na początku XX wieku. System wykorzystywany do automatycznego utrzymania zadanego kursu statku nazwano autopilotem. Powstanie autopilota na początku XX wieku było możliwe dzięki wykorzystaniu żyrokompasu. Urządzenie to wskazuje kurs statku, dostarczając informację do układu regulacji. Pierwszym żyrokompasem, w który został wyposażony statek, był *north-seeking gyrocompass*. W 1911 roku Elmer Sperry opatentował kompas balistyczny z tłumieniem pionowym oraz zaprojektował pierwszy mechanizm do automatycznego sterowania kursem statku, który nazwał Metal Mike [1], [5]. Następny ważny krok w sterowaniu statkiem poczynił Nicolas Minorsky, opracowując na podstawie obserwacji sterników matematyczne reguły sterowania proporcjonalno-całkująco-różniczkującego [65], które obecnie noszą nazwę regulatora PID (ang. *proportional-integral-derivative*). W kolejnych latach sterowanie PID zostało zastąpione przez sterowanie LQG (ang. *linear-quadratic-gaussian*), H_∞ oraz metody *backstepping*, zaprezentowane w pracach [15], [23], [55], [70], [99], [100]. Systemy do automatycznego utrzymywania kursu statku były pierwszym krokiem do precyzyjnego sterowania pozycją i kursem statku, których rozwój związany był z morskim przemysłem wydobywczym.

Na początku XIX wieku pod dnem Morza Kaspijskiego odkryto złoża ropy naftowej. Próby wydobywania znalezionych złóż dały początek morskiemu przemysłowi wydobywczemu. Wydobywanie złóż z dna morskiego wymagało rozwiązania problemów technicznych, co w znacznym stopniu przyczyniło się do rozwoju technologii na statkach. Morski przemysł wydobywczy zagwarantował finansowanie badań umożliwiających powstanie systemów i technologii pozycjonowania platform do wydobywania ropy. Początkowe rozwiązania umożliwiały eksploatację złóż znajdujących się na niewielkich głębokościach, do 600 m. Głównym ograniczeniem były możliwości kotwiczenia jednostki na większych głębokościach. W celu pokonania ograniczeń wcześniejszych technologii opracowano system umożliwiający utrzymanie jednostki morskiej w stałym położeniu poprzez wykorzystanie zainstalowanych na niej sterów i napędów.



1. Wstęp

Pierwszym statkiem, który utrzymywał pozycję i kurs za pomocą napędów i sterów, był „CUSS 1”. Statek ten był pierwowzorem dla wszystkich jednostek z systemem dynamicznego pozycjonowania (DP, ang. *dynamic positioning*) [23], [66]. Podstawowym zadaniem „CUSS 1” było prowadzenie odwiertów w dnie morskim. W celu utrzymania statku w zadanym położeniu w czasie odwiertu, system wykorzystywał wyłącznie siły wytwarzane przez napędy i stery statku. Pomimo wykorzystania istniejącej technologii statek „CUSS 1” nie spełniałby wymagań jednostki DP na podstawie obecnie obowiązujących przepisów, np. PRS (Polski Rejestr Statków) [74]. Za sterowanie statkiem „CUSS 1” odpowiedzialny był operator. Mała moc obliczeniowa systemu oraz ograniczenia ówczesnych algorytmów sterowania uniemożliwiały stworzenie w pełni automatycznego systemu pozycjonowania. Doświadczenia, które udało się zdobyć w czasie eksploatacji „CUSS 1”, zainicjowały powstanie pierwszych systemów DP.

Podstawowym zadaniem systemu dynamicznego pozycjonowania jest stabilizacja pozycji i kierunku ustawienia dziobu statku w czasie wykonywania zadania pozycjonowania lub sterowania po trajektorii z ograniczoną prędkością statku do około 2 m/s [23]. Do głównych problemów związanych z systemem dynamicznego pozycjonowania należy zaliczyć:

- fuzję danych (ang. *data fusion*),
- kompensację zakłóceń środowiskowych od wiatru, fali i prądów morskich,
- alokację sił naporu.

Fuzja danych w systemie dynamicznego pozycjonowania jest bardzo złożonym procesem, który odpowiedzialny jest za kilka zadań. Jednym z podstawowych jest zbieranie i archiwizowanie informacji pomiarowych z podsystemów statku. Kolejnym zadaniem jest wykorzystanie pomiarów, modeli systemów i obiektów do procesu estymacji parametrów podsystemów statku. Diagnostyka podsystemów statku również należy do zadań systemu fuzji danych. Dodatkowym utrudnieniem we współczesnych systemach DP jest występowanie nadmiarowych systemów pomiarowych. Mnogość problemów związanych z systemem DP spowodowała, że nadal prowadzone są prace nad usprawnieniem jego działania.

W latach 70. XX wieku do sterowania statkiem wykorzystano wielomodalne regulatory PID [21]. Pozycjonowanie statku odbywało się w trzech stopniach swobody: osi wzdłużnej, poprzecznej oraz po kursie. Do sterowania każdego z nich wykorzystywano niezależny regulator PID, co można uznać za początek systemu dynamicznego pozycjonowania.

W 1963 roku Kalman wraz ze współautorami opublikował koncepcję algorytmu sterowania z wykorzystaniem liniowego optymalnego regulatora kwadratowego (LQR, ang. *linear-quadratic regulator*) oraz filtra Kalmana. Nowe metody po rozpowszechnieniu i walidacji w latach 70. i 80. dawały możliwość rozwiązywania dotychczas występujących problemów związanych głównie z estymacją zakłóceń środowiskowych. Sterowanie LQR było alternatywą dla regulatora PID, natomiast filtr Kalmana umożliwiał estymację wolnozmiennych



zakłóceń środowiskowych. Regulator LQR dla systemu DP został zaprojektowany i zaimplementowany przez Balchena, Jenssena i Sælida [3],[4], oraz Grimble'a, Pattona i Wise'a [31], [34]. Algorytmy LQR i filtru Kalmana w kolejnych latach były rozwijane, będąc inspiracją dla wielu systemów dynamicznego pozycjonowania [4], [23], [25], [29], [32], [47], [51], [53], [63], [71], [79], [85], [95], [101].

Grimble w pracy z 1986 roku do sterowania statkiem DP zaproponował sterowanie H_∞ [32]. W 1997 roku Katebi zmodyfikował zaproponowane wcześniejsze metody H_∞ , dodając do modelu statku nieliniową dynamikę steru i poprawiając wyniki działania algorytmów [51].

Alternatywną drogą rozwoju algorytmów systemu dynamicznego pozycjonowania były prace Fossena i współautorów, którym udało się opracować nieliniowy regulator PID (NPID, ang. nonlinear proportional-integral-derivative controller), nieliniowy pasywny obserwator (NO, ang. *nonlinear observer*) oraz obserwator backstepping dla systemu dynamicznego pozycjonowania [27], [88], [89]. Zastosowanie nieliniowego obserwatora do adaptacyjnej filtracji fali pozwoliło na zredukowanie złożoności oprogramowania i uproszczeń w linearyzacji modelu, poprawiając jakość estymacji. Kolejne badania były nakierowane na metody sterowania dla statków niedosterowanych (ang. *underactuated*) [72], [73].

Równoległe do wcześniej przytaczanych badań pracowano nad innymi algorytmami do sterowania jednostkami DP. Stephens, Burnham i Reve w 1995 roku zaproponowali wykorzystanie logiki rozmytej (ang. *fuzzy logic*) [87]. Zespół Tannuri, Agostinho i Morsshita zaproponował natomiast użycie nieliniowego sterowania ślizgowego (ang. *nonlinear sliding mode control*) [94]. W 2007 roku Volodovov wraz ze współpracownikami przedstawił pracę dotyczącą sterowania statkiem podwodnym z wykorzystaniem metody Lapunowa [102].

Rozwój technologii i algorytmów umożliwił zastosowanie systemu DP na innych obiektach morskich: pogłębiarkach, statkach dostawczych, platformach wiertniczych, statkach do układania rurociągów i kabli oraz statkach badawczych. Wykorzystywanie systemu DP do większej ilości zadań zwiększyło zainteresowanie pracami i publikacjami dotyczącymi statków DP przedstawiającymi rozwiązania modernizacji i adaptacji już istniejących jednostek. Kolejnym naturalnym rozwinięciem dla systemu DP było zastosowanie dotychczasowych metod dla sześciu stopni swobody w statkach podwodnych. W 2000 roku Sørensen i Strand opublikowali badania nad sterowaniem statkiem podwodnym o małej wielkości z uwzględnieniem tłumienia przechyłu i pochylenia [93].

W celu optymalizacji pracy statków DP wykorzystywanych do wierceń głębokowodnych zespół w składzie Sørensen, Leira, Strand i Larsen analizowali wybór optymalnego umiejscowienia statku względem punktu odwiertu. Rozwinięciem prac nad optymalnym wyborem punktu docelowego było wykorzystanie strukturalnej niezawodności pionów wiertniczych poprzez włączenie modelowania dynamiki rur do naprowadzania systemu DP [46].

Dla zwiększenia możliwości systemu DP ważne okazały się badania związane z optymalizacją położenia i kursu statku w zależności od warunków atmosferycznych, przeprowadzone przez Fossena i Stranda. Wpłynęły one na zwiększenie



1. Wstęp

zakresu warunków atmosferycznych, przy których możliwe jest wykorzystanie statku DP, a także na zmniejszenie zużycia paliwa [26].

Inna metoda wykorzystywana do dynamicznego pozycjonowania polegała na zastosowaniu teorii sterowania hybrydowego, przedstawionej przez Hespanhę, Morse'a i Liberzona [38], [39], [40]. Sterowanie to wykorzystuje system przełączających się regulatorów, projektowanych dla różnych modeli statku.

Zespoły naukowe cały czas pracowały nad usprawnieniem już wykorzystywanych algorytmów filtracji i sterowania. Zespół badawczy Sørensen, Strand i Nyberg zaproponował natomiast pasywny nieliniowy obserwator bez filtrowania częstotliwości falowania dla regulatora PID [84], [90]. W 2003 roku firma Lindegaard uwzględniła w sterowaniu sprzężenie zwrotne od przyspieszenia [57]. Wykorzystanie proponowanych algorytmów umożliwiło sterowanie statkiem przy wysokim poziomie zakłóceń środowiskowych. Inną koncepcją mającą na celu zwiększenie możliwości operacyjnych systemu DP było sterowanie przełączane z nadzorem [92]. Wybiera ono najlepszy regulator z dostępnej puli regulatorów w zależności od warunków atmosferycznych i realizowanego zadania [68], [69]. Sterowanie to adaptuje się do warunków atmosferycznych, zwiększając wydajność i zmniejszając czas pracy potrzebny do realizacji zadania przy długotrwałych projektach związanych z pracami podwodnymi.

Blanke, Kinnaert, Lunze i Staroswiecki zajęli się z kolei tematem analizy tolerancji błędów, umożliwiając projektowanie architektury sterowania łączące dyskretne zdarzenia i ciągle sterowanie [7]. Ważnym elementem systemu DP jest diagnostyka i sterowanie w sytuacjach awaryjnych umożliwiające bezpieczne wyłączenie systemu. Badania w tym obszarze prowadzili Blanke, Nguyen, Sorsena i Fang [7], [67]. Właściwe testowanie i weryfikacja mają kluczowe znaczenie dla bezpieczeństwa i rentowności systemu dynamicznego pozycjonowania. Niezawodność i bezpieczeństwo systemów nadmiarowych jednostki DP są tematem kilku późniejszych publikacji napisanych przez Morschita, Corneta, Tannuriego, Bravina i Saada [48], [49].

Wyżej zaprezentowane metody nadal stanowią inspirację dla wielu zespołów badawczych analizujących alternatywne drogi rozwoju systemu DP. W ich publikacjach rozważane są następujące zagadnienia: sterowanie H_∞ [37], sterowanie backstepping, [107], [108], sterowanie rozmyte, [11], [41], [104], [109], sterowanie z wykorzystaniem sieci neuronowej [59], sterowanie hybrydowe [64], [97], [98], [104], oraz bezśladowy filtr Kalmana [54], [58], [80].

Innym rozwijanym kierunkiem w sterowaniu statkiem z systemem dynamicznego pozycjonowania jest zastosowanie algorytmu sterowania predykcyjnego (MPC, ang. *model predictive control*) [20], [45], [105] i filtru cząsteczkowego (PF, ang. *particle filter*) [77]. Sterowanie predykcyjne wymaga rozwiązania zadania minimalizacji funkcji celu, które dla nieliniowych obiektów takich jak statek jest czasochłonne. Dopiero obecny rozwój technologii umożliwia rozwiązywanie zadań o tak dużej złożoności obliczeniowej w czasie umożliwiającym sterowanie statkiem. Szczegółowe opisy dotyczące sterowania i filtracji można znaleźć w pracach [8], [22], [24], [43], [81], [91].

Na podstawie badań stwierdzono, że jakość estymacji ma kluczowe znaczenie dla dokładności sterowania. Istniejące prace naukowe związane ze systemem



DP w większości przypadków nie rozpatrują problemu syntezy algorytmów sterowania i fuzji danych z systemów o strukturze nadmiarowej. Kolejnym aspektem dotyczącym algorytmów fuzji danych dla systemów DP jest problem wpływu uszkodzenia układów pomiarowych na jakość estymacji. Z wyżej wymienionych powodów w pracy zwrócono szczególną uwagę na fuzję danych z systemów pomiarowych o strukturze nadmiarowej oraz estymację parametrów w czasie pracy normalnej i w sytuacjach awaryjnych. Zastosowanie kaskadowego połączenia filtra cząsteczkowego przedstawionego w pracy wykazuje wysoki poziom jakości estymacji oraz odporność algorytmu na scenariusze awaryjne.

Kolejnym problemem rozwiązywanym w pracy jest sterowanie predykcyjne z wykorzystaniem nieliniowego modelu obiektu. Stworzenie odpowiedniej funkcji celu w sterowaniu predykcyjnym umożliwi reaktywne sterowanie obiektem, wykazując lepsze własności dynamiczne i statyczne sterowania.

1.1 Cel i teza pracy

Z wyżej zaprezentowanej literatury wynika, że podjęto już szereg prób zaimplementowania algorytmu sterowania predykcyjnego dla statków DP. W przypadku statku konieczne jest wykorzystanie algorytmu z nieliniowym modelem obiektu. W pracy zaimplementowano metodę ograniczającą złożoność funkcji celu, jednocześnie uzależniono jej współczynniki od wektora stanu statku. Zmniejszenie złożoności obliczeniowej funkcji celu skróciło czas obliczeń w procesie optymalizacji i rozwiązywania zadania.

Proponowany system fuzji danych i sterowanie dedykowane są dla obiektów z nadmiarowością strukturalną systemów pomiarowych oraz umożliwiają diagnostykę działania tych systemów. Nowym rozwiązaniem proponowanym w pracy jest połączenie kaskadowo filtra cząsteczkowego i filtra Kalmana w systemie fuzji danych oraz synteza tego algorytmu ze sterowaniem predykcyjnym.

Celem pracy było zaprojektowanie systemu dynamicznego pozycjonowania, gdzie do sterowania zastosowano regulator predykcyjny z nieliniowym modelem obiektu a do estymacji wektora stanu algorytm fuzji danych z kaskadowym połączeniem filtra cząsteczkowego i rozszerzonego filtra Kalmana. Zaprojektowany system uwzględniał nadmiarowość strukturalną systemów pomiarowych, co pozwoliło na uzyskanie wysokiej dokładności estymacji wektora stanu, szczególnie w scenariuszach awaryjnych.

W pracy zostały opracowane następujące zagadnienia:

- fuzja danych z nadmiarowością strukturalną systemów pomiarowych, wykorzystująca filtr cząsteczkowy i rozszerzony filtr Kalmana;
- sterowanie predykcyjne z wykorzystaniem nieliniowego modelu statku.

W pracy zostały postawione dwie tezy:

- Zastosowanie sterowania predykcyjnego z systemem fuzji danych w układach dynamicznego pozycjonowania statkiem pozwoli na zwiększenie jakości sterowania i zmniejszenie wpływu uszkodzeń systemów pomiarowych



1. Wstęp

na jakość wykonywanych przez statek zadań, przez co zwiększy się bezpieczeństwo na morzu.

- Zastosowanie kaskadowo połączonych filtru cząsteczkowego i rozszerzonego filtru Kalmana umożliwi estymację wolnozmiennych zakłóceń środowiskowych oraz zmniejszenie błędu estymacji położenia, prędkości i kursu statku.


1.2 Układ pracy

Pracę podzielono na sześć rozdziałów. Po wstępie, w drugim rozdziale pracy został opisany matematyczny model statku z uwzględnieniem jego kinematyki i dynamiki. Trzeci rozdział poświęcono fuzji danych, podziałowi systemów fuzji danych oraz algorytmom wykorzystywanym do fuzji danych opisywanych w literaturze. Kolejny rozdział dotyczy zagadnień sterowania statkiem z systemem dynamicznego pozycjonowania. Badania symulacyjne zostały przedstawione w rozdziale piątym. Z kolei w rozdziale szóstym podsumowano wyniki badań.

Rozdział 2

Model matematyczny statku

W poniższym rozdziale zaprezentowano matematyczny model statku, który można podzielić na kinematykę opisującą położenie statku oraz dynamikę opisującą wpływ napędów, sterów i zakłóceń środowiskowych na położenie statku. Statek poruszający się po powierzchni morza czy oceanu jest obiektem mającym 6 stopni swobody ruchu (rys. 2.1).



Rys. 2.1: Ruchy statku o 6 stopniach swobody

gdzie:

- X_b - oś wzdłużna statku,
- Y_b - oś poprzeczna statku,
- Z_b - oś pionowa skierowana do centrum Ziemi,
- u - prędkość statku wzdłuż osi X_b ,
- v - prędkość statku wzdłuż osi Y_b ,
- w - prędkość statku wzdłuż osi Z_b ,
- p - prędkość kątowna wokół osi X_b ,
- q - prędkość kątowna wokół osi Y_b ,



2. Model matematyczny statku

- r - prędkość kątowna wokół osi Z_b .

Każdy ze stopni swobody odpowiada za przemieszczenie lub rotację względem osi współrzędnych związanych ze statkiem (tabela 2.1). Do opisu sił i momentów w pracy wykorzystano notację SNAME, zgodnie z tabelą 2.1. Dokładny opis modelu matematycznego został zawarty w następujących publikacjach [14], [23], [24].

Tabela 2.1: Zapis oznaczeń wykorzystywanych do opisu stopni swobody ruchu statku [83].

Lp.		Siły i momenty wymuszające	Prędkość liniowa i kątowna
1	Wzdłuż osi X_b	X	u
2	Wzdłuż osi Y_b	Y	v
3	Wzdłuż osi Z_b	Z	w
4	Obrót wokół osi X_b	K	p
5	Obrót wokół osi Y_b	M	q
6	Obrót wokół osi Z_b	N	r


gdzie:

- X - siła działająca wzdłuż osi X_b ,
- Y - siła działająca wzdłuż osi Y_b ,
- Z - siła działająca wzdłuż osi Z_b ,
- K - moment siły względem osi X_b ,
- M - moment siły względem osi Y_b ,
- N - moment siły względem osi Z_b .

Do opisu statku z systemem dynamicznego pozycjonowania wykorzystywany jest uproszczony model statku [23]. Uwzględniane są w nim tylko trzy stopnie swobody ruchu (rys. 2.2):

- ruch liniowy wzdłuż osi X_b , wzdłużny (ang. *surge*),
- ruch liniowy wzdłuż osi Y_b , poprzeczny (ang. *sway*),
- ruch kątowy wokół osi Z_b , myszkowanie (ang. *yaw*).






Rys. 2.2: Stopnie swobody uwzględnione w systemie dynamicznego pozycjonowania

Przyjmuje się, że dla statku DP poruszającego się po powierzchni wody przy stałym zanurzeniu dopuszczalne jest pominięcie (rys. 2.3) [23]:

- ruchu liniowego wzdłuż osi Z_b , nurzanie (ang. *heave*),
- ruchu kąтового wokół osi X_b , kołysanie (ang. *roll*),
- ruchu kąтового wokół osi Y_b , kiwanie (ang. *pitch*),



Rys. 2.3: Stopnie swobody pomijane w systemie dynamicznego pozycjonowania


gdzie + i – na rys. 2.2 i rys. 2.3 oznaczają dodatni i ujemny kierunek działania sił i momentów.

W kolejnych podrozdziałach przedstawiono opis modelu kinematyki i dynamiki statku wykorzystanego do fuzji danych i sterowania statkiem.



2.1 Kinematyka

Podstawowym aspektem przy opisie ruchu obiektu jest określenie układów współrzędnych, w których będzie on się poruszał i relacji pomiędzy nimi. W pracy do matematycznego opisu modelu statku wykorzystano układ NED (ang. *north-east-down*) oraz układ współrzędnych związany ze statkiem, którego początek znajduje się w centrum grawitacji statku (GC) (rys. 2.4).



Rys. 2.4: Układy współrzędnych stosowane do opisu matematycznego modelu statku

Dla prezentowanych układów współrzędnych przyjęto dwa wektory: pierwszy $\eta = [x_o, y_o, \psi]^T$ określający położenie x_o, y_o oraz kurs statku ψ , drugi $v = [u, v, r]^T$ określający prędkości liniowe wzdłużną u , poprzeczną v i prędkość kątową r [24].

Prędkości w nieruchomym układzie współrzędnych $[X_o, Y_o]$ są powiązane z prędkościami układu $[X_b, Y_b]$ za pomocą macierzy rotacji $\mathbf{R}(\psi)$:

$$\dot{\eta} = \mathbf{R}(\psi)v, \quad (2.1)$$

gdzie:

$$\mathbf{R}(\psi) = \begin{bmatrix} \cos(\psi) & -\sin(\psi) & 0 \\ \sin(\psi) & \cos(\psi) & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (2.2)$$

2.2 Dynamika

Równania opisujące zależności pomiędzy momentami i siłami oddziałującymi na statek zostały podzielone na dynamikę bryły sztywnej oraz siły i momenty hydrodynamiczne. Dynamika bryły sztywnej dotyczyć będzie opisu kadłuba statku



jako poruszającej się bryły sztywnej w cieczy. Siły i momenty hydrodynamiczne opisują oddziaływanie wody na bryłę sztywną.

W poniższym rozdziale przedstawiono model dynamiki statku dla trzech stopni swobody, którego dokładny opis został zaprezentowany w [23],[24]. Równanie ogólne dynamiki statku przedstawia zależność:

$$\mathbf{M}\dot{\mathbf{v}} + \mathbf{C}(\mathbf{v})\mathbf{v} + \mathbf{D}(\mathbf{v})\mathbf{v} = \boldsymbol{\tau}, \quad (2.3)$$

$$\mathbf{M} = \mathbf{M}_{RB} + \mathbf{M}_A, \quad (2.4)$$

$$\mathbf{C}(\mathbf{v}) = \mathbf{C}_{RB}(\mathbf{v}) + \mathbf{C}_A(\mathbf{v}), \quad (2.5)$$

$$\mathbf{D}(\mathbf{v}) = \mathbf{D}_L + \mathbf{D}_{NL}(\mathbf{v}), \quad (2.6)$$

gdzie:

- \mathbf{M} jest macierzą bezwładności statku,
- \mathbf{M}_{RB} jest macierzą bezwładności bryły sztywnej,
- \mathbf{M}_A jest macierzą hydrodynamicznych współczynników masy dodanej i wody tworzącej,
- $\mathbf{C}(\mathbf{v})$ jest macierzą Coriolisa i zawierającą siły dośrodkowe,
- $\mathbf{C}_{RB}(\mathbf{v})$ jest macierzą Coriolisa opisującą siły dośrodkowe oddziałujące na bryłę sztywną,
- $\mathbf{C}_A(\mathbf{v})$ jest macierzą Coriolisa opisującą siły dośrodkowe oddziałujące na masy dodane,
- $\mathbf{D}(\mathbf{v})$ jest macierzą związaną z hydrodynamicznymi siłami tłumiącymi,
- \mathbf{D}_L jest macierzą uwzględniającą liniową część hydrodynamicznych sił tłumiących,
- $\mathbf{D}_{NL}(\mathbf{v})$ jest macierzą uwzględniającą nieliniową część hydrodynamicznych sił tłumiących,
- $\boldsymbol{\tau}$ - jest wektorem sił X , Y i momentu N , zgodnie z tabelą 2.1.

Do wyliczenia współczynników macierzy \mathbf{M} , $\mathbf{C}(\mathbf{v})$ i $\mathbf{D}(\mathbf{v})$ założono symetrię kadłuba statku pomiędzy lewą i prawą burtą oraz równomierny rozkład mas.

Wykorzystując powyższe założenie, można wyznaczyć punkt środka ciężkości statku, który będzie znajdować się na osi X_b w odległości x_G od punktu GC. Macierz bezwładności bryły sztywnej przyjmuje wówczas postać:

$$\mathbf{M}_{RB} = \begin{vmatrix} m & 0 & 0 \\ 0 & m & mx_G \\ 0 & mx_G & I_z \end{vmatrix} \quad (2.7)$$

gdzie:



2. Model matematyczny statku

- m - masa statku,
- I_z - moment bezwładności wokół osi Z_b .

Macierz hydrodynamicznych współczynników masy dodanej opisana jest przez:

$$\mathbf{M}_A = \begin{vmatrix} X_{\dot{u}} & 0 & 0 \\ 0 & Y_{\dot{v}} & -Y_{\dot{r}} \\ 0 & Y_{\dot{r}} & -N_{\dot{r}} \end{vmatrix}, \quad (2.8)$$

gdzie współczynniki hydrodynamiczne $X_{\dot{u}}$, $Y_{\dot{v}}$, $Y_{\dot{r}}$, $N_{\dot{r}}$ są zależne od prędkości wypadkowej statku. Powyższe równania (2.3)-(2.6) są prawdziwe przy założeniu, że statek porusza się z małą prędkością a $\mathbf{M} = \mathbf{M}^T$ co oznacza, że \mathbf{M} jest macierzą symetryczną.

W pracach [23],[24] wyprowadzono macierz dośrodkową $\mathbf{C}_{RB}(\mathbf{v})$ związaną z bryłą sztywną i hydrodynamiką oraz macierz Coriolisa \mathbf{C}_A opisującą siły dośrodkowe oddziałujące na masy dodane. Macierze te przyjmują następującą formę:

$$\mathbf{C}_{RB}(\mathbf{v}) = \begin{vmatrix} 0 & 0 & -m(v + x_{Gr}) \\ 0 & 0 & mu \\ m(v + x_{Gr}) & -mu & 0 \end{vmatrix}, \quad (2.9)$$

$$\mathbf{C}_A = \begin{vmatrix} 0 & 0 & Y_{\dot{v}}v + Y_{\dot{r}}r \\ 0 & 0 & X_{\dot{u}}u \\ -Y_{\dot{v}}v - Y_{\dot{r}}r & X_{\dot{u}}u & 0 \end{vmatrix}. \quad (2.10)$$

Szczegółowy opis parametrów macierzy można znaleźć w [23].

Za liniową część macierzy tłumienia $\mathbf{D}(\mathbf{v})$ odpowiedzialne są głównie siły potencjalnego tłumienia (rozproszenie energii fal generowanych na powierzchni wody) i tarcia powierzchniowego. Wówczas macierz tłumienia \mathbf{D}_L przyjmuje postać:

$$\mathbf{D}_L = \begin{vmatrix} -X_u & 0 & 0 \\ 0 & -Y_v & -Y_r \\ 0 & -N_v & -N_r \end{vmatrix}. \quad (2.11)$$

Natomiast nieliniowa część macierzy tłumienia związana z wektorem prędkości \mathbf{v} może zostać przedstawiona w poniższej formie:

$$\mathbf{D}_{NL}(\mathbf{v})\mathbf{v} = \begin{vmatrix} |\mathbf{v}|^T \mathbf{D}_{n1} \\ |\mathbf{v}|^T \mathbf{D}_{n2} \\ |\mathbf{v}|^T \mathbf{D}_{n3} \end{vmatrix} \mathbf{v}, \quad (2.12)$$

gdzie \mathbf{D}_{n1} , \mathbf{D}_{n2} i \mathbf{D}_{n3} są macierzami o rozmiarze 3×3 a $|\mathbf{v}|^T = [|u|, |v|, |r|]$ jest wektorem wartości bezwzględnych prędkości wzdłużnej, poprzecznej i zmiany kursu. Dla małych prędkości przy założeniu niskiego poziomu zakłóceń od fal można wykazać, że $\mathbf{D}(\mathbf{v}) = \mathbf{D}(\mathbf{v})^T$, a siły $\mathbf{D}_{NL}(\mathbf{v})$ mogą zostać pominięte [6].



2.2.1 Model symulacyjny

W pracy do badań symulacyjnych wykorzystano model statku opisany w [23]. Prezentowany model statku Northern Clipper zależny jest od prędkości wypadkowej statku U_o i przyjmuje postać:

$$\mathbf{M}\dot{\mathbf{v}} + \mathbf{N}(U_o)\mathbf{v} = \boldsymbol{\tau}, \quad (2.13)$$

$$\boldsymbol{\tau} = \boldsymbol{\tau}_c + \mathbf{R}(\psi)^T \mathbf{b}, \quad (2.14)$$

$$U_o = \sqrt{u^2 + v^2}, \quad (2.15)$$

gdzie:

- $\mathbf{N}(U_o)$ - macierz reprezentująca sumę sił i momentów Coriolisa i tłumienia zależną od prędkości wypadkowej statku U_o ,
- $\boldsymbol{\tau}_c$ - wektor zawierający siły i moment wytwarzanych przez napędy i stery statku,
- $\mathbf{R}(\psi)$ - jest macierzą rotacji zależną od kursu statku ψ ,
- \mathbf{b} - wektor sił od wolnozmiennych zakłóceń środowiskowych.

W równaniu (2.13), macierze dla tego statku przyjmują następującą postać:

$$\mathbf{M} = \mathbf{M}_{RB} + \mathbf{M}_A = \begin{vmatrix} m - X_{\dot{u}} & 0 & 0 \\ 0 & m - Y_{\dot{v}} & mx_G - Y_{\dot{r}} \\ 0 & mx_G - Y_{\dot{r}} & I_z - N_{\dot{r}} \end{vmatrix}, \quad (2.16)$$

$$\mathbf{N}(U_o) = \mathbf{C}(\mathbf{v}) + \mathbf{D}(\mathbf{v}), \quad (2.17)$$

$$\mathbf{N}(U_o) = \begin{vmatrix} -X_m & 0 & 0 \\ 0 & -Y_v & (m - X_{\dot{u}} + Y_{\dot{v}})U_o - Y_r \\ 0 & (X_{\dot{u}} - 2Y_{\dot{v}})U_o - Y_r & (mx_G - Y_{\dot{r}})U_o - N_r \end{vmatrix}. \quad (2.18)$$

W celu budowy pełnego modelu matematycznego statku opisanego powyższymi równaniami wprowadzono współczynniki zgodnie z tabelą 2.2.



2. Model matematyczny statku

Tabela 2.2: Współczynniki dla statku Northern Clipper

	Wartość	Jednostka
U_0	0.2	[m/s]
L	76.2	[m]
I_z	$2.0903 \cdot 10^9$	[kgm ²]
x_G	0.0	[m]
$X_{\dot{u}}$	$-0.5096 \cdot 10^6$	[kg]
$Y_{\dot{v}}$	$-3.5608 \cdot 10^6$	[kg]
$Y_{\dot{r}}$	$-0.02268 \cdot 10^9$	[kgm]
$N_{\dot{v}}$	$-0.02268 \cdot 10^9$	[kgm]
$N_{\dot{r}}$	$-8780 \cdot 10^9$	[kgm ²]
X_u	$-0.05138 \cdot 10^6$	[kg/s]
Y_v	$-0.1698 \cdot 10^6$	[kg/s]
Y_r	$1.5081 \cdot 10^9$	[kgm/s]
N_r	$-0.2530 \cdot 10^9$	[kgm ² /s]

Wolnozmiennie zakłócenia środowiskowe w pracy zostały zamodelowane za pomocą wartości początkowej, która modyfikowana jest zmienną losową. Dynamikę zmiany zakłóceń wolnozmiennych zapisano równaniem:

$$\dot{\mathbf{b}} = \mathbf{\Omega} \mathbf{w}_b, \quad (2.19)$$

gdzie:

- \mathbf{b} - to wektor reprezentujący wolnozmiennie zakłócenia środowiskowe,
- $\mathbf{\Omega}$ - jest macierzą opisującą amplitudę zakłóceń środowiskowych,
- \mathbf{w}_b - jest wektorem zmiennych losowych o rozkładzie normalnym.

Wykorzystując równanie (2.1) i własności macierzy rotacji $\mathbf{R}(\psi)^T = \mathbf{R}(\psi)^{-1}$, można przeprowadzić poniższe przekształcenia:

$$\mathbf{v} = \mathbf{R}(\psi)^T \dot{\boldsymbol{\eta}}, \quad (2.20)$$

$$\dot{\mathbf{v}} = \mathbf{R}(\psi)^T \ddot{\boldsymbol{\eta}} + \dot{\mathbf{R}}(\psi)^T \dot{\boldsymbol{\eta}}. \quad (2.21)$$

Podstawiając (2.21) do (2.13), otrzymano:

$$\mathbf{J}(\boldsymbol{\eta}) \ddot{\boldsymbol{\eta}} + \mathbf{C}(\boldsymbol{\eta}, \dot{\boldsymbol{\eta}}) \dot{\boldsymbol{\eta}} + \mathbf{F}(\boldsymbol{\eta}) \dot{\boldsymbol{\eta}} - \mathbf{b} = \boldsymbol{\tau}^*, \quad (2.22)$$

gdzie:

$$\mathbf{J}(\boldsymbol{\eta}) \ddot{\boldsymbol{\eta}} = \mathbf{R}(\psi) \mathbf{M} \mathbf{R}(\psi)^T, \quad (2.23)$$

$$\mathbf{C}(\boldsymbol{\eta}, \dot{\boldsymbol{\eta}}) = \mathbf{R}(\psi) \mathbf{M} \dot{\mathbf{R}}(\psi)^T, \quad (2.24)$$

$$\mathbf{F}(\boldsymbol{\eta}) = \mathbf{R}(\psi) \mathbf{N}(U_o) \mathbf{R}(\psi)^T, \quad (2.25)$$

$$\boldsymbol{\tau}^* = \mathbf{R}(\psi) \boldsymbol{\tau}_c. \quad (2.26)$$



Powyższy zapisy umożliwia przedstawienie dyskretnego modelu statku w postaci równań stanu, gdzie wektorem stanu jest $\mathbf{x}_k^D = [\boldsymbol{\eta}_k, \mathbf{b}_k, \dot{\boldsymbol{\eta}}_k, \dot{\mathbf{b}}_k, \ddot{\boldsymbol{\eta}}_k]^T$ gdzie indeks dolny k oznacza chwilę czasu. Dla takiego wektora stanu uzyskano następujący model:

$$\mathbf{x}_k^D = \mathbf{A}_D \mathbf{x}_{k-1}^D + \mathbf{B}_D \mathbf{u}_k + \mathbf{v}_{pro}, \quad (2.27)$$

$$\mathbf{z}_k^D = \mathbf{y}(\mathbf{x}_k^D) + \mathbf{n}_{pom}, \quad (2.28)$$

gdzie:

- \mathbf{A}_D jest macierzą stanu w równaniach stanu dla wektora stanu \mathbf{x}_k^D ,
- \mathbf{B}_D jest macierzą wejść sterowania w równaniach stanu dla wektora stanu \mathbf{x}_k^D ,
- \mathbf{u}_k jest wektorem sił sterujących,
- \mathbf{v}_{pro} jest wektorem szumu procesu / niepewnością modelu,
- \mathbf{z}_k^D jest obliczonym wektorem pomiarowym,
- $\mathbf{y}(\mathbf{x}_k^D)$ jest wektorem funkcji wyjścia dla wektora stanu \mathbf{x}_k^D ,
- \mathbf{n}_{pom} jest wektorem szumu pomiaru / niepewnością pomiarową.

Do badań symulacyjnych stworzono także drugi model obiektu, który uwzględnia tylko nieruchomy układ współrzędnych, to znaczy opisuje tylko równania kinematyki statku. Wektor stanu dla takiego modelu przyjmuje postać $\mathbf{x}_k^K = [\boldsymbol{\eta}_k, \dot{\boldsymbol{\eta}}_k, \ddot{\boldsymbol{\eta}}_k]^T$. Ze względu na to, że model ten nie uwzględnia modelu dynamiki obiektu, niemożliwe jest obliczenie wektora przyspieszenia $\ddot{\boldsymbol{\eta}}$. Z tego powodu wektor $\ddot{\boldsymbol{\eta}}_k$ określany jest jako niepewność procesu:

$$\ddot{\boldsymbol{\eta}}_k = \mathbf{w}_{pro}. \quad (2.29)$$

Wtedy model przestrzeni stanu przyjmuje postać:

$$\mathbf{x}_k^K = \mathbf{A}_K \mathbf{x}_{k-1}^K + \mathbf{v}_{pro}, \quad (2.30)$$

$$\mathbf{z}_k^K = \mathbf{y}(\mathbf{x}_k^K) + \mathbf{n}_{pom}. \quad (2.31)$$

gdzie:

- \mathbf{A}_K jest macierzą stanu w równaniach stanu dla wektora stanu \mathbf{x}_k^K ,
- \mathbf{v}_{pro} jest wektorem szumu procesu / niepewnością modelu,
- \mathbf{z}_k^K jest obliczonym wektorem pomiarowym,
- $\mathbf{y}(\mathbf{x}_k^K)$ jest wektorem funkcji wyjścia dla wektora stanu \mathbf{x}_k^K ,



2. Model matematyczny statku

Dla równania (2.27) macierze \mathbf{A}_D , \mathbf{B}_D przyjmują następującą postać:

$$\mathbf{A}_D = \begin{pmatrix} \mathbf{I}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} \Delta t & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} \frac{\Delta t^2}{2} \\ \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} \Delta t \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} & \mathbf{J}^{-1}(\boldsymbol{\eta}) & -\mathbf{J}^{-1}(\boldsymbol{\eta})^{-1}(\mathbf{C}(\boldsymbol{\eta}, \dot{\boldsymbol{\eta}}) + \mathbf{F}(\boldsymbol{\eta})) & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \end{pmatrix}, \quad (2.32)$$

$$\mathbf{B}_D = \begin{pmatrix} \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} \\ \mathbf{0}_{3 \times 3} \\ \mathbf{J}^{-1}(\boldsymbol{\eta}) \end{pmatrix}. \quad (2.33)$$

Natomiast macierz \mathbf{A}_K dla równania (2.30) przyjmuje postać:

$$\mathbf{A}_K = \begin{pmatrix} \mathbf{I}_{3 \times 3} & \mathbf{I}_{3 \times 3} * \Delta t & \mathbf{I}_{3 \times 3} * \frac{\Delta t^2}{2} \\ \mathbf{0}_{3 \times 3} & \mathbf{I}_{3 \times 3} & \mathbf{I}_{3 \times 3} * \Delta t \\ \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} & \mathbf{0}_{3 \times 3} \end{pmatrix}, \quad (2.34)$$

gdzie $\mathbf{I}_{n \times n}$ jest macierzą jednostkową o rozmiarze $n \times n$, $\mathbf{0}_{n \times n}$ jest macierzą zer o rozmiarze $n \times n$ a Δt jest przyrostem czasu pomiędzy kolejnymi chwilami k .

Modele przedstawione w powyższym rozdziale zostały wykorzystane w badaniach symulacyjnych oraz przy projektowaniu algorytmów fuzji danych i sterowania.



Rozdział 3

Fuzja danych

Fuzja danych jest naturalnym dla człowieka sposobem oceny w zależności od cech, które jesteśmy w stanie zmierzyć lub zaobserwować. Codziennie wykorzystujemy różne przypadki fuzji danych pochodzących z ludzkich zmysłów. Fuzja danych jest sposobem łączenia informacji w celu uzyskania wniosków i podjęcia decyzji [35], [36], [56].

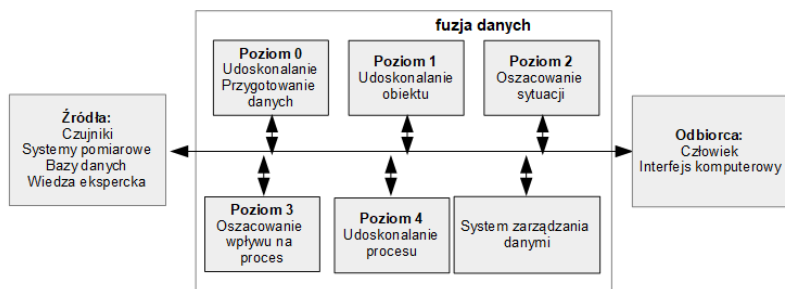
W technice pojęcie fuzji danych wykorzystywane jest między innymi do połączenia informacji z czujników pomiarowych w celu poprawy jakości estymacji oraz wniosków/informacji, których uzyskanie przy wykorzystaniu pojedynczego czujnika nie byłoby możliwe.

Najczęściej wykorzystywaną definicją systemu fuzji danych jest: „*A multi-level process dealing with the association, correlation, combination of data and information from single and multiple sources to achieve refined position, identify estimates and complete and timely assessments of situations, threat and their significance*” („Wielopoziomowy proces dotyczący powiązania, korelacji, połączenia danych i informacji z pojedynczego i większej liczby czujników mający na celu osiągnięcie dokładniejszej estymacji, kompletnej i terminowej oceny sytuacji, zagrożeń i ich znaczenia”) przedstawiona przez zespół Joint Directors of Laboratories (JDL) [106].

Rozwój techniki pomiarowej i niskie ceny czujników pomiarowych instalowanych w różnych systemach spowodowały, że problem fuzji danych w dzisiejszych czasach jest tematem wielu prac naukowych [2], [10], [52], [75]. W zależności od przyjętego spojrzenia powstało kilka typów podziałów systemów fuzji danych:

- ze względu na różne poziomy fuzji danych określone przez JDL (rys. 3.1) [60], [86],
- ze względu na wykorzystywaną architekturę (rys. 3.2, 3.3, 3.4) [9], [13],
- ze względu na poziom abstrakcji wykorzystywanych danych [62],
- ze względu na relacje pomiędzy danymi wejściowymi [18], [61],
- ze względu na rodzaj danych wejściowych i wyjściowych [13].

3. Fuzja danych



Rys. 3.1: Podział fuzji danych według JDL

Podział fuzji danych według JDL (rys. 3.1) różnicuje algorytmy ze względu na poziomy obróbki danych, na jakich są one wykorzystywane [60]:


- Poziom 0 jest najniższym z poziomów w fuzji danych i obejmuje fuzję na poziomie sygnału i piksela poprzez ich wstępne przetwarzanie.
- Poziom 1 wykorzystuje dane przetworzone z poziomu 0 do analizy powiązań, korelacji, grupowania, estymacji stanu usuwania fałszywych/błędnych pomiarów. Wartościami wyjściowymi z tego poziomu są uporządkowane struktury danych.
- Poziom 2 koncentruje się na wyższym w stosunku do poprzedniego poziomie wnioskowania. Ocena sytuacji ma na celu określenie prawdopodobnych sytuacji, biorąc pod uwagę zaobserwowane zdarzenia i uzyskane dane. Celem tego poziomu jest wnioskowanie i identyfikacja działań oraz zdarzeń w celu ich uporządkowania.
- Poziom 3 interpretuje dane z poziomu 2 w celu wykrycia uszkodzeń systemu lub przewidzenia przyszłych skutków na podstawie obecnego wnioskowania. Odbyma się tu również ocena ryzyka i opracowanie scenariuszy postępowania.
- Poziom 4 nadzoruje wszystkie pozostałe stany w celu doskonalenia całego procesu, efektywnego wykorzystania zasobów i harmonogramów pracy.

Kolejnym typem jest podział ze względu na architekturę systemu, gdzie wyróżniamy [13]:

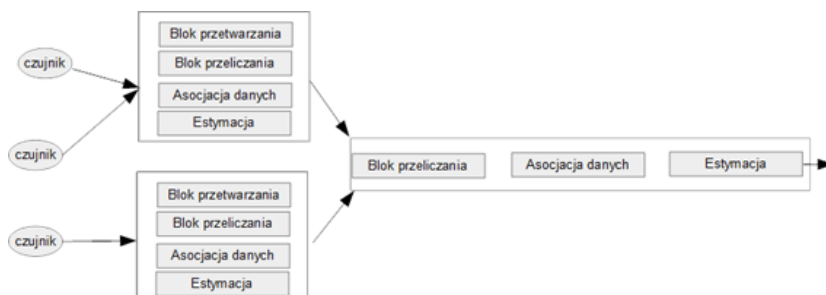
- architekturę scentralizowaną – fuzja danych odbywa się w centralnym procesorze, do którego dostarczane są sygnały ze wszystkich systemów pomiarowych (rys. 3.2);
- architekturę zdecentralizowaną – fuzja danych odbywa się w poszczególnych węzłach architektury, przy czym każdy węzeł ma własne bloki przetwarzania danych oraz nie występuje pojedynczy blok łączący (rys. 3.3);



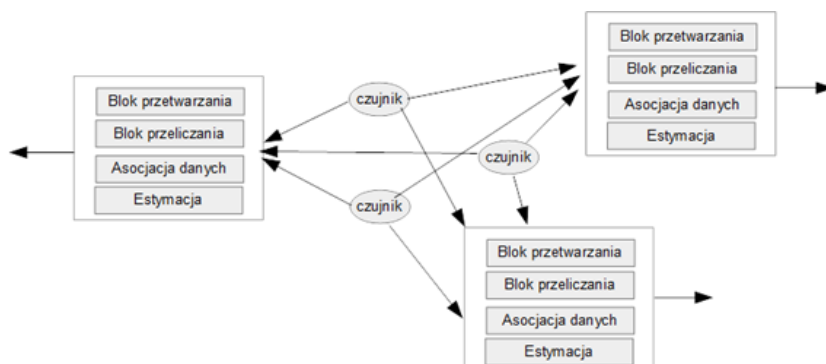
- architekturę rozproszoną – przetwarzanie danych odbywa się bezpośrednio w każdym węźle architektury, co umożliwia lokalną estymację, ale dane przesyłane są kolejno do systemu fuzji danych, gdzie poddawane są obróbce (rys. 3.4).



Rys. 3.2: Scentralizowana architektura systemu



Rys. 3.3: Zdecentralizowana architektura systemu



Rys. 3.4: Rozproszona architektura systemu

Klasyfikacja bazująca na poziomie abstrakcji danych przedstawia następujący podział [62]:

- fuzja danych niskiego poziomu: fuzja danych wykorzystuje bezpośrednio dane pomiarowe z procesu;

3. Fuzja danych

- fuzja danych średniego poziomu: fuzja danych wykorzystuje cechę lub cechy w celu uzyskania informacji o procesie między innymi na podstawie charakterystyk;
- fuzja danych wysokiego poziomu: fuzja danych nazywana decyzyjną, łącząca dane o procesie w celu uzyskania dokładniejszych wyników;
- fuzja danych wielopoziomowa: wielopoziomową fuzją danych nazywane są algorytmy łączące ze sobą zadania kilku poziomów abstrakcji.

Częstym podziałem algorytmów fuzji danych jest podział bazujący na relacjach pomiędzy danymi wejściowymi i wyjściowymi, który dzieli systemy fuzji danych na następujące typy [17]:

- dane na wejściu – dane na wyjściu (DAI–DAO): wartościami wejściowymi są nieobrobione pomiary, a wyjściowymi – wartości estymowane, cechują się one większą dokładnością;
- dane na wejściu – cecha na wyjściu (DAI–FEO): na tym etapie do fuzji danych wprowadzane są surowe dane wejściowe, na podstawie których określone są cechy, funkcje opisujące obiekt w środowisku;
- cecha na wejściu – cecha na wyjściu (FEI–FEO): na tym etapie zarówno dane wejściowe, jak i wyjściowe są cechami obiektu; w procesie fuzji danych cechy wejściowe wykorzystywane są do potwierdzenia cechy, określenia nowej cechy obiektu;
- cecha na wejściu – decyzja na wyjściu (FEI–DEO): na tym etapie na podstawie wejściowych cech obiektu określana jest decyzja jako wynik działania systemu;
- decyzja na wejściu – decyzja na wyjściu (DEI–DEO): na tym etapie na podstawie decyzji wejściowych wydawane są kolejne decyzje.

Odpowiednie określenie typu projektowanego systemu fuzji danych jest bardzo ważnym aspektem, gdyż określa zakres działania algorytmu oraz ułatwia dobór algorytmów potrzebnych w systemie fuzji danych.

3.1 Algorytmy fuzji danych

Temat algorytmów fuzji i interpretacji danych z nadmiarowych systemów pomiarowych obecnie jest problemem badawczym wielu prac naukowych. Wraz z rozpowszechnieniem się systemów pomiarowych wymagane są zaawansowane algorytmy, które łączą informacje o obiekcie z wielu źródeł w celu uzyskania dokładniejszej informacji o jego stanie w czasie rzeczywistym [36], [56].

Algorytmy fuzji danych przedstawione w pracy będą wykorzystywane do estymacji wektora stanu obiektu, którego wartość jest szacowana na podstawie pomiarów z czujników i matematycznego modelu statku. Zaprezentowane algorytmy odpowiedzialne są również za filtrację danych pomiarowych oraz



za sprawdzenie poprawności pomiarów. Celem estymacji w systemie fuzji danych jest uzyskanie wektora stanu obiektu określonego na podstawie pomiaru z kilku systemów pomiarowych.

Problem estymacji stanu polega na obliczeniu wartości wektora stanu, które powinny być zbliżone do wartości rzeczywistej, na podstawie zaszumionych danych pomiarowych z systemu. Fuzja danych na podstawie nadmiarowych i zależnych od siebie danych pomiarowych oblicza i interpretuje dane, określając jeden wektor stanu zależny od wszystkich danych wejściowych.

W literaturze wykorzystywane są dwa sposoby opisu modelu procesu/systemu:

- liniowy – w tym przypadku najlepszym rozwiązaniem do estymacji stanu jest filtr Kalmana;
- nieliniowy – jest przypadkiem, w którym dobór algorytmu nie jest prosty, nie ma uniwersalnego rozwiązania, dla którego wynik będzie optymalny.

Większość metod estymacji stanu opiera swoje działanie na teorii sterowania oraz wykorzystuje probabilistykę do obliczenia wektora wyjściowego. Najczęściej wykorzystywanymi algorytmami są: filtr Kalmana [30], [82], rozszerzony filtr Kalmana [76], [78], bezwony filtr Kalmana [12], [103], sieci neuronowe [44], [110] i filtry wykorzystujące sekwencyjne metody Monte Carlo, między innymi filtr cząsteczkowy [42], [75].

W pracy, do opisu modelu statku wykorzystano nieliniowy dyskretny model procesu:

$$\mathbf{x}_k = \mathbf{f}_{nl}(\mathbf{x}_{k-1}, \mathbf{v}_{k-1}), \quad (3.1)$$

gdzie:

- \mathbf{x}_k - jest wektorem stanu dla chwili k ,
- $\mathbf{f}_{nl}(\mathbf{x}_{k-1}, \mathbf{v}_{k-1})$ jest wektor nieliniowych funkcji opisująca przejście pomiędzy stanem w chwili $k-1$ do k z wykorzystaniem wektora stanu \mathbf{x}_{k-1} i szumu procesu \mathbf{v}_{k-1} ,

oraz nieliniowy dyskretny model pomiaru:

$$\mathbf{z}_k = \mathbf{h}_{nl}(\mathbf{x}_k, \mathbf{n}_k), \quad (3.2)$$

gdzie:

- \mathbf{z}_k - jest wektorem pomiaru dla chwili k obliczonym z wykorzystaniem modelu \mathbf{h}_{nl} ,
- $\mathbf{h}_{nl}(\mathbf{x}_k, \mathbf{n}_k)$ wektor nieliniowych funkcji opisujących model pomiaru w chwili k z wykorzystaniem, wektora stanu \mathbf{x}_k i szumu pomiarowego \mathbf{n}_k ,

Opis działania poszczególnych algorytmów fuzji danych wymaga również wprowadzenia podstawowych oznaczeń z teorii Bayesa [16]. Śledzenie obiektu w teorii Bayesa polega na rekurencyjnym obliczeniu stanu $x_{k|k}$ z pewnym



3. Fuzja danych

prawdopodobieństwem na podstawie danych z czujników pomiarowych y_k . Takie podejście wymaga określenia funkcji rozkładu prawdopodobieństwa a posteriori $p(x_k|y_{1:k})$ czyli rozkładu prawdopodobieństwa wystąpienia stanu x_k przy zbiorze pomiarów $y_{1:k}$. Przez co zakładamy, że znany jest stan początkowy i początkowy rozkład prawdopodobieństwa a posteriori $p(x_0|y_1) = p(x_0)$ gdzie rozkład prawdopodobieństwa stanu x_0 przy pomiarze y_1 jest równe rozkładowi prawdopodobieństwa stanu x_0 . Wykorzystując wcześniejsze założenia, funkcję rozkładu prawdopodobieństwa a posteriori $p(x_k|y_{1:k})$ można obliczyć rekurencyjnie z wykorzystaniem dwóch kroków predykcji i aktualizacji.

Przy poczynionych powyżej założeniach w chwili $k-1$ znana jest funkcja rozkładu prawdopodobieństwa a posteriori: $p(x_{k-1}|y_{1:k-1})$. Wykorzystując model obiektu, można obliczyć funkcję rozkładu prawdopodobieństwa a priori w chwili k przy użyciu równania Chapmana-Kołmogorowa [16]:

$$p(x_k|y_{1:k-1}) = \int p(x_k|x_{k-1})p(x_{k-1}|y_{1:k-1}) dx_{k-1}. \quad (3.3)$$

W równaniu (3.3) wykorzystano fakt, że $p(x_k|x_{k-1}, y_{1:k-1}) = p(x_k|x_{k-1})$ co oznacza że prawdopodobieństwo przejścia stanu x_{k-1} do stanu x_k przy serii pomiarów $y_{1:k-1}$ równe jest prawdopodobieństwu przejścia stanu ze stanu x_{k-1} do stanu x_k . Probabilistyczny model przejścia $p(x_k|x_{k-1})$ stanu x_{k-1} do stanu x_k ze znanym rozkładem szumu procesu v_{k-1} opisano równaniem (3.1). Do wykonania aktualizacji stanu $x_{k|k}$ konieczny jest pomiar y_k w chwili k przez co możliwe jest obliczenie kroku aktualizacji z zastosowaniem prawa Bayesa [16]:

$$p(x_k|y_{1:k}) = \frac{p(y_k|x_k)p(x_k|y_{1:k-1})}{p(y_k|y_{1:k-1})}, \quad (3.4)$$

gdzie:

$$p(y_k|y_{1:k-1}) = \int p(y_k|x_k)p(x_k|y_{1:k-1})dx_k, \quad (3.5)$$

w powyższym równaniu:

- $p(y_k|x_k)$ jest funkcją rozkładu prawdopodobieństwa wystąpienia pomiaru y_k dla stanu x_k .
- $p(y_k|y_{1:k-1})$ jest funkcją rozkładu prawdopodobieństwa wystąpienia pomiaru y_k dla serii pomiarów $y_{1:k-1}$.

Wykorzystując równanie (3.2) możliwe jest oszacowanie funkcji rozkładu prawdopodobieństwa pomiaru $p(y_k|x_k)$ dla danego stanu x_k i znanej niepewności pomiarowej n_k .

3.2 Filtr Kalmana

Filtr Kalmana (KF, ang. *Kalman filter*) jest estymatorem optymalnym w sensie minimalizacji kowariancji błędu estymacji dla obiektów liniowych [50]. Algorytm



filtracji Kalmana przyjmuje założenie, że model obiektu i pomiaru jest opisany przez równania liniowe oraz zmienne losowe, które mogą zostać opisane rozkładem gaussowskim ze znaną wartością średnią i kowariancją modelu/pomiaru. Pozwala to na następujący opis modelu stanu:

$$\begin{aligned} \mathbf{x}_k &= \mathbf{F}_l \mathbf{x}_{k-1} + \mathbf{v}_{k-1}, \\ \mathbf{z}_k &= \mathbf{C}_l \mathbf{x}_k + \mathbf{n}_k \end{aligned} \quad (3.6)$$

gdzie:

- \mathbf{F}_l jest macierzą stanu ,
- \mathbf{C}_l jest macierzą wyjścia,
- \mathbf{v}_{k-1} jest szumem modelu opisanym przez kowariancję modelu (\mathbf{Q}_K),
- \mathbf{n}_k jest szumem pomiaru opisanym przez kowariancję pomiaru (\mathbf{R}_K).

Korzystając z równań (3.3) i (3.4), algorytm filtru Kalmana można zapisać jako rekurencyjny zestaw równań:

$$p(\mathbf{x}_{k-1} \mid \mathbf{y}_{1:k-1}) = \mathcal{N}(\mathbf{x}_{k-1}; \mathbf{m}_{k-1|k-1}, \mathbf{P}_{k-1|k-1}), \quad (3.7)$$

$$p(\mathbf{x}_k \mid \mathbf{y}_{1:k-1}) = \mathcal{N}(\mathbf{x}_k; \mathbf{m}_{k|k-1}, \mathbf{P}_{k|k-1}), \quad (3.8)$$

$$p(\mathbf{x}_k \mid \mathbf{y}_{1:k}) = \mathcal{N}(\mathbf{x}_k; \mathbf{m}_{k|k}, \mathbf{P}_{k|k}), \quad (3.9)$$

gdzie:

$$\mathbf{m}_{k|k-1} = \mathbf{F}_l \mathbf{m}_{k-1|k-1}, \quad (3.10)$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_l \mathbf{P}_{k-1|k-1} \mathbf{F}_l^T + \mathbf{Q}_K, \quad (3.11)$$

$$\mathbf{m}_{k|k} = \mathbf{m}_{k|k-1} + \mathbf{K}_K (\mathbf{z}_k - \mathbf{C}_l \mathbf{m}_{k|k-1}), \quad (3.12)$$

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_K \mathbf{C}_l \mathbf{P}_{k|k-1}. \quad (3.13)$$

$\mathcal{N}(x, m, P)$ jest rozkładem gaussowskim o argumentach x , wartości oczekiwanej m i kowariancji P . Do algorytmu filtru Kalmana potrzebne są również: macierz kowariancji innowacji \mathbf{S}_K , macierz wzmocnień Kalmana \mathbf{K}_K , wektor innowacji \mathbf{I}_K oraz wektor pomiaru \mathbf{y}_k dla chwili k .

$$\mathbf{S}_K = \mathbf{C}_l \mathbf{P}_{k|k-1} \mathbf{C}_l^T + \mathbf{R}_K, \quad (3.14)$$

$$\mathbf{K}_K = \mathbf{P}_{k|k-1} \mathbf{C}_l^T \mathbf{S}_K^{-1}, \quad (3.15)$$

$$\mathbf{I}_K = \mathbf{y}_k - \mathbf{z}_{k|k-1}. \quad (3.16)$$

Uwzględniając powyższe zależności przedstawiono schemat algorytmu filtru Kalmana [50].



```

1 Algorytm: Filtr Kalmana(KF):
2   Predykcja:                                     /* Predykcja */
3    $\mathbf{x}_{k|k-1} = \mathbf{F}_l \cdot \mathbf{x}_{k-1|k-1}$            /* Predykcja stanu */
4    $\mathbf{z}_{k|k-1} = \mathbf{C}_l \cdot \mathbf{x}_{k|k-1}$            /* Predykcja pomiaru */
5    $\mathbf{P}_{k|k-1} = \mathbf{F}_l \cdot \mathbf{P}_{k-1|k-1} \cdot \mathbf{F}_l^T + \mathbf{Q}_K$ 
6   Aktualizacja:                                   /* Aktualizacja */
7    $\mathbf{I}_K = \mathbf{y}_k - \mathbf{z}_{k|k-1}$ 
8    $\mathbf{S}_K = \mathbf{C}_l \cdot \mathbf{P}_{k|k-1} \cdot \mathbf{C}_l^T + \mathbf{R}_K$ 
9    $\mathbf{K}_K = \mathbf{P}_{k|k-1} \cdot \mathbf{C}_l^T \cdot \mathbf{S}_K^{-1}$ 
10   $\mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_K \cdot \mathbf{I}_K$            /* Aktualizacja stanu */
11   $\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_K \cdot \mathbf{S}_K \cdot \mathbf{K}_K^T$ 
12   $\mathbf{z}_{k|k} = \mathbf{C}_l \cdot \mathbf{x}_{k|k}$            /* Aktualizacja pomiaru */
13  Wyjście  $\mathbf{x}_{k|k}, \mathbf{z}_{k|k}$                        /* Wyjście */
14 Powrót do linii nr. 2

```

Algorytm 1: Filtr Kalmana

Algorytm filtru Kalmana można podzielić na dwie fazy: predykcję i aktualizację. Predykcja na podstawie wartości estymowanych obliczonych w poprzedniej iteracji, to jest estymowanego wektora stanu $\mathbf{x}_{k-1|k-1}$ i estymowanej macierzy kowariancji stanu $\mathbf{P}_{k-1|k-1}$ ekstrapoluje wektor stanu $\mathbf{x}_{k|k-1}$ (linia 3), wektor pomiaru $\mathbf{z}_{k|k-1}$ (linia 4) i macierz kowariancji stanu $\mathbf{P}_{k|k-1}$ (linia 5). Faza aktualizacji dla filtru Kalmana rozpoczyna się od obliczenia innowacji \mathbf{I}_K (linia 7) z wykorzystaniem wektora pomiaru z czujników \mathbf{y}_k i predykcji stanu $\mathbf{x}_{k|k-1}$. Kolejnymi krokami algorytmu są obliczenia dotyczące macierzy kowariancji innowacji \mathbf{S}_K (linia 8) i macierzy wzmocnień Kalmana \mathbf{K}_K (linia 9). Ostatnią częścią fazy aktualizacji jest estymacja wektora stanu $\mathbf{x}_{k|k}$ (linia 10) i macierzy kowariancji stanu $\mathbf{P}_{k|k}$ (linia 11) poprzez wprowadzenie poprawki do ekstrapolowanych wartości wektora stanu i macierzy kowariancji stanu.

3.3 Rozszerzony filtr Kalmana

Rozszerzony filtr Kalmana (EKF, ang. *extended Kalman filter*) jest filtrem suboptymalnym dla obiektów, które są opisane nieliniowymi równaniami stanu. Aby z nieliniowego modelu obiektu (3.1) i (3.2) otrzymać model (3.6), konieczna jest linearyzacja modelu w każdej chwili k . Dla rozszerzonego filtru Kalmana można przyjąć, że zlinearyzowany model statku można aproksymować rozkładem gaussowskim [23]. W tym przypadku odpowiednio

$$p(\mathbf{x}_{k-1} | \mathbf{y}_{1:k-1}) \approx \mathcal{N}(\mathbf{x}_{k-1}; \mathbf{m}_{k-1|k-1}, \mathbf{P}_{k-1|k-1}), \quad (3.17)$$

$$p(\mathbf{x}_k | \mathbf{y}_{1:k-1}) \approx \mathcal{N}(\mathbf{x}_k; \mathbf{m}_{k|k-1}, \mathbf{P}_{k|k-1}), \quad (3.18)$$

$$p(\mathbf{x}_k | \mathbf{y}_{1:k}) \approx \mathcal{N}(\mathbf{x}_k; \mathbf{m}_{k|k}, \mathbf{P}_{k|k}), \quad (3.19)$$

gdzie:

$$\mathbf{m}_{k|k-1} = \mathbf{f}_{nl}(\mathbf{m}_{k-1|k-1}), \quad (3.20)$$



$$\mathbf{P}_{k|k-1} = \mathbf{Q}_K + \mathbf{A}_k \mathbf{P}_{k-1|k-1} \mathbf{A}_k^T, \quad (3.21)$$

$$\mathbf{m}_{k|k} = \mathbf{m}_{k|k-1} + \mathbf{K}_K (\mathbf{z}_k - \mathbf{H}_k \mathbf{m}_{k|k-1}), \quad (3.22)$$

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_K \mathbf{H}_k \mathbf{P}_{k|k-1}. \quad (3.23)$$

a $\mathbf{f}_{nl}(\mathbf{x}_{k-1|k-1})$ i $\mathbf{h}_{nl}(\mathbf{x}_{k|k})$ są nieliniowymi funkcjami opisanymi równaniami (3.1) i (3.2). Natomiast \mathbf{A}_k i \mathbf{H}_k są zlinearyzowanymi macierzami stanu :

$$\mathbf{A}_k = \mathbf{I} + \left. \frac{d\mathbf{f}_{nl}(\mathbf{x})}{d\mathbf{x}} \right|_{\mathbf{x}=\mathbf{x}_{k-1|k-1}}, \quad (3.24)$$

$$\mathbf{H}_k = \mathbf{I} + \left. \frac{d\mathbf{h}_{nl}(\mathbf{x})}{d\mathbf{x}} \right|_{\mathbf{x}=\mathbf{x}_{k-1|k-1}}, \quad (3.25)$$

i odpowiednio:

$$\mathbf{S}_K = \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_K, \quad (3.26)$$

$$\mathbf{K}_K = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \mathbf{S}_K^{-1}. \quad (3.27)$$

Do linearyzacji wykorzystano rozwinięcie modelu ciągłego w szereg Taylora pierwszego rzędu. Uwzględniając powyższe równania algorytm rozszerzonego filtru Kalmana przedstawiono poniżej.

```

1 Algorytm: Rozszerzony filtr Kalmana:
2   Predykcja:                                     /* Predykcja */
3    $\mathbf{x}_{k|k-1} = \mathbf{f}_{nl}(\mathbf{x}_{k-1|k-1})$            /* Predykcja stanu */
4    $\mathbf{z}_{k|k-1} = \mathbf{h}_{nl}(\mathbf{x}_{k|k-1})$            /* Predykcja pomiaru */
5    $\mathbf{A}_k = \mathbf{I} + \left[ \frac{\delta \mathbf{f}_{nl}(\mathbf{x}_{k-1|k-1})}{\delta x_j} \right]$ 
6    $\mathbf{H}_k = \mathbf{I} + \left[ \frac{\delta \mathbf{h}_{nl}(\mathbf{x}_{k|k-1})}{\delta x_j} \right]$ 
7    $\mathbf{P}_{k|k-1} = \mathbf{A}_k \cdot \mathbf{P}_{k-1|k-1} \cdot \mathbf{A}_k^T + \mathbf{Q}_K$ 
8   Aktualizacja:                                   /* Aktualizacja */
9    $\mathbf{I}_K = (\mathbf{y}_k - \mathbf{z}_{k|k-1})$ 
10   $\mathbf{S}_K = \mathbf{H}_k \cdot \mathbf{P}_{k|k-1} \cdot \mathbf{H}_k^T + \mathbf{R}_K$ 
11   $\mathbf{K}_K = \mathbf{P}_{k|k-1} \cdot \mathbf{H}_k^T \cdot \mathbf{S}_K^{-1}$ 
12   $\mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_K \cdot \mathbf{I}_K$            /* Aktualizacja stanu */
13   $\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_K \cdot \mathbf{S}_K \cdot \mathbf{K}_K^T$ 
14   $\mathbf{z}_{k|k} = \mathbf{h}_{nl}(\mathbf{x}_{k|k})$            /* Aktualizacja pomiaru */
15  Wyjście  $\mathbf{x}_{k|k}, \mathbf{z}_{k|k}$                        /* Wyjście */
16 Powrót do linii nr. 2

```

Algorytm 2: Rozszerzony filtr Kalmana

Algorytm rozszerzonego filtru Kalmana od filtru Kalmana różni się wykorzystaniem nieliniowych funkcji \mathbf{f}_{nl} , \mathbf{h}_{nl} do predykcji wektora stanu i pomiaru. Zlinearyzowane równania \mathbf{A}_k , \mathbf{H}_k wykorzystywane są jak macierze \mathbf{F}_l , \mathbf{C}_l w linii 7, 10 i 11. W algorytmie rozszerzonego filtru Kalmana, w porównaniu do filtru Kalmana macierz \mathbf{F}_l zastępowana jest przez \mathbf{A}_k a macierz \mathbf{H}_k podstawiana jest zamiast \mathbf{C}_l .



3.4 Nieliniowy obserwator

W latach 90. XX wieku Fossen i Grøvlen [28] zaproponowali alternatywną metodę obserwacji wektora stanu dla statków z systemem dynamicznego pozycjonowania. Ze względu na dużą liczbę parametrów macierzy \mathbf{Q}_K (macierz kowariancji niepewności procesu) i \mathbf{R}_K (macierz kowariancji niepewności pomiaru), oraz trudność w ich doborze zaproponowano algorytm bazujący na modelu statku, zakłóceń środowiskowych i teorii backstepping. Do projektowania nieliniowego obserwatora wykorzystano następujący model statku:

$$\mathbf{M}\dot{\mathbf{v}}_{k|k} + \mathbf{N}(U_o)\mathbf{v}_{k-1|k-1} = \boldsymbol{\tau}_c + \mathbf{R}(\psi)^T \mathbf{b}_{k|k}, \quad (3.28)$$

$$\mathbf{v}_{k|k} = \mathbf{R}(\psi)^T \dot{\boldsymbol{\eta}}_{k|k}. \quad (3.29)$$

Opisy macierzy występujących w modelu został przedstawiony w rozdziale 2.

Pasywny nieliniowy obserwator dla estymacji położenia i kursu (rys. 3.5) statku wykorzystuje matematyczny model statku (3.28), (3.29) i wektory wzmocnień błędu estymacji \mathbf{k}_1 , \mathbf{k}_2 , \mathbf{k}_3 , gdzie błąd estymacji położenia w poprzedniej chwili czasu to $\tilde{\mathbf{y}}_{k-1} = [\tilde{x}_o, \tilde{y}_o, \tilde{\psi}]^T$.

$$\tilde{\mathbf{y}}_{k-1} = \mathbf{y}_{k-1} - \tilde{\boldsymbol{\eta}}_{k-1|k-1}, \quad (3.30)$$

\mathbf{y}_{k-1} jest pomiarem położenia i kursu w poprzedniej chwili $k - 1$. Równania, do których wprowadzono poprawki związane z błędem estymacji przedstawiono poniżej:

$$\dot{\mathbf{b}}_{k|k} = \mathbf{k}_1 \tilde{\mathbf{y}}_{k-1}, \quad (3.31)$$

$$\dot{\mathbf{v}}_{k|k} = \frac{-\mathbf{N}(U_o)\mathbf{v}_{k-1|k-1} + \mathbf{R}(\psi)^T \mathbf{b}_{k-1|k-1} + \boldsymbol{\tau}_c + \mathbf{R}(\psi)^T \mathbf{k}_2 \tilde{\mathbf{y}}_{k-1}}{\mathbf{M}}, \quad (3.32)$$

$$\boldsymbol{\eta}_{k|k} = \boldsymbol{\eta}_{k-1|k-1} + \dot{\boldsymbol{\eta}}_{k|k} \Delta t + \frac{\mathbf{R}(\psi) \cdot \dot{\mathbf{v}}_{k|k} \cdot \Delta t^2}{2} + \mathbf{k}_3 \tilde{\mathbf{y}}_{k-1}. \quad (3.33)$$

gdzie:

- $\mathbf{b}_{k|k}$ - estymowana wartość wektora zakłóceń środowiskowych \mathbf{b} w chwili k ,
- $\mathbf{v}_{k|k}$ - estymowana wartość wektora prędkości \mathbf{v} w chwili k ,
- $\boldsymbol{\eta}_{k|k}$ estymowany wektor stanu położenia w chwili k ,
- Δt - przyrost czasu pomiędzy chwilami k i $k - 1$.

Uwzględniając powyższe równania działanie nieliniowego obserwatora przedstawiono w algorytmie 3:



```

1 Algorytm: Pasywny nieliniowy obserwator (NO):
2    $\dot{\mathbf{b}}_{k|k} = \mathbf{k}_1 \tilde{\mathbf{y}}_{k-1}$ 
3    $\mathbf{b}_{k|k} = \mathbf{b}_{k-1|k-1} + \dot{\mathbf{b}}_{k|k}$ 
4    $\dot{\mathbf{v}}_{k|k} = \frac{-\mathbf{N}(U_o) \mathbf{v}_{k-1|k-1} + \mathbf{R}(\psi)^T \mathbf{b}_{k|k} + \boldsymbol{\tau}_c + \mathbf{R}(\psi)^T \mathbf{k}_2 \tilde{\mathbf{y}}_{k-1}}{\mathbf{M}}$ 
5    $\mathbf{v}_{k|k} = \mathbf{v}_{k-1|k-1} + \dot{\mathbf{v}}_{k|k} \Delta t$ 
6    $\dot{\boldsymbol{\eta}}_{k|k} = \mathbf{R}(\psi) \mathbf{v}_{k|k}$ 
7    $\boldsymbol{\eta}_{k|k} = \boldsymbol{\eta}_{k-1|k-1} + \dot{\boldsymbol{\eta}}_{k|k} \Delta t + \frac{\mathbf{R}(\psi) \cdot \dot{\mathbf{v}}_{k|k} \cdot \Delta t^2}{2} + \mathbf{k}_3 \tilde{\mathbf{y}}_{k-1}$ 
8    $\tilde{\mathbf{y}}_k = \mathbf{y}_k - \boldsymbol{\eta}_{k|k}$ 
9    $\mathbf{x}_{k|k} = [\boldsymbol{\eta}_{k|k}; \mathbf{v}_{k|k}; \dot{\mathbf{v}}_{k|k}; \mathbf{b}_{k|k}]$ 
10   $\mathbf{z}_{k|k} = [\boldsymbol{\eta}_{k|k}]$ 
11  Wyjście  $\mathbf{x}_{k|k}, \mathbf{z}_{k|k}$  /* Wyjście */
12 Powrót do linii nr. 2


```

Algorytm 3: Pasywny nieliniowy obserwator

Działanie nieliniowego obserwatora odwzorowuje model obiektu, do którego wprowadzane są poprawki, których wartość zależy od wartości wektorów wzmocnień błędu estymacji obserwatora $\mathbf{k}_i, i \in \{1, 2, 3\}$ oraz wektora błędu estymacji z chwili $k-1$ ($\tilde{\mathbf{y}}_{k-1}$). Algorytm rozpoczyna się od obliczenia wartości wektora zmiany zakłóceń środowiskowych $\dot{\mathbf{b}}_{k|k}$ z wykorzystaniem równania (3.30) (linia 2). Kolejnym krokiem jest obliczenie wartości wektora zakłóceń środowiskowych $\mathbf{b}_{k|k}$ na podstawie poprzedniej jego wartości $\mathbf{b}_{k-1|k-1}$ i wektora zmiany zakłóceń środowiskowych $\dot{\mathbf{b}}_{k|k}$. Następnie na podstawie modelu dynamiki statku obliczane jest przyspieszenie dla chwili k , wykorzystując równanie (3.31) (linia 4). W linii 5 obliczana jest prędkość obiektu $\mathbf{v}_{k|k}$ a w linii 6 następuje konwersja jej do prędkości w nawigacyjnym układzie współrzędnych $\dot{\boldsymbol{\eta}}_{k|k}$. Ostatnim krokiem związanym z modelem statku jest obliczenie położenia obiektu $\boldsymbol{\eta}_{k|k}$ wykorzystując równanie (3.32) (linia 7). Na wyjściu pasywnego nieliniowego obserwatora uzyskiwany jest estymowany wektor stanu $\mathbf{x}_{k|k}$ i estymowany wektor pomiaru $\mathbf{z}_{k|k}$.

Schemat blokowy nieliniowego obserwatora przedstawiono na rys. 3.5. Wartościami wejściowymi do nieliniowego obserwatora są $\boldsymbol{\tau}_c$ (wektor sił i momentu wytworzonych przez napędy i stery statku) i \mathbf{y}_k (wektor wartości pomiarowych z czujnika położenia i kursu). Wektor sił i momentu sterowania sumowany jest z wektorem sił i momentu związanym z wprowadzoną poprawką od uchybu estymacji $\tilde{\mathbf{y}}_k$. Następnie do otrzymanego wektora dodawany jest wektor sił i momentu od zakłóceń środowiskowych oraz odejmowany jest wektor sił i momentu od sumy macierzy tłumienia i Coriolisa $\mathbf{N}(U_o)$. Wartość otrzymanych sił i momentu mnożona jest przez odwrotność macierzy bezwładności \mathbf{M} otrzymując na wyjściu z bloku estymowaną wartość przyspieszenia statku $\dot{\mathbf{v}}_{k|k}$. Dalej na schemacie poprzez całkowanie i macierz rotacji $\mathbf{R}(\psi)$ obliczane jest estymowane położenie i kurs statku $\boldsymbol{\eta}_{k|k}$, który jest wartością wyjściową z nieliniowego obserwatora.





Rys. 3.5: Schemat blokowy nieliniowego pasywnego obserwatora

3.5 Filtr cząsteczkowy

Filtr cząsteczkowy jest jednym z filtrów bazujących na algorytmach Monte Carlo [56]. W zależności od zastosowania jest wiele odmian filtru cząsteczkowego. W pracy zostanie przedstawiony filtr SIR (ang. *sampling importance resampling*). Jest to połączenie filtru cząsteczkowego SIS (ang. *sequential importance sampling*) z algorytmem ponownego próbkowania (ang. *resampling*) [2]. Zastosowanie algorytmu SIR umożliwia uniknięcie problemu degradacji próbek. Podstawowym założeniem filtru cząsteczkowego jest przedstawienie funkcji rozkładu prawdopodobieństwa a posteriori jako zbioru punktów z określonymi wagami, a wartość wyjściowa obliczana jest jako suma wszystkich próbek przemnożonych przez odpowiadające im wagi.

Na potrzeby dalszego opisu filtru wprowadzono następujące oznaczenia:

- $\{x_{0:k}^i, i = 0, \dots, N_s\}$ jest zbiorem losowych próbek w chwili k z obliczonymi dla nich wagami $\{w_{0:k}^i, i = 0, \dots, N_s\}$,
- $\{x_{0:k}^i, w_k^i\}_{i=1}^{N_s}$ jest oznaczeniem losowej próbki z funkcji rozkładu prawdopodobieństwa a posteriori $p(x_{0:k} | z_{1:k})$ z przypisaną jej wagą w_k^i ,
- $p(x_{0:k} | y_{1:k})$ jest funkcją prawdopodobieństwa wystąpienia zbioru stanu $x_{0:k}$ przy zbiorze pomiarów $y_{1:k}$,
- $x_{0:k} = \{x_j, j = 0, \dots, k\}$ jest zbiorem estymowanych stanów od chwili 0 do chwili k ,
- $y_{1:k} = \{y_j, j = 1, \dots, k\}$ jest zbiorem estymowanych pomiarów od chwili 1 do chwili k ,
- N_s to liczba losowych próbek przypadających na jedną chwilę k .

Dla filtru cząsteczkowego suma wag wszystkich próbek $x_{0:k}^i$ równa jest 1 co przedstawia następujące równanie $\sum_{i=1}^{N_s} \tilde{w}_k^i = 1$. Założenie to osiąga się przez normalizację wag. Znormalizowana waga \tilde{w}_k^i próbki obliczana jest za pomocą następującego wzoru $\tilde{w}_k^i = \frac{w_k^i}{\sum_{i=1}^{N_s} w_k^i}$. W takim przypadku funkcja rozkładu prawdopodobieństwa a posteriori dla chwili k opisywana jest równaniem:

$$p(x_{0:k}|y_{1:k}) \approx \sum_{i=1}^{N_s} \tilde{w}_k^i \delta(x_{0:k} - x_{0:k}^i). \quad (3.34)$$

gdzie: $\delta(x_{0:k} - x_{0:k}^i)$ jest deltą Diracka. Powyższe równanie zawiera dyskretną aproksymację wagi \tilde{w}_k^i dla rozkładu prawdopodobieństwa $p(x_{0:k}|y_{1:k})$. Wagi w algorytmie filtru cząsteczkowego obliczane są na podstawie zasady ważności próbek (ang. *importance sampling*). Zasada ważności próbek opiera się na kilku założeniach. Pierwszy z nich oznacza, że rozkład prawdopodobieństwa $p(x)$ zmiennej x jest wprost proporcjonalny do rozkładu $\pi(x)$ co opisuje równanie $p(x) \propto \pi(x)$, gdzie $\pi(\cdot)$ jest rozkładem prawdopodobieństwa. Rozkład $\pi(\cdot)$ posiada wysoką złożoność matematyczną, która jest trudna do opisu, ale dla $\pi(x)$ możliwe jest jego oszacowanie i jest ono proporcjonalne do $q(x)$. Próbki x^i , $i = 1, \dots, N_s$ są losowane z rozkładu prawdopodobieństwa $q(x)$. Wtedy wagi próbek można aproksymować z wykorzystaniem rozkładu prawdopodobieństwa $p(\cdot)$:

$$p(x_k) \approx \sum_{i=1}^{N_s} \tilde{w}_k^i \delta(x_k - x_k^i), \quad (3.35)$$

$$\tilde{w}_k^i \propto \frac{\pi(x_k^i)}{q(x_k^i)}, \quad (3.36)$$

gdzie:

- \tilde{w}_k^i jest znormalizowaną wagą dla i -tej próbki.

Dla każdej próbki $x_{0:k}^i$ wylosowanej z rozkładu ważności próbek $q(x_{0:k}|y_{1:k})$ dla zbioru wektora stanu $x_{0:k}$ i zbioru pomiarów $y_{1:k}$ znormalizowana waga próbki \tilde{w}_k^i określana jest wzorem:

$$\tilde{w}_k^i \propto \frac{p(x_{0:k}^i|y_{1:k})}{q(x_{0:k}^i|y_{1:k})}. \quad (3.37)$$

Oznacza to, że znormalizowana waga próbki \tilde{w}_k^i jest wprost proporcjonalna do iloczynu rozkładu prawdopodobieństwa a posteriori i rozkładu prawdopodobieństwa ważności próbek dla każdej z N_s próbek w chwili k . Filtr cząsteczkowy jest filtrem iteracyjnym. W każdej chwili k posiada zbiór próbek, które są aproksymacją $p(x_{0:k-1} | y_{1:k})$. Rozkład prawdopodobieństwa dla kolejnej chwili czasowych $p(x_{0:k} | y_{1:k})$ obliczany jest za pomocą modelu przejścia



3. Fuzja danych

$x_k = f_{nl}(x_{k-1})$. Znając funkcję rozkładu prawdopodobieństwa ważności próbek, można zapisać równanie w postaci:

$$q(x_{0:k}|y_{1:k}) = q(x_k|x_{0:k-1}, y_{1:k})q(x_{0:k-1}|y_{1:k-1}). \quad (3.38)$$

gdzie:

- $q(x_{0:k} | y_{1:k})$ - rozkład prawdopodobieństwa ważności próbek zbioru stanów $x_{0:k}$ dla zbioru pomiarów $y_{1:k}$,
- $q(x_k|x_{0:k-1}, y_{1:k})$ jest rozkładem prawdopodobieństwa ważności próbek osiągnięcia stanu x_k dla zbioru stanów $x_{0:k}$ i pomiarów $y_{1:k}$,
- $q(x_{0:k-1}|y_{1:k-1})$ - rozkład prawdopodobieństwa ważności próbek zbioru stanów $x_{0:k-1}$ dla zbioru pomiarów $y_{1:k-1}$.

Na podstawie powyższego równania (3.38), każdą z próbek można obliczyć z zależności: $x_{0:k}^i \sim q(x_{0:k} | y_{1:k})$ poprzez ekstrapolację zbioru próbek $x_{0:k-1}^i \sim q(x_{0:k-1} | y_{1:k-1})$ do kolejnej chwili k $x_k^i \sim q(x_k|x_{0:k-1}, y_{1:k})$. W celu wyprowadzenia wzoru na aktualizację wagi \tilde{w}_k^i na podstawie \tilde{w}_{k-1}^i należy zdefiniować:

- $p(x_{0:k-1} | y_{1:k-1})$ - rozkład prawdopodobieństwa otrzymania zbioru stanów $x_{0:k-1}$ przy zbiorze pomiarów $y_{1:k-1}$,
- $p(y_k | x_k)$ - rozkład prawdopodobieństwa uzyskania pomiaru y_k dla stanu x_k ,
- $p(x_k|x_{k-1})$ rozkład prawdopodobieństwa uzyskania stanu x_k jeżeli wcześniejszy stan wynosi x_{k-1} .

Korzystając z prawa Bayesa [16] aktualizację rozkładu prawdopodobieństwa osiągnięcia zbioru stanów $x_{0:k}$ przy zbiorze pomiarów $y_{1:k}$ jest równe:

$$\begin{aligned} p(x_{0:k} | y_{1:k}) &= \frac{p(y_k | x_{0:k}, y_{1:k-1})p(x_{0:k}|y_{1:k-1})}{p(y_k|y_{1:k-1})} \\ &= \frac{p(y_k | x_{0:k}, y_{1:k-1})p(x_k | x_{0:k-1}, y_{1:k-1})}{p(y_k | y_{1:k-1})}p(x_{0:k-1}|y_{1:k-1}) \\ &= \frac{p(y_k | x_k)p(x_k | x_{k-1})}{p(y_k | y_{1:k-1})}p(x_{0:k-1}|y_{1:k-1}) \\ &\propto p(y_k | x_k)p(x_k | x_{k-1})p(x_{0:k-1}|y_{1:k-1}) \end{aligned} \quad (3.39)$$

gdzie:

- $p(y_k|x_{0:k}, y_{1:k-1})$ jest rozkładem prawdopodobieństwa wystąpienia pomiaru y_k dla zbioru stanów $x_{0:k}$ i zbioru pomiarów $y_{1:k-1}$,
- $p(x_{0:k}|y_{1:k-1})$ jest rozkładem prawdopodobieństwa zbioru stanów $x_{0:k}$ dla zbioru pomiarów $y_{1:k-1}$,



- $p(y_k | y_{1:k-1})$ jest rozkładem prawdopodobieństwa wystąpienia pomiaru y_k dla zbioru pomiarów y_{k-1} .

Na podstawie wcześniejszych równań aktualizację wag można przedstawić jako:

$$\begin{aligned}\tilde{w}_k^i &\propto \frac{p(y_k | x_k^i) p(x_k^i | x_{k-1}^i) p(x_{0:k-1}^i | y_{1:k-1})}{q(x_k^i | x_{0:k-1}^i, y_{1:k}) q(x_{0:k-1}^i | y_{1:k-1})} \\ &= \tilde{w}_{k-1}^i \frac{p(y_k | x_k^i) p(x_k^i | x_{k-1}^i)}{q(x_k^i | x_{0:k-1}^i, y_{1:k})}.\end{aligned}\quad (3.40)$$

Przy dodatkowym założeniu, że $q(x_k | x_{0:k-1}, y_{1:k}) = q(x_k | x_{k-1}, y_k)$ rozkład prawdopodobieństwa próbki zależy tylko od x_{k-1} i y_k . Jeżeli do filtracji wykorzystujemy pomiar tylko z jednej chwili k , wtedy:

$$\tilde{w}_k^i \propto \tilde{w}_{k-1}^i \frac{p(y_k | x_k^i) p(x_k^i | x_{k-1}^i)}{q(x_k^i | x_{0:k-1}^i, y_k)}, \quad (3.41)$$

a funkcja rozkładu prawdopodobieństwa $p(x_k | y_{1:k})$ jest przybliżona przez:

$$p(x_k | y_{1:k}) \approx \sum_{i=1}^{N_s} \tilde{w}_k^i \delta(x_k - x_k^i). \quad (3.42)$$

gdzie: $\delta(x_k - x_k^i)$ jest deltą Diracka. Ponowne próbkowanie w algorytmie jest związane z pojęciem degradacji próbek. Zjawisko to jest spowodowane doбором funkcji rozkładu prawdopodobieństwa. Wraz z rosnącą liczbą iteracji waga próbek maleje do poziomu, w którym pojedyncze próbki mają wpływ na wynik filtracji. W takich sytuacjach zestaw próbek musi zostać wymieniony, próbki z małymi wagami powinny zostać zastąpione próbkami o większej wadze. Algorytm 4 przedstawia schemat działania algorytmu filtra cząsteczkowego typu SIR.

3. Fuzja danych

```

1 Algorytm: Filtr cząsteczkowy (PF):
2   for  $i=1; i < N_s; i++$  do
3      $\mathbf{x}_{k|k-1}^i = \mathbf{f}_{nl}(\mathbf{x}_{k-1|k-1}^i) + \mathbf{v}_i$            /* Predykcja stanu */
4      $\mathbf{z}_{k|k-1}^i = \mathbf{h}_{nl}(\mathbf{x}_{k|k-1}^i)$            /* Predykcja pomiaru */
5      $w_k^i = \left(\frac{1}{\sqrt{2*\pi*R}}\right) \exp -\frac{(\mathbf{y}_k - \mathbf{z}_{k|k-1}^i)^2}{2*R}$ 
6   end
7   for  $i=1; i < N; i++$  do
8      $\tilde{w}_k^i = \frac{w_k^i}{\sum_{i=1}^N w_k^i}$            /* Normalizacja wag */
9   end
10  for  $i=1; i < N_s; i++$  do
11     $SAMPLE = rand(0,1)$            /* Ponowne próbkowanie */
12     $SUM = 0$ 
13     $j = 1$ 
14    while  $SUM < SAMPLE$  do
15       $SUM = SUM + \tilde{w}_k^j$ 
16       $j++$ 
17    end
18     $\mathbf{x}_{k|k}^i = \mathbf{x}_{k|k-1}^j$ 
19     $\mathbf{z}_{k|k}^i = \mathbf{z}_{k|k-1}^j$ 
20  end
21   $\mathbf{x}_{k|k} = \frac{\sum_{i=1}^N \mathbf{x}_{k|k}^i}{N}$            /* Aktualizacja stanu */
22   $\mathbf{z}_{k|k} = \frac{\sum_{i=1}^N \mathbf{z}_{k|k}^i}{N}$            /* Aktualizacja pomiaru */
23  Wyjście  $\mathbf{x}_{k|k}, \mathbf{z}_{k|k}$            /* Wyjście */
24  Powrót do linii nr. 2
25

```

Algorytm 4: Filtr cząsteczkowy

Działanie algorytmu filtra cząsteczkowego bazuje na prowadzeniu równolegle N_s instancji wektora stanu zwanych próbkami. Algorytm rozpoczyna się od predykcji wektora stanu $\mathbf{x}_{k|k-1}$ i wektora pomiaru $\mathbf{z}_{k|k-1}$ nieliniowego modelu stanu obiektu (linia 3 i 4). Następnie na podstawie pomiaru \mathbf{y}_k z czujnika obliczana jest waga w_k^i każdego z wektorów stanu. Waga wyrażona jest jako rozkład gaussowski określający z jakim prawdopodobieństwem dana próbka może być rzeczywistym wektorem stanu gdzie R jest wariancją rozkładu (linia 5). Kolejnymi krokami jest normalizacja wag (linia 7, 8, 9). Część algorytmu odpowiedzialna za ponowne próbkowanie rozpoczyna się w linii 10 a kończy w linii 20. W linii 11 losowana jest liczba z zakresu $< 0, 1 >$ która zapisana jest do zmiennej $SAMPLE$. Następnie wartość zmiennej SUM ustawiana jest na 0. W pętli *while* do wartości SUM dodawane są kolejne znormalizowane wagi próbek (linia 15). Jeżeli suma wag okaże się większa od wartości $SAMPLE$ to zapamiętywana jest wartość zmiennej j . Kolejnym krokiem jest przepisanie do nowej puli próbek próbki o indeksie j z próbek wykorzystanych w algorytmie



w chwili k . Pętla ta wykonuje się tak długo aż zostanie wylosowana nowa pula próbek do kolejnej iteracji algorytmu. Estymowana wartość wektora stanu i pomiaru dla filtru cząsteczkowego określana jest jako wartość średnia ich wartości z nowej puli próbek (linia 21 i 22).

3.6 Fuzja danych w badaniach systemu DP

Statek z systemem DP jest jednostką autonomiczną (samowystarczalną), w której podsystem fuzji danych pełni bardzo ważną funkcję. Interpretacja oraz filtracja określonych sygnałów z urządzeń okrętowych umożliwia realizację sterowania i zapewnia bezpieczeństwo pracy. Sprzężenie zwrotne od poszczególnych podsystemów zainstalowanych na statku dostarcza informacji o warunkach atmosferycznych, prędkości obrotowej napędów, wychyleniu sterów, pozycji, kursie i prędkości statku. Algorytm fuzji danych odpowiedzialny jest za połączenie informacji z czujników pomiarowych oraz diagnostyka poprawności ich działania. Na statkach klasy DP dla zwiększenia niezawodności i dyspozycyjności statku instalowane są nadmiarowe struktury podsystemów, które w sytuacjach awaryjnych umożliwiają dalszą realizację zadania.

W pracy do interpretacji oraz filtracji sygnałów pomiarowych zaproponowano algorytm kaskadowego połączenia filtru cząsteczkowego i rozszerzonego filtru Kalmana, którego zadaniem jest filtracja zakłóceń pomiarowych oraz praca z nadmiarowymi systemami pomiarowymi. Algorytm ten umożliwia szybką diagnostykę uszkodzonych podsystemów oraz minimalizację wpływu uszkodzeń na jakość realizacji zadania dynamicznego pozycjonowania. Zaproponowane rozwiązanie łączy cechy filtru cząsteczkowego umożliwiającego pracę z danymi nadmiarowymi oraz wysoką jakość filtracji uzyskaną poprzez wykorzystanie rozszerzonego filtru Kalmana. Schemat działania algorytmu przedstawiono poniżej.

3. Fuzja danych

```

1 Algorytm: Kaskadowe połączenie filtra cząsteczkowego i
  rozszerzonego filtra Kalmana (PKF):
2   for  $i=1; i < N_s; i++$  do
3      $\mathbf{x}_{k|k-1}^i = \mathbf{f}_{nl}(\mathbf{x}_{k-1|k-1}^i) + \mathbf{v}_i$            /* Predykcja stanu */
4      $\mathbf{z}_{k|k-1}^i = \mathbf{h}_{nl}(\mathbf{x}_{k|k-1}^i)$                  /* Predykcja pomiaru */
5      $w_k^i = \left(\frac{1}{\sqrt{2 \cdot \pi \cdot R}}\right) \exp - \frac{(y_k - z_{k|k-1}^i)^2}{2R}$ 
6   end
7   for  $i=1; i < N_s; i++$  do
8      $\tilde{w}_k^i = \frac{w_k^i}{\sum_{i=1}^N w_k^i}$                        /* Normalizacja wag */
9   end
10  for  $i=1; i < N_s; i++$  do
11     $SAMPLE = rand(0,1)$                              /* Ponowne próbkowanie */
12     $SUM = 0$ 
13     $j = 1$ 
14    while  $SUM < SAMPLE$  do
15       $SUM = SUM + \tilde{w}_k^j$ 
16       $j++$ 
17    end
18     $\mathbf{x}_{k|k}^i = \mathbf{x}_{k|k-1}^j$ 
19     $\mathbf{z}_{k|k}^i = \mathbf{z}_{k|k-1}^j$ 
20  end
21   $\mathbf{z}_{k|k}^{PF} = \frac{\sum_{i=1}^{N_s} \mathbf{y}_{k|k}^i}{N}$                  /* Aktualizacja pomiaru */
22   $\mathbf{x}_{k|k-1} = \mathbf{f}_{nl}(\mathbf{x}_{k-1|k-1})$                  /* Predykcja stanu */
23   $\mathbf{z}_{k|k-1} = \mathbf{h}_{nl}(\mathbf{x}_{k|k-1})$                  /* Predykcja pomiaru */
24   $\mathbf{A}_k = \mathbf{I} + \left[ \frac{\delta \mathbf{f}_{nl}(\mathbf{x}_{k-1|k-1})}{\delta \mathbf{x}_j} \right]$ 
25   $\mathbf{H}_k = \mathbf{I} + \left[ \frac{\delta \mathbf{h}_{nl}(\mathbf{x}_{k|k-1})}{\delta \mathbf{x}_j} \right]$ 
26   $\mathbf{P}_{k|k-1} = \mathbf{A}_k \cdot \mathbf{P}_{k-1|k-1} \cdot \mathbf{A}_k^T + \mathbf{Q}_K$ 
27  Aktualizacja:                                       /* Aktualizacja */
28   $\mathbf{I}_K = (\mathbf{z}_{k|k}^{PF} - \mathbf{z}_{k|k-1})$ 
29   $\mathbf{S}_K = \mathbf{H}_k \cdot \mathbf{P}_{k|k-1} \cdot \mathbf{H}_k^T + \mathbf{R}_K$ 
30   $\mathbf{K}_K = \mathbf{P}_{k|k-1} \cdot \mathbf{H}_k^T \cdot \mathbf{S}_K^{-1}$ 
31   $\mathbf{x}_{k|k} = \mathbf{x}_{k|k-1} + \mathbf{K}_K \cdot \mathbf{I}_K$              /* Aktualizacja stanu */
32   $\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_K \cdot \mathbf{S}_K \cdot \mathbf{K}_K^T$ 
33   $\mathbf{z}_{k|k} = h_k(\mathbf{x}_{k|k})$                        /* Aktualizacja pomiaru */
34  Wyjście  $\mathbf{x}_{k|k}, \mathbf{z}_{k|k}$                          /* Wyjście */
35  Powrót do linii nr. 2
36

```

Algorytm 5: Kaskadowe połączenie filtra cząsteczkowego i rozszerzonego filtra Kalmana



Zaprojektowany algorytm fuzji danych dla systemu dynamicznego pozycjonowania statku składa się z filtru cząsteczkowego i rozszerzonego filtru Kalmana. Pierwszym krokiem algorytmu jest predykcja N_s próbek filtru cząsteczkowego (linia 3,4) i obliczenie wag dla każdej z próbek z wykorzystaniem rozkładu Gaussa, i wektora pomiaru \mathbf{y}_k (linia 5). Następnie w linii od 7 do 9 następuje normalizacji wag \tilde{w}_k^i której równanie zostało zaprezentowane we wcześniejszym podrozdziale. Aby zapobiec degradacji próbek, w linii od 10 do 20 zawarto procedurę ponownego próbkowania. W linii 11 losowana jest wartość z zakresu $\langle 0, 1 \rangle$, która zapisywana jest do zmiennej *SAMPLE*. Następnym krokiem jest zliczanie wag próbek od pierwszej $j = 1$ do momentu aż suma wag będzie większa od wartości zmiennej *SAMPLE*. Następnie dokonywane jest przypisanie cząstki o indeksie j ze obecnej puli cząstek do nowej puli (linia 18 i 19). Procedura ta powtarzana jest tak długo aż zostanie wylosowana cała pula nowych próbek. Ostatnim krokiem związanym z filtrem cząsteczkowym jest obliczenie wartości średniej estymowanego wektora pomiaru $\mathbf{z}_{k|k}^{PF}$ z próbek $\mathbf{z}_{k|k}^i$ (linia 21). Przechodząc do rozszerzonego filtru Kalmana, wykonywana jest predykcja stanu $\mathbf{x}_{k|k-1}$ z wykorzystaniem estymowanego wektora stanu z poprzedniej chwili czasu $\mathbf{x}_{k-1|k-1}$ (linia 22). Następnie wykorzystując predykcję stanu, obliczana jest predykcja pomiaru $\mathbf{z}_{k|k-1}$ (linia 23). Natomiast w linii 24 i 25 następuje linearyzacja funkcji przejścia i pomiaru. Po obliczeniu linearyzacji możliwe jest predykcja macierzy kowariancji stanu $\mathbf{P}_{k|k-1}$ (linia 26). Aktualizacja stanu dla rozszerzonego filtru Kalmana rozpoczyna się w linii 27. W linii 28 algorytmu następuje obliczenie innowacji, wykorzystując estymowany wektor pomiaru z filtru cząsteczkowego $\mathbf{z}_{k|k}^{PF}$ i predykcji pomiaru $\mathbf{z}_{k|k-1}$ z rozszerzonego filtru Kalmana. W kolejnych krokach obliczane są macierz kowariancji innowacji \mathbf{S}_K (linia 29) i macierz wzmocnień Kalmana \mathbf{K}_K (linia 30). Wykorzystując wcześniejsze obliczenia w linii 31 i 32 obliczana jest estymowana wartość wektora stanu $\mathbf{x}_{k|k}$ i macierz kowariancji stanu $\mathbf{P}_{k|k}$. Wyjściem z filtru jest estymowany wektor stanu $\mathbf{x}_{k|k}$ i estymowany pomiar $\mathbf{z}_{k|k}$.

Wyniki badań symulacyjnych dla algorytmu 5 przedstawiono w rozdziale 5 oraz porównano je z działaniem rozszerzonego filtru Kalmana (algorytm 2), filtru cząsteczkowy (algorytm 4) oraz nieliniowego obserwatora (algorytm 6). Ze względu na wykorzystanie w pracy pomiaru położenia $\boldsymbol{\eta}$ i prędkości wzdłużnej u i poprzecznej v statku dynamicznie pozycjonowanego, konieczna była modyfikacja nieliniowego obserwatora (algorytm 3). Aby w algorytmie 3 uwzględnić pomiar prędkości, wprowadzono wzmocnienie k_4 do równania prędkości w linii 5 (algorytm 6).



3. Fuzja danych

```

1 Algorytm: Pasywny nieliniowy obserwator:
2    $\dot{\mathbf{b}}_{k|k} = \mathbf{k}_1 \tilde{\mathbf{y}}_{k-1}$ 
3    $\mathbf{b}_{k|k} = \mathbf{b}_{k-1|k-1} + \dot{\mathbf{b}}_{k|k}$ 
4    $\dot{\mathbf{v}}_{k|k} = \frac{-\mathbf{N}(U_o) \mathbf{v}_{k-1|k-1} + \mathbf{R}^T(\psi) \mathbf{b}_{k-1|k-1} + \boldsymbol{\tau}_c + \mathbf{k}_2 \mathbf{y}_{k-1}}{\mathbf{M}}$ 
5    $\mathbf{v}_{k|k} = \mathbf{v}_{k-1|k-1} + \dot{\mathbf{v}}_{k|k} T + \mathbf{k}_4 \tilde{\mathbf{y}}_{k-1}$ 
6    $\dot{\boldsymbol{\eta}}_{k|k} = \mathbf{R}(\psi) \mathbf{v}_{k|k}$ 
7    $\boldsymbol{\eta}_{k|k} = \boldsymbol{\eta}_{k-1|k-1} + \dot{\boldsymbol{\eta}}_{k|k} T + \mathbf{k}_3 \tilde{\mathbf{y}}_{k-1}$ 
8    $\tilde{\mathbf{y}}_k = \mathbf{z}_k - [\boldsymbol{\eta}_{k|k}; \dot{\mathbf{v}}_{k|k}]$ 
9    $\mathbf{x}_{k|k} = [\boldsymbol{\eta}_{k|k}; \mathbf{v}_{k|k}; \dot{\mathbf{v}}_{k|k}; \mathbf{b}_{k|k}]$ 
10  Wyjście  $\mathbf{x}_{k|k}$  /* Wyjście */
11 Powrót do linii nr. 2

```

Algorytm 6: Pasywny nieliniowy obserwator wykorzystywany w symulacjach

Z kolei do badań wykorzystujących redundantne systemy pomiarowe konieczna jest modyfikacja nieliniowego obserwatora i rozszerzonego filtru Kalmana. Do tych algorytmów dodano procedurę łączenia danych z kilku czujników do pojedynczego wirtualnego pomiaru algorytm fuzji danych (algorytm 7). Dla algorytmu 2 procedura ta została zaimplementowana między linią 4 a 5, natomiast w przypadku algorytmu 6 fuzja danych została dodana między linią 7 i 8. Schemat procedury fuzji danych zaprezentowano w algorytmie 7.

```

1 Algorytm: Fuzja danych:
2    $SUM = 0$ 
3   for  $i=1:N_c$  do
4      $w_i = \frac{1}{|z_{(k|k-1)} - y_k^i|}$ 
5      $SUM = SUM + w_i$ 
6   end
7    $\hat{z}_k = 0$ 
8   for  $i=1:N_c$  do
9      $\tilde{w}_i = \frac{w_i}{SUM}$ 
10     $\hat{z}_k = \hat{z}_k + z_k^i \cdot \tilde{w}_i$ 
11  end
12  Wyjście  $\hat{z}_k$  /* Wyjście */
13  Powrót do linii nr. 2
14

```

Algorytm 7: Schemat procedury fuzji danych

Symboly występujące w algorytmie 7 zostały opisane poniżej:

- \hat{z}_k jest obliczoną wartością pomiaru,
- y_k^i to pomiar z pojedynczego czujnika,
- $z_{(k|k-1)}$ predykcja pomiaru,
- w_i waga dla pomiaru z pojedynczego czujnika przed normalizacją,



- \tilde{w}_i waga dla pomiaru z pojedynczego czujnika po normalizacją,
- SUM suma wag dla wszystkich czujników.
- N_c - liczba czujników

Algorytm 7 do obliczenia wirtualnego pomiaru wykorzystuje predykcję pomiaru $z_{k|k-1}$ oraz pomiar z liczby N_c czujników. Pomiar z pojedynczego czujnika pomiarowego zapisano jako y_k^i . Pierwszym krokiem algorytmu jest obliczenie wag dla każdego z pomiarów (linia 4), wykorzystując następującą funkcję:

$$w_i = \frac{1}{|z_{(k|k-1)} - y_k^i|}. \quad (3.43)$$

Następnie wagi dla każdego z czujników są normalizowane (linia 9). Wartość wirtualnego pomiaru \hat{z}_k obliczana jest jako suma iloczynów pomiarów y_k^i i przypisanych im znormalizowanych wag \tilde{w}_i .

Rozdział 4

Sterowanie

System dynamicznego pozycjonowania jest złożonym systemem pełniącym funkcje nadzorcze i sterujące. W celu realizacji swoich zadań integruje on podsystemy, napędy oraz stery znajdujące się na statku. Komputerowe algorytmy umożliwiają sterowanie położeniem i kursem statku, wykorzystując napędy, pędniki oraz stery zainstalowane na jednostce. Procedura fuzji danych zbiera informacje z referencyjnych czujników położenia, czujników ruchu, żyrokompasów oraz innych systemów pomiarowych związanych z warunkami atmosferycznymi. Analiza otrzymanych danych dostarcza informacji o pozycji, kursie i prędkości statku oraz o wielkości i kierunku sił środowiskowych wpływających na położenie i kurs statku. Algorytmy sterowania zawierają matematyczny model tego obiektu, który obejmuje kinematykę, dynamikę, napędy oraz wpływ zjawisk środowiskowych na położenie i kurs statku. Połączenie modelu i informacji z procedury fuzji danych umożliwia obliczenie potrzebnej mocy pędników i kątów dla sterów umożliwiających realizację wyznaczonego zadania.

Metody sterowania wykorzystywane w systemach dynamicznego pozycjonowania są tematami wielu prac badawczych. Do sterowania statkiem DP stosowane są różne koncepcje algorytmów:

- regulatory typu PID (ang. *proportional-integral-derivative controller*) [21],
- regulatory typu LQR (ang. *linear-quadratic regulator*) [3], [31],
- metoda sterowania H_∞ [32],
- regulatory rozmyte (FL, ang. *fuzzy logic*) [87],
- backstepping [107],
- regulatory ślizgowe [94],
- sieci neuronowe (NN, ang. *neural network*) [59],
- sterowanie predykcyjne (MPC, ang. *model predictive control*) [20].

Powyższe algorytmy w systemie dynamicznego pozycjonowania realizują trzy podstawowe zadania: utrzymywanie statku/obiektu morskiego w zadanej pozycji i kursie, sterowanie statkiem do zadanej pozycji i kursu oraz nadążanie za zadaną trajektorią z małą prędkością.



4.1 PID

Regulator PID (ang. *proportional-integral-derivative controller*) jest najczęściej wykorzystywanym algorytmem w systemach sterowania dla obiektów SISO (ang. *single input single output*) i MIMO (ang. *multi input multi output*).

Regulator PID dla statku z systemem dynamicznego pozycjonowania zaprojektowano wzorując się na modelu sprężyny z tłumieniem (4.1)[23]

$$m\ddot{x} + d\dot{x} + k_s x = \tau + w_s, \quad (4.1)$$

który odwzorowuje jeden ze stopni swobody statku DP [24], gdzie:

- m - współczynnik bezwładności/masy,
- d - współczynnik tłumienia,
- k_s - wzmocnienie sprzężenia zwrotnego,
- τ - siła sterująca,
- $w_s = b$ - siła wynikające z oddziaływania zakłóceń środowiskowych.

Dla regulatora PID ze sprzężeniem zwrotnym od przyspieszenia siły sterującej opisane są poniższym równaniem [23]:

$$\tau = \tau_{PID} - K_m \ddot{x}, \quad (4.2)$$

gdzie $K_m > 0$ jest wzmocnieniem sprzężenia zwrotnego od przyspieszenia (ang. *acceleration feedback*) τ_{PID} jest wektorem sił sterujących z regulatora PID. Podstawiając równanie (4.2) do równania (4.1), otrzymujemy:

$$(m + K_m) \ddot{x} + d\dot{x} + k_s x = \tau_{PID} + b. \quad (4.3)$$

Kolejnym krokiem w projektowaniu regulatora jest przekształcenie wzoru (4.3) do postaci:

$$\ddot{x} + \frac{d}{(m + K_m)} \dot{x} + \frac{k_s}{(m + K_m)} x = \frac{1}{(m + K_m)} \tau_{PID} + \frac{1}{(m + K_m)} b. \quad (4.4)$$

Po przekształceniu (4.4) można przyjąć, że poprzez człon K_m (wzmocnienie sprzężenia zwrotnego od przyspieszenia) zmniejszamy wpływ zakłóceń środowiskowych b . Wartość b w równaniu (4.4) mnożona jest przez odwrotność współczynnika $(m + K_m)$, co zmniejsza wpływ zakłóceń środowiskowych na statek. Zaproponowane rozwiązanie można zmodyfikować tak jak w pracy [24], zastępując człon K_m w równaniu (4.2) filtrem dolnoprzepustowym $h_m(s)$:

$$h_m(s) = \frac{K_m}{1 + T_m s}. \quad (4.5)$$

Przy założeniu, że $K_m > 0$, $T_m > 0$ i podstawieniu do równania (4.3) otrzymano równanie:




$$\left(m + \frac{K_m}{1 + T_m s}\right) \ddot{x} + d\dot{x} + k_s x = \tau_{PID} + b. \quad (4.6)$$

Sygnal z regulatora PID obliczany jest na podstawie prostego prawa sterowania

$$\tau_{PID} = -K_p \tilde{x} - K_d \dot{x} - K_I \int \tilde{x}(\tau) d\tau, \quad (4.7)$$

gdzie $\tilde{x} = x - x_d$ jest uchybem regulacji, x jest stanem obiektu i x_d jest zadany stanem. Pełen schemat regulatora PID dla sprężyny z tłumieniem, sprzężeniem zwrotnym od przyspieszenia i filtrem dolnoprzepustowym został przedstawiony poniżej.



Rys. 4.1: Schemat układu sterowania PID ze sprzężeniem zwrotnym od przyspieszenia

Rozszerzenie modelu sprężyny z tłumieniem można przyrównać do modelu statku DP o 3 stopniach swobody. Wymaga to podstawienia do równania (4.1) macierzy $(\mathbf{M}, \mathbf{N}(U_o), \mathbf{R}(\psi))$ i wektorów $(\boldsymbol{\eta}, \mathbf{v}, \boldsymbol{\tau}, \mathbf{b})$ z równań (2.1) i (2.13), które reprezentują matematyczny model statku. Poniżej przedstawiono, zależności wektorów i macierzy z modelu statku do zmiennych z modelu sprężyny z tłumieniem:

- stan obiektu $x := \mathbf{x} = [\boldsymbol{\eta}, \mathbf{v}]$,
- siłę $\tau := \boldsymbol{\tau}$,
- siłę od zakłóceń środowiskowych $b := \mathbf{b}$,
- współczynnik bezwładności $m := \mathbf{M}$,
- współczynnik tłumienia $d := \mathbf{N}(U_o)$.



4. Sterowanie

- wzmocnienie sprzężenia zwrotnego od przyspieszenia $h_m(s) := \mathbf{K}_m$.

Prezentowany model regulatora DP przyjmuje założenie, że położenie $\boldsymbol{\eta}$ i prędkość $\dot{\boldsymbol{\eta}}$ są znane. Rozważamy następujące prawo sterowania:

$$\boldsymbol{\tau}_{PID} = -\mathbf{K}_p \tilde{\boldsymbol{\eta}} - \mathbf{K}_d \dot{\tilde{\boldsymbol{\eta}}} - \mathbf{K}_i \int_0^t \tilde{\boldsymbol{\eta}}(\tau) d\tau, \quad (4.8)$$

gdzie uchyb sterowania położeniem jest równy $\tilde{\boldsymbol{\eta}} = \boldsymbol{\eta} - \boldsymbol{\eta}_d$, a $\boldsymbol{\eta}_d$ jest zadanym położeniem. Po podstawieniu macierzy $(\mathbf{M}, \mathbf{N}(U_o), \mathbf{R}(\psi))$ i wektorów $(\boldsymbol{\eta}, \mathbf{v}, \boldsymbol{\tau}, \mathbf{b})$ z modelu statku i równania (4.8) do równania (4.6) otrzymujemy następujący model:

$$\begin{aligned} (\mathbf{M} + \mathbf{K}_m) \dot{\mathbf{v}} + \left(\mathbf{N}(U_o) + \mathbf{R}^T(\psi) \mathbf{K}_d \mathbf{R}(\psi) \right) \mathbf{v} + \mathbf{R}^T(\psi) \mathbf{K}_p \tilde{\boldsymbol{\eta}} + \\ + \mathbf{R}^T(\psi) \mathbf{K}_i \int_0^t \tilde{\boldsymbol{\eta}}(\tau) d\tau = \mathbf{b}. \end{aligned} \quad (4.9)$$

4.2 Regulator backstepping

Wielowymiarowy regulator backstepping (BS) jest metodą sterowania, w której wektor $\boldsymbol{\tau}$ obliczany jest wektorową metodą backstepping. Do obliczenia wartości sterowania wykorzystywana jest teoria stabilności Lapunowa [24].

Do projektowania regulatora backstepping wykorzystano równania modelu statku DP w postaci,

$$\mathbf{M} \dot{\mathbf{v}} + \mathbf{N}(U_o) \mathbf{v} = \boldsymbol{\tau}_c + \mathbf{R}^T(\psi) \mathbf{b}, \quad (4.10)$$

$$\dot{\boldsymbol{\eta}} = \mathbf{R}(\psi) \mathbf{v}. \quad (4.11)$$

Opis modelu został zawarty w rozdziale 2. W celu wyprowadzenia prawa sterowania dla statku DP wprowadzono zmienne referencyjne $\boldsymbol{\eta}_r$ [24]:

$$\dot{\boldsymbol{\eta}}_r := \dot{\boldsymbol{\eta}}_d - \Lambda \tilde{\boldsymbol{\eta}}, \quad (4.12)$$

$$\mathbf{v}_r := \mathbf{R}(\psi)^{-1} \dot{\boldsymbol{\eta}}_r, \quad (4.13)$$

$$\tilde{\boldsymbol{\eta}} = \boldsymbol{\eta} - \boldsymbol{\eta}_d, \quad (4.14)$$

gdzie $\boldsymbol{\eta}_d$ jest zadanym położeniem, $\tilde{\boldsymbol{\eta}}$ jest uchybem położenia, a $\Lambda > 0$ i jest macierzą diagonalną. Zmienne referencyjne $\boldsymbol{\eta}_r$ będą wykorzystywane w funkcjach Lapunowa.

Kolejnym krokiem w projektowaniu algorytmu backstepping z regulacją uchybu położenia do zera jest założenie nowych zmiennych sterujących.

$$\mathbf{s} = \dot{\boldsymbol{\eta}} - \dot{\boldsymbol{\eta}}_r. \quad (4.15)$$

Przy założeniu, że $\dot{\tilde{\boldsymbol{\eta}}} = \dot{\boldsymbol{\eta}} - \dot{\boldsymbol{\eta}}_d$, po podstawieniu (4.12) do (4.15) otrzymamy bezpośrednią zależność nowej zmiennej od uchybu położenia:

$$\mathbf{s} = \dot{\tilde{\boldsymbol{\eta}}} + \Lambda \tilde{\boldsymbol{\eta}}. \quad (4.16)$$



Do projektowania sterowania backstepping wykorzystano przekształcenie równań modelu statku, które zostało przedstawione w równaniu (2.22). Do równania (2.22) podstawiono równanie (4.15) w wyniku czego otrzymano:

$$\mathbf{J}(\boldsymbol{\eta}) \dot{\mathbf{s}} = -\mathbf{C}(\boldsymbol{\eta}, \dot{\boldsymbol{\eta}}) \mathbf{s} - \mathbf{F}(\boldsymbol{\eta}) \mathbf{s} + \boldsymbol{\tau}_c^* + \mathbf{J}(\boldsymbol{\eta}) \ddot{\boldsymbol{\eta}}_r - \mathbf{C}(\boldsymbol{\eta}, \dot{\boldsymbol{\eta}}) \dot{\boldsymbol{\eta}}_r - \mathbf{F}(\boldsymbol{\eta}) \dot{\boldsymbol{\eta}}_r + \mathbf{b}. \quad (4.17)$$

Opis macierzy $\mathbf{J}(\boldsymbol{\eta})$, $\mathbf{C}(\boldsymbol{\eta}, \dot{\boldsymbol{\eta}})$, $\mathbf{F}(\boldsymbol{\eta})$ i wektora $\boldsymbol{\tau}^*$ przedstawiono w podrozdziale 2.2. Następnie obliczono pochodną uchybu położenia na podstawie wzoru (4.11), otrzymując poniższe równanie w postaci:

$$\dot{\boldsymbol{\eta}} - \dot{\boldsymbol{\eta}}_d = \mathbf{R}(\boldsymbol{\psi})(\mathbf{v} - \mathbf{v}_d), \quad (4.18)$$

gdzie \mathbf{v}_d jest zadany wektorem prędkości oraz

$$\dot{\boldsymbol{\eta}}_d = \mathbf{R}(\boldsymbol{\psi}) \mathbf{v}_d. \quad (4.19)$$

Wektor prędkości statku \mathbf{v} przyjęto jako wirtualny wektor sterowania w postaci:

$$\mathbf{R}(\boldsymbol{\psi}) \mathbf{v} := \mathbf{s} + \boldsymbol{\alpha}_1, \quad (4.20)$$

gdzie $\boldsymbol{\alpha}_1$ jest wektorem funkcji stabilizujących. Podstawiając równanie (4.19) do równania pochodnej uchybu położenia (4.18) uzyskano:

$$\dot{\tilde{\boldsymbol{\eta}}} = \mathbf{s} + \boldsymbol{\alpha}_1 - \mathbf{R}(\boldsymbol{\psi}) \mathbf{v}_d. \quad (4.21)$$

Podstawiając (4.16) do (4.20) uzyskano:

$$\boldsymbol{\alpha}_1 = \dot{\boldsymbol{\eta}}_r = \dot{\boldsymbol{\eta}}_d - \Lambda \tilde{\boldsymbol{\eta}}, \quad (4.22)$$

Następnie pierwsza sterująca funkcja Lapunowa (CLF, ang. *control Lapunove function*) [23] została określona jako:

$$\mathbf{V}_1 = \frac{1}{2} \tilde{\boldsymbol{\eta}}^T \mathbf{K}_p \tilde{\boldsymbol{\eta}}, \quad \mathbf{K}_p = \mathbf{K}_p^T > 0. \quad (4.23)$$

Pochodną funkcji Lapunowa obliczono, wykorzystując równanie (4.16) i (4.23):

$$\dot{\mathbf{V}}_1 = \tilde{\boldsymbol{\eta}}^T \mathbf{K}_p \dot{\tilde{\boldsymbol{\eta}}} = \tilde{\boldsymbol{\eta}}^T \mathbf{K}_p (-\Lambda \tilde{\boldsymbol{\eta}} + \mathbf{s}) = -\tilde{\boldsymbol{\eta}}^T \mathbf{K}_p \Lambda \tilde{\boldsymbol{\eta}} + \mathbf{s}^T \mathbf{K}_p \tilde{\boldsymbol{\eta}}. \quad (4.24)$$

Kolejnym krokiem algorytmu backstepping jest wyprowadzenie drugiej sterującej funkcji Lapunowa z wykorzystaniem (4.23), (4.24) i (4.17) i jej pochodnej:

$$\mathbf{V}_2 = \frac{1}{2} \mathbf{s}^T \mathbf{J}(\boldsymbol{\eta}) \mathbf{s} + \mathbf{V}_1, \quad (4.25)$$

$$\dot{\mathbf{V}}_2 = \mathbf{s}^T \mathbf{J}(\boldsymbol{\eta}) \dot{\mathbf{s}} + \frac{1}{2} \mathbf{s}^T \dot{\mathbf{J}}(\boldsymbol{\eta}) \mathbf{s} + \dot{\mathbf{V}}_1, \quad (4.26)$$

$$\begin{aligned} \dot{\mathbf{V}}_2 &= -\mathbf{s}^T [\mathbf{C}(\boldsymbol{\eta}, \dot{\boldsymbol{\eta}}) + \mathbf{F}(\boldsymbol{\eta})] \mathbf{s} \\ &+ \mathbf{s}^T \mathbf{R}(\boldsymbol{\psi})^{-T} \left[\boldsymbol{\tau}_c \mathbf{u} + \mathbf{R}^T(\boldsymbol{\psi}) \mathbf{b} - \mathbf{M} \dot{\mathbf{v}}_r - \mathbf{N}(U_o) \mathbf{v}_r \right] \\ &+ \frac{1}{2} \mathbf{s}^T \dot{\mathbf{J}}(\boldsymbol{\eta}) \mathbf{s} - \tilde{\boldsymbol{\eta}}^T \mathbf{K}_p \Lambda \tilde{\boldsymbol{\eta}} + \mathbf{s}^T \mathbf{K}_p \tilde{\boldsymbol{\eta}}. \end{aligned} \quad (4.27)$$



4. Sterowanie

Z własności macierzy skośnie symetrycznych [24] można przyjąć że:

$$\mathbf{s}^T (\dot{\mathbf{J}}(\boldsymbol{\eta}) - 2\mathbf{C}(\boldsymbol{\eta}, \dot{\boldsymbol{\eta}})) \mathbf{s} = 0, \quad \forall \mathbf{v}, \boldsymbol{\eta}, \mathbf{s}. \quad (4.28)$$


Po (4.28) podstawieniu do równania (4.27):

$$\begin{aligned} \dot{\mathbf{V}}_2 = \mathbf{s}^T \mathbf{R}^{-T}(\psi) \left[\boldsymbol{\tau}_c + \mathbf{R}^T(\psi) \mathbf{b} - \mathbf{M} \dot{\mathbf{v}}_r - \mathbf{N}(\mathbf{v}) \mathbf{v}_r + \mathbf{R}(\psi) \mathbf{K}_p \tilde{\boldsymbol{\eta}} \right] \\ - \mathbf{s}^T \mathbf{F}(\boldsymbol{\eta}) \mathbf{s} - \tilde{\boldsymbol{\eta}}^T \mathbf{K}_p \Lambda \tilde{\boldsymbol{\eta}}, \end{aligned} \quad (4.29)$$

otrzymano następujące prawo sterowania:

$$\boldsymbol{\tau}_c = -\mathbf{R}^T(\psi) \mathbf{b} + \mathbf{M} \dot{\mathbf{v}}_r + \mathbf{N}(U_o) \mathbf{v}_r - \mathbf{R}^T(\psi) \mathbf{K}_p \tilde{\boldsymbol{\eta}} - \mathbf{R}^T(\psi) \mathbf{K}_d \mathbf{s}. \quad (4.30)$$

Schemat blokowy dla sterowania backstepping zaprezentowano poniżej:



Rys. 4.2: Schemat blokowy regulatora backstepping

W rezultacie otrzymujemy następującą postać funkcji Lapunowa:

$$\dot{\mathbf{V}}_2 = -\mathbf{s}^T (\mathbf{F}(\boldsymbol{\eta}) + \mathbf{K}_d) \mathbf{s} - \tilde{\boldsymbol{\eta}}^T \mathbf{K}_p \Lambda \tilde{\boldsymbol{\eta}}, \quad (4.31)$$

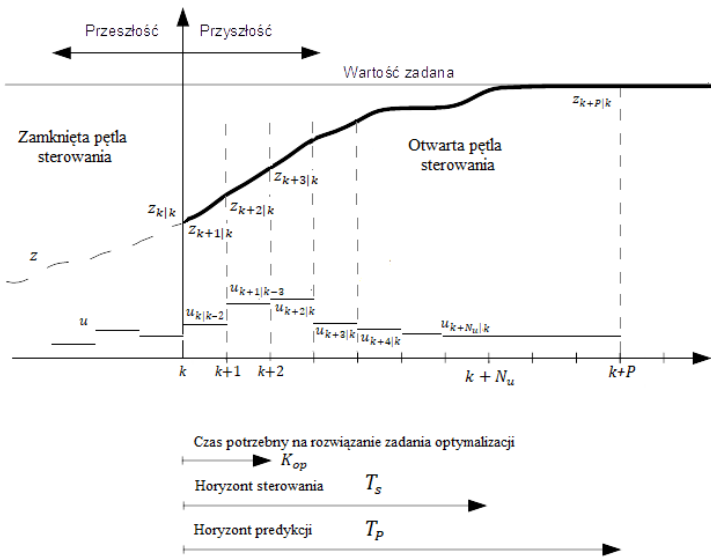
zakładając że $\mathbf{K}_p > 0$ i $\mathbf{F}(\boldsymbol{\eta}) + \mathbf{K}_d > 0$. W przypadku, gdy \mathbf{V}_2 jest dodatnio zdefiniowana i $\dot{\mathbf{V}}_2$ jest ujemnie zdefiniowana spełniony jest warunek stabilności w sensie globalnej stabilności eksponencjalnej (ang. *global exponential stability*) korzystając bezpośrednio z teorii Lapunowa. Dowód na stabilność układu został wprowadzony w [24].

4.3 Sterowanie predykcyjne

Sterowanie predykcyjne (MPC, ang. model predictive control), inaczej sterowanie z przesuwym horyzontem (RHC, ang. receding horizon control), jest metodą



sterowania obiektem dynamicznym [96]. Regulator predykcyjny w każdej chwili, k posiadając informację o aktualnym stanie wektora stanu $\mathbf{x}_{k|k}$, dynamicznym modelem obiektu, pomiarach zmiennych wyjściowych $\mathbf{y}_{1:k}$ oraz założonej trajektorii. Na podstawie wszystkich powyższych informacji wyznaczane są wartości sterowania $u_k = [u_{k+K_{op}|k}, u_{k+K_{op}+1|k}, \dots, u_{k+N_u-1|k}]$ gdzie K_{op} oznacza czas potrzebny na rozwiązanie zadania optymalizacji funkcji celu, a N_u oznacza liczbę kroków czasowych na horyzont sterowania T_s . Indeksy dolne przy wektorze sterowania i wektorze estymowanego wyjścia $k+P|k$ należy rozumieć jako wartość tych wektorów w chwili $k+P$, która została obliczona na podstawie danych z chwili k gdzie P może być dowolną liczbą całkowitą. Wartość wektora sterowania wyznaczana jest w taki sposób aby zminimalizować różnicę pomiędzy predykowanymi wyjściami obiektu $z_{k+P|k}$ w chwili k a założoną trajektorią wartości zadanych na horyzoncie predykcyjnym T_P ($l = 1, 2, \dots, P$) składającym się z P chwil. Funkcja celu za pomocą równania matematycznego określa kryterium regulacji. Równanie to w procesie optymalizacji jest minimalizowane w celu znalezienia najlepszego rozwiązania. Następnie cała procedura jest powtarzana dla każdego kolejnego kroku $k+K_{op}$. Do sterowania obiektem wykorzystywanych jest tylko kilka próbek z horyzontu sterowania. Liczba tych próbek określona jest przez czas potrzebny do obliczenia nowego sterowania K_{op} . W sterowaniu predykcyjnym horyzont sterowania nie musi być równy horyzontowi predykcyjnemu. Zależności czasowe sterowania predykcyjnego przedstawiono na rys. 4.3.



Rys. 4.3: Wykres zależności czasowych dla sterowania predykcyjnego [96]

Algorytmy MPC dzielimy na dwie główne grupy [96]:

- Sterowanie predykcyjne liniowe (liniowa funkcja celu):



- model obiektu liniowy, ograniczenia liniowe.
- Sterowanie predycyjne nieliniowe (nieliniowa funkcja celu):
 - model obiektu liniowy, ograniczenia nieliniowe,
 - model obiektu nieliniowy, ograniczenia liniowe,
 - model obiektu nieliniowy, ograniczenia nieliniowe.

W pracy model statku przedstawiono jako nieliniowy model zapisany jako równania stanu

$$\dot{\mathbf{x}}_{k+1} = f(\mathbf{x}_k, \mathbf{u}_k), \quad (4.32)$$

z warunkami początkowymi $\mathbf{x}(0) = \mathbf{x}_0$ oraz ograniczeniami na stan obiektu i sterowanie:

$$\mathbf{x}_k \in X, \quad \forall k \geq 0, \quad (4.33)$$

$$\mathbf{u}_k \in U, \quad \forall k \geq 0, \quad (4.34)$$

$$X := \{\mathbf{x} \in R^n \mid \mathbf{x}_{min} \leq \mathbf{x} \leq \mathbf{x}_{max}\}. \quad (4.35)$$

$$U := \{\mathbf{u} \in R^m \mid \mathbf{u}_{min} \leq \mathbf{u} \leq \mathbf{u}_{max}\}. \quad (4.36)$$

Gdzie \mathbf{x}_k jest wektorem stanu, \mathbf{u}_k jest wektorem sterowania, X jest zbiorem wektorów stanu, U jest zbiorem wektorów sterowania, wektor stanu jest ograniczony przez \mathbf{x}_{min} i \mathbf{x}_{max} , a wektor sterowania jest ograniczony przez \mathbf{u}_{min} i \mathbf{u}_{max} .

Wykorzystanie takiego modelu umożliwia zastosowanie kilku możliwych rozwiązań zadania sterowania predycyjnego [96]:

- MPC-NO (ang. *Model Predictive Control- Nonlinear Optimisation*) Sterowanie predycyjne z nieliniową predykcją i funkcją optymalizacji. Wykorzystanie nieliniowej predykcji daje dużą dokładność predykcji, minimalizując jej błąd. Nieliniowa funkcja optymalizacji powoduje, że jest ona niekwadratowa i niewypukła. Taka forma funkcji celu wymusza zastosowanie algorytmów, które nie gwarantują rozwiązania zadania niezawodnie, szybko i z określoną dokładnością.
- MPC-NSL (ang. *Model Predictive Control Nonlinear Successive Linearization*) Sterowanie predycyjne z nieliniowe sukcesywną linearyzacją w punkcie pracy. W każdej chwili czasu wyznaczany jest linearyzacja modelu. Sterowania wyznaczane są w wyniku rozwiązania liniowej funkcji celu. Jest to rozwiązanie suboptymalne ale gwarantuje szybki znalezienie rozwiązania problemu optymalizacji.
- MPC-NPL (ang. *Model Predictive Control Nonlinear Prediction and Linearization*) Sterowanie predycyjne z nieliniową predykcją i linearyzacją. Ten typ algorytmów cechuje się wykorzystaniem nieliniowego modelu obiektu do predykcji punktu początkowego funkcję celu. W punkcie tym następuje linearyzacja modelu i rozwiązywane jest liniowe zadanie optymalizacji. Algorytm ten jest wykorzystywany jeżeli czas obliczeń dla algorytmu MPC-NSL jest dłuższy od okresu próbkowania.



Funkcja celu wykorzystuje otwartą pętlę sterowania o skończonym horyzoncie predykcji. Rozwiązanie zadania minimalizacji funkcji celu jest sterowaniem w kolejnych chwilach k . Problem minimalizacji funkcji celu w literaturze zapisywany jest w postaci [96]:

$$\min_{\bar{\mathbf{u}}} J(\mathbf{x}_k, \bar{\mathbf{u}}) \quad (4.37)$$

z założeniem, że:

$$\bar{\mathbf{x}}_{k+1} = f(\mathbf{x}_k, \bar{\mathbf{u}}_k), \quad (4.38)$$

$$\bar{\mathbf{u}}_k \in U, \forall k \in [k, k + N_u], \quad (4.39)$$

$$\bar{\mathbf{u}}_k = \mathbf{u}_{k+N_u}, \forall k \in [k + N_u, k + P], \quad (4.40)$$

$$\bar{\mathbf{x}}_k \in X, \forall k \in [k, k + P], \quad (4.41)$$

$$J(\mathbf{x}_k, \bar{\mathbf{u}}) := \mathbf{F}_c(\bar{\mathbf{x}}_k, \bar{\mathbf{u}}_k) \quad (4.42)$$

gdzie $\bar{\mathbf{x}}_k$ jest zbiorem kolejnych wektorów stanów w funkcji celu a $\bar{\mathbf{u}}_k$ jest zbiorem kolejnych wektorów sterowań w funkcji celu. W rzeczywistych systemach przewidywana wartość wektora stanu różni się od rzeczywistej wartości z obiektu sterowania. Z tego powodu w każdej chwili $k + K_{op}$ zadanie optymalizacji rozwiązywane jest ponownie po wprowadzeniu aktualnych danych o obiekcie. Wówczas funkcja celu \mathbf{F}_c przyjmuje następującą postać:

$$\begin{aligned} \mathbf{F}_c(\bar{\mathbf{x}}_k, \bar{\mathbf{u}}_k) = & \sum_k^{k+P} (\mathbf{x}_k - \mathbf{x}_d)^T \mathbf{Q}_{MPC} (\mathbf{x}_k - \mathbf{x}_d)^T + \\ & + (\mathbf{u}_k - \mathbf{u}_d)^T \mathbf{R}_{MPC} (\mathbf{u}_k - \mathbf{u}_d) + \lambda(\mathbf{x}_k, \mathbf{u}_k) \end{aligned} \quad (4.43)$$

gdzie \mathbf{Q}_{MPC} i \mathbf{R}_{MPC} są macierzami wag, a $\lambda(\mathbf{x}_k, \mathbf{u}_k)$ jest funkcją kary za przekroczenie ograniczeń. Natomiast \mathbf{x}_d to zadana trajektoria stanu a \mathbf{u}_d jest wektorem ograniczeń sterowania.

4.4 Realizacja sterowania predykcyjnego w badaniach symulacyjnych

W pracy zaproponowano rozwiązanie sterowania predykcyjnego z wykorzystaniem algorytmu MPC-NO. Do tego celu wykorzystano nieliniową predykcję o zmiennym kroku i nieliniową funkcję celu. W celu przeprowadzenia badań symulacyjnych przyjęto kilka założeń:

- aktualizacja pomiaru dokonywana jest co 0,1 s - system pomiarowy ma dużą częstotliwość określania położenia i prędkości, założenie to umożliwi otrzymanie dobrej jakości estymowanego wektora stanu w krótkim czasie,
- sterowanie zmienia swoją wartość co 1 s - założenie to ogranicza częstotliwość zmiany sterowania względem aktualizacji pomiaru,



4. Sterowanie

- czas potrzebny na rozwiązanie zadania optymalizacji to 5 s ($K_{op} = 5s$).
- horyzont predykcji P równy jest horyzontowi sterowania N_u i wynoszą 95 s (wartość ta wynika z ograniczenia liczby zmiennych, które można było wprowadzić do zadania optymalizacji w środowisku Matlab)

Do zaprojektowania funkcji celu wykorzystano przedstawiony w podrozdziale 2.2 model, który był obliczany iteracyjnie na podstawie poniższych wzorów:

$$\mathbf{R}(\psi) = \mathbf{R}(\boldsymbol{\eta}_{k-1|k-1}), \quad (4.44)$$


$$\boldsymbol{\eta}_{k|k} = \boldsymbol{\eta}_{k-1|k-1} + \dot{\boldsymbol{\eta}}_{k-1|k-1} \Delta t, \quad (4.45)$$

$$\mathbf{v}_{k|k} = \mathbf{v}_{k-1|k-1} + \dot{\mathbf{v}}_{k-1|k-1} \Delta t, \quad (4.46)$$

$$\dot{\boldsymbol{\eta}}_{k|k} = \mathbf{R}(\psi) \mathbf{v}_{k|k}, \quad (4.47)$$

$$\dot{\mathbf{v}}_{k|k} = \frac{-\mathbf{N} \mathbf{v}_{k-1|k-1} + \mathbf{R}^T(\psi) \mathbf{b}_{k-1|k-1} + \boldsymbol{\tau}_c}{\mathbf{M}}, \quad (4.48)$$

gdzie przyjęto, że wektor sił wolnozmiennych zakłóceń środowiskowych $\mathbf{b}_{k-1|k-1}$ jest stały na całym horyzoncie predykcji. Dla zmniejszenia złożoności obliczeniowej w funkcji celu wykorzystano zmienną wartość kroku predykcji Δt zgodnie z rysunkiem 4.4. Do wyznaczenia funkcji celu dla pierwszych 5 s przyjęto, że krok predykcji wynosi 0.2 s od 5 s zwiększany jest on do wartości 0.5 s a od 10 s za krok predykcji przyjęto 5 s.



Rys. 4.4: Wykres realizowanego kroku predykcji dla projektowanego algorytmu MPC

Przy projektowaniu funkcji celu uwzględniono następujące założenia:

- w zadaniu optymalizacji wykorzystywane są zmiany sterowania $\Delta \mathbf{u}$,
- funkcja celu ma ograniczyć przeregulowania położenia,
- funkcja celu będzie nakładać karę za przekroczenie wartości prędkości w funkcji odległości od punktu zadanego.
- funkcja celu będzie zakładała ograniczenie na maksymalne prędkości statku $\dot{\boldsymbol{\eta}} = [u_o, v_o, r_o]$ (prędkości statku w nawigacyjnym układzie współrzędnych)



Po uwzględnieniu powyższych założeń przyjęto następującą funkcję celu:

$$F_c = \sum_{i=1}^P (\mathbf{A}_1 i^2 (\boldsymbol{\eta}_d - \boldsymbol{\eta}_i) + \mathbf{A}_2(\mathbf{x}_0) |\dot{\boldsymbol{\eta}}_k| + \mathbf{A}_3(x_0) \frac{1}{(\boldsymbol{\eta}_k - 2, 5)^{10}}), \quad (4.49)$$

gdzie :

$$\boldsymbol{\eta}_d = [x_d, y_d, \psi_d], \quad (4.50)$$

$$\mathbf{A}_1 = \begin{bmatrix} a_{11}^1 & 0 & 0 \\ 0 & a_{22}^1 & 0 \\ 0 & 0 & a_{33}^1 \end{bmatrix}, \quad (4.51)$$

$$\mathbf{A}_2 = \begin{bmatrix} a_{11}^2 \frac{|u_0|+0.01}{|x_d-x_0|+0.00001} & 0 & 0 \\ 0 & a_{22}^2 \frac{|v_0|+0.01}{|y_d-y_0|+0.00001} & 0 \\ 0 & 0 & a_{33}^2 \frac{|r_0|+0.01}{|\psi_d-\psi_0|+0.0001} \end{bmatrix}, \quad (4.52)$$

$$\mathbf{A}_3 = \begin{bmatrix} a_{11}^3 10^{|u_0|} & 0 & 0 \\ 0 & a_{22}^3 10^{|v_0|} & 0 \\ 0 & 0 & 0 \end{bmatrix}, \quad (4.53)$$

we wzorach (4.50)-(4.53) x_d, y_d to zadane położenie, ψ_d to zadany kurs, a_i^j są stałymi współczynnikami.

W funkcji celu F_c (4.49) zmienna P oznacza horyzont predykcji. Pierwszy człon funkcji celu wykorzystywany jest do minimalizacji błędu położenia i kursu statku. Człon ten jest pomnożony przez stały współczynnik \mathbf{A}_1 oraz i^2 , co powoduje, że kara za błąd położenia i kursu dla pierwszych kroków predykcji jest mała i rośnie z czasem. Współczynnik ten ma na celu minimalizację oscylacji położenia i kursu statku w okolicy zadanego położenia i kursu. Drugi człon funkcji celu zależny jest od macierzy \mathbf{A}_2 , ma on na celu wymusić spadek prędkości statku w okolicy punktu zadanego, poprzez wprowadzenie kary powiązanej z prędkością statku i odległością od punktu zadanego. Macierz \mathbf{A}_2 zależna jest od uchybu położenia statku w chwili rozpoczęcia zadania optymalizacji, zwiększa swoją wartość wraz z zmniejszeniem uchybu sterowania. Trzeci człon funkcji celu zależny jest od macierzy \mathbf{A}_3 i odpowiedzialny jest za ograniczenie prędkości statku do małych wartości. Człon ten tak jak poprzedni oblicza karę związaną z ograniczeniami. W tym przypadku kara dla funkcji optymalizacji obliczana jest za zbliżanie się wartości wektora prędkości do maksymalnych prędkości założonych dla zadania sterowania. Wartości macierz \mathbf{A}_3 uzależniono od wektora prędkości statku $\dot{\boldsymbol{\eta}}_k$ w chwili k . Wartość kary za przekroczenie wartości prędkości uwzględniono w taki sposób, aby była ona naliczana głównie wtedy, gdy statek w chwili rozpoczęcia rozwiązywania zadania optymalizacji funkcji celu posiada prędkość zbliżoną do maksymalnej. Zależności wprowadzone w macierzy \mathbf{A}_3 nie ograniczają możliwości zmiany prędkości statku w przypadku kiedy wektor prędkości statku w chwili k zawiera małe wartości.



Rozdział 5

Badania symulacyjne algorytmów fuzji danych

Badania symulacyjne w pracy zostały podzielone na dwie części: badanie algorytmów fuzji danych i sterowanie statkiem DP. W poniższym rozdziale przedstawiono badania algorytmów fuzji danych. Natomiast w kolejnym rozdziale będzie dotyczył algorytmów sterowania. W poniższym rozdziale przedstawiono wyniki badań symulacyjnych algorytmów fuzji danych z wykorzystaniem kaskadowego połączenia filtra cząsteczkowego i rozszerzonego filtra Kalmana (PKF, ang. *particle Kalman filter*), w porównaniu do filtra cząsteczkowego (PF, ang. *particle filter*), rozszerzonego filtra Kalmana (EKF, ang. *extended Kalman filter*) i nieliniowego obserwatora (NO, ang. *nonlinear observer*). W badaniach symulacyjnych zwrócono szczególną uwagę na:

- jakość estymacji dla różnej konfiguracji czujników pomiarowych;
- wpływ złożoności modelu na jakość estymacji;
- scenariusze uwzględniające awarie systemu pomiarowego:
 - uszkodzenie czujnika pomiarowego,
 - chwilowy zanik sygnału pomiarowego,
 - dryft czujnika pomiarowego.

5.1 Opis i założenia dotyczące badania symulacyjnego estymacji stanu i fuzji danych


Rozdział ten został poświęcony analizie jakości estymacji wektora stanu i fuzji danych. Głównym celem jest porównanie wyników zaprojektowanego kaskadowego połączenia filtra cząsteczkowego i rozszerzonego filtra Kalmana z wynikami powszechnie wykorzystywanych filtrów w systemie dynamicznego pozycjonowania, jakimi są rozszerzony filtr Kalmana i nieliniowy obserwator. W badaniach wykorzystano model statku Northern Clipper [23], który został opisany w rozdziale 2.

Do badań symulacyjnych algorytmów fuzji danych stworzono dwa scenariusze. Dane scenariuszy opisano za pomocą macierzy sił sterujących i macierzy zakłóceń środowiskowych działających na statek podczas symulacji. Za pomocą tych dwóch macierzy możliwa jest powtarzalność symulacji, w których jedynym zmiennym czynnikiem jest szum pomiarowy. Do wygenerowania sił sterujących w scenariuszach wykorzystano pętlę sterowania składającą się z algorytmu



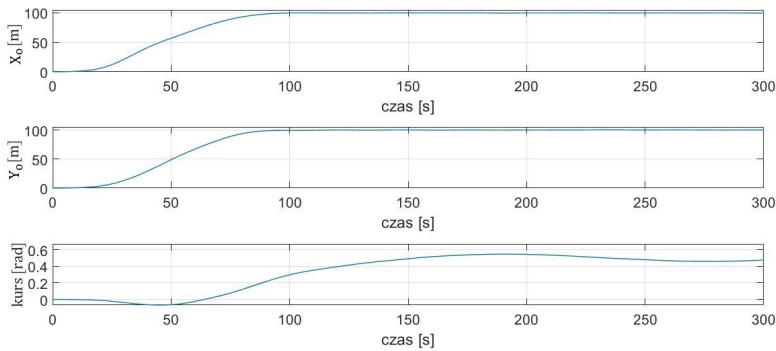
5. Badania symulacyjne algorytmów fuzji danych

MPC oraz kaskadowego połączenia filtra cząsteczkowego i rozszerzonego filtra Kalmana. Jako dane wejściowe do algorytmu fuzji danych wykorzystano pierwszą konfigurację czujników pomiarowych zaprezentowaną w tabeli 5.1. Opis konfiguracji czujników zostanie przedstawiony w dalszej części rozdziału. Przebieg sił i momentu zakłóceń środowiskowych występujące podczas symulacji zostały przedstawione na rys. 5.1. Siły i moment zostały dobrane w taki sposób, aby były zbliżone co do wartości w stosunku do zakłóceń środowiskowych prezentowanych w literaturze dla statku Northern Clipper [24] na podstawie równania (2.19).




Rys. 5.1: Siły od zakłóceń działające na statek dla scenariuszy

Pierwszy scenariusz wykorzystany w badaniach reprezentuje manewr statku. Statek w chwili t_0 znajduje się w położeniu $[x_o = 0 \text{ m}, y_o = 0 \text{ m}]$ a jego kurs wynosi $\psi = 0 \text{ rad}$. W chwili t_0 następuje zmiana wartości zadanej położenia i kursu statku na $[x_d = 100 \text{ m}, y_d = 100 \text{ m}, \psi_d = 0.5 \text{ rad}]$. Położenie, kurs oraz prędkości osiągnięte przez statek podczas pierwszego scenariusza zaprezentowano na rys. 5.2-5.3.



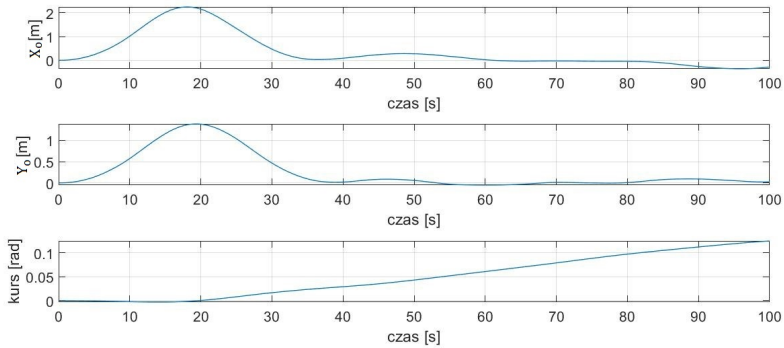
Rys. 5.2: Położenie i kurs statku w układzie współrzędnych NED w czasie wykonywania manewru




Rys. 5.3: Prędkości statku w układzie związanym ze statkiem w czasie wykonywania manewru

Drugi scenariusz reprezentuje stabilizację położenia statku w punkcie $[x_o = 0 \text{ m}, y_o = 0 \text{ m}]$ oraz utrzymanie kursu statku $\psi_d = 0.0$ rad. Położenie, kurs oraz prędkości statku osiągnięte przez statek podczas drugiego scenariusza zaprezentowano na rys. 5.4-5.5.

5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.4: Położenie i kurs statku w układzie współrzędnym NED podczas stabilizacji



Rys. 5.5: Prędkości statku w układzie związonym ze statkiem podczas stabilizacji

W czasie badań symulacyjnych wykorzystano trzy konfiguracje czujników, dla których określono odchylenie standardowe i zaprezentowano je w tabeli 5.1. Dla każdej z konfiguracji przyjęto okres odświeżania informacji równy 0.1 s. Reprezentują one określone konfiguracje systemów pomiarowych występujące na statkach o określonej klasie DP [74] i odpowiednio:

- pierwsza konfiguracja reprezentuje statek bez nadmiarowych systemów pomiarowych wykorzystujący DGPS, żyrokompas i czujniki prędkości,
- druga konfiguracja reprezentuje statek z nadmiarowym systemem pomiarowym wykorzystujący GPS, żyrokompas i czujniki prędkości,
- trzecia konfiguracja reprezentuje statek z nadmiarowym systemem pomiarowym wykorzystujący DGPS, żyrokompas i czujniki prędkości.



Tabela 5.1: Konfiguracje czujników pomiarowych

	Konfiguracja 1	Konfiguracja 2	Konfiguracja 3
Liczba czujników położenia	1	3	3
Błąd czujnika położenia	$\pm 2[m]$	$\pm 15[m]$	$\pm 2[m]$
Liczba czujników prędkości	1	3	3
Błąd czujnika/ów prędkości	$\pm 0.1[\frac{m}{s}]$	$\pm 0.1[\frac{m}{s}]$	$\pm 0.1[\frac{m}{s}]$
Liczba czujnika/ów kursu	1	3	3
Błąd czujnika/ów kursu	$\pm 2^\circ$ $\pm 0.0349[\text{rad}]$	$\pm 2^\circ$ $\pm 0.0349[\text{rad}]$	$\pm 2^\circ$ $\pm 0.0349[\text{rad}]$

W badaniach symulacyjnych jako miarę jakości estymacji wykorzystano błąd średniokwadratowy (RMSE, ang. *root mean square error*) przedstawiony za pomocą wzoru 5.1, jest to najczęściej występujący wskaźnik jakości estymacji w literaturze [56]:

$$\text{RMSE}(k) = \sqrt{\frac{1}{N_i} \sum_{i=1}^{N_i} (\tilde{x}_i(k))^2}, \quad (5.1)$$

gdzie:

- $\text{RMSE}(k)$ - błąd średniokwadratowy w chwili k z N_i przebiegów,
- N_i - liczba przebiegów,
- $\tilde{x}_i(k)$ - błąd estymacji w i -tej symulacji, w chwili k .

Drugim kryterium oceny jakości estymacji jest wartość średnia błędu średniokwadratowego RMSE_{mean} obliczana za pomocą wzoru:

$$\text{RMSE}_{mean} = \frac{\sum_{k=1}^{N_k} \text{RMSE}(k)}{N_k} \quad (5.2)$$

gdzie $N_k = \frac{\text{czasy symulacji}}{\Delta t}$, jest liczbą przedziałów czasowych w symulacji.

Rezultaty badań symulacyjnych zaprezentowano za pomocą wykresów i tabel. Do obliczenia RMSE wykorzystano $N_i = 50$ przebiegów dla każdego z badanych scenariuszy. Pierwszy scenariusz odwzorowuje manewr zmiany kursu i położenia statku, który zaprezentowano na rys. 5.2–5.3. Drugi scenariusz ma za zadanie zaprezentowanie jakości estymacji w czasie stabilizacji położenia i kursu statku, wykres położenia i prędkości zaprezentowano na rys. 5.4–5.5.

Jakość filtracji dla zaprezentowanych algorytmów zależy od dostrojenia ich parametrów. Parametry dla poszczególnych filtrów zostały określone na podstawie badań symulacyjnych.



5. Badania symulacyjne algorytmów fuzji danych

W pracy zaprojektowano dwa algorytmy filtru Kalmana. Pierwszy algorytm filtru Kalmana (algorytm 1) wykorzystuje model w przestrzeni stanu opisany równaniami (2.30)-(2.31). Drugi algorytm filtru Kalmana jest rozszerzonym filtrem Kalmana wykorzystującym model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 2). Filtry Kalmana są strojne za pomocą dwóch macierzy \mathbf{Q}_K i \mathbf{R}_K . Macierz \mathbf{R}_K odpowiedzialna za kowariancję błędu pomiaru uzupełniana jest wariancją policzoną na podstawie odchylenia standardowego z tabeli 5.1. Kolejnym krokiem jest dobór macierzy \mathbf{Q}_K (macierzy niepewności modelu procesu). Aby ją obliczyć wykorzystano dwie macierze \mathbf{G} i \mathbf{Q} . Macierz \mathbf{Q} zakłada, że błąd modelu obiektu występuje w równaniach związanych z przyspieszeniem statku i zakłada wariancję tego błędu. Macierz \mathbf{G} opisuje, jak błąd przyspieszenia propaguje się na pozostałe równania:

$$\mathbf{Q} = \begin{vmatrix} 0.01 & 0 & 0 \\ 0 & 0.01 & 0 \\ 0 & 0 & 0.001 \end{vmatrix} \quad \mathbf{G} = \begin{vmatrix} \frac{T^2}{2} & 0 & 0 \\ 0 & \frac{T^2}{2} & 0 \\ 0 & 0 & \frac{T^2}{2} \\ T & 0 & 0 \\ 0 & T & 0 \\ 0 & 0 & T \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{vmatrix}. \quad (5.3)$$

$$\mathbf{Q}_K = \mathbf{G}\mathbf{Q}\mathbf{G}^T \quad (5.4)$$

W równaniu 5.4 przedstawiono macierz kowariancji modelu dla pierwszej wersji filtru Kalmana. Druga wersja filtru Kalmana rozbudowana jest o zakłócenia środowiskowe, przez co macierz \mathbf{Q}_K tego filtru przyjmuje następującą postać:

$$\mathbf{Q}_K = \begin{vmatrix} \mathbf{G}\mathbf{Q}\mathbf{G}^T, & \mathbf{0}_{3 \times 9} \\ \mathbf{0}_{9 \times 3} & \mathbf{J} * 5 \end{vmatrix}. \quad (5.5)$$

Z kolei dobór parametrów nieliniowego obserwatora odbywał się w następujący sposób. Początkowo przyjęto, że wzmocnienie \mathbf{k}_1 będzie zależało tylko od uchybu prędkości i kursu. Wzmocnienie \mathbf{k}_1 odpowiedzialne jest za zmianę estymowanej wartości zakłóceń środowiskowych. Ze względu na fakt, że uchyb prędkości i kursu są wartościami kilka rzędów mniejszymi od wartości zakłóceń środowiskowych konieczne było przemnożenie ich przez wartość wystarczająco dużą aby miały one wpływ na estymowane zakłócenia środowiskowe. Natomiast poprawka do położenia \mathbf{k}_3 i prędkości \mathbf{k}_4 musi być mała, aby szum pomiarowy nie powodował destabilizacji filtra. Wartości wektora \mathbf{k}_2 są małe ze względu, że reprezentuje on błąd sił wytworzonych przez napędy, który w prezentowanych badaniach jest pomijany. W wyniku wielokrotnych badań symulacyjnych ustalono następującą



wartość wzmocnień:

$$\mathbf{k}_1 = \begin{pmatrix} 0 \\ 0 \\ 500000 \\ 10000 \\ 100000 \end{pmatrix}, \mathbf{k}_2 = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0.1 \\ 0.1 \end{pmatrix}, \mathbf{k}_3 = \begin{pmatrix} 0.1 \\ 0.1 \\ 0.1 \\ 0 \\ 0 \end{pmatrix}, \mathbf{k}_4 = \begin{pmatrix} 0.1 \\ 0.1 \\ 0.1 \\ 0 \\ 0 \end{pmatrix}. \quad (5.6)$$

W pracy rozważane są dwa filtry cząsteczkowe pierwszy wykorzystujący model 2.30-2.31 drugi wykorzystuje model (2.27)-(2.28). W algorytmie filtru cząsteczkowego pierwszym krokiem jest losowanie próbek przy pomocy zmiennej \mathbf{v}_i , która jest wektorem zmiennych losowych o rozkładzie normalnym, wartości średniej równej 0 i znanym odchyleniu standardowym. Drugim parametrem dobieranym dla filtru cząsteczkowego jest wariancja dla rozkładu normalnego, wykorzystywana przy wyznaczaniu wagi próbki i oznaczona jako \mathbf{R} .

Dla pierwszego filtru cząsteczkowego (algorytm 4), który wykorzystuje model statku opisany w przestrzeni stanu równaniami (2.30) i (2.31) przyjęto następującą wartość odchyłeń standardowych i wariancji:

$$\text{dla } \mathbf{v}_i \begin{pmatrix} X_o \\ Y_o \\ \psi \\ \dot{x}_o \\ \dot{y}_o \\ \dot{\psi} \\ u \\ v \\ r \\ \dot{u} \\ \dot{v} \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0.003 \\ 0.1 \\ 0.1 \end{pmatrix}, \text{ dla } \mathbf{R} \begin{pmatrix} X_o \\ Y_o \\ \psi \\ u \\ v \end{pmatrix} = \begin{pmatrix} 0.5 \\ 0.5 \\ 0.05 \\ 0.016 \\ 0.016 \end{pmatrix}. \quad (5.7)$$

Dla drugiego filtru cząsteczkowego (algorytm 4), który wykorzystuje model statku opisany w przestrzeni stanu równaniami (2.27) i (2.28) dobrano natomiast następujące wartości:

$$\text{dla } \mathbf{v}_i \begin{pmatrix} X_o \\ Y_o \\ \psi \\ \dot{x}_o \\ \dot{y}_o \\ \dot{\psi} \\ u \\ v \\ r \\ \dot{u} \\ \dot{v} \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0.003 \\ 0.1 \\ 0.1 \end{pmatrix}, \text{ dla } \mathbf{R} \begin{pmatrix} X_o \\ Y_o \\ \psi \\ u \\ v \end{pmatrix} = \begin{pmatrix} 0.3 \\ 0.3 \\ 0.008 \\ 0.06 \\ 0.06 \end{pmatrix}. \quad (5.8)$$

Parametry te zostały dobrane na podstawie wielokrotnych prób symulacyjnych. W pracy zaprojektowano również dwa algorytmy kaskadowego połączenia filtru



5. Badania symulacyjne algorytmów fuzji danych

cząsteczkowego i filtru Kalmana/ rozszerzonego filtru Kalmana. Pierwszy z tych filtrów wykorzystuje model zawarty w równaniach 2.30-2.31. Parametry tego filtru to:

$$\mathbf{Q} = \begin{vmatrix} 0.1 & 0 & 0 \\ 0 & 0.1 & 0 \\ 0 & 0 & 0.001 \end{vmatrix}, \quad \mathbf{Q}_K = \mathbf{G}\mathbf{Q}\mathbf{G}^T, \quad (5.9)$$

$$\text{dla } \mathbf{v}_i \begin{vmatrix} X_o \\ Y_o \\ \psi \\ \dot{x}_o \\ \dot{y}_o \\ \dot{\psi} \\ u \\ v \\ r \\ \dot{u} \\ \dot{v} \\ \dot{r} \end{vmatrix} = \begin{vmatrix} 3 \\ 3 \\ 0 \\ 0 \\ 0 \\ 0.001 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0.4 \\ 0.4 \\ 0.01 \end{vmatrix}, \quad \text{dla } \mathbf{R} \begin{vmatrix} X_o \\ Y_o \\ \psi \\ u \\ v \end{vmatrix} = \begin{vmatrix} 0.3 \\ 0.3 \\ 0.005 \\ 0.1 \\ 0.1 \end{vmatrix}. \quad (5.10)$$

Drugi filtr wykorzystuje model zawarty w równaniach (2.27)-(2.28). Parametry tego filtru to:

$$\mathbf{Q} = \begin{vmatrix} 0.1 & 0 & 0 \\ 0 & 0.1 & 0 \\ 0 & 0 & 0.001 \end{vmatrix}, \quad \mathbf{Q}_K = \begin{vmatrix} \mathbf{G}\mathbf{Q}\mathbf{G}^T, & 0_{1 \times 9} \\ 0_{9 \times 1} & \mathbf{J} * 5 \end{vmatrix}, \quad (5.11)$$

$$\text{dla } \mathbf{v}_i \begin{vmatrix} X_o \\ Y_o \\ \psi \\ \dot{x}_o \\ \dot{y}_o \\ \dot{\psi} \\ u \\ v \\ r \\ \dot{u} \\ \dot{v} \\ \dot{r} \end{vmatrix} = \begin{vmatrix} 0 \\ 0 \\ 0 \\ 0.1 \\ 0.1 \\ 0.03 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0.141 \\ 0.141 \\ 0 \end{vmatrix}, \quad \text{dla } \mathbf{R} \begin{vmatrix} X_o \\ Y_o \\ \psi \\ u \\ v \end{vmatrix} = \begin{vmatrix} 1 \\ 1 \\ 0.008 \\ 0.06 \\ 0.06 \end{vmatrix}. \quad (5.12)$$

5.2 Badania symulacyjne estymacji i fuzji danych

W dalszej części pracy zostaną przedstawione szczegółowe badania estymacji położenia i kursu statku DP. W kolejnych rozdziałach zostaną zaprezentowane badania dotyczące:



- estymacji położenia i kursu statku z wykorzystaniem czujników komplementarnych,
- porównania estymacji położenia i kursu statku dla algorytmów o różnej złożoności modelu obiektu,
- estymacji położenia i kursu statku dla nadmiarowej konfiguracji pomiarowej,
- estymacji położenia i kursu statku dla różnej konfiguracji czujników pomiarowych,
- estymacji położenia i kursu statku dla różnych scenariuszy awaryjnych.

Wszystkie badania zostały wykonane z wykorzystaniem środowiska Matlab.

5.2.1 Estymacja położenia i kursu statku bez nadmiarowej konfiguracji czujników

W poniższym rozdziale przedstawiono wyniki badań symulacyjnych estymacji położenia i kursu statku dla czujników komplementarnych. Komplementarność czujników w badaniach rozumiana jest jako pomiary, które reprezentują różne zmienne badanego obiektu (prędkość, położenie). Celem badania jest analiza porównawcza działania algorytmów fuzji danych z uwzględnieniem komplementarności danych pomiarowych gdzie porównano:

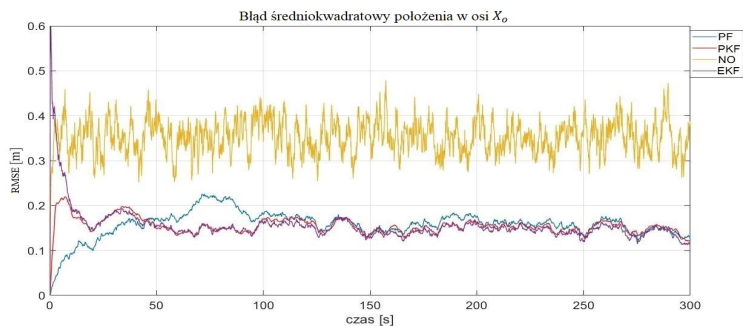
- PF - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27) i (2.28) (algorytm 4),
- PKF - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27) i (2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 6),
- EKF - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 2).

w dwóch scenariuszach opisanych w rozdziale 5.1. Pierwszym scenariusz (manewr) jest symulacją zmiany położenia i kursu przez statek (rys. 5.2). Drugi scenariusz (stabilizacja) jest symulacją utrzymania przez statek w stałym położeniu i na stałym kursu (rys. 5.4). W badaniach wykorzystano pierwszą konfigurację czujników prezentowaną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkość statku bez szumu pomiarowego.


Wyniki dla pierwszego scenariusza (manewr) przedstawiono na rys. 5.6-5.10 i w tabeli 5.2.



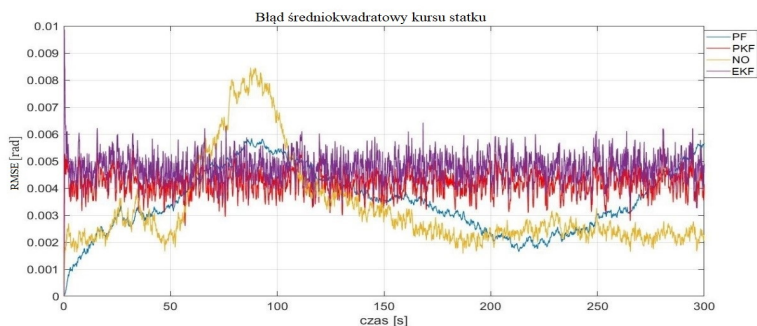
5. Badania symulacyjne algorytmów fuzji danych



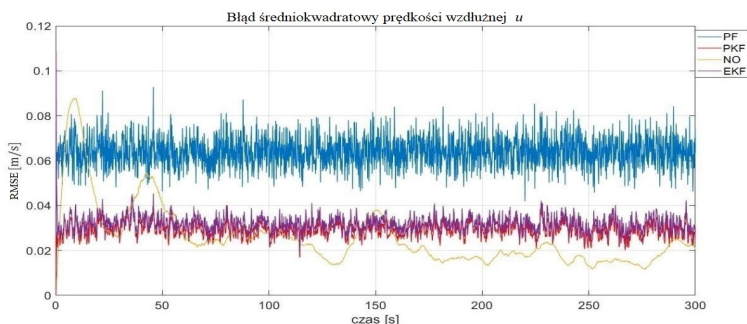
Rys. 5.6: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - manewr



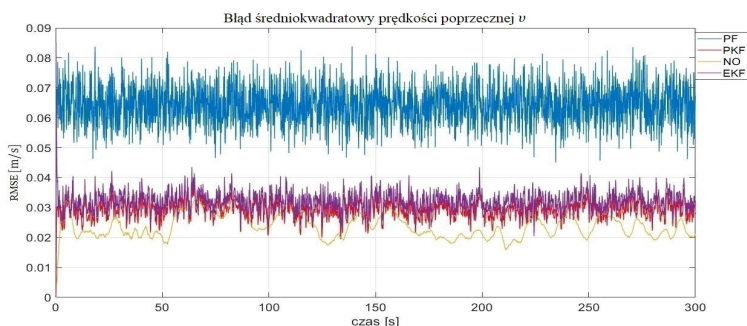
Rys. 5.7: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - manewr



Rys. 5.8: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - manewr



Rys. 5.9: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - manewr



Rys. 5.10: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - manewr

Tabela 5.2: Wartość uśredniona błędów średniokwadratowych estymacji dla manewru statku.

	$X_o [m]$	$Y_o [m]$	$\psi [rad]$	$u [m/s]$	$v [m/s]$
PF	0.1579	0.1513	0.0036	0.0637	0.0641
PKF	0.1599	0.1604	0.0041	0.0293	0.0293
NO	0.3225	0.3481	0.0042	0.0378	0.0251
EKF	0.1738	0.1673	0.0048	0.0324	0.0324


Analiza wykresów $RMSE(k)$ (rys. 5.6–5.8) i tabeli $RMSE_{mean}$ (tabela 5.2) pozwala na stwierdzenie, że wyniki uzyskane dla algorytmu PKF i EKF są zbliżone. Algorytm PF osiągnął najniższy wynik $RMSE(k)$ dla estymacji kursu statku. Dla algorytmu NO błąd średniokwadratowy estymacji $RMSE(k)$ znacznie odbiega od wyników osiągniętych przez pozostałe algorytmy. Natomiast algorytm NO osiągnął mniejszy $RMSE(k)$ dla estymacji prędkości wzdłużnej u i poprzecznej v (rys. 5.9-5.10). Na podstawie wykresów $RMSE(k)$ (rys. 5.6-5.8)




5. Badania symulacyjne algorytmów fuzji danych

i tabeli $\overline{\text{RMSE}}_{\text{mean}}$ (tabela 5.2) należy stwierdzić, że wszystkie algorytmy w znacznym stopniu ograniczyły szumy pomiarowe.

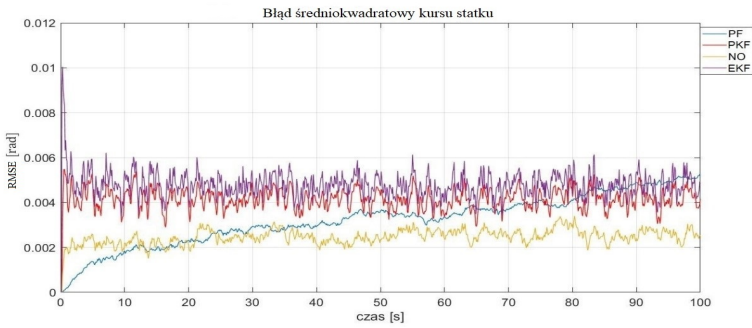
Wyniki badań symulacyjnych dla drugiego scenariusza (stabilizacja) zostały zaprezentowane na rys. 5.11-5.15 oraz w tabeli 5.3.



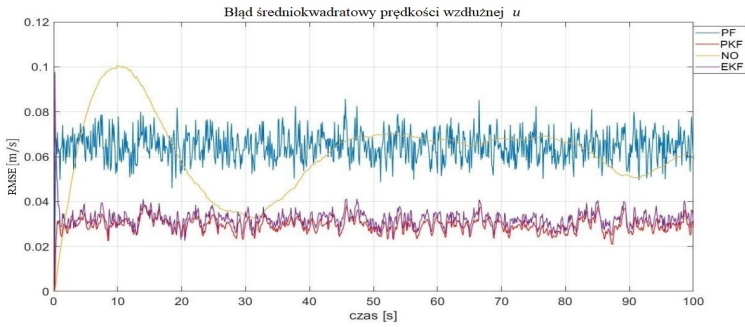
Rys. 5.11: Błąd średniokwadratowy $\text{RMSE}(k)$ położenia statku w osi X_o -stabilizacja



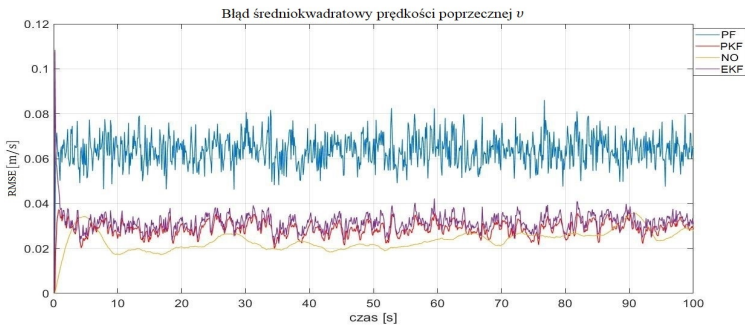
Rys. 5.12: Błąd średniokwadratowy $\text{RMSE}(k)$ położenia statku w osi Y_o -stabilizacja



Rys. 5.13: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - stabilizacja



Rys. 5.14: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - stabilizacja



Rys. 5.15: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - stabilizacja



5. Badania symulacyjne algorytmów fuzji danych

Tabela 5.3: Wartość uśredniona błędu średniokwadratowego estymacji dla stabilizacji położenia i kursu statku.

	X_o [m]	Y_o [m]	ψ [rad]	u [m/s]	v [m/s]
PF	0.1542	0.1403	0.0032	0.0645	0.0637
PKF	0.1604	0.1546	0.0041	0.0293	0.0288
NO	0.3600	0.3545	0.0025	0.0317	0.0236
EKF	0.1668	0.1626	0.0048	0.0323	0.0318

Analiza wykresów $RMSE(k)$ (rys. 5.11-5.15) i tabeli $RMSE_{mean}$ (tabela 5.3) pozwala na stwierdzenie, że algorytmy PKF i EKF osiągnęły zbliżone wyniki. Algorytmy te uzyskały najmniejszy błąd estymacji $RMSE(k)$ dla prędkości wzdłużnej u i poprzecznej v . Algorytm PF osiągnął najmniejszy błąd estymacji $RMSE(k)$ dla estymacji położenia statku (rys. 5.11-5.12). Błąd średniokwadratowy $RMSE(k)$ dla algorytmu NO jest znacząco większy w porównaniu do pozostałych algorytmów. Na podstawie wykresów $RMSE(k)$ (rys. 5.11-5.15) i tabeli $RMSE_{mean}$ (tabela 5.3) należy stwierdzić, że wszystkie algorytmy w znacznym stopniu ograniczyły szumy pomiarowe.

Porównanie wyników otrzymanych dla pierwszego i drugiego scenariusza pozwoliły na stwierdzenie, że algorytmy uzyskały zbliżone wyniki $RMSE(k)$ i $RMSE_{mean}$ dla obu scenariuszy. Badanie miało na celu wykazanie wpływu prędkości na błąd średniokwadratowy $RMSE(k)$. Po analizie wyników badań stwierdzono, że algorytmy PF, PKF i EKF nie zmieniają jakości estymacji w zależności od prędkości statku. Porównanie wyników algorytmu NO dla obu scenariuszy wykazuje, że dla pierwszego scenariusza uzyskano mniejsze błędy estymacji $RMSE(k)$ w porównaniu do błędów uzyskanych dla drugiego scenariusza.

5.2.2 Porównanie estymacji położenia i kursu dla algorytmów estymacji z wykorzystujących różną złożoność modelu obiektu

Kolejne przedstawione badania dotyczą analizy jakości estymacji w zależności od złożoności modelu statku wykorzystywanego w algorytmie fuzji danych. W rozdziale zastosowano następujący zapis nazw filtrów biorących udział w badaniu:


- PF 1 - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 4),
- PKF 1 - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami (2.27) i (2.28) (algorytm 6),



- EKF 1 - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27)-(2.28) (algorytm 2).
- PF 2 - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.30)-(2.31) (algorytm 4),
- PKF 2 - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.30)-(2.31) (algorytm 5),
- KF 2 - filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami (2.30)-(2.31) (algorytm 1).

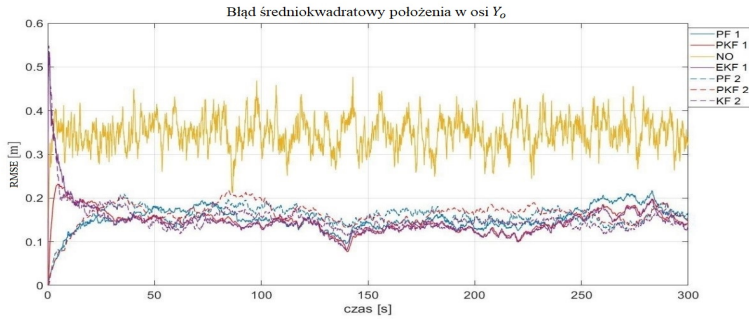
Badania symulacyjne zostały przeprowadzone dla pierwszego scenariusza prezentowanego w rozdziale 5.1 (rys. 5.2-5.3). Modele wykorzystywane w algorytmach estymacji różnią się opisem przyspieszenia i zakłóceń środowiskowych, z tego względu badania zostały przeprowadzone z wykorzystaniem tylko pierwszego scenariusza z rozdziału 5.1. W badaniach wykorzystano pierwszą konfigurację czujników prezentowaną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkość statku bez szumu pomiarowego.

Wyniki dla pierwszego scenariusza (manewr) przedstawiono na rys. 5.16-5.20 i w tabeli 5.4.




Rys. 5.16: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - różna złożoność modelu obiektu podczas manewru


5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.17: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - różna złożoność modelu obiektu podczas manewru




Rys. 5.18: Błąd średniokwadratowy $RMSE(k)$ kursu ψ - różna złożoność modelu obiektu podczas manewru



Rys. 5.19: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej u - różna złożoność modelu obiektu podczas manewru





Rys. 5.20: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej v - różna złożoność modelu obiektu podczas manewru

Tabela 5.4: Wartość uśredniona błęd średniokwadratowego estymacji podczas manewru z wykorzystaniem różnej złożoności modelu obiektu.

	$X_o [m]$	$Y_o [m]$	$\psi [rad]$	$u [m/s]$	$v [m/s]$
PF 1	0.1579	0.1513	0.0036	0.0637	0.0641
PKF 1	0.1599	0.1604	0.0041	0.0293	0.0293
NO	0.3225	0.3481	0.0042	0.0378	0.0251
EKF 1	0.1738	0.1673	0.0048	0.0324	0.0324
PF 2	0.1599	0.1584	0.0045	0.0581	0.0579
PKF 2	0.1679	0.1628	0.0041	0.0373	0.0367
KF 2	0.1492	0.1520	0.0055	0.0420	0.0416

Analiza wykresów $RMSE(k)$ (rys. 5.16-5.20) i tabeli $RMSE_{mean}$ (tabela 5.4) pozwala na stwierdzenie, że wykorzystanie obu modeli obiektu w algorytmach estymacji daje zbliżone wyniki dla czasu odświeżania pomiaru równego 10,1 s. Wyniki przedstawione w tabeli 5.4 wskazują, że filtry, które wykorzystywały model statku opisany równaniami (2.27)-(2.28), osiągają nieznacznie lepsze od filtrów z kinematycznym modelem statku (2.30)-(2.31). Wyjątkiem jest filtr Kalmana, który osiąga lepszy wynik dla liniowego modelu statku. Wynik ten uległby zmianie dla większych okresów próbkowania. Badanie wykazało że nawet dla dużej częstotliwości odświeżania pomiarów algorytmy wykorzystujące pełen model dynamiki statku uzyskują lepsze wyniki.

Ponadto badania wykazały, że nawet przy dużej częstotliwości odświeżania pomiarów algorytmy z wykorzystaniem pełnego modelu statku uzyskują lepsze wyniki. Przewagą filtrów z pełnym modelem statku (2.27)-(2.28) w stosunku do uwzględniających tylko kinematykę (2.30-2.31), jest możliwość estymacji wolnozmiennych zakłóceń środowiskowych i predykcja przyspieszenia na podstawie sił i momentu generowanych przez napędy i stery. W przypadku małego okresu pomiarowego błąd predykcji przyspieszenia nie ma znaczącego wpływu na jakość estymacji położenia, kursu i prędkości statku. Natomiast estymowana wartość zakłóceń wolnozmiennych stanowi ważną informację



5. Badania symulacyjne algorytmów fuzji danych

dla algorytmów sterowania. Estymacja zakłóceń środowiskowych umożliwia algorytmom sterowania dokładniejszą kompensację zakłóceń przez co uzyskują one lepsze parametry.

5.2.3 Fuzja danych

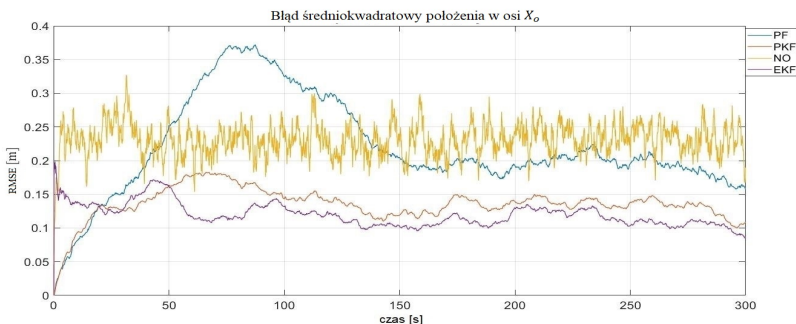
Ze względu na przepisy towarzystw klasyfikacyjnych jednym z podstawowych problemów na statkach klasy DP jest łączenie informacji z wielu nadmiarowych urządzeń pomiarowych. Jako przykład nadmiarowej konfiguracji czujników dla statku DP wykorzystano trzecią konfigurację czujników zaprezentowaną w tabeli 5.1. Zawiera ona trzykrotną nadmiarowość czujników położenia, kursu i prędkości.

W badaniu fuzji danych użyto następujących algorytmów:

- PF - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 4),
- PKF - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 6 + algorytm 7),
- EKF - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27)-(2.28) (algorytm 2 + algorytm 7).


Badania zostały przeprowadzone dla dwóch scenariuszy opisanych w rozdziale 5.1. Pierwszy scenariusz (manewr) jest symulacją zmiany położenia i kursu przez statek (rys. 5.2) Drugi scenariusz (stabilizacja) jest symulacją utrzymania przez statek stałego położenia i kursu (rys. 5.4). Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkość statku bez szumu pomiarowego.

Wyniki dla pierwszego scenariusza (manewr) przedstawiono na rys. 5.21-5.25 i w tabeli 5.5.

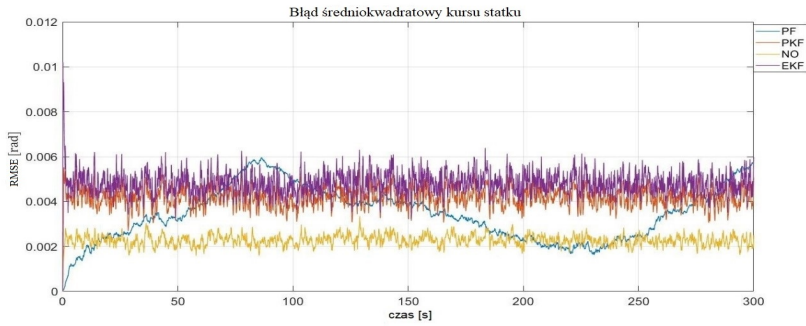


Rys. 5.21: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - nadmiarowa konfiguracja czujników podczas manewru






Rys. 5.22: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - nadmiarowa konfiguracja czujników podczas manewru

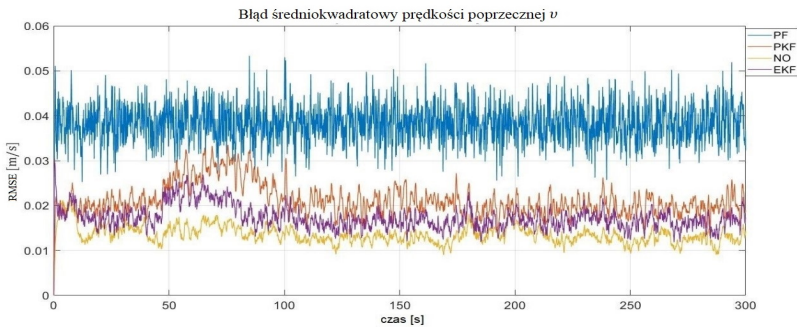


Rys. 5.23: Błąd średniokwadratowy $RMSE(k)$ kursu ψ - nadmiarowa konfiguracja czujników podczas manewru



Rys. 5.24: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej u - nadmiarowa konfiguracja czujników podczas manewru

5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.25: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej v - nadmiarowa konfiguracja czujników podczas manewru


Tabela 5.5: Wartość uśredniona błęd średniokwadratowego estymacji podczas manewru przy nadmiarowej konfiguracji czujników.

	$X_o [m]$	$Y_o [m]$	$\psi [rad]$	$u [m/s]$	$v [m/s]$
PF	0.2197	0.1690	0.0035	0.0382	0.0383
PKF	0.1358	0.1337	0.0042	0.0213	0.0212
NO	0.2307	0.2329	0.0023	0.0153	0.0135
EKF	0.1197	0.1310	0.0048	0.0175	0.0173


Analiza wykresów $RMSE(k)$ (rys. 5.21-5.25) i tabeli $RMSE_{mean}$ (tabela 5.5) pozwala na stwierdzenie, że najlepszą jakość estymacji uzyskał algorytm EKF. Jakość estymacji położenia algorytmów NO i PF rys. 5.21-5.22 znacznie odbiega od wyników osiąganych przez algorytmy PKF i EKF. Natomiast algorytm NO wykazał się lepszą jakością estymacji prędkości wzdłużnej u i poprzecznej v (rys. 5.23-5.24). Na podstawie wykresów $RMSE(k)$ (rys. 5.21-5.25) i tabeli $RMSE_{mean}$ (tabela 5.5) należy stwierdzić, że wyniki algorytmów EKF i PKF są do siebie zbliżone.

Wyniki badania symulacyjnych dla drugiego scenariusza (stabilizacja) zostały zaprezentowane na rys. 5.26-5.30 oraz w tabeli 5.6.






Rys. 5.26: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_0 - nadmiarowa konfiguracja czujników podczas stabilizacji




Rys. 5.27: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - nadmiarowa konfiguracja czujników podczas stabilizacji




Rys. 5.28: Błąd średniokwadratowy $RMSE(k)$ kursu ψ - nadmiarowa konfiguracja czujników podczas stabilizacji

5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.29: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej u - nadmiarowa konfiguracja czujników podczas stabilizacji



Rys. 5.30: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej v - nadmiarowa konfiguracja czujników podczas stabilizacji

Tabela 5.6: Wartość uśredniona błęd średniokwadratowego estymacji podczas stabilizacji przy nadmiarowej konfiguracji czujników.

	X_o [m]	Y_o [m]	ψ [rad]	u [m/s]	v [m/s]
PF	0.1514	0.1531	0.0032	0.0385	0.0379
PKF	0.1652	0.1488	0.0042	0.0260	0.0215
NO	0.2374	0.2339	0.0023	0.0272	0.0133
EKF	0.1747	0.1366	0.0048	0.0191	0.0170


Analiza wykresów $RMSE(k)$ (rys. 5.26-5.30) i tabeli $RMSE_{mean}$ (tabela 5.6) pozwala na stwierdzenie, że najlepszą jakością estymacji uzyskał algorytm PKF. Jakość estymacji położenia algorytmu NO rys. 5.26-5.27 znacznie odbiega od wyników osiągniętych przez pozostałe algorytmy. Natomiast algorytmy NO i EKF wykazały się lepszą jakością estymacji prędkości wzdłużnej u i poprzecznej v (rys. 5.29-5.30).




5.2.4 Porównanie działania algorytmów fuzji danych dla różnych dokładności pomiaru położenia

Kolejne badanie dotyczy działania algorytmów w zależności od różnych dokładności pomiaru położenia statku. W badaniu wykorzystano drugą i trzecią konfigurację czujników z tabeli 5.1. Dla uproszczenia zapisu skróty nazw algorytmów dla drugiej konfiguracji zostały oznaczone 1, a dla trzeciej 2. Badania symulacyjne przeprowadzono dla pierwszego scenariusza prezentowanego w rozdziale 5.1 (rys. 5.2-5.3). Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkości statku bez szumu pomiarowego.

Wyniki badań symulacyjnych przedstawiono na rys. 5.31-5.35 i w tabeli 5.7.




Rys. 5.31: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_0 - porównanie różnej konfiguracji czujników podczas manewru




Rys. 5.32: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - porównanie różnej konfiguracji czujników podczas manewru




5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.33: Błąd średniokwadratowy $RMSE(k)$ kursu ψ - porównanie różnej konfiguracji czujników podczas manewru



Rys. 5.34: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - - porównanie różnej konfiguracji czujników podczas manewru



Rys. 5.35: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - - porównanie różnej konfiguracji czujników podczas manewru



Tabela 5.7: Porównanie średniego błędu średniokwadratowego estymacji dla dwóch różnych konfiguracji czujników pomiarowych.

	$X_o [m]$	$Y_o [m]$	$\psi [rad]$	$u [m/s]$	$v [m/s]$
PF 1	0.2197	0.1690	0.0035	0.0382	0.0383
PKF 1	0.1358	0.1337	0.0042	0.0213	0.0212
NO 1	0.2307	0.2329	0.0023	0.0153	0.0135
EKF 1	0.1197	0.1310	0.0048	0.0175	0.0173
PF 2	0.4569	0.3678	0.0035	0.0383	0.0383
PKF 2	0.5224	0.5382	0.0042	0.0214	0.0211
NO 2	1.7250	1.7136	0.0023	0.0153	0.0134
EKF 2	0.2653	0.3025	0.0048	0.0176	0.0171

Analiza wykresów $RMSE(k)$ (rys. 5.31-5.35) i tabeli $RMSE_{mean}$ (tabela 5.7) pozwala na stwierdzenie, że zwiększenie błędu pomiarowego położenia ma niekorzystny wpływ na jakość estymacji położenia algorytmów. Na podstawie wykresów $RMSE(k)$ (rys. 5.31-5.35) i tabeli $RMSE_{mean}$ (tabela 5.7) stwierdzono, że zmiana jakości pomiaru położenia w prezentowanym przypadku nie ma negatywnego wpływu na jakość estymacji prędkości. Najmniejszą zmianę jakości estymacji zaobserwowano dla algorytmu EKF.

5.2.5 Uszkodzenie 1 z 3 czujników

W tym rozdziale zostały przedstawione wyniki symulacji dla scenariusza uszkodzenia 1 z 3 czujników położenia i prędkości. Za uszkodzenie systemu pomiarowego w pracy przyjęto stan, w którym czujnik dostarcza pomiaru w dużym stopniu różniące się od wartości rzeczywistej:

- dla czujnika położenia przyjęto, że będzie on wskazywał położenie ($x_o = -100 m$; $y_o = -100 m$),
- dla czujnika prędkości przyjęto, że będzie on wskazywał prędkość ($u = -2 \frac{m}{s}$; $v = -2 \frac{m}{s}$).

Badania zostały przeprowadzone dla dwóch scenariuszy, które opisano w rozdziale 5.1. Pierwszy scenariusz (manewr) jest symulacją zmiany położenia i kursu przez statek (rys. 5.2). Drugi scenariusz (stabilizacja) jest symulacją utrzymania przez statek stałego położenia i kursu (rys. 5.4). W badaniach wykorzystano trzecią konfigurację czujników przedstawioną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkość statku bez szumu pomiarowego. Dla uproszczenia zapisów użyto następujących skrótów:


- PF - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 4),




5. Badania symulacyjne algorytmów fuzji danych

- PKF - kaskadowo połączone filtry cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 6 + algorytm 7),
- EKF - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27)-(2.28) (algorytm 2 + algorytm 7).


Poniżej przedstawiono wyniki badań symulacyjnych dla uszkodzenia 1 z 3 czujników położenia dla pierwszego scenariusza (manewr) (rys. 5.36-5.40).




Rys. 5.36: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - uszkodzenie 1 z 3 czujników położenia podczas manewru




Rys. 5.37: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 1 z 3 czujników położenia podczas manewru



Rys. 5.38: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 1 z 3 czujników położenia podczas manewru



Rys. 5.39: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 1 z 3 czujników położenia podczas manewru



Rys. 5.40: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 1 z 3 czujników położenia podczas manewru


Analiza wykresów $RMSE(k)$ (rys 5.36-5.40) pozwala na stwierdzenie, że uszkodzenie 1 z 3 czujników położenia dla pierwszego scenariusza ma niekorzystny wpływ na jakość estymacji stosując algorytmy NO i EKF. Na podstawie




5. Badania symulacyjne algorytmów fuzji danych

wykresów $RMSE(k)$ (rys. 5.36-5.40) stwierdzono, że uszkodzenie jednego z czujników położenia w znacznie mniejszym stopniu wpływa na jakość estymacji algorytmów PF i PKF. Porównując rys. 5.21-5.22 oraz rys. 5.36-5.40 stwierdzono, że zaprojektowane algorytmy PF i PKF są odporne na uszkodzenie 1 z 3 czujników położenia w czasie manewru. Analiza porównawcza rys. 5.24-5.25 względem rys. 5.39-5.40 wykazała, że uszkodzenie jednego czujnika położenia nie wpływa negatywnie na jakość estymacji prędkości dla wszystkich z analizowanych algorytmów.


Wyniki badań symulacyjnych dla drugiego scenariusza (stabilizacja) i uszkodzenia 1 z 3 czujników położenia zostały zaprezentowane na rys. 5.41-5.45.




Rys. 5.41: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji




Rys. 5.42: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji



Rys. 5.43: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji



Rys. 5.44: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji



Rys. 5.45: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 1 z 3 czujników położenia podczas stabilizacji


Analiza wykresów $RMSE(k)$ dla obu scenariuszy (rys. 5.36-5.45) pozwala na stwierdzenie, że jakość estymacji przy uszkodzeniu 1 z 3 czujników położenia nie wpływa negatywnie na jakość estymacji prędkości algorytmów. Na podstawie




5. Badania symulacyjne algorytmów fuzji danych

wykresów $RMSE(k)$ (rys. 5.41-5.45) stwierdzono, że uszkodzenie jednego z czujników nie ma negatywnego wpływu na jakość estymacji algorytmów PF i PKF.


Wyniki badań symulacyjnych dla pierwszego scenariusza (manewr) i i uszkodzenia 1 z 3 czujników prędkości zostały zaprezentowane na rys. 5.46-5.50.




Rys. 5.46: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_0 - uszkodzenie 1 z 3 czujników prędkości podczas manewru




Rys. 5.47: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - uszkodzenie 1 z 3 czujników prędkości podczas manewru



Rys. 5.48: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 1 z 3 czujników prędkości podczas manewru



Rys. 5.49: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 1 z 3 czujników prędkości podczas manewru



Rys. 5.50: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 1 z 3 czujników prędkości podczas manewru


Analiza wykresów $RMSE(k)$ (rys. 5.46-5.50) pozwala na stwierdzenie, że uszkodzenie 1 z 3 czujników prędkości zwiększa kilkukrotnie błąd estymacji położenia w osi X_o i Y_o dla algorytmu EKF. W badaniu na rys. 5.49 i 5.50




5. Badania symulacyjne algorytmów fuzji danych

widoczny jest wzrost $RMSE(k)$ dla estymacji prędkości stosując algorytmy EKF i NO. Na podstawie wykresów $RMSE(k)$ (rys. 5.46-5.50 i rys. 5.21-5.25) stwierdzono, że najlepsze wyniki podczas badania uzyskał algorytm PKF, dla którego jakość estymacji $RMSE(k)$ nie jest zależna od uszkodzenia 1 z 3 czujników prędkości podczas pierwszego scenariusza (manewr).


Wyniki badań symulacyjnych dla drugiego scenariusza (stabilizacja) i uszkodzenia 1 z 3 czujników prędkości zostały zaprezentowane na rys. 5.51-5.55.




Rys. 5.51: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji




Rys. 5.52: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji



Rys. 5.53: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji



Rys. 5.54: Błąd średniokwadratowy $RMSE(k)$ prędkość wzdłużnej statku u - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji



Rys. 5.55: Błąd średniokwadratowy prędkości poprzecznej statku v - uszkodzenie 1 z 3 czujników prędkości podczas stabilizacji

Analiza wykresów $RMSE(k)$ (rys. 5.51-5.55) pozwala na stwierdzenie, że uszkodzenie 1 z 3 czujników prędkości w czasie utrzymywania pozycji i kursu przez statek również ma negatywny wpływ na jakość estymacji EKF i NO dla



wszystkich estymowanych stanów. W badaniu rys. 5.49-5.50 widoczny jest wzrost $RMSE(k)$ dla algorytmów EKF i NO dla estymacji prędkości. Na podstawie wykresów $RMSE(k)$ (rys. 5.46-5.50 i rys. 5.21-25) stwierdzono, że najlepsze wyniki w symulacjach uzyskał algorytm PKF, dla którego jakość estymacji nie jest zależna od uszkodzenia 1 z 3 czujników prędkości $RMSE(k)$ podczas drugiego scenariusza.

5.2.6 Uszkodzenie 2 z 3 czujników

W tym rozdziale zostały przedstawione wyniki symulacji dla scenariusza uszkodzenia 2 z 3 czujników położenia i prędkości. Za uszkodzenie systemu pomiarowego w pracy przyjęto stan, w którym czujniki dostarczają pomiary w dużym stopniu różniące się od wartości rzeczywistej:


- dla czujnika położenia przyjęto, że będzie on wskazywał położenie $(-100m; -100m)$,
- dla czujnika prędkości przyjęto, że będzie on wskazywał prędkość $(-2\frac{m}{s}; -2\frac{m}{s})$.

Badania zostały przeprowadzone dla pierwszego scenariusza opisanego w rozdziale 5.1. Scenariusz ten (manewr) jest symulacją zmiany położenia i kursu przez statek (rys. 5.2). W badaniach wykorzystano trzecią konfigurację czujników przedstawioną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkość statku bez szumu pomiarowego. Dla uproszczenia zapisów użyto następujących skrótów:


- PF - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 4),
- PKF - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 6 + algorytm 7),
- EKF - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27)-(2.28) (algorytm 2 + algorytm 7).

Poniżej przedstawiono wyniki badań symulacyjnych dla uszkodzenia 2 z 3 czujników położenia dla pierwszego scenariusza (manewr) (rys. 5.56-5.60).






Rys. 5.56: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X - uszkodzenie 2 z 3 czujników położenia podczas manewru




Rys. 5.57: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - uszkodzenie 2 z 3 czujników położenia podczas manewru




Rys. 5.58: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 2 z 3 czujników położenia podczas manewru

5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.59: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 2 z 3 czujników położenia podczas manewru




Rys. 5.60: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 2 z 3 czujników położenia podczas manewru


Analiza wykresów $RMSE(k)$ (rys. 5.56-5.60) pozwala na stwierdzenie, że uszkodzenie 2 z 3 czujników położenia dla algorytmów EKF i NO powoduje wystąpienie wartości $RMSE(k)$, która uniemożliwiła by dalszą pracę systemu DP. Z rys. 5.59-5.60 wynika, że estymacja prędkości uległa pogorszeniu tylko w przypadku algorytmu EKF. Na podstawie wykresów $RMSE(k)$ (rys. 5.56-5.60) stwierdzono, że uszkodzenie 2 z 3 czujników położenia nie wpływa negatywnie na jakość estymacji algorytmów PF i PKF. Porównując rys. 5.21-5.22 i rys. 5.56-5.57 stwierdzono, że zaprojektowane algorytmy PF i PKF są odporne na uszkodzenie 2 z 3 czujników położenia w czasie manewru.

Poniżej przedstawiono wyniki badań symulacyjnych dla uszkodzenia 2 z 3 czujników prędkości dla pierwszego scenariusza (manewr) prezentowanego w rozdziale 5.1 (rys. 5.61-5.65).






Rys. 5.61: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_0 - uszkodzenie 2 z 3 czujników prędkości podczas manewru




Rys. 5.62: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - uszkodzenie 2 z 3 czujników prędkości podczas manewru




Rys. 5.63: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - uszkodzenie 2 z 3 czujników prędkości podczas manewru





Rys. 5.64: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - uszkodzenie 2 z 3 czujników prędkości podczas manewru



Rys. 5.65: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - uszkodzenie 2 z 3 czujników prędkości podczas manewru

Analiza wykresów $RMSE(k)$ (rys. 5.61-5.65) pozwala na stwierdzenie, że uszkodzenie 2 z 3 czujników prędkości dla algorytmów EKF i NO uniemożliwia dalszą pracę systemu, gdyż estymowana wartość położenia i prędkości osiąga zbyt duży $RMSE(k)$. Na podstawie wykresów $RMSE(k)$ (rys. 5.61-5.65) stwierdzono, że uszkodzenie 2 z 3 czujników pomiarowych prędkości w niewielkim stopniu wpływa na jakość estymacji algorytmów PF i PKF. Porównując rys. 5.24-5.25 oraz rys. 5.64-5.65 stwierdzono, że zaprojektowane algorytmy PF i PKF są odporne na uszkodzenie 2 z 3 czujników prędkości.

5.2.7 Brak aktualizacji pomiaru 1 z 3 czujników


W tym rozdziale zostały przedstawione wyniki badań symulacyjnych dla scenariusza z brakiem aktualizacji pomiaru 1 z 3 czujników położenia lub prędkości. W symulacjach brak aktualizacji pomiaru zaprojektowano jako dostarczanie przez 20 s w czasie od 40 do 60 sekundy scenariusza stałej wartości równej wartości pomiarowej przed wystąpieniem braku aktualizacji pomiaru.

Badania zostały przeprowadzone dla dwóch scenariuszy, które opisano w rozdziale 5.1. Pierwszy scenariusz (manewr) jest symulacją zmiany położenia

i kursu przez statek (rys. 5.2). Drugi scenariusz (stabilizacja) jest symulacją utrzymywania przez statek stałego położenia i kursu (rys. 5.4). W badaniach wykorzystano trzecią konfigurację czujników prezentowaną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkość statku bez szumów pomiarowych. Dla uproszczenia zapisu użyto następujących skrótów:


- PF - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 4),
- PKF - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 6 + algorytm 7),
- EKF - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27)-(2.28) (algorytm 2 + algorytm 7).

Poniżej przedstawiono wyniki badań symulacyjnych dla braku aktualizacji pomiaru 1 z 3 czujników położenia dla pierwszego scenariusza (manewr) prezentowanego w rozdziale 5.1 (rys. 5.66-5.70).




Rys. 5.66: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru


5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.67: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru




Rys. 5.68: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru



Rys. 5.69: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru






Rys. 5.70: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas manewru

Analiza wykresów $RMSE(k)$ (rys. 5.65-5.70) pozwala na stwierdzenie, że algorytm EKF i NO w czasie braku aktualizacji pomiaru położenia zwiększają kilkukrotnie $RMSE(k)$ (rys. 5.66-5.67). Na podstawie wykresów $RMSE(k)$ (rys. 5.65-5.70) stwierdzono, że brak aktualizacji pomiaru 1 z 3 czujników położenia nie wpływa negatywnie na jakość estymacji prędkości wzdłużnej u (rys. 5.59) i poprzecznej v (rys. 5.70) dla wszystkich z algorytmów. Badanie wykazało również że algorytm PF i PKF są odporne na wystąpienie braku aktualizacji pomiaru 1 z 3 czujników położenia.


Wyniki badań dla scenariusza, w którym występuje brak aktualizacji pomiaru 1 z 3 czujników położenia podczas drugiego scenariusza (stabilizacja) prezentowanego w rozdziale 5.1 na rys. 5.4 przedstawiono na rys. 5.71-5.75.




Rys. 5.71: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji




5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.72: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji




Rys. 5.73: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji



Rys. 5.74: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji






Rys. 5.75: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 1 z 3 czujników położenia podczas stabilizacji

Analiza wykresów $RMSE(k)$ (rys. 5.71-5.75) pozwala na stwierdzenie, że brak aktualizacji pomiaru położenia dla 1 z 3 czujników podczas utrzymywania stałego położenia i kursu nie wpływa negatywnie na działanie algorytmów estymacji. Analizując wykresy $RMSE(k)$ rys. 5.66-5.75 stwierdzono, że wystąpienie braku aktualizacji pomiaru 1 z 3 czujników położenia wpływa negatywnie na działanie algorytmów estymacji tylko w przypadku niezerowej prędkości statku. Dodatkowo wartość błędu estymacji zależna jest od prędkości poruszania się statku.


Wyniki badań dla scenariusza, w którym występuje brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas pierwszego scenariusza (manewr) prezentowanego w rozdziale 5.1 na rys. 5.2 przedstawiono na rys. 5.76-5.80.




Rys. 5.76: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru




5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.77: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru




Rys. 5.78: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru



Rys. 5.79: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru






Rys. 5.80: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas manewru

Analiza wykresów $RMSE(k)$ (rys. 5.76-5.80) pozwala na stwierdzenie, że w przypadku wystąpienia braku aktualizacji pomiaru 1 z 3 czujników prędkości zaobserwowano zwiększenie $RMSE(k)$ położenia dla algorytmów EKF, PF i PKF. Najmniejszy błąd estymacji położenia i prędkości uzyskał algorytm NO. Na podstawie wykresów $RMSE(k)$ (rys. 5.79-5.80) można zaobserwować wzrost wartości $RMSE(k)$ w czasie od 40 do 60 s symulacji, a następnie w krótkim czasie powrót do $RMSE(k)$ z przed wystąpienia braku aktualizacji pomiaru.

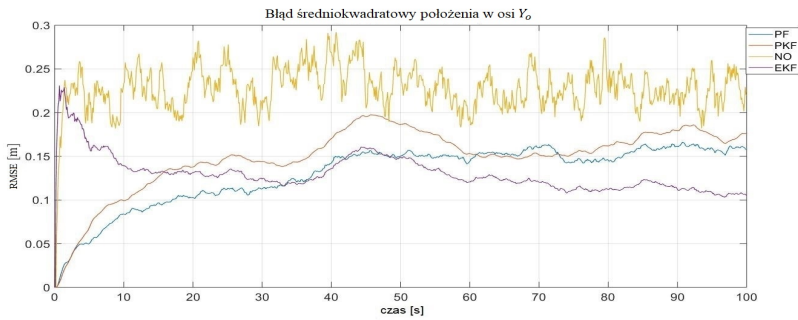
Wyniki badań dla scenariusza, w którym występuje brak aktualizacji pomiaru 1 z 3 czujników położenia podczas drugiego scenariusza (stabilizacja) prezentowanego w rozdziale 5.1 na rys. 5.4 przedstawiono na rys. 5.81-5.85.




Rys. 5.81: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji




5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.82: Błęd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji




Rys. 5.83: Błęd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji



Rys. 5.84: Błęd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji





Rys. 5.85: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 1 z 3 czujników prędkości podczas stabilizacji

Analiza wykresów $RMSE(k)$ (rys. 5.81-5.85) pozwala na stwierdzenie, że wartość $RMSE(k)$ nie uległ znaczącym zmianom w porównaniu do rys. 5.21-5.25, co wskazuje, że jakość estymacji w przypadku braku aktualizacji pomiaru dla 1 z 3 czujników prędkości zależy jest od zmiany prędkości statku podczas której wystąpiło zdarzenie braku aktualizacji pomiaru.

5.2.8 Brak aktualizacji pomiaru 2 z 3 czujników

W tym rozdziale zostały przedstawione wyniki symulacji dla scenariusza braku aktualizacji pomiaru 2 z 3 czujników położenia lub prędkości. W symulacjach brak aktualizacji pomiaru zaprojektowano jako dostarczanie przez 20 s od w czasie 40 do 60 s scenariusza stałej wartości równej wartości pomiarowej przed wystąpieniem braku aktualizacji pomiaru.


Badania zostały przeprowadzone dla dwóch scenariuszy, które opisano w rozdziale 5.1. Pierwszy scenariusz (manewr) jest symulacją zmiany położenia i kursu przez statek (rys. 5.2). Drugi scenariusz (stabilizacja) jest symulacją utrzymania położenia i kursu (rys. 5.4). W badaniach wykorzystano trzecią konfigurację czujników prezentowaną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkości statku bez szumu pomiarowego. Dla uproszczenia zapisu użyto następujących skrótów:

- PF - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 4),
- PKF - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 6 + algorytm 7),
- EKF - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27)-(2.28) (algorytm 2 + algorytm 7).




5. Badania symulacyjne algorytmów fuzji danych


Wyniki badań dla pierwszego scenariusza (manewr), w którym 2 z 3 czujników położenia uległy jednoczesnej awarii związanej z brakiem aktualizacji pomiaru trwającym 20 s, przedstawiono na rys. 5.86–5.90.



Rys. 5.86: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru




Rys. 5.87: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru




Rys. 5.88: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru





Rys. 5.89: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru




Rys. 5.90: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas manewru


Analiza wykresów $RMSE(k)$ (rys. 5.86-5.90) pozwala na stwierdzenie, że w czasie trwania uszkodzenia od 40 do 60 s dla algorytmu NO oraz EKF wartość $RMSE(k)$ rośnie wraz z czasem trwania braku aktualizacji pomiaru. Wartość $RMSE(k)$ (rys. 5.86-5.87) po powrocie prawidłowego pomiaru dla algorytmu NO (po 60 s) maleje bardzo szybko, wraca do wartości z przed wystąpienia braku aktualizacji pomiaru (rys. 5.21-5.22), natomiast czas ten dla algorytmu EKF jest dużo dłuższy. Wystąpienie braku aktualizacji pomiaru 2 z 3 czujników położenia wpływa nieznacznie na wartość $RMSE(k)$ prędkości w czasie wystąpienia awarii dla wszystkich algorytmów poza algorytmem PF (rys. 5.89-5.90).

Wyniki badań dla drugiego scenariusza (stabilizacja), w którym 2 z 3 czujników położenia uległy jednoczesnej awarii związanej z brakiem aktualizacji pomiaru trwającym 20 s, przedstawiono na rys. 5.86-5.90.


5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.91: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji




Rys. 5.92: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji




Rys. 5.93: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji





Rys. 5.94: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku ψ - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji




Rys. 5.95: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 2 z 3 czujników położenia podczas stabilizacji


Analiza wykresów $RMSE(k)$ (rys. 5.91-5.95) pozwala na stwierdzenie, że w czasie trwania uszkodzenia od 40 do 60 s dla algorytmów PKF, NO oraz EKF wartość $RMSE(k)$ rośnie wraz z czasem trwania brakiem aktualizacji. Wartość $RMSE(k)$ (rys. 5.86-5.87) po powrocie prawidłowego pomiaru dla algorytmu NO (po 60 s) maleje bardzo szybko, wraca do wartości z przed wystąpienia braku aktualizacji pomiaru (rys. 5.21-5.22), natomiast czas ten dla algorytmów PKF i EKF jest znacznie dłuższy. Wystąpienie braku aktualizacji pomiaru 2 z 3 czujników położenie w podczas utrzymywania położenia i kursu statku nie wpływa na $RMSE(k)$ prędkości w czasie wystąpienie braku aktualizacji pomiaru dla wszystkich algorytmów (rys. 5.94-5.95).

Wyniki badań dla pierwszego scenariusza (manewr), w którym 2 z 3 czujników prędkości uległy jednoczesnej awarii związanej z brakiem aktualizacji pomiaru trwającym 20 s, przedstawiono na rys. 5.96-5.100.


5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.96: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas manewru




Rys. 5.97: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji 2 z 3 czujników prędkości podczas manewru




Rys. 5.98: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi ψ - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas manewru





Rys. 5.99: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji pomiaru z 3 czujników prędkości podczas manewru




Rys. 5.100: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru z 3 czujników prędkości podczas manewru


Analiza wykresów $RMSE(k)$ (rys. 5.96-5.100) pozwala na stwierdzenie, że w czasie trwania uszkodzenia od 40 do 60 s dla wszystkich algorytmów wartość $RMSE(k)$ rośnie wraz z czasem trwania braku aktualizacji pomiaru. Wartość $RMSE(k)$ w położeniu (rys. 5.96-5.97) dla algorytmu NO po 60 s jest najniższa i bardzo szybko wraca do wartości z przed wystąpienia braku aktualizacji pomiaru, natomiast czas ten dla algorytmów PKF, PF i EKF jest znacznie dłuższy. Wystąpienie braku aktualizacji pomiaru dla 2 z 3 czujników prędkości w czasie manewru statku wpływa na wartość $RMSE(k)$ prędkości w czasie braku aktualizacji pomiaru dla wszystkich algorytmów (rys. 5.99-5.100).

Wyniki badań dla drugiego scenariusza (stabilizacja), w którym 2 z 3 czujników prędkości uległy jednoczesnej awarii związanej z brakiem aktualizacji pomiaru trwającym 20 s, przedstawiono na rys. 5.101–5.105.


5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.101: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas stabilizacji




Rys. 5.102: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas stabilizacji




Rys. 5.103: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas stabilizacji





Rys. 5.104: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - brak aktualizacji 2 z 3 czujników prędkości podczas stabilizacji



Rys. 5.105: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - brak aktualizacji pomiaru 2 z 3 czujników prędkości podczas stabilizacji

Analiza wykresów $RMSE(k)$ (rys 5.101-5.105) pozwala na stwierdzenie, że tak jak w przypadku braku aktualizacji pomiaru dla 1 z 3 czujników prędkości, wystąpienie braku aktualizacji pomiaru prędkości podczas utrzymywania pozycji i kursu statku nie ma negatywnego wpływu na wartość $RMSE(k)$.

5.2.9 Dryft sygnału pomiarowego 1 z 3 czujników

W tym rozdziale zostały przedstawione wyniki symulacji dla scenariusza dryftu 1 z 3 czujników położenia oraz prędkości. dryft czujnika uzyskano poprzez dodanie stałej wartości do pomiarów i odpowiednio:

- pomiar współrzędnych czujnika położenia został przesunięty o $(+5 [m], +5 [m])$,
- pomiar prędkość czujnika prędkości został zwiększony o $+0.05 \frac{m}{s}$, $+0.05 \frac{m}{s}$.

Badania zostały przeprowadzone dla dwóch scenariuszy opisany w rozdziale 5.1. Pierwszy scenariusz (manewr) jest symulacją zmiany położenia i kursu przez statek (rys. 5.2). Drugie scenariusz (stabilizacja) jest symulacją utrzymywania




5. Badania symulacyjne algorytmów fuzji danych


przez statek stałego położenia i kursu (rys. 5.4). W badaniach wykorzystano trzecią konfigurację czujników prezentowaną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkości statku bez szumu pomiarowego. Dla uproszczenia zapisu użyto następujących skrótów:

- PF - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 4),
- PKF - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 6 + algorytm 7),
- EKF - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27)-(2.28) (algorytm 2 + algorytm 7).


Wyniki badań dla pierwszego scenariusza (manewr), w którym 1 z 3 czujników położenia posiada dryft sygnału pomiarowego, przedstawiono na rys. 5.106–5.110.




Rys. 5.106: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - dryft 1 z 3 czujników położenia podczas manewru



Rys. 5.107: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - dryft 1 z 3 czujników położenia podczas manewru




Rys. 5.108: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 1 z 3 czujników położenia podczas manewru



Rys. 5.109: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 1 z 3 czujników położenia podczas manewru


5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.110: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku w osi v - dryft 1 z 3 czujników położenia podczas manewru


Analiza wykresów $RMSE(k)$ (rys. 5.106-110) pozwala na stwierdzenie, że w przypadku dryftu 1 z 3 czujników algorytmy EKF i NO zwiększają wartość $RMSE(k)$ położenia. Na podstawie wykresów $RMSE(k)$ (rys. 5.106-5.110) stwierdzono, że dryft 1 z 3 czujników położenia nie wpływa na jakość estymacji algorytmu PF i PKF. Analiza wyników symulacyjnych wykazała, że dryft 1 z 3 czujników położenia nie ma negatywnego wpływu na jakość estymacji prędkości (rys. 5.109-5.110) dla wszystkich z prezentowanych algorytmów.

Wyniki badań dla drugiego scenariusza (stabilizacja), w którym 1 z 3 czujników położenia posiada dryft sygnału pomiarowego, przedstawiono na rys. 5.111–5.115.




Rys. 5.111: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_0 - dryft 1 z 3 czujników położenia podczas stabilizacji






Rys. 5.112: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 1 z 3 czujników położenia podczas stabilizacji




Rys. 5.113: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 1 z 3 czujników położenia podczas stabilizacji



Rys. 5.114: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 1 z 3 czujników położenia podczas stabilizacji


5. Badania symulacyjne algorytmów fuzji danych




Rys. 5.115: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku w osi X_o - dryft 1 z 3 czujników położenia podczas stabilizacji

Analiza wykresów $RMSE(k)$ (rys. 5.111-5.115) pozwala na stwierdzenie, że w przypadku dryftu 1 z 3 czujników położenia algorytmy EKF i NO zwiększają wartość $RMSE(k)$ dla położenia. Na podstawie wykresów $RMSE(k)$ (rsy. 5.111-5.115) stwierdzono, że dryft 1 z 3 czujników położenia nie wpływa negatywnie na jakość estymacji algorytmów PF i PKF.


Wyniki badań dla pierwszego scenariusza (manewr), w którym 1 z 3 czujników prędkości posiada dryft sygnału pomiarowego, przedstawiono na rys. 5.116–5.120.



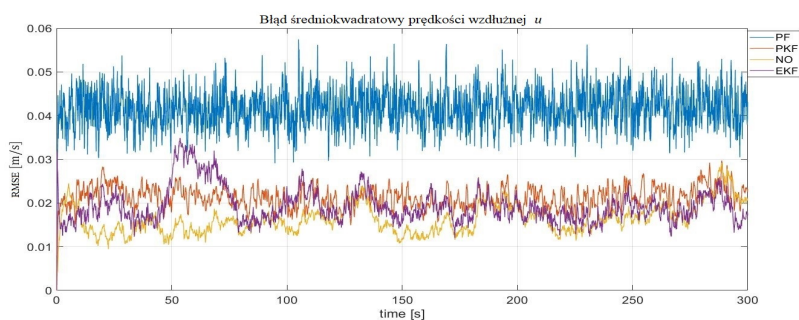
Rys. 5.116: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - dryft 1 z 3 czujników prędkości podczas manewru



Rys. 5.117: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - dryft 1 z 3 czujników prędkości podczas manewru




Rys. 5.118: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 1 z 3 czujników prędkości podczas manewru



Rys. 5.119: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 1 z 3 czujników prędkości podczas manewru



5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.120: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - dryft 1 z 3 czujników prędkości podczas manewru

Analiza wykresów $RMSE(k)$ (rys. 5.116-5.120) pozwala na stwierdzenie, że dryft 1 z 3 czujników prędkości zwiększa $RMSE(k)$ położenia (rys. 5.116-5.117) dla wszystkich z algorytmów fuzji danych. Na podstawie wykresów $RMSE(k)$ (rys. 5.116-5.120) stwierdzono, że $RMSE(k)$ prędkości (rys. 5.119-5.120) nie zmienia się znacząco do estymacji tej wielkości przez algorytmu podczas braku dryftu.

5.2.10 Dryft sygnału pomiarowego 2 z 3 czujników

W tym rozdziale zostały przedstawione wyniki symulacji dla scenariusza dryftu 2 z 3 czujników położenia oraz prędkości. Dryft czujnika uzyskano poprzez dodanie stałej wartości do pomiarów i odpowiednio:

- pomiar współrzędnych czujnika położenia został przesunięty o $(+5 [m], +5 [m])$,
- pomiar prędkość czujnika prędkości został zwiększony o $+0.05 \frac{m}{s}, +0.05 \frac{m}{s}$.


Badania zostały przeprowadzone dla pierwszego scenariusza (manewr), który symulacją zmiany położenia i kursu przez statek (rys. 5.2). W badaniach wykorzystano trzecią konfigurację czujników prezentowaną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkości statku bez szumu pomiarowego. Dla uproszczenia zapisu użyto następujących skrótów:

- PF - filtr cząsteczkowy wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 4),
- PKF - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model w przestrzeni stanu opisany równaniami (2.27)-(2.28) (algorytm 5),
- NO - nieliniowy obserwator wykorzystujący model w przestrzeni stanu opisany równaniami(2.27) i (2.28) (algorytm 6 + algorytm 7),




- EKF - rozszerzony filtr Kalmana wykorzystujący model w przestrzeni stanu opisany równaniami(2.27)-(2.28) (algorytm 2 + algorytm 7).

Wyniki badań dla pierwszego scenariusza (manewr), w którym 2 z 3 czujników położenia posiada dryft sygnału pomiarowego, przedstawiono na rys. 5.121–5.125.




Rys. 5.121: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_o - dryft 2 z 3 czujników położenia podczas manewru




Rys. 5.122: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_o - dryft 2 z 3 czujników położenia podczas manewru


5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.123: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 2 z 3 czujników położenia podczas manewru



Rys. 5.124: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft 2 z 3 czujników położenia podczas manewru




Rys. 5.125: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - dryft 2 z 3 czujników położenia podczas manewru


Analiza wykresów $RMSE(k)$ (rys. 5.121-5.126) pozwala na stwierdzenie, że dryft 2 z 3 czujników położenia znacząco pogorszył wartości $RMSE(k)$ dla estymacji położenia wszystkich algorytmów.




Wyniki badań dla pierwszego scenariusza (manewr), w którym 2 z 3 czujników prędkości posiada dryft sygnału pomiarowego, przedstawiono na rys. 5.126–5.130.



Rys. 5.126: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi X_0 - dryft 2 z 3 czujników prędkości podczas manewru




Rys. 5.127: Błąd średniokwadratowy $RMSE(k)$ położenia statku w osi Y_0 - dryft 2 z 3 czujników prędkości podczas manewru




Rys. 5.128: Błąd średniokwadratowy $RMSE(k)$ kursu statku ψ - dryft 2 z 3 czujników prędkości podczas manewru



5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.129: Błąd średniokwadratowy $RMSE(k)$ prędkości wzdłużnej statku u - dryft z 3 czujników prędkości podczas manewru



Rys. 5.130: Błąd średniokwadratowy $RMSE(k)$ prędkości poprzecznej statku v - dryft z 3 czujników prędkości podczas manewru

Analiza wykresów $RMSE(k)$ (rys. 5.126-5.130) pozwala na stwierdzenie, że prezentowany scenariusz ma negatywny wpływ na jakość estymacji położenia (rys. 5.126-5.127) dla wszystkich prezentowanych algorytmów, ale najmniejszy wzrost wartości $RMSE(k)$ uzyskano dla NO.

5.2.11 Estymacja zakłóceń środowiskowych


Estymacja zakłóceń środowiskowych umożliwia lepszą kompensację i stanowi istotną informację dla algorytmów sterowania. W badaniu użyto następujących algorytmów fuzji danych:

- PKF - kaskadowo połączone filtr cząsteczkowy i rozszerzony filtr Kalmana, wykorzystujący model przestrzeni stanu opisany równaniami (2.27)-(2.28),
- NO - nieliniowy obserwator,
- EKF - rozszerzony filtr Kalmana wykorzystujący model przestrzeni stanu z równań (2.27)-(2.28).




Badania zostały przeprowadzone dla dwóch scenariuszy opisanych w rozdziale 5.1. Pierwszy scenariusz (manewr) jest symulacją zmiany położenia i kursu przez statek (rys.5.2) Drugi scenariusz (stabilizacja) jest symulacją utrzymania przez statek stałego położenia i kursu (rys.5.4). W badaniu wykorzystano trzecią konfigurację czujników prezentowaną w tabeli 5.1. Do inicjalizacji algorytmów estymacji wykorzystano początkowe położenie, kurs i prędkość statku bez szumu pomiarowego.

Wyniki dla pierwszego scenariusza (manewr) przedstawiono na rys. 5.130-5.133.




Rys. 5.131: Błąd średniokwadratowy $RMSE(k)$ zakłuceń wolnozmiennych w osi X_o - podczas manewru



Rys. 5.132: Błąd średniokwadratowy $RMSE(k)$ siły zakłuceń wolnozmiennych w osi Y_o - podczas manewru



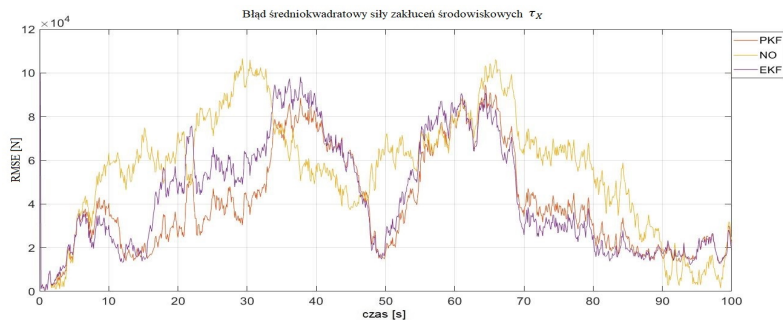
5. Badania symulacyjne algorytmów fuzji danych



Rys. 5.133: Błąd średniokwadratowy $RMSE(k)$ momentu zakłóceń wolnozmiennych w okół osi Z_o - podczas manewru


Analiza wykresów $RMSE(k)$ (rys. 5.130-5.133) pozwala na stwierdzenie, że $RMSE(k)$ dla wszystkich z algorytmów uzyskał podobny zakres wartości. Wartość błędu estymacji zakłóceń środowiskowych stanowi od kilku do kilkunastu procent wartości zakłóceń ale w dalszym ciągu stanowią istotną informację dla algorytmów sterowania.

Wyniki dla drugiego scenariusza (stabilizacja) przedstawiono na rys. 5.133-5.136.




Rys. 5.134: Błąd średniokwadratowy $RMSE(k)$ zakłóceń wolnozmiennych w osi X_o - podczas manewru





Rys. 5.135: Błąd średniokwadratowy $RMSE(k)$ siły zakłuceń wolnozmiennych w osi Y_o - podczas manewru



Rys. 5.136: Błąd średniokwadratowy $RMSE(k)$ momentu zakłuceń wolnozmiennych w okół osi Z_o - podczas manewru

Analiza wykresów $RMSE(k)$ (rys. 5.130-5.136) pozwala na stwierdzenie, że $RMSE(k)$ dla obu scenariuszy przyjmuje podobny zakres. Badanie wykazało, że prędkość statku nie wpływa na jakość estymacji zakłóceń środowiskowych.

5.3 Wnioski

Na podstawie przeprowadzonych badań symulacyjnych prezentowanych w powyższych rozdziałach można sformułować następujące wnioski:

- Fuzja danych z wykorzystaniem nadmiarowej konfiguracji czujników pomiarowych obniża wartość $RMSE(k)$ dla wszystkich prezentowanych z algorytmów. Analizując wyniki badań symulacyjnych prezentowanych w tabelach 5.3 i 5.6 zaobserwowano, że algorytm NO uzyskał w badaniach największą zmianę jakości estymacji ze wszystkich badanych algorytmów. Błąd położenia dla tego algorytmu obniżył się z poziomu 0.3600 m i 0.3545 m (tabela 5.3) do poziomu 0.2374 m i 0.2339 m (tabela 5.6). Wykorzystanie nadmiarowej konfiguracji pomiarowej zmniejszyło również $RMSE(k)$ dla prędkości z poziomu $0.0517 \frac{m}{s}$ i $0.0236 \frac{m}{s}$ do poziomu 0.0272



5. Badania symulacyjne algorytmów fuzji danych

$\frac{m}{s}$ i $0.0133 \frac{m}{s}$. Analizując wykresy $RMSE(k)$ rys.5.11 - 5.15 oraz rys.5.26-5.30 zaobserwowano, że zastosowanie nadmiarowej konfiguracji pomiarowej w znacznym stopniu obniżyło wartość $RMSE(k)$ prędkości dla wszystkich badanych algorytmów. W testach prezentowanych w rozdziale 5.2.1 i 5.2.3 stwierdzono, że najlepsze wyniki uzyskał algorytm EKF, natomiast wyniki dla algorytmu PKF były bardzo zbliżone co do wartości $RMSE(k)$.

- Na podstawie badań przeprowadzonych w rozdziale 5.2.2 stwierdzono, że przy małym okresie odświeżania pomiaru wynoszącym 0.1 s, $RMSE(k)$ w niewielkim stopniu zależy od złożoności modelu matematycznego wykorzystanego w algorytmie estymacji. Jednak dla filtrów o większej złożoności modelu możliwa jest estymacja wartości sił od zakłóceń środowiskowych, które mają znaczący wpływ na parametry osiągnięte przez algorytmy sterowania.
- Analizując $RMSE(k)$ (rys. 5.31-5.35) i $RMSE_{mean}$ zawartego w tabeli 5.7 stwierdzono, że konfiguracja z czujnikiem położenia o większym odchyleniu standardowym osiąga większe błędy $RMSE(k)$ w estymacji położenia ale nie wpływa to negatywnie na jakość estymacji prędkości.

W czasie wykonywania zadania dynamicznego pozycjonowania algorytmy fuzji danych muszą być odporne na różne awarie systemów pomiarowych. Z tego powodu na statkach wykorzystuje się nadmiarowe konfiguracji pomiarowe, które ze względów bezpieczeństwa wykorzystują różne technologie do pomiaru jednego stanu, cechy np. położenia (GPS, GLONAS, radar).

W kolejnych rozdziałach przedstawiono kilka możliwych scenariuszy awaryjnych i odpowiednio ich wpływ na jakość estymacji:

- Uszkodzenie czujnika pomiarowego symulowane jest jako wskazywanie przez czujnik stałej bardzo dużej wartości. Badania wykazały, że wystąpienie uszkodzenia 1 z 3 i 2 z 3 czujników nie wpływa negatywnie na jakość estymacji algorytmów PF i PKF. Algorytmy EKF i NO dla uszkodzenia 1 z 3 czujników pomiarowych kilkukrotnie zwiększają średniokwadratowy błąd estymacji $RMSE(k)$. Wykorzystanie estymowanego wektora stanu z takimi błędami do sterowania statkiem mogłoby skutkować znaczącym obniżeniem jakości sterowania. W krytycznym przypadku uszkodzenia 2 z 3 czujników pomiarowych, dane z algorytmów EKF i NO uniemożliwiłyby dalszą realizację zadania przez statek DP.
- Brak aktualizacji pomiaru w rozprawie rozumiany jest jako wskazywanie przez czujnik stałej wartości spowodowane błędnym działaniem systemu pomiarowego. Do algorytmów, które uzyskały najlepsze wyniki podczas braku aktualizacji pomiaru, należy zaliczyć algorytmy PF i PKF. W czasie braku aktualizacji pomiaru położenia podczas manewru, $RMSE(k)$ (rys. 5.66-5.75 oraz rys 5.86-5.90) zwiększa swoją wartość dla algorytmów EKF i NO tylko w osiach X_o i Y_o . Natomiast kryterium $RMSE(k)$ prędkości jest niezmiennie dla wszystkich algorytmów. W przypadku scenariusza



awaryjnego w którym następuje brak aktualizacji pomiaru z czujnika prędkości w czasie manewru dla wszystkich algorytmów rośnie $RMSE(k)$. W przypadku badań dotyczących braku aktualizacji pomiaru prędkości podczas stabilizacji nie zauważono pogorszenia wartości $RMSE(k)$.

- Dryft sygnału pomiarowego rozumiany jest jako stałe przesunięcie pomiaru względem wartości rzeczywistej. W zależności od rodzaju scenariusza awaryjnego najlepsze wyniki uzyskuje algorytm NO, PF i PKF. Z analizy wyników badań wynika, że wystąpienie tego typu awarii nie powoduje znaczącego wzrostu średniokwadratowego błędu estymacji .

Rozdział 6

Badania symulacyjne algorytmów sterowania

W dalszej części pracy zostaną przedstawiane badania symulacyjne algorytmów sterowania. Badane algorytmy sterowania oceniono pod względem kryterium odpowiedzi skokowej, które reprezentowane jest przez szereg parametrów statycznych i dynamicznych opisanych w rozdziale 6.1. Na parametry kryterium odpowiedzi skokowej mają wpływ parametry algorytmów (dostrojenie algorytmów) oraz jakość danych wejściowych (błędy pomiarowe/ estymacji). W pracy przeprowadzono cztery odrębne badania i odpowiednio:

- pierwsze badanie zakłada, że dane wejściowe do algorytmów sterowania stanowi rzeczywisty wektor stanu statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe), oraz w czasie badania na statek nie działają zakłócenia środowiskowe,
- drugie badanie zakłada, że dane wejściowe do algorytmów sterowania stanowi rzeczywisty wektor stanu statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe), oraz w czasie badania na statek działają zakłócenia środowiskowe, których wartości zostały zaprezentowane na rys. 5.2,
- trzecie badanie zakłada, że dane wejściowe do algorytmów sterowania stanowi estymowany wektor stanu statku (położenie, prędkość, przyspieszenie) i rzeczywista wartość zakłóceń środowiskowych, oraz w czasie badania na statek działają zakłócenia środowiskowe, których wartości zostały zaprezentowane na rys. 5.2,
- czwarte badanie zakłada, że dane wejściowe do algorytmów sterowania stanowi estymowany wektor stanu statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe), oraz w czasie badania na statek działają zakłócenia środowiskowe, wartości zostały zaprezentowane na rys. 5.2.

6.1 Założenia dotyczące badań algorytmów sterowania

Poniższy rozdział przedstawia założenia dotyczące badań symulacyjnych algorytmów sterowania. Celem tego rozdziału jest przedstawienie założeń przyjętych podczas badań symulacyjnych, kryterium oceny algorytmów i parametrów algorytmów: sterowania predykcyjnego (MPC), backsteppingu (BS) i regulatora PID. Pierwszym krokiem przed przystąpieniem do badań było dostrojenie algorytmów tak, aby realizowały zadanie sterowania do punktu zadanego oraz utrzymania położenia i kursu statku, podczas gdy na wejście algorytmów dostarczany jest



6. Badania symulacyjne algorytmów sterowania

rzeczywisty wektor stanu statku (nie obarczony błędem estymacji). Wartości parametrów zostały zaprezentowane w tabeli 6.1. Parametry dla algorytmów sterowania dobrane zostały w wyniku wielokrotnych badań symulacyjnych. Podczas doboru parametrów algorytmów sterowania zwrócono szczególną uwagę aby uzyskać, możliwie mały czas po którym obiekt znajduje się w stanie ustalonym i małe przeregulowanie.


Tabela 6.1: Parametry algorytmów sterowania

MPC	BS	PID
$a_{11}^1 = 30000000000$ $a_{22}^1 = 45000000000$ $a_{33}^1 = 15000000000000$ $a_{11}^2 = 1000000000000$ $a_{22}^2 = 100000000000$ $a_{33}^2 = 30000000000$ $a_{11}^3 = 200000000000$ $a_{22}^3 = 200000000000$	$A = [0.05; 0.05; 0.05]$ $K_p =$ $[8000; 8000; 8000]$ $K_d =$ $[2000; 2000; 2000]$	$K_p = [5000; 5000; 20000000]$ $K_i = [0.1; 0.1; 0.1]$ $K_d = [50; 350; 0]$ $K_{FF} = [1; 1; 1]$
Równanie (4.51)	Równanie (4.33)	Równanie (4.9)

Do optymalizacji funkcji celu dla algorytmu MPC wykorzystano metodę sekwencyjnego programowania kwadratowego [96] (SQP, ang. *sequence quadratic programming*) korzystając z wbudowanych bibliotek środowiska Matlab. W pracy założono, że algorytm MPC będzie aktualizował wartości wektora sterowania co 5 s. z tego powodu algorytm SQP ograniczono do 10 000 iteracji, gdyż dla tej wartości obliczenia trwały w przybliżeniu 5 s. Algorytm MPC do obliczenia sterowania wymaga na wejściu informacji o wartości wektora stanu. Z tego powodu działanie algorytmu rozpoczyna się w 5 sekundzie symulacji. Zgodnie z opisem w rozdziale 4.3 i rys. 4.3. w chwili k (5 sekunda symulacji) obliczane jest sterowanie dla chwili $k + K_{op}$ (10 sekundy symulacji) gdzie K_{op} jest czasem potrzebnym na rozwiązanie zadania optymalizacji. Funkcja celu dla algorytmu MPC została opisana w równaniu (4.51). Dla wszystkich algorytmów sterowania założono, że sterowanie obliczane jest z krokiem 1-sekundowym i ograniczono maksymalną wartość zmiany sterowania do 50 000 N/ 50 000 Nm na sekundę, co oznacza, że kolejne wartości wektora sił i momentu sterowania mogą różnić się o 50 000 N / 50 000 Nm. Powyższe założenie poczyniono ze względu na ujednoczenie założeń dla wszystkich algorytmów.

Do badań symulacyjnych wykorzystano dwa zadania realizowane przez statek z systemem dynamicznego pozycjonowania. Pierwszym zadaniem jest przemieszczenie statku z pozycji $[0\ m, 0\ m]$ i kursu $0.0\ rad$ do położenia $[100\ m, 100\ m]$ i kursu $0.5\ rad$ poprzez skokową zmianę zadanego położenia w czasie $t_0 = 0$. Drugim zadaniem jest stabilizacja statku w zadanym położeniu $[0\ m, 0\ m]$ i kursie $0.0\ rad$. Jako kryteria oceny algorytmów sterowania przyjęto parametry charakterystyki skokowej układu przedstawione na rys. 6.1.





Rys. 6.1: Statyczne i dynamiczne parametry sterowania

Odpowiednio dla odpowiedzi skokowej układu kryteria są opisane następującymi parametrami sterowania [19]:

- $t_{10\%}$ - czas, w którym obiekt osiąga 10 % wartości zadanej,
- $t_{90\%}$ - czas, w którym obiekt osiąga 90 % wartości zadanej,
- t_n - czas narastania, w którym obiekt osiąga od 10% do 90% wartości zadanej,
- A_p - przeregulowanie,
- t_A - czas wystąpienia przeregulowania,
- t_u - czas, po którym obiekt jest w stanie ustalonym,
- $\tilde{x}_{ur\,sme}$ - średniokwadratowy uchyb w stanie ustalonym,
- A_u - najwyższa amplituda w stanie ustalonym,
- Δ - uchyb sterowania, dla którego przyjmujemy, że obiekt jest w stanie ustalonym.

Brak wypełnienia pola parametru w tabelach oznacza, że niemożliwe jest określenie jego wartości.

6.1.1 Sterowanie z rzeczywistymi danymi wejściowymi bez zakłóceń środowiskowych


W poniższym rozdziale zaprezentowano wyniki realizacji zadań sterowania przez algorytmy PID, BS i MPC (rozdział 4), które opisano w rozdziale 6.1, w przypadku kiedy na wejście algorytmów sterowania podawany jest rzeczywisty wektor




6. Badania symulacyjne algorytmów sterowania

stanu statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe) oraz w czasie symulacji na statek nie działają zakłócenia środowiskowe. Otrzymane parametry odpowiedzi skokowej układu, będą wartościami referencyjnymi dla pozostałych algorytmów.

Wyniki badań dla pierwszego zadania, w którym statek realizuje zmianę położenia i kursu oraz utrzymanie statku w stanie ustalonym przedstawiono na rys. 6.2-6.6 oraz w tabeli 6.2.




Rys. 6.2: Położenie statku w osi X_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe




Rys. 6.3: Położenie statku w osi Y_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe






Rys. 6.4: Kurs ψ statku podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe



Rys. 6.5: Prędkość wzdłużna statku u podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe



Rys. 6.6: Prędkość poprzeczna statku v podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe


6. Badania symulacyjne algorytmów sterowania

Tabela 6.2: Statyczne i dynamiczne parametry algorytmu sterowania dla kryterium odpowiedzi skokowej (zmiana położenia z [0 m, 0 m, 0 rad] do [100 m, 100 m, 0.5 rad]) - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe.


	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	$\tilde{x}_{ur\text{sm}e}$	A_u	Δ
X_o									
MPC	27.6	60.1	32,5	1.1	75.5	63.5	0.1179	1.1	5 [m]
BS	18.6	69.1	50.5	–	–	82.4	0.9760	–	5 [m]
PID	22.8	111.6	88.8	8.2	192.7	225.7	1.7099	1.3	5 [m]
	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	$\tilde{x}_{ur\text{sm}e}$	A_u	Δ
Y_o									
MPC	31.6	72.8	41.2	–	–	77.3	0.1127	–	5[m]
BS	22.5	61.1	38.6	–	–	65.4	1.0816	–	5 [m]
PID	26.4	130.7	108.1	–	–	148.8	2.8980	–	5 [m]
	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	$\tilde{x}_{ur\text{sm}e}$	A_u	Δ
ψ									
MPC	68.5	141.3	72.8	–	–	141.3.	0.0080	–	0.1 [rad]
BS	59.5	135.8	76.3	–	–	135.8	0.0216	–	0.1 [rad]
PID	50.4	131.4	81.0	–	–	131.4	0.0177	0.017	0.1 [rad]

Na podstawie przebiegu wykresów (rys. 6.2-6.6) oraz tabeli (tabela 6.2) stwierdzono, że najmniejszy czas narastania t_n uzyskał algorytm MPC. Analiza wykresów (rys. 6.2-6.6) pozwala na stwierdzenie, że algorytm BS osiągnął najmniejsze przeregulowanie A_p sterowania podczas wejścia statku na zadane położenie i kurs. Najmniejszą wartość uchybu średniokwadratowego w stanie ustalonym $\tilde{x}_{ur\text{sm}e}$ uzyskał algorytm MPC. Porównanie wyników algorytmów z tabeli 6.2 wynika, że najlepsze wyniki uzyskał algorytm MPC. W przypadku tego algorytmu uzyskano najmniejszym uchybem średniokwadratowy w stanie ustalonym $\tilde{x}_{ur\text{sm}e}$, najmniejszym czasem narastania t_n oraz brakiem amplitudy w stanie ustalonym A_u .


Wyniki badań dla drugiego zadania, w którym statek utrzymuje położenie i kurs przedstawiono na rys. 6.7-6.11.




Rys. 6.7: Położenie statku w osi X_o podczas badania parametrów algorytmów sterowania w stanie ustalony, - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe




Rys. 6.8: Położenie statku w osi Y_o podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe



Rys. 6.9: Kurs statku ψ podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe



Rys. 6.10: Prędkość wzdłużna statku u podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe



Rys. 6.11: Prędkość poprzeczna v podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek nie działają zakłócenia środowiskowe

Na podstawie przebiegu wykresów (rys. 6.7-6.11) stwierdzono, że dla badania utrzymania pozycji i kursu statku kiedy na wejście algorytmów sterowania podawany jest rzeczywisty wektor stanu a na statek nie działają zakłócenia środowiskowe wszystkie z algorytmów osiągają zerową amplitudę w stanie ustalony ($A_u = 0$) i zerowy uchyb średniokwadratowy ($\tilde{x}_{ur\text{srme}} = 0$). Regulator MPC ze względu na suboptymalne rozwiązanie wyznacza niezerowe sterowanie, które spowodowało zmianę położenia statku (rys. 6.7-6.8) ale jest ona bardzo mała.


6.1.2 Sterowanie z rzeczywistymi danymi wejściowymi i zakłóceniami środowiskowymi

W poniższym rozdziale zaprezentowano wyniki realizacji zadań sterowania opisanych w rozdziale 6.1 przez algorytmy PID, BS i MPC w przypadku kiedy na wejście algorytmów sterowania podawany jest rzeczywisty wektor stanu




statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe) oraz w czasie symulacji na statek działają zakłócenia środowiskowe których wartości zaprezentowano na wykresie rys. 5.2.

Wyniki badań dla pierwszego zadania, w którym statek realizuje zmianę położenia i kursu oraz utrzymanie statku w stanie ustalonym przedstawiono na rys. 6.12-6.16 oraz w tabeli 6.3.




Rys. 6.12: Położenie statku w osi X_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe




Rys. 6.13: Położenie statku w osi Y_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe


6. Badania symulacyjne algorytmów sterowania



Rys. 6.14: Kurs statek ψ podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statek oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.15: Prędkość wzdłużna statek u podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statek oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.16: Prędkość poprzeczna statek v podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statek oraz w czasie badania na statek działają zakłócenia środowiskowe




Tabela 6.3: Statyczne i dynamiczne parametry algorytmu sterowania dla kryterium odpowiedzi skokowej (zmiana położenia z [0 m, 0 m, 0 rad] do [100 m, 100 m, 0.5 rad]) - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe.

	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
X_o									
MPC	23.8	57.7	33.9	1	72.1	61.1	0.1486	1	5 [m]
BS	16.8	68.6	51.8	–	–	82.3	08523	–	5 [m]
PID	24.1	109.7	85.6	8.6	182.2	226.4	1.6123	0.78	5 [m]
	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
Y_o									
MPC	28.4	70.8	42.4	0.1	124.8	75.1	0.0719	–	5 [m]
BS	20.9	71.8	50.9	0.7	74.9	62.6	1.4941	–	5 [m]
PID	24.6	109.7	85.6	–	–	145.0	4.4537	–	5 [m]
	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
ψ									
MPC	66.3	140.2	73.9	0.002	182.8	140.2	0.0090	–	0.1 [rad]
BS	57.9	132.9	75.0	–	–	132.9	0.0210	–	0.1 [rad]
PID	48.7	128.4	79.7	–	–	128.4	0.0248	0.0167	0.1 [rad]


Na podstawie przebiegu wykresów (rys. 6.11-6.16) oraz tabeli (tabela 6.3) stwierdzono, że przy dokładnej informacji o zakłóceniach środowiskowych algorytmy sterowania uzyskują zbliżoną wartość co do wartości prezentowanej w rozdziale 6.1.1. Porównując parametry algorytmów w tabeli 6.3 stwierdzono, że najlepsze wyniki uzyskał algorytm MPC. Wyróżnia się on t_u dla osi X_o najmniejszym uchybem średniokwadratowy w stanie ustalonym \tilde{x}_{ursme} oraz najmniejszym czasem narastania t_n . Na wykresach prędkości (rys. 6.15-6.16) zaobserwowano negatywny wpływ zakłóceń środowiskowych na utrzymanie zerowej prędkości statku w stanie ustalonym.

Wyniki badań dla drugiego zadania, w którym statek utrzymuje położenie i kurs przedstawiono na rys. 6.17-6.21 oraz w tabeli 6.4.


6. Badania symulacyjne algorytmów sterowania



Rys. 6.17: Położenie statku w osi X_o podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe




Rys. 6.18: Położenie statku w osi Y_o podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe




Rys. 6.19: Kurs statku ψ podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe





Rys. 6.20: Prędkość wzdłużna statku u podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.21: Prędkość poprzeczna v podczas badania parametrów algorytmów sterowania w stanie ustalony - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe

Tabela 6.4: Statyczne parametry algorytmu sterowania podczas badania kryterium sterowania w stanie ustalonym - danymi wejściowymi do algorytmów są wartości rzeczywiste wektora stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe

	X_o			Y_o			ψ_o		
	A_p	t_A	$\tilde{x}_{ur\text{sme}}$	A_p	t_A	$\tilde{x}_{ur\text{sme}}$	A_p	t_A	$\tilde{x}_{ur\text{sme}}$
MPC	1.9	16.1	0.1827	1.055	16.2	0.0202	0.0091	29.3	0.0001
BS	0.221	17.1	0.0405	0.1167	16.1	0.0312	0.0000	0	0
PID	0.54	43.0	0.1383	0.235	36.1	0.0930	0.0000	0	0.0000

Na podstawie przebiegu wykresów (rys. 6.17-6.21) oraz tabeli (tabela 6.4) stwierdzono, że pomimo dokładnej informacji o zakłóceniach środowiskowych wszystkie algorytmy sterowania pogorszyły swoje parametry względem wyników




prezentowanych w rozdziale 6.1.1. Porównanie wyników algorytmów rys. 6.7-6.11 i rys. 6.17.6.21 wynika, że najlepsze wyniki uzyskał algorytm BS. Algorytm MPC ze względu na opóźnienie w pierwszej fazie nie kompensuje zakłóceń środowiskowych. Na rys. 6.17-6.21 widoczne są fluktuacje położenia i prędkości dla algorytmu MPC. Wynikają one z suboptymalnego rozwiązania zadania sterowania wynikającego z nieliniowej funkcji celu i błędem predykcji związanym ze zmianą siły zakłóceń środowiskowych w czasie.

6.1.3 Sterowanie z estymowanym danymi wejściowymi i informacją o zakłóceniach środowiskowych


W poniższym rozdziale zaprezentowano wyniki realizacji zadań sterowania opisanych w rozdziale 6.1 przez algorytmy PID, BS i MPC w przypadku kiedy na wejście algorytmów sterowania podawany jest estymowany wektor stanu statku (położenie, prędkość, przyspieszenie), i informacja o zakłóceniach środowiskowych (wartość rzeczywista) oraz w czasie symulacji na statek działają zakłócenia środowiskowe.

Wyniki badań dla pierwszego zadania, w którym statek realizuje zmianę położenia i kursu oraz utrzymanie statku w stanie ustalonym przedstawiono na rys. 6.22-6.26 oraz w tabeli 6.5.




Rys. 6.22: Położenie statku w osi X_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe






Rys. 6.23: Położenie statku w osi Y_0 podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe




Rys. 6.24: Kurs statku ψ podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.25: Prędkość wzdłużna statku u podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe

6. Badania symulacyjne algorytmów sterowania



Rys. 6.26: Prędkość poprzeczna statku v podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe

Tabela 6.5: Statyczne i dynamiczne parametry algorytmu sterowania dla kryterium odpowiedzi skokowej (zmiana położenia z $[0 \text{ m}, 0 \text{ m}, 0 \text{ rad}]$ do $[100 \text{ m}, 100 \text{ m}, 0.5 \text{ rad}]$) - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe.


	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
X_o									
MPC	26.7	65.5	38.8	–	–	69.9	0.8383	1.2	5 [m]
BS	16.9	61.7	44.8	1.2	128.1	–	–	–	5 [m]
PID	21.3	110.9	89.6	8.9	179.0	231.5	1.6749	–	5 [m]
	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
Y_o									
MPC	32.3	80.2	47.9	–	–	86.2	1.7815	3.002	5 [m]
BS	20.9	67.6	60.6	12.2	174.2	–	–	–	5 [m]
PID	24.9	127.8	102.9	–	–	143.0	1.9519	–	5 [m]
	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
ψ									
MPC	76.6	181.7	105.1	–	–	181.7	0.0205	–	0.1 [rad]
BS	52.3	88.1	35.8	0.583	186.4	–	4	–	0.1 [rad]
PID	48.8	124.4	75.6	0.035	173.7	124.4	0.0238	0.035	0.1 [rad]

Na podstawie przebiegów przedstawionych na wykresach (rys. 6.22-6.26) oraz tabeli (tabela 6.5) stwierdzono, że dla zaprezentowanego badania wszystkie z algorytmów uzyskały gorsze parametry niż w rozdziale 6.1.1. Porównanie wykresów rys. 6.2-6.6 i rys. 6.22-6.26 zaobserwowano znaczący wzrost A_p oraz to, że algorytm BS nie osiąga stanu ustalonego. Porównując tabele 6.2 i 6.5 można




zaobserwować kilkukrotny wzrost wartości średniokwadratowej uchybu w stanie ustalonym $\tilde{x}_{ur\text{sm}e}$ dla algorytmu MPC, natomiast $\tilde{x}_{ur\text{sm}e}$ dla algorytmu PID uzyskał podobny wynik co do wartości jak w rozdziale 6.1.1.

Wyniki badań dla drugiego zadania, w którym statek utrzymuje położenie i kurs przedstawiono na rys. 6.27-6.31 oraz w tabeli 6.6.




Rys. 6.27: Położenie statku w osi X_o podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe




Rys. 6.28: Położenie statku w osi Y_o podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe


6. Badania symulacyjne algorytmów sterowania



Rys. 6.29: Kurs statek ψ podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statek, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.30: Prędkość wzdłużna statek u podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statek, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.31: prędkość poprzeczna statek v podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statek, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe



Tabela 6.6: Statyczne parametry algorytmu sterowania podczas badania kryterium sterowania w stanie ustalonym - danymi wejściowymi do algorytmów są estymowany wektor stanu statku, informacja o zakłóceniach środowiskowych oraz w czasie badania na statek działają zakłócenia środowiskowe


	X_o			Y_o			ψ_o		
	A_p	t_A	$\tilde{x}_{ur sme}$	A_p	t_A	$\tilde{x}_{ur sme}$	A_p	t_A	$\tilde{x}_{ur sme}$
MPC	6.004	39.9	1.5062	2.947	46.7	1.3531	0.0907	300	0.0471
BS	0.8783	20.5	0.2322	0.9371	28.2	00.2834	0.0237	251.	0.0096
PID	0.5047	41.3	0.2463	0.7447	38.4	0.3760	0.0090	289.	0.0022

Na podstawie przebiegu wykresów (rys. 6.27-6.31) oraz tabeli (tabela 6.6) stwierdzono, że wprowadzenie błędu estymacji do algorytmów sterowania spowodowało pogorszenie parametrów osiąganých przez algorytmy. Porównanie wyników algorytmów z rys.6.2-6.6 i rys.6.27-6.31 wynika, że dla wszystkich z algorytmów znacząco wzrasta A_p oraz $\tilde{x}_{ur sme}$ w czasie stabilizacji.

6.1.4 Sterowanie z estymowanym danymi wejściowymi bez informacją o zakłóceniach środowiskowych


W poniższym rozdziale zaprezentowano wyniki realizacji zadań sterowania opisanych w rozdziale 6.1 przez algorytmy PID, BS i MPC w przypadku kiedy na wejście algorytmów sterowania podawany jest estymowany wektor stanu statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe) oraz w czasie symulacji na statek działają zakłócenia środowiskowe.

Wyniki badań dla pierwszego zadania, w którym statek realizuje zmianę położenia i kursu oraz utrzymanie statku w stanie ustalonym przedstawiono na rys. 6.32-6.36 oraz w tabeli 6.7.




Rys. 6.32: Położenie statku w osi X_o podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów są estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe


6. Badania symulacyjne algorytmów sterowania




Rys. 6.33: Położenie statku w osi Y_0 podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.34: Kurs statku ψ podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.35: Prędkość wzdłużna statku u podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.36: Prędkość poprzeczna statku v podczas badania parametrów odpowiedzi skokowej algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe

Tabela 6.7: Statyczne i dynamiczne parametry algorytmu sterowania dla kryterium odpowiedzi skokowej (zmiana położenia z $[0 \text{ m}, 0 \text{ m}, 0 \text{ rad}]$ do $[100 \text{ m}, 100 \text{ m}, 0.5 \text{ rad}]$) - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe.

	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
X_o									
MPC	26.7	68.1	41.4	–	–	74.4	0.7485	2.03	5 [m]
BS	16.9	53.0	36.6	5.7	81.7	264.3	2.0559	2.4	5 [m]
PID	21.6	117.5	86.1	10.9	172.3	–	–	–	5 [m]
	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
Y_o									
MPC	32.1	80.6	48.5	–	–	87.3	1.5795	4.11	5 [m]
BS	20.9	59.1	60.6	1	75.1	62.8	2.6780	4.5	5 [m]
PID	25.1	131.1	106.0	–	–	194.6	3.1280	4.9	5 [m]
	$t_{10\%}$	$t_{90\%}$	t_n	A_p	t_A	t_u	\tilde{x}_{ursme}	A_u	Δ
ψ									
MPC	76.7	173.9	97.2	–	–	173.9	0.0594	–	0.1 [rad]
BS	58.1	103.5	45.4	0.531	182.7	–	0.0134	0.0137	0.1 [rad]
PID	48.6	120.3	71.7	0.032	154.9	120.3	0.0168	0.0468	0.1 [rad]


Na podstawie przebiegu wykresów (rys. 6.32-6.36) oraz tabeli (tabela 6.7) stwierdzono, że dla badania utrzymania pozycji i kursu statku wszystkie parametry znacząco pogorszyły się. Porównując wykresy rys. 6.2-6.6 i rys. 6.32-6.36 zaobserwowano znaczący wzrost uchybu średniokwadratowego w stanie ustalonym \tilde{x}_{ursme} oraz amplitudy w czasie ustalonym A_u . Analiza wykresów (rys. 6.32-6.36) i tabeli (tabela 6.7) pozwala na stwierdzenie, że najlepsze parametry




6. Badania symulacyjne algorytmów sterowania

uzyskał algorytm MPC, wskazuje na to najmniejsza wartość \tilde{x}_{ursme} , i brak przeregulowania A_p .


Wyniki badań dla drugiego zadania, w którym statek utrzymuje położenie i kurs przedstawiono na rys. 6.37-6.41 oraz w tabeli 6.8.




Rys. 6.37: Położenie statku w osi X_o podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe




Rys. 6.38: Położenie statku w osi Y_o podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.39: Kurs statku ψ podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.40: Prędkość poprzeczna statku u podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe



Rys. 6.41: Prędkość wzdłużna statku v podczas badania parametrów algorytmów sterowania - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe

6. Badania symulacyjne algorytmów sterowania

Tabela 6.8: Statyczne parametry algorytmu sterowania podczas badania kryterium sterowania w stanie ustalonym - danymi wejściowymi do algorytmów jest estymowany wektor stanu statku oraz w czasie badania na statek działają zakłócenia środowiskowe

	X_o			Y_o			ψ_o		
	A_p	t_A	$\tilde{x}_{ur\text{sme}}$	A_p	t_A	$\tilde{x}_{ur\text{sme}}$	A_p	t_A	$\tilde{x}_{ur\text{sme}}$
MPC	8.889	42.4	1.9304	3.183	195	1.1524	0.0874	200	0.0488
BS	1.768	86.2	0.9569	0.7561	248	0.3439	0.0165	168	0.0070
PID	7.306	99.3	3.6209	2.905	300	1.1644	0.0176	300	0.0050

Na podstawie przebiegu wykresów (rys. 6.37-6.41) oraz tabeli (tabela 6.8) stwierdzono, że wprowadzenie błędu estymacji do algorytmów sterowania spowodowało pogorszenie parametrów osiąganych przez algorytmy. Porównanie wyników algorytmów z rys. 6.7-6.11 i rys. 6.37-6.41 wynika, że wartości parametrów dla wszystkich algorytmów znacząco wzrasta.

6.2 Wnioski

W pracy przedstawiono cztery badania, w których analizowano statyczne i dynamiczne parametry algorytmów sterowania dla kryterium odpowiedzi skokowej i sterowania w stanie ustalonym. Pierwsze badania (rozdział 6.1.1) przedstawiają wyniki działania algorytmów dla przypadku gdy dane wejściowe dla sterowania są nieobciążone błędem estymacji oraz w czasie badania na statek nie działają siły zakłóceń środowiskowych. Przebiegi sterowania uzyskane w wyniku badań stanowią odniesienie (przebiegi referencyjne) w stosunku do pozostałych badań.

W drugiej części badań algorytmów sterowania przedstawionych w rozdziale 6.1.2, analizowano wpływ błędu predykcji zakłóceń środowiskowych na parametry algorytmów sterowania. Analiza przeprowadzonych badań pozwala na sformułowanie następujących wniosków:

- dla pierwszego zadania sterowania (sterowanie do punktu zadanego położenia i kursu) prezentowanego w rozdziale 6.1.2 zaobserwowano (rys. 6.12-6.16, tabela 6.3):
 - nieznaczny wzrost czasu narastania t_n dla wszystkich algorytmów względem pierwszego badania,
 - brak zmiany przeregulowania sterownia A_p względem pierwszego badania,
 - wzrost błędu średniokwadratowego w stanie ustalonym $\tilde{x}_{ur\text{sme}}$,
 - wzrostu maksymalnego przeregulowania w stanie ustalonym A_u ,
- dla drugiego zadania sterowania (utrzymanie zadanego położenia i kursu) prezentowanego w rozdziale 6.1.2 zaobserwowano (rys. 6.17-6.21, tabela 6.4):



- wzrost średniego błędu w stanie ustalonym $\tilde{x}_{ur sm}$. Algorytmy PID i BS pomimo odchylenia od punktu zadanego dążą do zerowego błędu sterowania, algorytm MPC przez opóźnienie czasu pierwszego sterowania zostaje wyprowadzony ze stanu równowagi znacznie bardziej i oscyluje, wokół tego punktu.
- wzrost maksymalnego przeregulowania w stanie ustalonym A_u względem wyników referencyjnych.

Celem badania algorytmów sterowania przedstawionego w rozdziale 6.1.3. jest analiza wpływu błędu estymacji (położenia, prędkości i przyspieszenia) na parametry kryterium odpowiedzi skokowej i sterowania w stanie ustalonym przy znanych zakłóceniach środowiskowych. W czasie analizy zaobserwowano następujące zależności:

- dla pierwszego zadania sterowania (sterowanie do punktu zadanego położenia i kursu) prezentowanego w rozdziale 6.1.3 zaobserwowano (rys. 6.22-6.26, tabela 6.6):
 - wzrost czasu narastania t_n dla wszystkich algorytmów względem wartości referencyjnych,
 - wzrost zmiany przeregulowania sterowania A_p względem wartości referencyjnej,
 - wzrost średniego błędu średniokwadratowego w stanie ustalonym $\tilde{x}_{ur sme}$ względem wartości referencyjnych
 - wzrost maksymalnego przeregulowania w stanie ustalonym A_u ,
 - brak stanu ustalonego dla algorytmu BS.
- dla drugiego zadania sterowania (utrzymanie zadanego położenia i kursu) prezentowanego w rozdziale 6.1.3 zaobserwowano (rys. 6.27-6.31, tabela 6.7):
 - wzrost średniego błędu średniokwadratowego w stanie ustalony $\tilde{x}_{ur sme}$, w okolicy punktu zadanego widoczne są oscylacje dla wszystkich algorytmów,
 - wzrost maksymalnego przeregulowania w stanie ustalonym A_u względem badań prezentowanych w rozdziale 6.1.1.

Badanie algorytmów sterowania przedstawione w rozdziale 6.1.4 zostało przeprowadzone w celu dotyczą wpływu estymacji wektora stanu (położenia, prędkości, przyspieszenia i zakłóceń środowiskowych) na parametry algorytmów sterowania dla kryterium odpowiedzi skokowej i sterowania w stanie ustalonym. Analiza wyników badań pozwala na zaobserwowanie:

- dla pierwszego zadania sterowania (sterowanie do punktu zadanego położenia i kursu) prezentowanego w rozdziale 6.1.4 zaobserwowano (rys. 6.32-6.36, tabela 6.7):



6. Badania symulacyjne algorytmów sterowania

- wzrost czasu narastania t_n dla wszystkich algorytmów względem wartości referencyjnych,
 - wzrost przeregulowania sterowania A_p względem wartości referencyjnych,
 - wzrost średniego błędu średniokwadratowego w stanie ustalony $\tilde{x}_{ur\,sme}$ względem wartości referencyjnych,
 - wzrost maksymalnego przeregulowania w stanie ustalony A_u dla wszystkich algorytmów względem wartości referencyjnych,
- dla drugiego zadania sterowania (utrzymanie zadanego położenia i kursu) prezentowanego w rozdziale 6.1.4 zaobserwowano (rys. 6.37-6.41, tabela 6.8):
 - wzrost średniego błędu średniokwadratowego w stanie ustalonym $\tilde{x}_{ur\,sme}$, oraz występują większe oscylacje w okolicy punktu zadanego dla wszystkich algorytmów,
 - wzrost maksymalnego przeregulowania w stanie ustalonym A_u dla wszystkich algorytmów względem wartości referencyjnych.

Analiza wyników badań algorytmów sterowania statku wskazuje, że najważniejszym czynnikiem wpływającym na jakość sterowania są dane wejściowe. Analizując wyniki algorytmów w kolejnych badaniach zaobserwowano pogorszenie parametrów statycznych i dynamicznych, pokazuje to jak ważnym aspektem jest jakość estymacji algorytmów. W badaniach przedstawiono, że błąd estymacji położenia i prędkości ma największy wpływ na parametry statyczne kryteriów dla algorytmów sterowania. Po dodaniu błędu estymacji zakłóceń środowiskowych parametry dla algorytmów sterowania ulegają jeszcze większemu pogorszeniu.

Rozdział 7

Podsumowanie

Przedstawiona praca dotyczy zagadnień związanych z projektowaniem algorytmów fuzji danych i sterowania dla statku z systemem dynamicznego pozycjonowania. Zadaniem systemu dynamicznego pozycjonowania jest sterowanie położeniem i kursem statku z wykorzystaniem wyłącznie napędów i sterów zainstalowanych na statku, kompensując zakłócenia środowiskowe. Poruszone problemy badawcze, zaprezentowane w pracy, dotyczą bezpieczeństwa i precyzyjnego sterowania statkiem poruszającego się z małymi prędkościami. Pomimo znaczącego rozwoju algorytmów estymacji wektora stanu statku w dalszym ciągu w publikacjach dotyczących systemu dynamicznego pozycjonowania pomijany jest problem nadmiarowych układów pomiarowych wykorzystywanych na statkach oraz działanie algorytmów w sytuacjach awaryjnych, takich jak:

- uszkodzenie czujnika pomiarowego,
- brak aktualizacji pomiaru z czujnika pomiarowego,
- dryft czujnika pomiarowego

W rozprawie szczególną uwagę zwrócono na metody sterowania z nieliniowym modelem obiektu i zastosowaniem zaawansowanych nieliniowych algorytmów fuzji danych, ze szczególnym uwzględnieniem sytuacji awaryjnych.

W rozprawie doktorska przyjęto dwie tezy. W celu potwierdzenia postawionych tez pracy, które dotyczą sterowania statkiem DP i fuzji danych z czujników pomiarowych zaprojektowano algorytm sterowania predykcyjnego z nieliniową funkcją optymalizacji (MPC-NO). Natomiast do fuzji danych zaprojektowano autorski algorytm kaskadowego połączenia filtra cząsteczkowego i rozszerzonego filtra Kalmana (PKF). Ocenę działania sformułowanych algorytmów przeprowadzono w oparciu o badania symulacyjne, gdzie porównano je z algorytmami. Algorytm sterowania predykcyjnego porównano z algorytmem sterowania backstepping i nieliniowym regulatorem PID. W badaniach tych porównano parametry algorytmów sterowania dla scenariuszy nawigacyjnych. Badania te zaprezentowano w rozdziale 6 i dotyczyły one:

- sterowania statkiem podczas manewru i stabilizacji wykorzystując jako dane wejściowe do algorytmów rzeczywisty wektor stanu statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe), oraz w czasie badania na statek nie działają zakłócenia środowiskowe,
- sterowania statkiem podczas manewru i stabilizacji wykorzystując jako dane wejściowe do algorytmów rzeczywisty wektor stanu statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe), oraz w czasie badania na statek działają zakłócenia środowiskowe,



7. Podsumowanie

- sterowania statkiem podczas manewru i stabilizacji z wykorzystując jako dane wejściowe do algorytmów estymowany wektor stanu statku (położenie, prędkość, przyspieszenie) i rzeczywista wartość zakłóceń środowiskowych, oraz w czasie badania na statek działają zakłócenia środowiskowe,
- sterowania statkiem podczas manewru i stabilizacji z wykorzystując jako dane wejściowe do algorytmów estymowany wektor stanu statku (położenie, prędkość, przyspieszenie i zakłócenia środowiskowe), oraz w czasie badania na statek działają zakłócenia środowiskowe,.

Analiza badań dotycząca porównania algorytmów sterownia pozwala na sformułowanie następujących wniosków:

- algorytm sterowania predykcyjnego umożliwia precyzyjne sterowanie statkiem uzyskując małą wartość uchybu średnookwadratowego w stanie ustalonym $\tilde{x}_{ur\,sme}$ oraz w badaniach uzyskuje małe przeregulowania A_p ,
- sterowanie z wykorzystaniem nieliniowego algorytmu MPC do stabilizacji osiąga wyższe parametry uchybu średnookwadratowego w stanie ustalonym $\tilde{x}_{ur\,sme}$ oraz maksymalnej amplitudy w stanie ustalonym A_u od pozostałych algorytmów sterowania pomimo rzeczywistych danych wejściowych (braku błędu estymacji) (rozdział 6.1.2),
- połączenie algorytmów PKF i MPC przedstawione w rozdziale 6.1.4, wskazuje, że wykorzystanie tych algorytmów w systemach dynamicznego pozycjonowania może zwiększyć niezawodność i bezpieczeństwo statków DP.

Badania związane z postawioną tezą dotyczącą filtracji obejmowały porównanie działania algorytmów rozszerzonego filtru Kalmana (KF), nieliniowego obserwatora (NO), filtru cząsteczkowego (PF) i kaskadowego połączenia filtru cząsteczkowego i rozszerzonego filtru Kalmana (PKF). W badaniach poświęconych działaniu algorytmom fuzji danych uwzględniono: '

- jakość estymacji dla komplementarnych czujników pomiarowych,
- jakość estymacji algorytmów o różnej dokładności opisu statku,
- jakość estymacji dla nadmiarowej konfiguracji czujników pomiarowych,
- jakość estymacji dla konfiguracji o różnej dokładności pomiaru położenia,
- jakość estymacji dla różnych scenariuszy awaryjnych:
 - uszkodzenia 1 z 3 czujnika położenia podczas manewru i stabilizacji,
 - uszkodzenia 1 z 3 czujnika prędkości podczas manewru i stabilizacji,
 - uszkodzenia 2 z 3 czujników położenia podczas manewru i stabilizacji,
 - uszkodzenia 2 z 3 czujników prędkości podczas manewru i stabilizacji,



-
- braku aktualizacji dla 1 z 3 czujnika położenia podczas manewru i stabilizacji,
 - braku aktualizacji dla 1 z 3 czujnika prędkości podczas manewru i stabilizacji,
 - braku aktualizacji dla 2 z 3 czujników położenia podczas manewru i stabilizacji,
 - braku aktualizacji dla 2 z 3 czujników prędkości podczas manewru i stabilizacji,
 - dryft 1 z 3 czujnika położenia podczas manewru i stabilizacji,
 - dryft 1 z 3 czujnika prędkości podczas manewru i stabilizacji,
 - dryft 2 z 3 czujnika położenia podczas manewru i stabilizacji,
 - dryft 2 z 3 czujnika prędkości podczas manewru i stabilizacji,
- jakość estymacji zakłóceń wolnozmiennych.

Na podstawie analizy przeprowadzonych badań związanych z fuzją danych można sformułować następujące wnioski:

- zastosowanie algorytmu PKF umożliwiło estymację zakłóceń wolnozmiennych uzyskując wysoką jakość estymacji stanu dla czujników komplementarnych (5.1.1) oraz nadmiarowych systemów pomiarowych (5.1.3),
- badania symulacyjne scenariuszy awaryjnych potwierdziły że:
 - algorytm PKF uzyskuje wysoką jakość estymacji zmiennych stanu dla:
 - * czujników komplementarnych (rozdział 5.1.1),
 - * nadmiarowych systemów pomiarowych (rozdział 5.1.3),
 - algorytm PKF uzyskuje wysoką jakość estymacji wolnozmiennych zakłóceń środowiskowych (rozdział 5.1.11)
 - algorytm PKF pomimo uszkodzenia czujników pomiarowych zachowuje dokładność estymacji zmiennych (rozdział 5.1.5 i 5.1.6),
 - algorytm PKF jest odporny na brak aktualizacji z czujników położenia. W przypadku wystąpienia braku aktualizacji z czujnika prędkości zwiększa się błąd estymacji, ale po wystąpieniu poprawnej aktualizacji z czujników pomiarowych błąd estymacji z czasem spada do poziomu sprzed wystąpienia awarii (rozdział 5.1.7 i 5.1.8),
 - algorytm PKF nie jest odporny na dryft czujników pomiarowych (w rozdziale 5.1.9 i 5.1.10).
 - połączenie algorytmów PKF i MPC przedstawione w rozdziale 6.1.4, wskazuje, że wykorzystanie tych algorytmów w systemach dynamicznego pozycjonowania może zwiększyć niezawodność i bezpieczeństwo statków DP.



7. Podsumowanie

Do najważniejszych oryginalnych rozwiązań, jakie przedstawiono w pracy, należy zaliczyć: itemize

opracowanie i analiza teoretyczna metod fuzji danych z wykorzystaniem nieliniowego obserwatora, filtru Kalmana, filtru cząsteczkowego,

opracowanie i analiza algorytmu kaskadowego połączenia filtru cząsteczkowego oraz rozszerzonego filtru Kalmana,

analiza działania algorytmów fuzji danych z wykorzystaniem scenariuszy awaryjnych,

opracowanie i analiza teoretyczna regulatora PID, backstepping i sterowania predykcyjnego z wykorzystaniem nieliniowego modelu statku,

opracowanie i analiza połączonego algorytmu fuzji danych i sterowania predykcyjnego z wykorzystaniem nieliniowego modelu obiektu,

przeprowadzenie badań symulacyjnych dotyczących wykorzystania algorytmów PKF do wyznaczania wartości wejściowych dla algorytmu MPC.

Podsumowując przeprowadzone badania symulacyjne wskazują, że zastosowanie zaprojektowanych algorytmów może w sposób istotny wpłynąć na dokładność sterowania oraz na bezpieczeństwo statków DP.

Prezentowane badania mogą stanowić wprowadzenie do dalszych prac nad analizą algorytmów sterowania statkiem oraz wpływem jakości estymacji i rodzaju zakłóceń środowiskowych na parametry sterowania. Przyszłe prace badawcze mogą dotyczyć sterowania statkiem po zadanych trajektoriach oraz rozszerzenie algorytmu MPC-NO o optymalizację alokacji napędów i sterów statku.

Bibliografia

- [1] Allensworth, T. “A short history of Sperry Marine”. In: *Litton Marine Systems* (1999).
- [2] Arnaud Doucet and Adam M. Johansen. *A Tutorial on Particle Filtering and Smoothing Fifteen yeras later*. Apr. 2008.
- [3] Balchen, J. G., Jenssen, N. A., and Sælid, S. “Dynamic positioning using Kalman filtering and optimal control theory”. In: *IFAC/IFIP symposium on automation in offshore oil field operation*. Vol. 183. 1976, p. 186.
- [4] Balchen, J. G. et al. “A Dynamic Positioning System Based on Kalman Filtering and Optimal Control”. In: *Modeling, Identification and Control* vol. 1, no. 3 (1980), pp. 135–163.
- [5] Bennett, S. “A history of control engineering 1800-1930: Peter Peregrinus”. In: *Stevenage, UK* (1979).
- [6] Berge, S. and Fossen, T. “On the properties of the nonlinear ship equations of motion”. In: *Mathematical and Computer Modelling of Dynamical Systems* vol. 6, no. 4 (2000), pp. 365–381.
- [7] Blanke, M. et al. “Diagnosis and fault-tolerant control”. In: *Based Algorithms in PMSG Drives* (2003).
- [8] Breivik, M. “Topics in guided motion control of marine vehicles”. In: *Tapir Uttrykk* (2010).
- [9] Brooks, R. R., Ramanathan, P., and Sayeed, A. M. “Distributed target classification and tracking in sensor networks”. In: *Proceedings of the IEEE* vol. 91, no. 8 (Aug. 2003), pp. 1163–1171.
- [10] Castanedo, F. *A Review of Data Fusion Techniques*. en. Research article. 2013.
- [11] Chang, W., Liang, H., and Ku, C. “Fuzzy controller design subject to actuator saturation for dynamic ship positioning systems with multiplicative noises”. In: *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering* vol. 224, no. 6 (2010), pp. 725–736.
- [12] Chowdhary, G. and Jategaonkar, R. “Aerodynamic parameter estimation from flight data applying extended and unscented Kalman filter”. In: *Aerospace Science and Technology* vol. 14, no. 2 (Mar. 2010), pp. 106–117.
- [13] Dasarathy, B. V. “Sensor fusion potential exploitation-innovative architectures and illustrative applications”. In: *Proceedings of the IEEE* vol. 85, no. 1 (Jan. 1997), pp. 24–38.



- [14] Do, K. D. and Pan, J. *Control of Ships and Underwater Vehicles: Design for Underactuated and Nonlinear Marine Systems*. en. Google-Books-ID: OSC9L4X801sC. Springer Science & Business Media, Aug. 2009.
- [15] Donha, D. C. et al. “H adaptive controllers for auto-pilot applications”. In: *International journal of adaptive control and signal processing* vol. 12, no. 8 (1998), pp. 623–648.
- [16] Doucet, A., Freitas, N. de, and Gordon, N. “An Introduction to Sequential Monte Carlo Methods”. en. In: *Sequential Monte Carlo Methods in Practice*. Ed. by Doucet, A., Freitas, N. de, and Gordon, N. Statistics for Engineering and Information Science. New York, NY: Springer New York, 2001, pp. 3–14.
- [17] Du, J. et al. “Robust dynamic positioning of ships with disturbances under input saturation”. In: *Automatica* vol. 73 (2016), pp. 207–214.
- [18] Durrant-Whyte, H. F. “Sensor Models and Multisensor Integration”. en. In: *The International Journal of Robotics Research* vol. 7, no. 6 (Dec. 1988), pp. 97–113.
- [19] Dębowski, A. *Automatyka: podstawy teorii*. Wydawnictwo WNT, Warszawa, 2012.
- [20] Fannemel, Å. V. “Dynamic positioning by nonlinear model predictive control”. MA thesis. Institutt for teknisk kybernetikk, 2008.
- [21] Faÿ, H. *Dynamic Positioning Systems: Principles, Design, and Applications*. Editions OPHRYS, 1990.
- [22] Fossen, T. I. “A survey on nonlinear ship control: from theory to practice”. In: *IFAC Proceedings Volumes* vol. 33, no. 21 (2000), pp. 1–16.
- [23] Fossen, T. I. *Guidance and control of ocean vehicles*. John Wiley & Sons Inc, 1994.
- [24] Fossen, T. I. *Handbook of Marine Craft Hydrodynamics and Motion Control*. en. Google-Books-ID: oR3sBgAAQBAJ. John Wiley & Sons, May 2011.
- [25] Fossen, T. I., Sagatun, S. I., and Sørensen, A. J. “Identification of dynamically positioned ships”. In: *Control Engineering Practice* vol. 4, no. 3 (1996), pp. 369–376.
- [26] Fossen, T. I. and Strand, J. P. “Nonlinear passive weather optimal positioning control (WOPC) system for ships and rigs: experimental results”. In: *Automatica* vol. 37, no. 5 (2001), pp. 701–715.
- [27] Fossen, T. I. and Strand, J. P. “Passive nonlinear observer design for ships using Lyapunov methods: full-scale experiments with a supply vessel”. In: *Automatica* vol. 35, no. 1 (1999), pp. 3–16.
- [28] Fossen, T. I. *Nonlinear modelling and control of underwater vehicles*. Fakultet for informasjonsteknologi, matematikk og elektroteknikk, 1991.

- [29] Fung, P. and Grimble, M. “Dynamic ship positioning using a self-tuning Kalman filter”. In: *IEEE Transactions on Automatic Control* vol. 28, no. 3 (1983), pp. 339–350.
- [30] Gan, Q. and Harris, C. J. “Comparison of two measurement fusion methods for Kalman-filter-based multisensor data fusion”. In: *IEEE Transactions on Aerospace and Electronic Systems* vol. 37, no. 1 (Jan. 2001), pp. 273–279.
- [31] Grimble, M., Patton, R., and Wise, D. “The design of dynamic ship positioning control systems using extended Kalman filtering techniques”. In: *OCEANS’79. IEEE. 1979*, pp. 488–497.
- [32] Grimble, M. J. and Johnson, M. A. *Optimal control and stochastic estimation: theory and applications*. John Wiley & Sons, Inc., 1986.
- [33] Grimble, M. J. and Johnson, M. A. *Optimal control and stochastic estimation: theory and applications*. John Wiley & Sons, Inc., 1986.
- [34] Grimble, M., Patton, R., and Wise, D. “The design of dynamic ship positioning control systems using stochastic optimal control theory”. In: *Optimal Control Applications and Methods* vol. 1, no. 2 (1980), pp. 167–202.
- [35] Hall, D. and Llinas, J. *Multisensor Data Fusion*. en. CRC Press, June 2001.
- [36] Hall, D. L. and McMullen, S. A. H. *Mathematical Techniques in Multisensor Data Fusion*. en. Artech House, 2004.
- [37] Hassani, V. et al. “Robust dynamic positioning of offshore vessels using mixed- μ synthesis modeling, design, and practice”. In: *Ocean Engineering* vol. 129 (2017), pp. 389–400.
- [38] Hespanha, J. P. “Tutorial on supervisory control”. In: *Lecture Notes for the workshop Control using Logic and Switching for the 40th Conf. on Decision and Contr., Orlando, Florida*. 2001.
- [39] Hespanha, J. P. and Morse, A. S. “Switching between stabilizing controllers”. In: *Automatica* vol. 38, no. 11 (2002), pp. 1905–1917.
- [40] Hespanha, J. P., Liberzon, D., and Morse, A. S. “Hysteresis-based switching algorithms for supervisory control of uncertain systems”. In: *Automatica* vol. 39, no. 2 (2003), pp. 263–272.
- [41] Hu, X., Du, J., and Shi, J. “Adaptive fuzzy controller design for dynamic positioning system of vessels”. In: *Applied Ocean Research* vol. 53 (2015), pp. 46–53.
- [42] Hue, C., Cadre, J. L., and Perez, P. “Sequential Monte Carlo methods for multiple target tracking and data fusion”. In: *IEEE Transactions on Signal Processing* vol. 50, no. 2 (Feb. 2002), pp. 309–325.
- [43] Ihle, I. “Nonlinear Cooperated Control of Marine Craft”. PhD thesis. PhD Thesis, Department of Engineering Cybernetics, Faculty of Information . . . , 2006.



- [44] Ivan, J. N. et al. “Real time data fusion for arterial streer incident detection usinf neral newtworks.” In: *Transportation Research Record*, no. 1497 (1995).
- [45] Jayasiri, A. et al. “Dynamic positioning of vessels using a UKF-based observer and an NMPC-based controller”. In: *IEEE Transactions on Automation Science and Engineering* vol. 14, no. 4 (2017), pp. 1778–1785.
- [46] Jensen, G. A. “Offshore pipelaying dynamics”. In: (2010).
- [47] Jenssen, N. “Estimation and control in dynamic positioning of vessels”. In: *NTH (NTNU), Norway* (1981).
- [48] Johansen, T. A., Fossen, T. I., and Vik, B. “Hardware-in-the-loop testing of DP systems”. In: *Dynamic positioning conference*. Citeseer. 2005.
- [49] Johansen, T. A. and Sørensen, A. J. “Experiences with HIL simulator testing of power management systems”. In: *Marine Technology Society Dynamic Positioning Conf.* 2009.
- [50] Kalman, R. E. “Mathematical description of linear dynamical systems”. In: *Journal of the Society for Industrial and Applied Mathematics, Series A: Control* vol. 1, no. 2 (1963), pp. 152–192.
- [51] Katebi, M., Grimble, M., and Zhang, Y. “H robust control design for dynamic ship positioning”. In: *IEE Proceedings-Control Theory and Applications* vol. 144, no. 2 (1997), pp. 110–120.
- [52] Khaleghi, B. et al. “Multisensor data fusion: A review of the state-of-the-art”. In: *Information Fusion* vol. 14, no. 1 (Jan. 2013), pp. 28–44.
- [53] Kijima, K., Murata, K., and Furukawa, Y. “Design of dynamic positioning system for self-propulsive barge under external disturbances”. In: *Journal of the Society of Naval Architects of Japan* vol. 1998, no. 183 (1998), pp. 153–163.
- [54] Kolås, S., Foss, B. A., and Schei, T. “Constrained nonlinear state estimation based on the UKF approach”. In: *Computers & Chemical Engineering* vol. 33, no. 8 (2009), pp. 1386–1401.
- [55] Koyama, N. “On dominance rank and kinship of a wild Japanese monkey troop in Arashiyama”. In: *Primates* vol. 8, no. 3 (1967), pp. 189–216.
- [56] Liggins II, M., Hall, D., and Llinas, J. *Handbook of multisensor data fusion: theory and practice*. CRC press, 2017.
- [57] Lindegaard, K.-P. “Acceleration feedback in dynamic positioning”. In: (2003).
- [58] Liu, D., Tang, C., and Zhang, Y. “UKF-based INS/single-satellite Navigation Dynamic Positioning Algorithm”. In: *2018 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)*. IEEE. 2018, pp. 1–4.
- [59] Liu, L., Wang, D., and Peng, Z. “Direct and composite iterative neural control for cooperative dynamic positioning of marine surface vessels”. In: *Nonlinear Dynamics* vol. 81, no. 3 (2015), pp. 1315–1328.



- [60] Llinas, J. et al. *Revisiting the JDL Data Fusion Model II*. en. Tech. rep. July 2004.
- [61] Luo, R. C. and Kay, M. G. “Multisensor integration and fusion in intelligent systems”. In: *IEEE Transactions on Systems, Man, and Cybernetics* vol. 19, no. 5 (Sept. 1989), pp. 901–931.
- [62] Luo, R. C., Yih, C.-C., and Su, K. L. “Multisensor fusion and integration: approaches, applications, and future research directions”. In: *IEEE Sensors Journal* vol. 2, no. 2 (Apr. 2002), pp. 107–119.
- [63] Mandžuka, S. and Vukić, Z. “Use of Optimal Constrained Covariance Control (OC3) in Dynamic Positioning of Floating Vessels”. In: *IFAC Proceedings Volumes* vol. 28, no. 2 (1995), pp. 9–15.
- [64] Mathiesen, E. et al. *Dynamic hybrid control*. US Patent App. 15/559,889. 2019.
- [65] Minorsky, N. “Directional stability of automatically steered bodies”. In: *Journal of the American Society for Naval Engineers* vol. 34, no. 2 (1922), pp. 280–309.
- [66] Morgan, M. J. “Dynamic positioning of offshore vessels”. In: (1978).
- [67] Nguyen, D. T., Blanke, M., and Sørensen, A. J. “Diagnosis and fault-tolerant control for thruster-assisted position mooring”. In: *IFAC Proceedings Volumes* vol. 40, no. 17 (2007), pp. 287–292.
- [68] Nguyen, D. T. and Sørensen, A. J. “Switching control for thruster-assisted position mooring”. In: *Control Engineering Practice* vol. 17, no. 9 (2009), pp. 985–994.
- [69] Nguyen, T. D., Sorensen, A. J., and Quek, S. T. “Multi-operational controller structure for station keeping and transit operations of marine vessels”. In: *IEEE Transactions on Control Systems Technology* vol. 16, no. 3 (2008), pp. 491–498.
- [70] Norrbin, N. “On the added resistance due to steering on a straight course”. In: *13th ITTC Report of Performance Committee* (1972), pp. 182–189.
- [71] Perez, T. and Donaire, A. “Constrained control design for dynamic positioning of marine vehicles with control allocation”. In: (2009).
- [72] Pettersen, K. Y. and Fossen, T. I. “Underactuated dynamic positioning of a ship-experimental results”. In: *IEEE Transactions on Control Systems Technology* vol. 8, no. 5 (2000), pp. 856–863.
- [73] Pettersen, K. Y., Mazenc, F., and Nijmeijer, H. “Global uniform asymptotic stabilization of an underactuated surface vessel: Experimental results”. In: *IEEE Transactions on Control Systems Technology* vol. 12, no. 6 (2004), pp. 891–903.
- [74] PRS. *Przepisy nadzoru konwencjonalnego statków morskich. Część 5 Urządzenia nawigacyjne*. Polski. July 2017.



- [75] Rigatos, G. G. “Particle Filtering for State Estimation in Nonlinear Industrial Systems”. In: *IEEE Transactions on Instrumentation and Measurement* vol. 58, no. 11 (Nov. 2009), pp. 3885–3900.
- [76] Rigatos, G. and Tzafestas, S. “Extended Kalman filtering for fuzzy modelling and multi-sensor fusion”. In: *Mathematical and Computer Modelling of Dynamical Systems* vol. 13, no. 3 (June 2007), pp. 251–266.
- [77] Rigatos, G. G. “Sensor fusion-based dynamic positioning of ships using Extended Kalman and Particle Filtering”. In: *Robotica* vol. 31, no. 3 (2013), pp. 389–403.
- [78] Roumeliotis, S. I. and Bekey, G. A. “Extended Kalman filter for frequent local and infrequent global sensor data fusion”. In: *Sensor Fusion and Decentralized Control in Autonomous Robotic Systems*. Vol. 3209. International Society for Optics and Photonics, Sept. 1997, pp. 11–23.
- [79] Saelid, S., Jenssen, N., and Balchen, J. “Design and analysis of a dynamic positioning system based on Kalman filtering and optimal control”. In: *IEEE Transactions on Automatic Control* vol. 28, no. 3 (1983), pp. 331–339.
- [80] Safarinejadian, B. and Kowsari, E. “Fault detection in non-linear systems based on GP-EKF and GP-UKF algorithms”. In: *Systems Science & Control Engineering: An Open Access Journal* vol. 2, no. 1 (2014), pp. 610–620.
- [81] Skjetne, R. “The maneuvering problem”. In: *NTNU, PhD-thesis* vol. 1 (2005).
- [82] Smyth, A. and Wu, M. “Multi-rate Kalman filtering for the data fusion of displacement and acceleration response measurements in dynamic system monitoring”. In: *Mechanical Systems and Signal Processing* vol. 21, no. 2 (Feb. 2007), pp. 706–723.
- [83] SNAME, T. “Nomenclature for treating the motion of a submerged body through a fluid”. In: *The Society of Naval Architects and Marine Engineers, Technical and Research Bulletin No.* (1950), pp. 1–5.
- [84] Sorensen, A., Strand, J. P., and Nyberg, H. “Dynamic positioning of ships and floaters in extreme seas”. In: *OCEANS’02 MTS/IEEE*. Vol. 3. IEEE. 2002, pp. 1849–1854.
- [85] Sorheim, H.-R. *Dynamic Positioning in Single-point Mooring: Atheoretical Analysis of Motions and Design and Evaluation of an Optimal Control System*. University of Trondheim, Institut for Teknisk Kybernetikk, 1981.
- [86] Steinberg, A. N. and Bowman, C. L. *Revisions to the JDL Data Fusion Model*. en. Jan. 2017.
- [87] Stephens, R. I., Burnham, K. J., and Reeve, P. J. “A practical approach to the design of fuzzy controllers with application to dynamic ship positioning”. In: *IFAC Proceedings Volumes* vol. 28, no. 2 (1995), pp. 370–377.



- [88] Strand, J. P. “Nonlinear Position Control Systems Design for Marine Vessels”. In: (1999).
- [89] Strand, J. P. and Fossen, T. I. “Nonlinear passive observer design for ships with adaptive wave filtering”. In: *New Directions in nonlinear observer design*. Springer, 1999, pp. 113–134.
- [90] Sørensen, A., Quek, S., and Nguyen, T. “Improved operability and safety of dp vessels using hybrid control concept”. In: *International Conference on Technology & Operation of Offshore Support Vessels-OSV*. 2005, pp. 20–21.
- [91] Sørensen, A. J. “A survey of dynamic positioning control systems”. In: *Annual reviews in control* vol. 35, no. 1 (2011), pp. 123–136.
- [92] Sørensen, A. J. “Structural issues in the design and operation of marine control systems”. In: *Annual Reviews in Control* vol. 29, no. 1 (2005), pp. 125–149.
- [93] Sørensen, A. J. and Strand, J. P. “Positioning of small-waterplane-area marine constructions with roll and pitch damping”. In: *Control Engineering Practice* vol. 8, no. 2 (2000), pp. 205–213.
- [94] Tannuri, E. et al. “Dynamic positioning systems: An experimental analysis of sliding mode control”. In: *Control engineering practice* vol. 18, no. 10 (2010), pp. 1121–1132.
- [95] Tannuri, E. A. and Donha, D. C. “H Controller Design for Dynamic Positioning of a Turret Moored FPSO”. In: *IFAC Proceedings Volumes* vol. 33, no. 21 (2000), pp. 263–268.
- [96] Tatjewski, P. *Sterowanie zaawansowane obiektów przemysłowych: struktury i algorytmy*. Akademicka Oficyna Wydawnicza EXIT, 2002.
- [97] Tomera, M. “Hybrid real-time way-point controller for ships”. In: *2016 21st International Conference on Methods and Models in Automation and Robotics (MMAR)*. IEEE. 2016, pp. 630–635.
- [98] Tomera, M. “Hybrid switching controller design for the maneuvering and transit of a training ship”. In: *International Journal of Applied Mathematics and Computer Science* vol. 27, no. 1 (2017), pp. 63–77.
- [99] Tzeng, C. “Optimal control of a ship for a course-changing maneuver”. In: *Journal of Optimization Theory and Applications* vol. 97, no. 2 (1998), pp. 281–297.
- [100] Van Amerongen, J. and Nauta Lemke, H. van. *Optimum steering of ships with an adaptive autopilot*. Tech. rep. Delft University of Technology, 1978.
- [101] Volovodov, S. et al. “Control principle for dynamic positioning of offshore drilling platforms and ships”. In: *11-th Symposium Maritime Elektrotechnik, Elektronik und Informationstechnik*. Rostock University. 2004, pp. 81–86.



- [102] Volovodov, S. et al. “Synthesis of exponentially stable dynamic positioning systems for sea mobile objects using Lyapunov’s method”. In: *Proc. Symposium Maritime Electronic*. 2007, pp. 4271–4276.
- [103] Wan, E. A. and Merwe, R. V. D. “The unscented Kalman filter for nonlinear estimation”. In: *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium (Cat. No.00EX373)*. Oct. 2000, pp. 153–158.
- [104] Wang, Y.-L. et al. “Network-based T–S fuzzy dynamic positioning controller design for unmanned marine vehicles”. In: *IEEE transactions on cybernetics* vol. 48, no. 9 (2018), pp. 2750–2763.
- [105] Wang, Y. et al. “Research on nonlinear model predictive control technology for ship dynamic positioning system”. In: *2012 IEEE International Conference on Automation and Logistics*. IEEE. 2012, pp. 348–351.
- [106] White, F. E. *Data Fusion Lexicon*: en. Tech. rep. Fort Belvoir, VA: Defense Technical Information Center, Oct. 1991.
- [107] Witkowska, A. and Śmierchalski, R. “Adaptive dynamic control allocation for dynamic positioning of marine vessel based on backstepping method and sequential quadratic programming”. In: *Ocean Engineering* vol. 163 (2018), pp. 570–582.
- [108] Xia, G. et al. “Backstepping Control Using Barrier Lyapunov Function for Dynamic Positioning Control System with Passive Observer”. In: *Mathematical Problems in Engineering* vol. 2019 (2019).
- [109] Ye, J. “Dynamic Positioning during Heavy Lift Operations: Using fuzzy control techniques, Nonlinear Observer and H-Infinity Method Separately to Obtain Stable DP Systems for Heavy Lift Operations”. In: (2016).
- [110] Zhang, Y.-Q. et al. “Granular neural networks for numerical-linguistic data fusion and knowledge discovery”. In: *IEEE Transactions on Neural Networks* vol. 11, no. 3 (May 2000), pp. 658–667.