

Krzysztof SKRZYPCZYK
Politechnika Śląska

STEROWANIE WSPOMAGAJĄCE NAWIGACJĘ POJAZDÓW W DYNAMICZNYM ŚRODOWISKU UWZGLĘDNIAJĄCE NIEPEWNOŚĆ PREDYKCJI STANU OTOCZENIA

Streszczenie. Praca dotyczy zagadnienia nawigacji autonomicznej pojazdu w dynamicznym środowisku. W pracy przedyskutowano przydatność modelu gier przeciwko naturze do modelowania niepewności predykcji stanu otoczenia sterowanego pojazdu. Pokazano możliwość syntezy prawa sterowania realizującego bezkolizyjny ruch pojazdu w dynamicznym środowisku na bazie strategii gry przeciwko naturze. Działanie oraz efektywność proponowanego podejścia zweryfikowano za pomocą symulacji przeprowadzonych w środowisku MATLAB.

PREDICTIVE CONTROL SUPPORTING VEHICLE NAVIGATION IN DYNAMIC ENVIRONMENT WITH ENVIRONMENTAL UNCERTAINTY HANDLING

Summary. This paper addresses the problem of navigating an autonomous vehicle using environmental dynamic prediction. The usefulness of the game against nature for modeling environmental prediction uncertainty was discussed. The possibility of the control law synthesis on the basis of strategies against nature was presented. The properties and effectiveness of the approach presented were verified by simulations carried out in MATLAB.

1. Wprowadzenie

Zaawansowany poziom technologiczny w dziedzinie robotyki stał się przyczynkiem do pojawienia się coraz większej liczby potencjalnych aplikacji robotów, szczególnie robotów mobilnych. Co więcej, urządzenia te coraz częściej znajdują zastosowanie poza zamkniętymi przestrzeniami laboratoriów. Działanie ich w dynamicznych środowiskach nakłada na systemy sterowania nowe wyzwania, którym muszą sprostać. Jednym z intensywniej rozwijanych zagadnień współczesnej robotyki jest problem syntezy systemów nawigacyjnych dedykowanych do wspomagania pracy inteligentnych wózków inwalidzkich z napędem elektrycznym (ang. *Smart Electric Powered Wheelchair* – SEPW) [1]. Ten rodzaj autonomicznego czy też semiautonomicznego pojazdu mobilnego stanowi dobry przykład nowych problemów implikowanych koniecznością nawigacji w zatłoczonych i dynamicznych

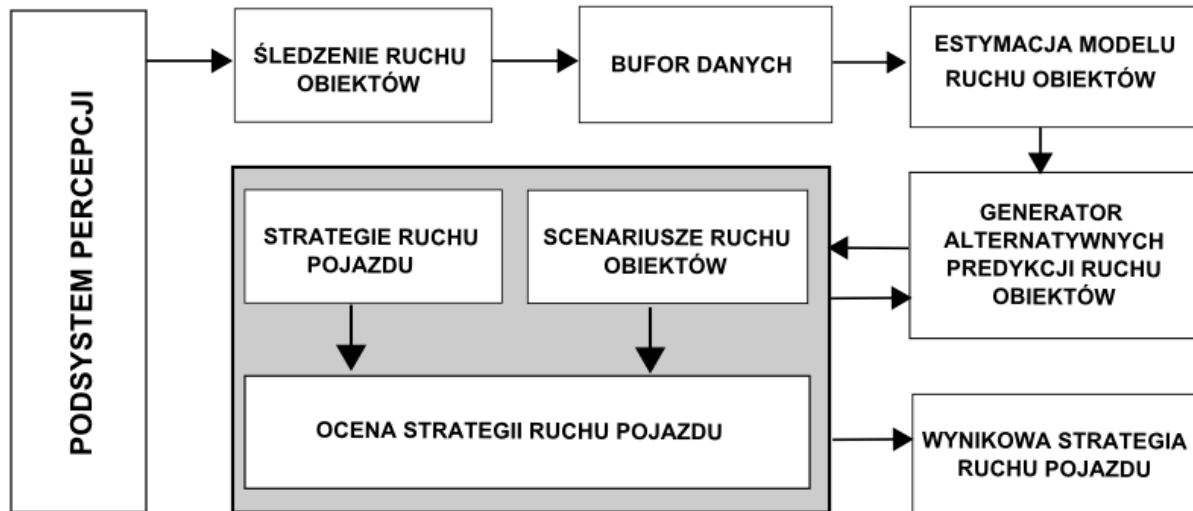
środowiskach. Podczas automatycznego sterowania ruchem pojazdu w obecności osób pojawia się konieczność uwzględnienia specyfiki środowiska i interakcji pomiędzy urządzeniem a ludźmi. Otóż wszelkie nienaturalne z punktu widzenia psychologii tłumu, zachowania systemu sterowania stanowią zaburzenie w procesie zbiorowej nawigacji. Dlatego ważne jest, by system sterowania pojazdu uwzględniał ten fakt w procesie nawigacji. To bardzo ważne zagadnienie stało się przedmiotem wielu badań i znane jest pod nazwą nawigacji z uwzględnieniem czynnika ludzkiego (ang. *human-aware navigation*) [4]. Kluczową kwestią w syntezie tego rodzaju algorytmów sterowania ruchem jest identyfikacja wzorców ruchu ruchomych obiektów oraz możliwość predykcji ich położenia w stosunkowo długim horyzoncie czasu. Posiadając wiedzę o potencjalnych przemieszczeniach osób i obiektów można zaplanować ruch pojazdu, który w sposób jak najmniejszy zaburzałby proces nawigacji w danym środowisku [4,6]. Celowe, zatem w tym przypadku jest zastosowanie sterowania predykcyjnego. Polega ono na wyznaczeniu sterowania bądź sekwencji sterowań w określonym horyzoncie czasowym, na bazie prognozy stanu środowiska otrzymanej na podstawie modelu zmian środowiska, w którym realizowany jest proces nawigacji [7]. Model taki tworzony jest na podstawie przeszłych pomiarów stanu środowiska. Wyraźny wpływ na jakość sterowania ma zastosowany model predykcji. Od jego adekwatności zależy długość horyzontu, w jakim można planować ruch pojazdu w oparciu o wybrane kryteria.

W pracy przedstawiono metodę dedykowaną do planowania ruchu semiautonomicznego wózka inwalidzkiego. Celem systemu wspomaganie nawigacji jest utrzymywanie prostoliniowego, zadanego przez pacjenta toru ruchu. Zakłada się również, że wózek w trakcie realizacji zadania, w sposób autonomiczny, może zmieniać tor ruchu na taki, który zapewnia najmniejsze ryzyko kolizji z jednej strony oraz najmniejsze odchyłki od zadanego toru jazdy. Sterowanie ruchem wózka ma również uwzględniać czynnik ludzki oraz być tolerowane przez pacjenta. Do realizacji tego zadania użyto metody predykcji bazującej na identyfikacji modelu kinematyki pojazdu [7]. Wyniki zilustrowano wybranymi przykładami symulacyjnymi.

2. Opis systemu

Działanie system można opisać w sposób następujący (rys. 1): Podsystem percepcji dostarcza informacji o otoczeniu. Zakłada się, iż jakość informacji musi umożliwiać detekcje i śledzenie obiektów w otoczeniu pojazdu. W niniejszej pracy nie są rozważane wspomniane problemy. Zakłada się, że system jest w stanie wykryć i wyznaczyć lokalizacje obiektów w zasięgu działania swojego systemu sensorycznego. Dane zebrane przez podsystem percepcji przechowywane są w buforze o określonym rozmiarze. Na podstawie tych danych tworzone są modele ruchu śledzonych obiektów. Z kolei używając otrzymanych modeli, wyznaczana jest predykcja położenia śledzonych obiektów w określonym horyzoncie czasowym. Wyznaczona hipotetyczna zmiana położenia obiektów w przyszłości stanowi podstawę do oceny ryzyka nawigacji zgodnie z przyjętą strategią. Jako, że każda predykcja jest obarczona niepewnością wynikającą z przyjętego modelu zastosowano metodę modelowania tego stanu w postaci gry przeciwko naturze. Rozważa się określoną liczbę scenariuszy ruchu obiektów obrazujących zakładane odchyłki od wyznaczonego

z predykcji stanu. W odniesieniu do tych scenariuszy ocenia się zgodnie z przyjętym kryterium, jakość wybranych strategii nawigacyjnych. Ta z nich, która optymalizuje przyjęty wskaźnik jakości użyta jest do sterowania ruchem pojazdu w przyjętym horyzoncie czasowym.



Rys. 1. Schemat ideowy predycyjnego systemu wspomagania nawigacji pojazdu

3. Sformułowanie problemu nawigacyjnego

Na początku zdefiniujemy konfigurację pojazdu w dyskretnej chwili czasu n , jako wektor:

$$R(n) = [x_{R,n}, y_{R,n}, \theta_{R,n}]^T, \quad (1)$$

gdzie pierwszy i drugi element oznaczają położenie zdefiniowane w zewnętrznym układzie współrzędnych skojarzonym z przestrzenią, w której pojazd porusza się, natomiast trzeci element wektora to orientacja pojazdu. Zakładamy, że pojazd wyposażony jest w układ sensoryczny umożliwiający detekcję oraz śledzenie N obiektów znajdujących się w jego zasięgu. Ponadto system wyposażony jest w bufor umożliwiający przechowywanie M przeszłych pomiarów położenia śledzonych obiektów opisanych zbiorem:

$$P_i = \{p_{i,k}\}, i = 1, 2, \dots, N, k = \langle n - M, n \rangle, \quad (2)$$

gdzie $p_{i,k} = [x_{i,k}, y_{i,k}]^T$ jest wektorem zawierającym koordynaty położenia i -tego obiektu zarejestrowanego w k -tej chwili czasu. Bieżąca chwila oznaczona jest indeksem n . Na podstawie danych (2) w systemie wyznaczana jest predykcja przyszłego położenia obiektów, w chwili h w określonym horyzoncie czasu H , na podstawie zastosowanego m -tego modelu predykcji:

$$\hat{p}_{i,h}^m = \bar{p}_i^m(h), h = n+1, \dots, n+H \quad (3)$$

Metody wyznaczania modelu predykcji ruchu ruchomego obiektu zostały zaprezentowane w pracy [7].

Założmy, że celem projektowanego układu sterowania jest utrzymywanie kierunku i prędkości ruchu pojazdu, wybranych przez operatora. Zdefiniujmy, zatem ścieżkę, po której ma podążać pojazd, jako:

$$Y_0(n) = (l(n), \Delta w), \quad (4)$$

gdzie $l(n)$ oznacza półprostą wychodzącą z punktu zdefiniowanego przez położenie środka geometrycznego pojazdu pod kątem $\theta_R^*(n)$. Wartość Δw oznacza dopuszczalną odległość, na jaką, pojazd może oddalić się od zadanej ścieżki. Elementarne zadanie nawigacyjne sformułowane zostanie, zatem w sposób następujący: W danej chwili czasu n , na podstawie predykcji otoczenia (3) wyznaczyć sterowanie:

$$u_R^*(n) = [\theta_R(n), v_R(n)]^T, \quad (5)$$

gdzie elementy wektora (5) oznaczają kierunek i prędkość pojazdu. Sterowanie to zastosowane w następujących po sobie $H-1$ chwilach czasu ma zapewniać minimalne ryzyko kolizji oraz jak najdokładniejsze śledzenie ścieżki (8). Bardziej złożone zadania nawigacyjne mogą być rozpatrywane, jako sekwencja elementarnych zadań nawigacyjnych.

4. Niepewności predykcji jako gra przeciwko naturze

Przedstawiany problem może być rozpatrywany, jako gra dwuosobowa pomiędzy decydentem a fikcyjnym graczem zwanym *naturą* [3,5]. Grę taką można zdefiniować w postaci normalnej, jako dwójkę:

$$G = \{D, C\}, \quad (6)$$

gdzie D oznacza przestrzeń decyzyjną gry zdefiniowaną, jako iloczyn kartezjański zbioru decyzyjnego D_G , definiującego wszystkie, możliwe do podjęcia przez decydenta działania oraz zbioru D_N określającego możliwe, wyróżnione stany natury, których zaistnienie zakłada się w procesie. W tym przypadku zbiór stanów natury odzwierciedla zakładaną liczbę rozpatrywanych scenariuszy rozwoju wypadków, na które decydent nie ma żadnego wpływu.

Niepewność rozpatrywana w niniejszej pracy dotyczy adekwatności wyznaczonego modelu ruchu obiektów, w oparciu, o który wyliczana jest predykcja stanu otoczenia. Można, zatem uwzględnić niepewność, zakładając pewną liczbę scenariuszy rozwoju wypadków. W tym przypadku rozważać będziemy kilka, alternatywnych zestawów parametrów modelu ruchu, odzwierciedlających możliwe, inne trajektorie ruchu śledzonych obiektów. Wprowadźmy zbiór możliwych stanów Natury, jako zbiór indeksów identyfikujących rozpatrywane predykcje otoczenia (3):

$$D_N = \{m\}, \quad m \in [1, K] \quad (7)$$

Z kolei dyskretny zbiór sterowań pojazdu, którymi będzie można oddziaływać na jego kierunek i prędkość ruchu, zwany dalej przestrzenią sterowań przyjmujemy, jako:

$$D_G = \{u_{R,k} = [v_{R,k}, \theta_{R,k}]^T\} = V_R \times \Theta_R, \quad (8)$$

gdzie:

$$V_R = \{v_{R,i}\}, \quad i = 1, \dots, \bar{V}_R, \quad \Theta_R = \{\theta_{R,j}\}, \quad j = 1, \dots, \bar{\Theta}_R. \quad (9)$$

Zbiór V_R zawiera wybrane z zakresu zmienności, dyskretne wartości prędkości postępowej natomiast Θ_R wybrane wartości orientacji, które może przyjąć pojazd.

Skutki przyjęcia określonej strategii sterowania (8) w obecności rozpatrywanego scenariusza (7) oceniane są za pomocą funkcji:

$$C : D \rightarrow \mathfrak{R} \quad (10)$$

Funkcja ta reprezentowana będzie przez macierz $C = [c_{ij}]$, której wiersze odpowiadają poszczególnym strategiom decydenta $i \in D_G$, natomiast kolumny poszczególnym, wyróżnionym stanom natury $j \in D_N$. W dalszej części pracy będziemy zakładać, że decydent zainteresowany jest minimalizacją kosztów procesu, a zatem funkcję C nazywać będziemy funkcją kosztów.

Synteza prawa sterowania polega na przyjęciu w chwili n -tej strategii należącej do zbioru (8), wynikającej z rozwiązania problemu (6) zgodnie z przyjętym kryterium. W pracy zastosowano dwa kryteria wyboru, które zastosowane przez $H-1$ następujących po sobie okresów próbkowania powinny prowadzić do realizacji celu nawigacyjnego przy minimalnym ryzyku kolizji, z uwzględnieniem niepewności predykcji

5. Modelowanie funkcji kosztów

Przyjmijmy następującą, dwuskładnikową postać funkcji kosztów:

$$C(u_{R,k}, m) = \beta_r C_{risk}^m + \beta_p C_{pdev}, \quad (11)$$

gdzie C_{risk}^m oznacza ocenę ryzyka nawigacji zgodnie z przyjętą strategią $u_{R,k}$ przy założeniu m -tego wariantu predykcji. Drugi z komponentów funkcji opisuje koszt odejścia od założonej ścieżki ruchu (4).

Ocena ryzyka kolizji

Ocena ryzyka kolizji, w predykowanym horyzoncie czasowym H przeprowadzana jest na podstawie następującego wskaźnika:

$$C_{risk}(u_{R,k}, m) = \frac{1}{\sum_{h=n+1}^H \min_{i=1, \dots, N} |\hat{p}_{R,h}(u_{R,k}) - \hat{p}_{i,h}^m|_{L=2}} \quad (12)$$

Wartość wskaźnika wyznaczana jest na podstawie agregacji predykowanych odległości pomiędzy poruszającym się pojazdem a śledzonym obiektem na podstawie m tego modelu. Udział tej oceny w funkcji kosztów (14) dostrajany jest za pomocą parametru β_r , którego wartość dobierana jest doświadczalnie.

Ocena kosztu odejścia od ścieżki

Ponieważ pojazd z założenia ma poruszać się wewnątrz zdefiniowanego pasa ruchu (4) zaproponowany został dwukomponentowy wskaźnik kosztu:

$$C_{pdev}(u_{R,k}) = C_{dist} + C_{ang} \quad (13)$$

Pierwszy z komponentów określa koszt związany z odejściem pojazdu od osi pasa ruchu, i wyrażony jest formułą:

$$C_{dist}(u_{R,k}) = w_d \sum_{h=n+1}^{n+H} \hat{d}(\hat{p}_{R,h}, l(n)) \quad (14)$$

gdzie $\hat{d}(\hat{p}_{R,h}, l(n))$ jest predykowaną odległością pojazdu od osi pasa ruchu obliczaną w chwili czasu h zgodnie z zależnością:

$$\hat{d}(\hat{p}_{R,h}, l(n)) = \begin{cases} \hat{d}(\hat{p}_{R,h}, l(n)) & \text{for } \hat{d}(\hat{p}_{R,h}, l(n)) \geq \Delta w \\ 0 & \text{w przeciwnym wypadku} \end{cases} \quad (15)$$

Współczynnik wagowy w_d dobierany jest eksperymentalnie w sposób umożliwiający zbilansowanie wpływu poszczególnych priorytetów sterowania. Drugi ze składników (14) związany jest z kosztem zmiany kierunku ruchu pojazdu w odniesieniu do wartości zadanej (4):

$$C_{ang}(u_{R,k}) = w_a \left| \theta_{R,k} - \theta_{R,n}^* \right| \quad (16)$$

Podobnie jak w (14) wpływ w_a tego aspektu sterowania dopierany jest eksperymentalnie.

6. Strategia sterowania

Sterowanie pojazdem polega na przyjęciu w chwili n -tej strategii należącej do zbioru (8), wynikającej z rozwiązania problemu (6) zgodnie z przyjętym kryterium. W pracy przyjęto dwa kryteria wyboru strategii, opisane poniżej.

Kryterium Walda

Kryterium to charakteryzuje postępowanie decydenta o nastawieniu pesymistycznym, który zakłada najgorszy z możliwych rozwój wypadków. Wyraża, zatem nastawienie decydenta, charakteryzujące się największą awersją do podejmowania ryzyka. Zgodnie z nim, dla każdej z hipotetycznie wybranej strategii zakłada on najgorszy możliwy rozwój wypadków dający w rezultacie największą wartość funkcji kosztów (3). Wybiera on tę strategię i^* , która gwarantuje najniższy z zakładanych najwyższych kosztów. To kryterium można, zatem sformułować [4], jako następujące zadanie minimalizacji:

$$i_0^W = \min_i \max_j c_{ij} \quad (17)$$

Takie sformułowanie kryterium może nie wyłonić pojedynczej strategii, lecz ich zbiór, pomimo, że któraś ze strategii w tym zbiorze może być wyraźnie lepsza od innych. W celu redukcji liczności zbioru, ułatwiającej wybór strategii można zastosować metody opisane w [2].

Kryterium Hurwicza

Drugie z omawianych kryteriów charakteryzuje odmienne nastawienie decydenta, który z określonym optymizmem spodziewa się, korzystnego dla siebie rozwoju wypadków. Zgodnie z nim [3] wybiera strategię/strategie będące rozwiązaniem następującego zadania minimalizacji:

$$i_0^H = \min_i [\alpha \min_j c_{ij} + (1 - \alpha) \max_j c_{ij}] \quad (18)$$

Współczynnik $\alpha \in [0,1]$ jest miarą optymizmu decydenta. Warto zauważyć, że dla wartości $\alpha = 0$ kryterium to redukuje się do omówionego wcześniej kryterium pesymistycznego (3).

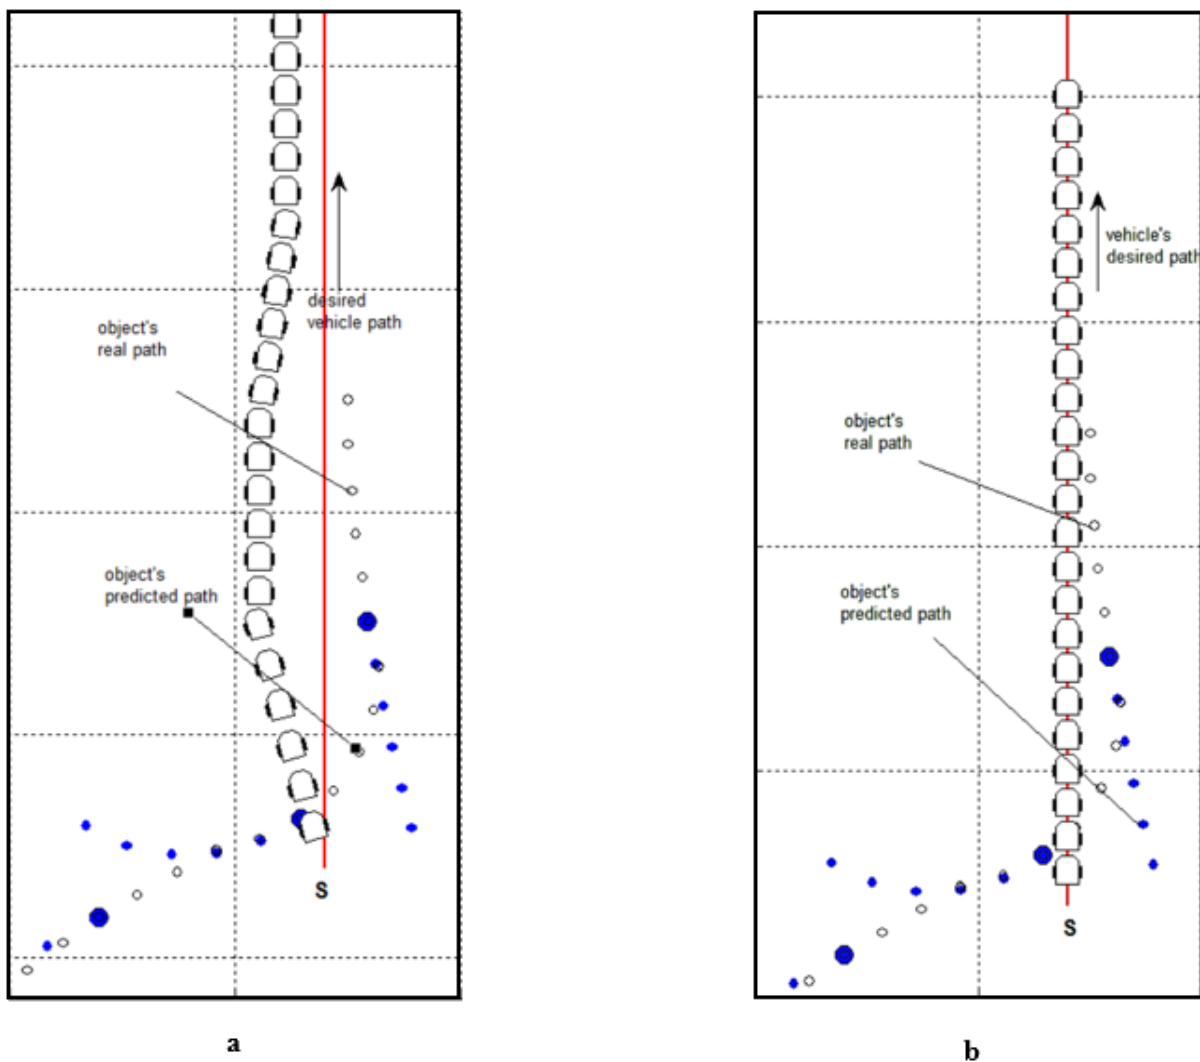
Zastosowanie wybranego kryterium przez $H-1$ następujących po sobie okresów próbkowania powinny prowadzić do realizacji celu nawigacyjnego przy minimalnym ryzyku kolizji, z uwzględnieniem niepewności predykcji (3).

7. Wyniki symulacyjne

W celu weryfikacji zaproponowanego podejścia przeprowadzono szereg symulacji, uwzględniających różnorodne scenariusze. Jako ilustrację, wybrano jeden reprezentatywny przykład. Zadanie nawigacyjne polegało na utrzymaniu kursu pojazdu z zadaną prędkością w obecności ruchomego obiektu. Zadany kurs pojazdu oznaczono półprostą zaczynającą się w punkcie oznaczającym położenie pojazdu w chwili $t=0$. Rzeczywista ścieżka obiektu oznaczona została okręgami, natomiast ścieżka predykowana dla horyzontu $H=6$ za pomocą punktów. Rysunek 2a


przedstawia sytuację, w której prędkość i kierunek pojazdu zostały wyznaczone na podstawie predykcji. Jak widać po czasie $t=0$ (oznaczonym czarną kropką), pojazd wykonał nagłą zmianę, kursu, która nie mogła być uwzględniona w wyznaczonej predykcji.

Skutkiem tego, zaplanowana trajektoria pojazdu spełnia dobrze parametry zadanego kursu, niemniej jednak prowadzi do sytuacji, w której obiekt i pojazd mijają się w odległości mniejszej niż, zakładana odległość krytyczna. W drugim przypadku, stosując model gry przeciwko naturze, uwzględniono pięć scenariuszy (7) zmiany kursu, i w odniesieniu do nich wyznaczono koszty nawigacji. Stosując kryterium pesymistyczne, wyznaczono strategię bezpieczną biorącą pod uwagę najgorsze z możliwych sytuacji i dokonano zmiany parametrów nawigacyjnych na bezpieczniejsze (rys. 2b). Na rysunku 3 z kolei przedstawiono zastosowanie kryterium optymistycznego, w odniesieniu do tego samego, opisanego wyżej scenariusza. Dla parametru $\alpha=1$, odpowiadającego sytuacji, w której parametry sterowania dobierane są na podstawie wysokiego zaufania do wyznaczonego modelu predykcji.



Rys. 2. Predykcyjne sterowanie pojazdem w przypadku nieuwzględnienia niepewności modelu (a) oraz z użyciem strategii opartej o kryterium pesymistyczne (b)

W takim przypadku rezultat działania jest zbliżony do tego, zilustrowanego na rysunku 2b. Dla parametru $\alpha = 0.5$ wyrażającego umiarkowany optymizm otrzymujemy wynik pośredni, w którym poprawiona została nadążność za kursem oraz bezpieczeństwo nawigacji.



Rys. 3. Predykcyjne sterowanie pojazdem z użyciem strategii opartej o kryterium optymistyczne dla współczynnika $\alpha = 0.5$

8. Podsumowanie

W pracy przedstawiono możliwości aplikacji teorii gier przeciwko naturze do zagadnienia modelowania niepewności informacyjnej oraz sterowania w warunkach o takim charakterze. Jako przykład wybrano proces predykcyjnego sterowania ruchem autonomicznego pojazdu w dynamicznym środowisku. W takim procesie kluczową rolę jest dokładność predykcji, której w warunkach o dużej zmienności nie można zapewnić w dłuższym horyzoncie czasowym. Ujęcie takiego problemu w ramach teorii gier pozwala na rozpatrywanie skończonej liczby spodziewanych scenariuszy rozwoju wypadków, w tym przypadku odchyłeń od wyznaczonego modelu.

Przedyskutowano zastosowanie dwóch, klasycznych kryteriów wyboru strategii i na drodze symulacyjnej potwierdzono korzyści płynące z zastosowania opisywanego podejścia.

Praca częściowo finansowana ze środków BK213/RAu1/2016/1.

LITERATURA

1. Ding D., Cooper R. A.: Electric-Powered Wheelchairs: A review of current technology and insight into future directions. IEEE Control Systems Magazine, Volume: 25, Issue: 2, April 2005, pp. 22-34, 10.1109/MCS.2005.1411382.
2. Laskowski S.: O regularyzacji rozwiązań niejednoznacznych w grze przeciwko naturze. Telekomunikacja i Techniki Informacyjne, nr 3-4, 2007, s. 30-46.
3. Milnor, J.: Games against nature, in: Thrall, R., Coombs, C., and Davis, R. (eds.), Decision Processes, Wiley, New York, 1954, p. 49-59.
4. Moussaid M., Helbing D., Theraulaz G.: How simple rules determine pedestrian behavior and crowd disasters. Proceedings of the National Academy of Science of the United States of America, vol 108, no. 17, p. 6884-6888, 2011.
5. Straffin P.D.: Teoria gier. Schollar, 2001.
6. Shi D., Collins E. G. Jr., Donate A., Liu X.: Human-Aware Robot Motion Planning with Velocity Constraints. International Symposium on Collaborative Technologies and Systems, 2008. Irvin, CA, May 2008, p. 490-497, 10.1109/CTS.2008.4543969.
7. Skrzypczyk K.: Objects movement prediction for smart electric wheelchair human aware navigation, Proc. of 13th Annual Industrial Simulation Conference, June 1-3, 2015, UPV, Valencia, Spain.
8. Skrzypczyk K.: On Modeling Uncertainty in Resource Division Process Using Game Against Nature Approach, Proc. Of The European Simulation and Modelling Conference, October 22-24, 2014 Porto, Portugal, p. 178-183.