

Zastosowanie maszyny wektorów nośnych w sterowaniu sygnalizacją świetlną

Artur Całuch*, Adam Cieślowski*, Małgorzata Plechawska-Wójcik

Politechnika Lubelska, Katedra Informatyki, Nadbystrzycka 36B, 20-618 Lublin, Polska

Streszczenie. Niniejszy artykuł przedstawia proces dostosowania parametrów modelu maszyny wektorów nośnych, który posłuży do zbadania wpływu wartości parametru długości cyklu sygnalizacji świetlnej na jakość ruchu. Badania przeprowadzono z użyciem danych pozyskanych w trakcie przeprowadzonych symulacji w autorskim symulatorze ruchu ulicznego. W artykule przedstawiono i omówiono wyniki poszukiwania optymalnej wartości parametru długości cyklu sygnalizacji świetlnej.

Słowa kluczowe: uczenie maszynowe; symulator ruchu ulicznego; maszyna wektorów nośnych

*Autor do korespondencji.

Adresy e-mail: arturcaluch@gmail.com, a.cieslikowski95@gmail.com

Application of support vector machine in a traffic lights control

Artur Całuch*, Adam Cieślowski*, Małgorzata Plechawska-Wójcik

Department of Computer Science, Lublin University of Technology, Nadbystrzycka 36B, 20-618 Lublin, Poland

Abstract. This article presents the process of adapting support vector machine model's parameters used for studying the effect of traffic light cycle length parameter's value on traffic quality. The survey is carried out using data collected during running simulations in author's traffic simulator. The article shows results of searching for optimum traffic light cycle length parameter's value.

Keywords: machine learning; traffic simulator; support vector machine

*Corresponding author.

E-mail addresses: arturcaluch@gmail.com, a.cieslikowski95@gmail.com

1. Wprowadzenie

Proces tworzenia infrastruktury drogowej jest niezwykle skomplikowany. Jednym z najistotniejszych etapów jest zaplanowanie szeroko pojętej organizacji ruchu, na którą, w głównej mierze, składa się sygnalizacja świetlna. Ma ona największe znaczenie w kontekście komfortu korzystania z powstającej infrastruktury - źle skonfigurowana będzie miała negatywny wpływ na jakość ruchu. Ustawienie sygnalizacji, utworzone na etapie planowania, w większości przypadków nie zdaje egzaminu, ponieważ nie można przewidzieć warunków drogowych bez obserwacji ruchu i analizy zebranych w ten sposób danych. Z pomocą przychodzą wszelkiego rodzaju symulatory oraz algorytmy uczenia maszynowego, z pomocą których można stworzyć bardzo wydajne konfiguracje sygnalizacji świetlnej.

W niniejszym artykule przedstawiono przegląd istniejących rozwiązań, proces adaptacji modeli maszyny wektorów nośnych, które odpowiadały za dostosowanie optymalnej konfiguracji sygnalizacji świetlnej w autorskim symulatorze ruchu ulicznego oraz wyniki badań nad optymalizacją wspomnianej konfiguracji.

1.1. Przegląd literatury

Autor artykułu "Q-Learning for Adaptive Traffic Signal Control Based on Delay Minimization Strategy" skupił się na porównaniu statycznie ustawionego cyklu sygnalizacji

świetlnej do zarządzanego przez algorytm Q-Learning [7]. Jest to algorytm uczenia maszynowego, który opiera się na zasadzie uczenia przez wzmacnianie, z tą różnicą, że nie posiada modelu dla środowiska (źródła danych) oraz nie wymaga nadzorowania procesu uczenia. Algorytm samodzielnie nabiera doświadczenia, potrafi dynamicznie dostosować się do zmian zachodzących w środowisku. Poprzez użycie algorytmu Q-Learning, podczas badań wykonywanych przez autorów artykułu, udało się zredukować oczekiwanie podczas przejazdów przez skrzyżowanie o średnio 21 sekund na cykl świateł dla samochodu, co przełożyło się na o 11 minut krótszy przejazd w stosunku do statycznie ustawionych cykli sygnalizacji świetlnej, gdzie przejazd zajmował godzinę (18,3% krócej).

W artykule "Urban Traffic Control Based on Learning Agents" autorzy postanowili wykorzystać algorytm uczenia ze wzmocnieniem w symulatorze ruchu pojazdów [9]. Dla porównania wykonano symulacje ze stałym ustawieniem sygnalizatorów świetlnych oraz z wykorzystaniem algorytmu Q-Learning, czego wynikiem były podobne rezultaty w przypadku stałego poziomu natężenia ruchu, a dla ruchu losowego - nieco ponad 10% krótsze czasy postoju.

Rozszerzoną wersję badań z poprzednich artykułów przedstawili Samah El-Tantawy i Baher Abdulhai w pracy dotyczącej koordynacji sygnalizacji świetlnej na wielu połączonych ze sobą skrzyżowaniach [2]. Wykorzystano do tego celu bezmodelowe, wieloagentowe uczenie ze wzmacnianiem (wieloagentowy Q-Learning). Efektem

przeprowadzonych badań było uzyskanie tzw. "zielonego czasu" (ang. green time), czyli czasu trwania zielonego światła, zgodnego z zapotrzebowaniem ze strony użytkowników ruchu. Analizując przedstawione przez autorów wykresy można zauważyć jak bardzo podobne, w przeciwieństwie do czasu ustawionego statycznie, jest przydzielenie "zielonego czasu" wyznaczonego za pomocą algorytmu uczącego do zapotrzebowania na zielone światło.

Rozwiązanie przedstawione w artykule "A group-based traffic signal control with adaptive learning ability" wykorzystuje wieloagentowe uczenie przez wzmacnianie. Porównywany jest do istniejącego genetycznego algorytmu kontroli i pokazuje wyższość koncepcji opisanej przez autorów dzięki swojej możliwości adaptacji [4].

Przykładem wykorzystania skoordynowanego algorytmu Q-Learning jest badanie opisane w artykule "Traffic Light Control in Non-stationary Environments based on Multi Agent Q-learning" [1]. Badano efektywność tego algorytmu w autorskim symulatorze, gdzie, jak w większości wymienionych powyżej prac badawczych, wybierano drogę otrzymującą zielone światło na podstawie długości pojazdów oczekujących na światłach oraz liczby nadjeżdżających samochodów. Wynikiem było stwierdzenie, że dla zwiększającego się natężenia pojazdów, użycie dynamicznej kontroli sygnalizacją jest coraz bardziej efektywne.

Artykuł "Multiagent Reinforcement Learning for Urban Traffic Control Using Coordination Graphs", autorstwa Kuyer L., Whiteson S., Bakker B. oraz Vlassis N., pokazuje rozszerzenie algorytmu wieloagentowego uczenia przez wzmacnianie poprzez dodanie koordynacji pomiędzy agentami i zwraca uwagę na poprawę działania w porównaniu do poprzedniej, nieskoordynowanej wersji [5].

Ciekawe podejście przedstawiono w pracy pod tytułem "Intelligent Traffic Light Control Using Distributed Multi-agent Q Learning" [6]. Autorzy postanowili stworzyć rozwiązanie oparte nie tylko na analizie ruchu pojazdów, ale włączyć do niej również ruch pieszych, co miałyby stanowić podstawę kierowanie ruchem w inteligentnym mieście. Przedstawione wyniki na obecnym poziomie prac deklasują istniejące rozwiązania, choć sami autorzy deklarują podjęcie pracy w ulepszaniu algorytmu.

Praca badawcza pod tytułem "Coordinated Deep Reinforcement Learners for Traffic Light Control" przedstawia użycie Q-Learning w głębokiej konwolucyjnej sieci neuronowej [10]. Jest to jedynie próba wykorzystania takiego podejścia, jednak jak wynika z badań, potrzeba znacznie więcej pracy aby zapewnić niezawodność głębokiego uczenia przez wzmacnianie, gdyż nie jest ono stabilne. Jednak udowodnione zostało, że algorytm ten przewyższa swojego poprzednika (wieloagentowe uczenie przez wzmacnianie), pomijając wiele problemów oraz pozwala na szybsze i bardziej skalowalne uczenie.

„Traffic Light Control Using Deep Policy-Gradient and Value-Function Based Reinforcement Learning” [8] to praca, która przedstawia to samo podejście do problemu sterowania

ruchem, co poprzednio wspomniany artykuł. Skupiono się na polityce zachowań oraz wartościach uzyskanych z analizy migawek pobranych z symulatora ruchu w postaci obrazu, które analizują zaproponowanymi przez siebie algorytmami głębokiego uczenia przez wzmacnianie: polityka gradientów i oparte na funkcji wartości nagrody. W porównaniu do sztywno ustawionych sygnalizacji świetlnych użycie obu algorytmów skutkowało znacznie mniejszą średnią liczbą samochodów oczekujących na przejazd przez skrzyżowanie.

Autorzy artykułu "Adaptive Traffic Signal Control: Deep Reinforcement Learning Algorithm with Experience Replay and Target Network" przedstawili własne rozwiązanie problemu sterowania sygnalizacją świetlną. Zwrócili uwagę na fakt, że w większości przypadków stosuje się podejście, w którym pierwszeństwo ma najdłuższa kolejka samochodów, a pomijane są dane takie jak prędkość każdego pojazdu czy jego pozycja. Uzyskana płynność ruchu w porównaniu do algorytmu "najdłuższej kolejki" jest lepsza o 47% i aż 86% do statycznego ustawienia świateł [3].

1.2. Cel badań

Sposoby zarządzania sygnalizacją świetlną przedstawione w przeglądzie literatury opierają się na ciągłej analizie ruchu ulicznego. W artykule podjęto się analizy sytuacji, w której dany system dostosowujemy tylko jeden raz, na podstawie danych zebranych w trakcie pewnego okresu obserwacji. Maszyna wektorów nośnych, ze względu na swoje założenia oraz sposób działania, odnajduje swoje zastosowanie w rozwiązywaniu tego typu problemów. Niniejszy artykuł skupia się na doborze odpowiednich parametrów trenowanych modeli opartych o algorytm maszyny wektorów nośnych. Kolejnym obszarem, który poddano badaniom, była optymalizacja konfiguracji sygnalizacji świetlnej w stworzonym symulatorze na podstawie obserwacji jakości ruchu z pomocą utworzonych modeli maszyny wektorów nośnych. Jakość ruchu definiowana jest przez trzy cechy: średnia prędkość przejazdu, średni czas postoju i średnia liczba wypadków. Hipoteza badawcza, związana z procesem optymalizacji konfiguracji sygnalizacji świetlnej, postawiona w tej pracy, brzmi następująco: "Czy długość cyklu sygnalizacji świetlnej ma wpływ na jakość ruchu ulicznego?".

1.3. Zakres artykułu

W rozdziale drugim opisano obiekt badań oraz autorski symulator ruchu ulicznego.

Rozdział trzeci zawiera charakterystykę metody wykorzystanej w przeprowadzonych badaniach.

Rozdział czwarty prezentuje wyniki dostosowania modelu wykorzystanego w procesie optymalizacji parametru długości cyklu sygnalizacji świetlnej.

W rozdziale piątym omówiono uzyskane wyniki badań, natomiast w rozdziale szóstym przedstawiono wnioski powstałe w trakcie badań.

2. Opis obiektu badań

Parametr długości cyklu sygnalizacji świetlnej wydłuża czas trwania światła zielonego o zadaną wartość, co przekłada

się na przedłużenie całego cyklu. Minimalną wartość, jaką może przyjąć parametr to 5 sekund (mniejsze wartości uniemożliwiłyby przejazd przez skrzyżowanie).

Jakość ruchu rozumiana jest jako ogół warunków na drogach składających się na płynność przejazdu. Jest definiowana na podstawie współczynników:

- średniej prędkości przejazdu,
- średniego czasu postoju,
- średniej liczby kolizji.

Parametr długości cyklu sygnalizacji świetlnej jest kluczowym elementem autorskiego symulatora, który ma wpływ na jakość ruchu ulicznego.

2.1. Symulator ruchu ulicznego

Zadaniem systemu jest symulowanie ruchu pojazdów oraz pieszych na dwuwymiarowej makiecie fragmentu miasta. Uczestnicy ruchu poruszają się z punktu A do punktu B wraz z obowiązującymi zasadami ruchu drogowego, takimi jak: ustępowanie pierwszeństwa, zatrzymywanie się na czerwonym świetle czy przepuszczanie pieszych na przejściach. Symulator uwzględnia również poziom przyspieszania oraz maksymalnej prędkości z jaką poruszają się uczestnicy ruchu, tzn. przy dozwolonej prędkości 50km/h będzie osiągnięta prędkość oscylująca w jej granicach, odzwierciedlając sposób jazdy kierującego. Symulator, dla lepszego przedstawienia rzeczywistości, uwzględnia uczestników łamiących przepisy ruchu drogowego np. dopuszczających się znacznego przekroczenia prędkości lub nie zatrzymywania pojazdu w wyznaczonych miejscach. Ostatnim zadaniem symulatora jest uwzględnienie wypadków drogowych. W chwili ich wystąpienia ma miejsce czasowa blokada danej części drogi, na której zdarzył się wypadek.

3. Metoda badawcza

Plan badań zakłada przeprowadzenie symulacji w trzech różnych wariantach:

- poziom zagrożenia 0% - tryb bezpieczny, brak uczestników ruchu łamiących przepisy ruchu drogowego,
- poziom zagrożenia 50% - połowa uczestników ruchu łamie przepisy ruchu drogowego,
- poziom zagrożenia 100% - wszyscy uczestnicy łamią przepisy ruchu drogowego.

Symulacje zostaną wykonane dla:

- parametru długości cyklu sygnalizacji świetlnej o wartościach 5-15, oraz 20, 25 i 30 sekund,
- liczby samochodów wynoszącej 100 dla danych trenujących i 50 samochodów dla danych testowych,
- liczby pieszych: 50.

Do zebrania danych trenujących, w każdej konfiguracji, zostaną przeprowadzone dwie symulacje, a dla danych testowych jedna. Przełoży się to na maksymalnie 680 próbek dla zbioru trenującego i 476 próbek dla zbioru testowego. Samochody mogą poruszać się po 34 drogach. Każda z nich posiada dwa pasy ruchu. W analizie nie będą brane pod

uwagę drogi na których samochód rozpoczyna, bądź kończy trasę. W rezultacie 21 dróg jest poddanych analizie. Dla dróg dwukierunkowych dane z pasów ruchu zbierane są osobno (różny kierunek ruchu), a dla jednokierunkowych razem, ponieważ możliwa jest zmiana pasa ruchu, a dane zbierane są dla całej długości drogi - powodowałoby to odrzucenie dużej ilości danych. Uwzględnienie kierunku ruchu daje 34 analizowane elementy. Ze względu na losowość wybranej trasy może wydarzyć się sytuacja, w której po niektórych drogach i kierunku, w danej konfiguracji, nie przejedzie żaden samochód, czego wynikiem będzie nieznaczne zmniejszenie liczby próbek. Zebrane dane zostaną zsumowane w obrębie każdego elementu, dla poszczególnych wartości parametru długości cyklu sygnalizacji świetlnej, i zapisane do pliku wraz z liczbą wyników. Następnie zostaną obliczone średnie wartości współczynników (średnia prędkość, średni czas przejazdu i średnia liczba wypadków) w zakresie poszczególnych czasów, dla każdej drogi i kierunku ruchu.

Dla każdego ze zbiorów wartości badanych parametrów zostaną wyznaczone po cztery wartości:

- minimalna - kres dolny zbioru,
- kwartyl pierwszy,
- kwartyl trzeci,
- maksymalna - kres górny zbioru.

Tak przetworzone dane umożliwią podział każdego z badanych zbiorów na trzy klasy:

- dla zbioru średniej liczby kolizji i zbioru średniego czasu postoju na drodze:
 - "najlepsza", gdy zawiera się w przedziale od wartości minimalnej do kwartyla pierwszego,
 - "średnia", gdy zawiera się w przedziale od kwartyla pierwszego do kwartyla trzeciego,
 - "najgorsza", gdy zawiera się w przedziale od kwartyla trzeciego do wartości maksymalnej.
- dla zbioru średniej prędkości:
 - "najlepsza", gdy zawiera się w przedziale od kwartyla trzeciego do wartości maksymalnej,
 - "średnia", gdy zawiera się w przedziale od kwartyla pierwszego do kwartyla trzeciego,
 - "najgorsza", gdy zawiera się w przedziale od wartości minimalnej do kwartyla pierwszego.

Podane wartości obliczane są oddzielnie dla każdego identyfikatora drogi. Dane te zostaną wykorzystane do trenowania modeli - każdy model odpowiadać będzie za klasyfikowanie poszczególnego parametru i identyfikatora drogi. Modele zostaną stworzone w oparciu o model maszyny wektorów nośnych (SVM). Został on odpowiednio dopasowany dla analizowanego zbioru danych - złożonego, ale o niedużym rozmiarze (mniej niż 700 próbek).

Trenowanie modeli wykonane zostanie przy pomocy klasyfikatora wektorów nośnych (SVC) z parametrami:

- kernel - jądro klasyfikatora, np. liniowe,
- C - oznacza stopień tolerancji na błędną klasyfikację próbek; im większa wartość, tym mniejsza tolerancja,
- gamma - definiuje wartość wpływu poszczególnych próbek,

- degree - stopień wielomianu jądra wielomianowego.

Trenowanie modeli zostanie przeprowadzone z różnymi wartościami podanych parametrów. Każdy z modeli zostanie przetestowany celem wyłonienia zestawu parametrów klasyfikatora dającego najlepsze wyniki.

Wpływ długości światła zostanie określony w następujący sposób:

- dla każdego parametru długości cyklu sygnalizacji świetlnej obliczona będzie suma wyników klasyfikacji wszystkich trzech parametrów wszystkich dróg (dla dróg bez wyników, istnieje możliwość, że w danej symulacji po danej drodze nie przejedzie żaden pojazd, przyjęty zostanie klasyfikator "średnia"),
- powstałe sumy wyników klasyfikacji zostaną poddane analizie, w wyniku której będzie można jednoznacznie określić, czy parametr długości światła ma realny wpływ na jakość ruchu ulicznego.

4. Prezentacja rezultatów badań

Ze względu na dwa etapy badań przedstawienie rezultatów podzielono na dwie części: dostosowanie modelu oraz dostosowanie wartości parametru sterującego sygnalizacją świetlną.

4.1. Dostosowanie modelu

Parametry zostały dopasowane w następującej kolejności:

1) degree

Na początku wybrano najlepszą wartość *degree* dla jądra wielomianowego. Miało to na celu wyłonienie modelu wielomianowego o najwyższej precyzji, aby móc porównywać jego najlepszy wariant z innymi jądrami. Model odpowiedzialny za średnią prędkość uzyskiwał najdokładniejsze wyniki dla wartości parametru *degree* równej 7. Średni czas oczekiwania na drodze był wyznaczany najprecyzyjniej przez model z wartością parametru *degree* równą 9. Modele dla średniej liczby kolizji otrzymywały wyniki z podobną dokładnością. Piąty stopień wielomianu uzyskał najlepszy wynik i zostanie wykorzystany dla jądra wielomianowego w dalszej części badań.

2) gamma

Parametr *gamma* jest używany przez modele z jądrem wielomianowym oraz radialnym, dlatego jądro liniowe zostało pominięte w tym kroku.

Dla jądra wielomianowego model średniej prędkości oraz średniego czasu oczekiwania na drodze był najdokładniejszy dla *gamma* równego 1. Model średniej liczby kolizji uzyskiwał wyniki na tym samym poziomie bez względu na wartość parametru *gamma*. Do dalszych badań, w celu ujednoczenia tego parametru dla wszystkich modeli, ustawiono jego wartość na 1. Zabieg ten nie wpłynął na dokładność wyników.

Dla jądra radialnego model średniej prędkości uzyskał najwyższy wynik, gdy wartość *gamma* wyniosła 0,75 i 1 - dla

kolejnych etapów selekcji parametrów przyjęto wartość 1. Model średniego czasu oczekiwania na drodze okazał się najdokładniejszy dla wartości *gamma* równej 1.5. *Gamma* nie miała wpływu na wyniki klasyfikacji modelu średniej liczby kolizji. Dla każdej wartości otrzymano maksymalny wynik - do dalszych badań przyjęto wartość 1.

3) kernel

Jądro radialne okazało się bezkonkurencyjne. Uzyskane wyniki modeli z tym jądrem były najwyższe.

4) C

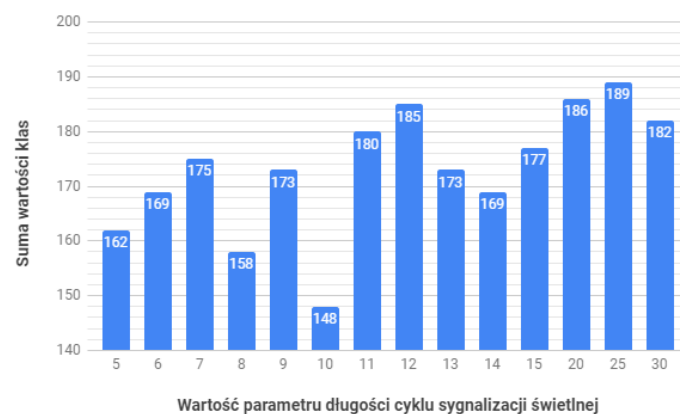
Model średniej prędkości klasyfikował dane z największą dokładnością dla parametru *C* równego 1 000. Model średniego czasu oczekiwania na drodze wykazywał najlepsze wyniki, wyróżniające się tle pozostałych, gdy parametr był równy 10 000 000. Dla modelu średniej liczby kolizji zwiększenie parametru *C* spowodowało zmniejszenie dokładności. Wartości 1 000 i 10 000 pozwalały na uzyskanie maksymalnego wyniku. Bazując na tendencji spadku precyzji wraz ze wzrostem parametru *C*, wybrano wartość 1 000.

4.2. Dostosowanie wartości parametru długości cyklu sygnalizacji świetlnej

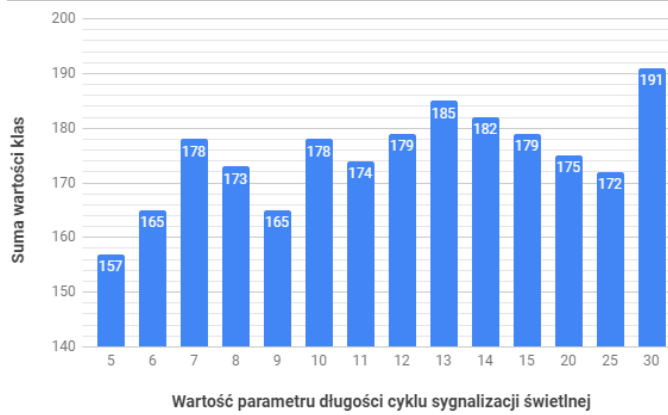
Dla każdego parametru długości cyklu sygnalizacji świetlnej obliczona została suma wyników klasyfikacji wszystkich trzech parametrów wszystkich dróg, oddzielnie dla badanych poziomów zagrożenia. Suma wartości klas została wyznaczona w następujący sposób:

- 1) Próbkę została pobrana ze zbiorów danych reprezentujących kolejny poziom.
- 2) Jeżeli dana próbka danych została sklasyfikowana przez model jako:
 - najlepsza - otrzymuje wartość 1,
 - średnia - otrzymuje wartość 2,
 - najgorsza - otrzymuje wartość 3.
- 3) Wartości próbek zostały zsumowane w obrębie każdej wartości parametru długości cyklu sygnalizacji świetlnej.

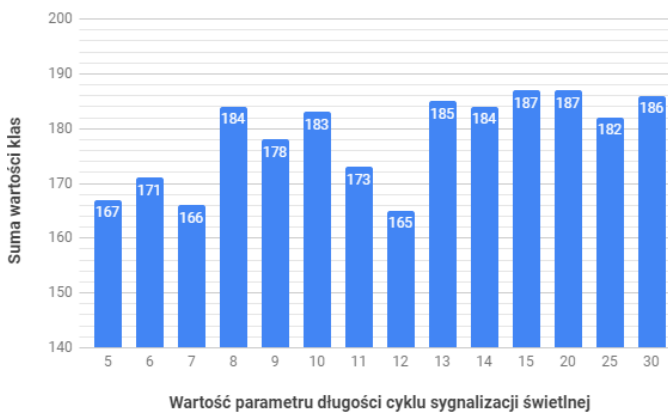
Wyniki tej operacji przedstawiono na rysunkach 2, 3, 4. Jakość ruchu ulicznego jest odwrotnie proporcjonalna do sumy wartości klas.




Rys. 2. Wpływ parametru długości cyklu sygnalizacji świetlnej na jakość ruchu ulicznego dla poziomu zagrożenia wynoszącego 0%.



Rys. 3. Wpływ parametru długości cyklu sygnalizacji świetlnej na jakość ruchu ulicznego dla poziomu zagrożenia wynoszącego 50%.



Rys. 4. Wpływ parametru długości cyklu sygnalizacji świetlnej na jakość ruchu ulicznego dla poziomu zagrożenia wynoszącego 100%.



Rys. 5. Średnia arytmetyczna z sumy wartości klas dla wszystkich poziomów zagrożenia.

5. Dyskusja wyników

Analizując wykresy przedstawione na rysunkach 3-5, można stwierdzić, że nie można dopasować jednoznacznego wzorca do zależności pomiędzy parametrem długości cyklu sygnalizacji świetlnej, a jakością ruchu. Mimo tendencji wzrostu sumy wartości klas wraz ze zwiększeniem parametru długości cyklu sygnalizacji świetlnej we wszystkich badanych poziomach zagrożenia, najniższa wartość tego parametru nie zawsze wiąże się z najmniejszą wartością sumy wartości klas. Powodem tego jest duża losowość w przeprowadzanych

symulacjach. Jest dużo czynników, które mają wpływ na przebieg symulacji, na przykład miejsce wypadku, prędkość pojazdu czy natężenie ruchu na danym odcinku. Z tego powodu sumy wartości klas wszystkich poziomów zagrożenia zostały uśrednione i przedstawione na rysunku 5.

Uśrednienie wartości pozwoliło na ograniczenie skutków losowości przy zbieraniu danych. Odczytując powyższy wykres można z całą pewnością potwierdzić zależność pomiędzy parametrem długości cyklu sygnalizacji świetlnej a jakością ruchu ulicznego tj. wraz ze wzrostem parametru długości cyklu sygnalizacji świetlnej spada jakość ruchu ulicznego. Można stwierdzić, że najbardziej optymalną wartością dla parametru długości cyklu sygnalizacji świetlnej była wartość 5, czyli wartość najmniejsza.

6. Wnioski

W wyniku przeprowadzonych badań otrzymano optymalny zestaw parametrów dla modeli wytrenowanych w sprawdzaniu wpływu wartości parametru długości cyklu na jakość ruchu. Analiza przeprowadzona na podstawie wyników zebranych i zaprezentowanych w postaci wykresów doprowadziła do ustalenia następujących wniosków:

- 1) mimo niewielkich różnic pomiędzy wartościami w otrzymanych rezultatach dla każdego poziomu zagrożenia konieczne było przeanalizowanie wyników zbiorczo w postaci średniej arytmetycznej każdej wartości parametru wyciągniętej ze wszystkich badanych poziomów zagrożenia w celu określenia prawidłowości zachodzących w przedmiocie badań,
- 2) parametr długości cyklu sygnalizacji świetlnej ma niewielki wpływ na jakość ruchu ulicznego,
- 3) najniższa wartość parametru długości cyklu sygnalizacji świetlnej okazała się najlepsza,
- 4) wydłużenie cyklu sygnalizacji świetlnej, z małymi wyjątkami, wiązało się z obniżeniem jakości ruchu,
- 5) charakter i zróżnicowanie próbek danych ma bardzo duży wpływ na parametryzację modeli implementujących algorytmy uczenia maszynowego oraz przebieg ich dostrajania: im dane są mniej skomplikowane, tym proces trenowania i dostosowywania modelu jest krótszy i mniej złożony,
- 6) nieprawidłowe dobranie wartości parametrów skutkuje uzyskaniem niepożądanych wyników oraz wydłużeniem procesu trenowania do niebotycznych długości.

Podsumowując wykonane badania można stwierdzić, że hipoteza: "Czy długość cyklu sygnalizacji świetlnej ma wpływ na jakość ruchu ulicznego?" została potwierdzona. Analizując wyniki badań można zauważyć tendencję spadku jakości ruchu wraz ze wzrostem parametru długości cyklu sygnalizacji świetlnej - im cykl jest dłuższy, tym bardziej negatywnie wpływa na ruch uliczny.

Warto zaznaczyć, że duży wpływ na wyniki badań mógł mieć losowy charakter zebranych próbek danych tworzących zbiory: trenujący oraz wykorzystany w analizie problemu.

Literatura

- [1] Abdoos M., Mozayani N., Bazzan A. L. C., Traffic Light Control in Non-stationary Environments based on Multi Agent Q-learning, 14th International IEEE Conference on Intelligent Transportation Systems (ITSC), s. 1580 - 1585, 2011
- [2] El-Tantawy S., Abdulhai B., An Agent-Based Learning Towards Decentralized and Coordinated Traffic Signal Control, 13th International IEEE Conference on Intelligent Transportation Systems, s. 665 - 670, 2010
- [3] Gao J., Shen Y., Liu J., Ito M., Shiratori S., Adaptive Traffic Signal Control: Deep Reinforcement Learning Algorithm with Experience Replay and Target Network, arXiv:1705.02755, 2017
- [4] Jin J., Ma X., A group-based traffic signal control with adaptive learning ability, Engineering applications of artificial intelligence, s. 282-293, 2017
- [5] Kuyer L., Whiteson S., Bakker B., Vlassis N., Multiagent Reinforcement Learning for Urban Traffic Control Using Coordination Graphs, Obrady ECML/PKDD, Antwerp, Belgia, s.656-671,2008
- [6] Liu Y., Liu L., Chen W., Intelligent Traffic Light Control Using Distributed Multi-agent Q Learning, IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), Październik 2017
- [7] Lu S., Liu X., Dai S., Q-Learning for Adaptive Traffic Signal Control Based on Delay Minimization Strategy, 2008 IEEE International Conference on Networking, Sensing and Control, s. 687-691, 2008
- [8] Mousav S. S., Schukat M., Howley E., Traffic Light Control Using Deep Policy-Gradient and Value-Function Based Reinforcement Learning, IET Intelligent Transport System, vol.11 No.7, s. 417-423, Wrzesień 2017
- [9] Pierre-Luc G., Desjardins C., Laumonier J., Chaïb-draa B., Urban Traffic Control Based on Learning Agents, 2007 IEEE Intelligent Transportation Systems Conference, s. 916-921, 2007
- [10] van der Pol E. Oliehoek F. A., Coordinated Deep Reinforcement Learners for Traffic Light Control, Artykuły naukowe Uniwersytetu Amsterdamskiego, 2016