

Marcin BERNAŚ, Bartłomiej PŁACZEK

ZASTOSOWANIE AUTOMATU KOMÓRKOWEGO DO MODELOWANIA RUCHU DROGOWEGO W ZMIENNYCH WARUNKACH POGODOWYCH

Streszczenie. Publikowane w literaturze wyniki badań dowodzą, że warunki pogodowe mają znaczny wpływ na zachowania kierujących, a co za tym idzie także na parametry strumieni pojazdów i efektywność sterowania ruchem drogowym. Istnieje zatem potrzeba prognozowania wpływu warunków pogodowych na zmiany efektywności procedur sterowania ruchem drogowym. Chcąc umożliwić taką prognozę, niezbędne jest opracowanie modelu ruchu, który będzie uwzględniał wpływ czynników pogodowych. W tym celu zaproponowano modyfikację automatu komórkowego Nagela-Schreckenberga (NaSch). Dokonano rozszerzenia definicji modelu NaSch o elementy, które pozwalają odwzorować funkcjonowanie sygnalizacji świetlnej na skrzyżowaniu oraz dostosować prędkość maksymalną pojazdów do warunków pogodowych. Przedstawione w artykule wyniki symulacji dotyczą wpływu zmiany warunków pogodowych na straty czasu i liczby zatrzymań pojazdów obserwowane na wlocie skrzyżowania z sygnalizacją świetlną.

APPLICATION OF CELLULAR AUTOMATA FOR ROAD TRAFFIC MODELLING IN VARYING WEATHER CONDITIONS

Summary. The research presented in many papers suggests that weather conditions have major influence on drivers' behaviour; leading to parameters change of vehicles streams in road network. Therefore, there is a need to forecast the influence of the weather conditions on traffic control procedures. To make it possible the weather sensitive traffic model has to be proposed. Nagel-Schreckenberg (NaSch) model were used as a base for a proposed model. The model were enhanced by three equations to simulate traffic signal control and to adjust the maximum speed representing various weather conditions. Results of performed simulations show changes in number of stops and stop delays at the intersection approach in various weather conditions.

1. WPROWADZENIE

Systemy sterowania ruchem drogowym realizują programy stałoczasowe lub adaptacyjne, optymalizowane na podstawie pomiarów ruchu. Proces optymalizacji sterowania dla pojedynczych skrzyżowań oraz sieci drogowych powinien uwzględniać zmiany parametrów ruchu oraz straty czasu wynikające ze złych warunków pogodowych.

Istnieje wiele czynników, które mają wpływ na pogorszenie warunków drogowych [11] m.in.: nasłonecznienie; kąt padania promieni słonecznych; zachmurzenie; opady; mgła; niska, bliska zeru lub skrajnie wysoka temperatura. Prowadzone dotychczas badania dotyczyły modeli makroskopowych dla autostrad, miast [8] oraz dróg ekspresowych [6, 7]. Ich wyniki zawierają analizę warunków ruchu drogowego w zależności od cyklicznych zmian pogody [9, 10, 12]. Dostępne wyniki badań przedstawiają zależności pomiędzy stanem pogody a liczbą wypadków oraz opisują dostępne sposoby poprawy bezpieczeństwa ruchu [7].

Badania wskazują na znaczny wpływ następujących parametrów pogodowych na natężenie ruchu i średnią prędkość pojazdów:

- wahania temperatury powietrza wokół temperatury zamarzania, przy dużej wilgotności powietrza,
- silne podmuchy wiatru bocznego,
- opady atmosferyczne,
- ograniczona widoczność – mgła.

W obszarach aglomeracji miejskich największy wpływ na warunki ruchu mają opady deszczu oraz śniegu w połączeniu z ujemną lub oscylującą wokół zera temperaturą [8, 9]. Natomiast w przypadku ruchu lokalnego główną przyczyną utrudnień i kolizji są oblodzenie oraz błoto poślizgowe [15].

Do predykcji warunków pogodowych wykorzystywane są meteorologiczne systemy lokalne i regionalne. Zawierają one skomplikowane procedury numeryczne oparte na równaniach różniczkowych opisujących stan pogody [16], oraz systemy sztucznej inteligencji. Spośród wielu dostępnych technik najlepsze wyniki uzyskano stosując systemy ekspertowe klasyczne [1] i bazujące na wnioskowaniu rozmytym [2, 3].

Drugą grupę metod wykorzystywanych do prognozowania i wnioskowania o stanie pogody stanowią metody bazujące na sieciach neuronowych [4, 5]: wielowarstwowa sieć perceptronów (MLPN), rekurencyjna sieć neuronowa Elmana (ERNN), radialna sieć funkcji prostych (RBFN) oraz model Hopfielda (HFM). Tego typu modele pozwalają na analizę danych pogodowych w czasie rzeczywistym.

Korzystając ze zdefiniowanej w literaturze klasyfikacji stanów nawierzchni (RWIS [13] oraz ITS [14]), zaproponowano model, w którym stan nawierzchni drogi został uwzględniony poprzez wprowadzenie ograniczeń prędkości maksymalnej pojazdów. Jako model ruchu wykorzystano automat komórkowy.

2. MODELOWANIE RUCHU DROGOWEGO Z ZASTOSOWANIEM AUTOMATÓW KOMÓRKOWYCH

Automaty komórkowe pozwalają łączyć wielkie liczby komponentów i poziomów organizacyjnych w model umożliwiający bardzo szybką symulację zachowań systemu złożonego [20]. Modele ruchu oparte na automatach komórkowych są systemami dynamicznymi, w których zarówno droga, czas, jak i stany systemu stanowią wielkości

dyskretne. Ewolucja modelu określana jest za pomocą reguł uaktualniania, które działają lokalnie (w sąsiedztwie danej komórki).

W metodzie modelowania ruchu drogowego, bazującej na automatach komórkowych, droga została podzielona na komórki o stałej długości, natomiast pojazdy reprezentowane są przez punkty, które posiadają niezbędny zestaw parametrów. Co pewien stały krok czasowy każdy pojazd przemieszcza się zgodnie z regułami rządzącymi jego zachowaniem [18].

Ze względu na swoją prostotę automaty komórkowe stanowią popularne narzędzie mikroskopowego modelowania ruchu drogowego. Wykorzystujące je modele posiadają dużą wydajność obliczeniową oraz oferują możliwość odwzorowania i symulowania rzeczywistych zjawisk ruchu drogowego z zadowalającą dokładnością. Pozwalają na realistycznie odwzorowanie środowiska ruchu miejskiego [21]. Ponadto, umożliwiają prognozę parametrów, które stanowią podstawę optymalizacji adaptacyjnego sterowania ruchem [19, 22].

W literaturze nie znaleziono informacji o metodach modelowania ruchu drogowego z zastosowaniem automatów komórkowych, w których byłyby uwzględnione warunki pogodowe.

2.1. Model NaSch

Model ruchu drogowego, wykorzystujący automat komórkowy, został zaproponowany w 1992 roku przez Nagela i Schreckenberga (NaSch) [17]. W modelu NaSch pas ruchu został podzielony na 7,5-metrowe komórki, każdy pojazd (i) posiada prędkość v_i nie mniejszą od zera i nie większą od ustalonej prędkości maksymalnej. Prędkość mierzona jest jako liczba komórek przebyta przez pojazd w trakcie kroku czasowego, który odpowiada jednej sekundzie czasu rzeczywistego. Ruch pojazdów opisany jest regułą składającą się z trzech kroków, które wykonywane są równoległe dla wszystkich pojazdów. Model NaSch posiada zdolność odwzorowywania najistotniejszych parametrów rzeczywistych potoków ruchu. Pozwala odtwarzać podstawowe właściwości ruchu drogowego, m.in. zależność natężenia od gęstości ruchu.

Reguła automatu komórkowego Nagela-Schreckenberga opisana jest następującymi zależnościami:

- 1 $v_i(t) \leftarrow \min\{v_i(t-1) + 1, g_i(t), v_{max}\}$, $g_i(t) = x_j(t) - x_i(t) - 1$,
- 2 jeżeli $\xi < p$, to $v_i(t) \leftarrow \max\{0, v_i(t) - 1\}$,
- 3 $x_i(t) \leftarrow x_i(t-1) + v_i(t)$,

gdzie:

i – nr pojazdu,

j – nr pojazdu bezpośrednio poprzedzającego pojazd i ,

t – nr kroku czasowego,

$x_i(t)$ – nr komórki zajmowanej przez pojazd i w chwili t ,

ξ – zmienna losowa o rozkładzie równomiernym, przyjmująca wartości z przedziału $[0; 1]$.

Pierwszy krok reguły automatu komórkowego opisuje optymalną strategię jazdy – kierowca przyspiesza aż do osiągnięcia prędkości maksymalnej v_{max} i hamuje, gdy odstęp pomiędzy pojazdami (tzw. luka) g jest zbyt mały, aby uniknąć wypadku. Ta część reguły jest całkowicie deterministyczna, co oznacza że stan ustalony zależy tylko od warunków początkowych. Wprowadzenie w drugim kroku reguły parametru prawdopodobieństwa zahamowania pojazdu p stanowi podstawę dla realistycznego modelowania ruchu drogowego.

Parametr ten naśladuje złożone interakcje pomiędzy pojazdami i losowe zachowania kierujących. Trzeci krok reguły dotyczy przemieszczenia pojazdu. W każdym kroku czasowym pojazd przenoszony jest o odpowiednią liczbę komórek, która wynika z jego aktualnej prędkości.

2.2. Modyfikacje modelu NaSch

Funkcjonowanie sygnalizacji świetlnej zostało uwzględnione w modelu ruchu poprzez dodanie do reguły automatu komórkowego kroku 1a:

$$1a \quad \text{jeżeli } s(t) = 1 \text{ i } x_i(t) < x_s, \text{ to } v_i(t) \leftarrow \min\{v_i(t), x_s - x_i(t) - 1\},$$

gdzie:

$s(t)$ – oznacza sygnał wyświetlany dla pojazdów w chwili t ($s(t) = 1$, gdy wyświetlany jest sygnał czerwony),

x_s – jest numerem komórki, która znajduje się na modelowanym wlocie skrzyżowania, bezpośrednio za linią warunkowego zatrzymania.

Aby umożliwić regulowanie prędkości pojazdów w modelu wprowadzony został parametr p_{vmax} , który określa prawdopodobieństwa zahamowania pojazdu poruszającego się z prędkością maksymalną. Zmodyfikowano definicję kroku 2 reguły automatu komórkowego:

$$2. \quad \begin{aligned} &\text{jeżeli } v_i(t) < v_{max} \text{ i } \xi < p \text{ to } v_i(t) \leftarrow \max\{0, v_i(t) - 1\}, \\ &\text{jeżeli } v_i(t) = v_{max} \text{ i } \xi < p_{vmax} \text{ to } v_i(t) \leftarrow \max\{0, v_{max} - 1\}. \end{aligned}$$

Ponadto przyjęto założenie, że musi zostać spełniony warunek $p \leq p_{vmax}$. W związku z powyższym średnia prędkość pojazdów poruszających się swobodnie dla zmodyfikowanego modelu jest dana wzorem $v_s = v_{max} - p_{vmax}$.

3. WYNIKI EKSPERYMENTALNE

Przeprowadzono symulację ruchu drogowego na wlocie skrzyżowania z sygnalizacją świetlną. Natężenie ruchu symulowanego strumienia pojazdów wynosiło 900 P/h. Przyjęto następujące wartości parametrów modelu ruchu: prędkość maksymalna $v_{max} = 2$ k/s, długość komórki 7,5 m, prawdopodobieństwo zahamowania $p = 0,15$. Założona wartość parametru p odpowiada natężeniu nasycenia ok. 2000 P/h [19]. Dobrano wartości parametru p_{vmax} , które pozwoliły ustalić prędkość pojazdów w ruchu swobodnym v_s , tak aby odpowiadała zmianom warunków obserwowanym dla różnych stanów nawierzchni jezdni [14].

Wartości parametru p_{vmax} wyznaczono na podstawie wzoru:

$$p_{vmax}(\Delta v) = p + \Delta v(v_{max} - p),$$

gdzie Δv oznacza spadek prędkości maksymalnej.


Tabela 1 przedstawia dane literaturowe dotyczące wpływu stanu nawierzchni na spadek prędkości pojazdów [13] oraz odpowiadające im parametry komórkowego modelu ruchu.

Tabela 1.

Szacowany spadek prędkości dla różnych klas stanów nawierzchni [13]

Stan nawierzchni	Poziom zagrożenia	Szacowany spadek prędkości (Δv)	p_{vmax}	vs	
				[k/s]	[km/h]
sucha	1	0%	0,15	1,85	49,95
wilgotna	2	0%	0,15	1,85	49,95
wilgotna + śnieg	3	13%	0,39	1,61	43,47
wilgotna + grząska	4	22%	0,56	1,44	38,88
grząska w ścieżkach kół	5	30%	0,71	1,30	35,10
zaśnieżona	6	35%	0,80	1,20	32,40
zaśnieżona i ubita masa	7	42%	0,93	1,07	28,89


Symulację przeprowadzono dla długości cyklu sygnalizacji świetlnej w zakresie 10 – 120 sekund. Czas sygnału zielonego w każdym analizowanym przypadku był równy połowie długości cyklu. Przeprowadzono po 20 symulacji ruchu dla każdej długości cyklu oraz dla każdej z siedmiu klas stanów nawierzchni. Wyniki poszczególnych symulacji zostały uśrednione. Analiza wyników wykazała silny wpływ stanu nawierzchni na straty czasu zatrzymania oraz liczby zatrzymań (rys. 1 oraz rys. 2).



Rys. 1. Średnie straty czasu zatrzymania oraz średnie liczby zatrzymań dla cyklu równego 10 s
Fig. 1. Average number of stops and average delays for a cycle equals 10 s


W przypadku cyklu o długości 10 sekund (rys. 1) zaobserwowano 8-krotny wzrost strat czasu zatrzymania dla wilgotnej i zaśnieżonej nawierzchni oraz ponad 20-krotny wzrost w przypadku zaśnieżonej i ubitej masy w porównaniu do strat obserwowanych dla suchej nawierzchni. Natomiast średnia liczba zatrzymań była odpowiednio 8, oraz 25-krotnie wyższa w stosunku do wyniku uzyskanego dla nawierzchni suchej.

Wydłużenie cyklu do 60 sekund (rys. 2) powoduje zmniejszenie przyrostu strat czasu zatrzymania, który jest odpowiednio 3,5-krotny dla powierzchni lekko zaśnieżonej, oraz 9-krotny dla zbitego zalegającego śniegu. Wzrost liczby zatrzymań dla cyklu 60 sekund był odpowiednio 9 i 12-krotny. Taki wynik jest spowodowany dłuższym czasem potrzebnym do rozładowania kolejki pojazdów w przypadku występowania niekorzystnych warunków pogodowych.




Rys. 2. Średnie straty czasu zatrzymania oraz średnie liczby zatrzymań dla cyklu równego 60 s
Fig. 2. Average number of stops and average delays for a cycle equals 60 s

Na kolejnych wykresach przedstawiono zależność strat czasu zatrzymania od poziomów zagrożenia (odpowiadającym stanom nawierzchni) oraz długości cyklu sygnalizacji świetlnej (rys. 3).



Rys. 3. Średnie straty czasu zatrzymania dla zdefiniowanych poziomów zagrożeń
Fig. 3. Average stop delays for defined weather threat level

Wykres strat czasu zatrzymania dla dobrych warunków pogodowych (poziomy 1 oraz 2) ma charakter liniowy, natomiast w przypadku poziomów od 3 do 7 wartości strat rosną szybciej dla długości cyklu poniżej 50 sekund. Taki wzrost jest spowodowany gwałtownie rosnącą w tym przedziale liczbą zatrzymań (rys. 4). Stała wartość liczby zatrzymań dla długości cyklu powyżej 50 sekund jest związana z formowaniem się dłuższych kolejek i dłuższym czasem zatrzymań.



Rys. 4. Liczba zatrzymań dla zdefiniowanych poziomów zagrożeń
 Fig. 4. Average stops number for a defined weather threat level

4. PODSUMOWANIE

W artykule zaproponowano zastosowanie automatu komórkowego do symulacji ruchu na wlocie skrzyżowania z sygnalizacją świetlną dla zmiennych warunków pogodowych. Za pomocą zmodyfikowanego modelu NaSch wyznaczono średnie straty czasu zatrzymania oraz średnie liczby zatrzymań dla siedmiu klas stanu nawierzchni drogi i długości cyklu sygnalizacji z zakresu 10 – 120 sekund.

Wyniki symulacji określają wzrost strat czasu zatrzymania oraz liczby zatrzymań na skutek pogarszających się warunków pogodowych. Wpływ warunków pogodowych na ruch drogowy został uwzględniony przez wprowadzenie parametru p_{vmax} , który pozwala ograniczyć prędkość maksymalną pojazdów. Zaproponowany model jest bardzo czuły na zmiany parametru p_{vmax} . Przy 13% spadku prędkości liczba zatrzymań pojazdów wzrosła od 3,5- do 8-krotnie (w zależności od długości cyklu). Przeprowadzone badania wykazały niewielki wpływ zmian długości cyklu powyżej 50 sekund na zmianę liczby zatrzymań dla klas stanów nawierzchni od 3 do 7.

Wstępne badania wskazują na możliwość wykorzystania zaproponowanych modyfikacji modelu komórkowego do odwzorowania wpływu warunków pogodowych. Kolejnym krokiem będzie walidacja modelu oraz określenie bezpośrednich zależności parametrów modelu od temperatury, wilgotności oraz opadów. Takie rozwiązanie umożliwi dostosowanie programów sygnalizacji świetlnej do aktualnie panujących warunków pogodowych.

Bibliografia

1. Sujitjorn S., Sookjaras P., Wainikorn W.: An expert system to forecast visibility in Don-Muang Air Force Base. Systems, Man, and Cybernetics, Vol. 3, 1994, p. 2528.

2. Rahman S., Bhatnagar R.: An expert system based algorithm for short term load forecast. *Power Systems*, Vol. 3 ,2002, p. 392.
3. Denis R., Bjarne K.: A fuzzy case-based system for weather prediction. *Engineering Intelligent Systems*, 2002, p. 139.
4. Kuligowski R., Barros A.: Localized precipitation forecasts from a numerical weather prediction model using artificial neural networks. *Weather Forecast*, Vol. 13, 1998, p. 1194.
5. Marzban C.: A Bayesian neural network for severe-hail size prediction. *Weather and Forecasting*, Vol. 16, No. 5, 2001, p. 600.
6. Datla S., Satish S.: Impact of Cold and Snow on Temporal and Spatial Variations of Highway Traffic Volumes. *Journal of Transport Geography*, Vol. 16, 2008, p. 358.
7. Eisenburg D.: The Mixed effects of Precipitation on traffic Crashed. *Accident Analysis & Prevention*, Vol. 36, 2004, p. 637.
8. Hranac R.: Empirical Studies on Traffic Flow in Inclement Weather. *Cambridge Systematic - FHWA*, 2006, p. 4.
9. Keay K., Simmonds I.: The Association of Rainfall and Other Weather Variables with Road Traffic Volume in Melbourne. *Accident Analysis & Prevention*, Vol. 37, 2005, p. 109.
10. Nofal F., Saeed A.: Seasonal Variation and Weather Effects on Road Traffic Accidents in Riyadh City. *Public health*, Vol. 111, 1997, p. 51.
11. Bijleveld F., Churchill T.: The influence of weather conditions on road safety. *SWOV Institute for Road Safety Research*, 2009, p. 11.
12. Bernaś M., Dąbkowski M.: Rozwiązania programowo-sprzętowe dla poprawy bezpieczeństwa transportu drogowego. *Zeszyty Naukowe Transport z. 70*, 2011, s. 11.
13. Agarwal M., Maze T., Souleyrette R.: Impact of weather on urban freeway traffic flow characteristics and facility capacity. *Integration of Road Waeather Information with Traffic Data*, 2005, p. 8.
14. Wytuczne komisji rządowej USA dla ITS:
http://ntl.bts.gov/lib/31000/31400/31419/14497_files/chap_2.htm
15. Specyfikacja techniczna D – przyczyny powstawania śliskiej nawierzchni. *Brązowy Zakład Doświadczalny Budownictwa Drogowego i Mostowego*, 2001, s. 18.
16. Bennett A., Chua B., Leslie L.: Generalized inversion of a global numerical weather prediction model. *Meteorology and Atmospheric Physics*, Vol. 60, No. 1-3, 1996, p. 165.
17. Nagel K., Schreckenberg M.: A cellular automaton model for freeway traffic. *Journal de Physique I France*, Vol. 2, No. 12, 1992, p. 2221.
18. Maerivoet S., De Moor B.: Cellular automata models of road traffic. *Physics Reports*, Vol. 419, No. 1, 2005, p. 1.
19. Spyropoulou I.: Modelling a signal controlled traffic stream using cellular automata. *Transportation Research Part C*, Vol. 15, No. 3, 2007, p. 175.
20. Płaczek B.: Metoda określania danych wejściowych dla automatu komórkowego na podstawie algorytmu rozpoznawania kształtu pojazdów. *Rozprawa doktorska. Politechnika Śląska, Wydział Automatyki, Elektroniki i Informatyki, Gliwice 2004.*
21. Piecha J., Płaczek B.: Automat komórkowy w sterowaniu ruchem drogowym. *Magazyn Autostrady*, nr 6, 2004, s. 40.
22. Płaczek B., Piecha J.: The cellular automata for road traffic control procedures. [in:] Piecha J. (ed.) *Transactions on Transport Systems Telematics. Emerging Technologies. Publishing House of Silesian Univ. of Technology, Gliwice 2004*, p. 26.

Recenzent: prof. dr hab. inż. Romuald Szopa