

Determinanty efektywności inteligentnych sieci transportowych

Przemysław Szufel¹

¹ Kolegium Analiz Ekonomicznych, Szkoła Główna Handlowa w Warszawie

Rozpowszechnienie się inteligentnych samochodów na stałe podłączonych do sieci zmienia sposób w jaki sieci transportowa działają w nowoczesnych miastach. Technologie ciągłej wymiany danych są dostępne zarówno w rozwiązaniach klasy vehicle-to-vehicle (V2V) jak i well as vehicle-to-infrastructure (V2I), a rozwojowi możliwości komunikacji towarzyszy gwałtowny rozwój technologii autonomicznych pojazdów. Te zmiany technologiczne stawiają nowe wyzwania w optymalizacji systemów transportowych – zarówno w zakresie codziennych dojazdów do pracy jak i innych obszarach transportowych. Jednym z głównych wyzwań jest identyfikacja optymalnych regulacji w zakresie udostępniania sieci drogowej uczestnikom systemu i możliwości planowania przez nich tras. W szczególności, kiedy kompletna informacja jest dostępna dla wszystkich uczestników systemu, decyzje przez nich podejmowane prowadzą do stanu stabilnego — równowagi Nasha, która niekoniecznie jednak jest równowagą optymalną w sensie Pareto (inne równowagi mogłyby polepszyć sytuację wszystkich uczestników systemu transportowego). Oznacza to, że z jednej strony zcentralizowane zarządzanie takim systemem może być korzystne dla jego uczestników (dalej ich nazywamy agentami), ale z drugiej strony agenci mają bardzo silną motywację aby nie przestrzegać tych reguł dla własnych korzyści.

Celem projektu jest identyfikacja determinant optymalności dla zbiorów reguł oraz polityk dla inteligentnych systemów transportowych. To z kolei w oczywisty sposób prowadzi do pytania co determinuje optymalność mechanizmów reguł zaprojektowanych dla takich systemów oraz jak przekonać agentów aby postępowali zgodnie z tymi regułami zamiast kierować się wyłącznie własnymi korzyściami (tzw. problem gapowicza). Omawiany problem jest złożony w wielu wymiarach. Po pierwsze system transportowy składa się z heterogenicznych klas agentów (np. samochody prowadzone przez ludzi z ciągłym dostępem do danych i bez niego, samochody autonomiczne) gdzie w ramach klasy agenci różnią się cechami (np. prędkość, wartość czasu) oraz, ponadto, decyzje są podejmowane niezależnie przez kierowców oraz rozwiązania oparte o tzw. sztuczną inteligencję (AI). Po drugie, przedstawiony problem nie jest deterministyczny — przepływ pojazdów w systemie transportowym cały czas ulega zmianie. Po trzecie konieczne są algorytmy mogące funkcjonować w rzeczywistych sieciach transportowych. Dlatego projekty mechanizmów tego typu muszą zawierać rozwiązania motywujące zachowania (np. dynamiczne wyznaczanie cen za korzystanie z infrastruktury drogowej, modele współpłatności), rozwiązania optymalnego planowania przejazdów dla dużych grup samochodów z uwzględnieniem współzależności decyzji (decyzje podejmowane przez jednych agentów wpływają na sytuację decyzyjną innych) — zarówno w środowiskach deterministycznych jak i stochastycznych.



Rysunek 1: Przykładowy model symulacji wieloagentowej przestrzeni miejskiej. Samochody oznaczono prostokątami a skrzyżowania okręgami.

Podjęciem do modelowania problemów tego typu są wieloagentowe modele symulacyjne. W tym podejściu jest tworzony tzw. „cyfrowy bliźniak” rzeczywistego miasta (dla przykładu zobacz Rysunek 1). Taka cyfrowa reprezentacja rzeczywistości może być następnie przedmiotem eksperymentów numerycznych które pozwalają zrozumieć i oceniać skutki różnych polityk regulacyjnych. Po stworzeniu symulatora narzędzie jest następnie łączone z różnymi modelami i heurystykami optymalizacyjnymi, które pozwalają na wyznaczanie najlepszych regulacji dla systemu transportowego.