

Streszczenie

Pojazdy autonomiczne są obecnie jednym z najbardziej zaawansowanych i aktywnych obszarów rozwoju technologicznego, który musi radzić sobie zarówno z problemami percepcji, jak i sterowania. Zastosowane w nich systemy sterowania muszą radzić sobie z coraz bardziej złożonymi scenariuszami drogowymi, które coraz częściej wymagają podejścia wykorzystującego uczenie maszynowe. Jednocześnie uczenie ze wzmocnieniem (z ang. RL) to dziedzina sztucznej inteligencji, która ma na celu tworzenie inteligentnych agentów zdolnych do działania w wcześniej zdefiniowanych środowiskach. Niniejsza praca podsumowuje badania przeprowadzone w zakresie wykorzystania metodologii uczenia ze wzmocnieniem do sterowania ruchem autonomicznego samochodu. Przeprowadzając serię eksperymentów, byliśmy w stanie sprawdzić, jak różne podejścia do sterowania mogą być wykorzystane w połączeniu z polityką opartą o uczenie przez wzmacnianie oraz jakie rodzaje scenariuszy drogowych można rozwiązać za pomocą takiej metodyki.

W pierwszym eksperymencie przeprowadzono uczenie agenta do kontrolowania zachowania symulowanego samochodu na autostradzie za pomocą wysokopoziomowego interfejsu sterowania, definiującego manewr i prędkość zadaną. Realizacja tej akcji spoczywała na algorytmach deterministycznych. Celem agenta było osiągnięcie docelowego pasa na zadanej odległości w jak najkrótszym czasie, przy jednoczesnym przestrzeganiu przepisów ruchu i optymalizacji komfortu jazdy. Zaprezentowano, w jaki sposób różne strategie wykonania działań agenta wpływają zarówno na funkcjonalność, jak i efektywność treningu.

W eksperymencie drugim agent został przeszkolony do określenia trasy pojazdu, mając na celu samodzielne zaparkowanie we wcześniej zdefiniowanym miejscu parkingowym. Przy użyciu naturalnej definicji nagrody opartej o osiągnięcie celu, agent był w stanie zaparkować w określonej pozycji w skomplikowanych scenariuszach parkowania, w tym miejscach parkingowych równoległych i prostopadłych. Dokonano również ewaluacji użycia różnych architektur sieci neuronowych i sprawdzenia ich wpływu na funkcjonalność i wydajność obliczeniową.

W ostatniej serii eksperymentów uczenie przez wzmacnianie zastosowano do problemu koordynacji wielu agentów, gdzie kilka pojazdów musiało nawigować w skomplikowanych scenariuszach drogowych, takich jak zwężenia czy skrzyżowania. Wszystkie pojazdy uczestniczące w scenariuszu były sterowane tą samą polityką użytą w procesie uczenia i były w stanie opracować skuteczne strategie sterowania w wymagających scenariuszach. Byliśmy w stanie wykazać, że korzystanie z mechanizmu współdzielenia nagrody, w którym każdy agent był nagradzany za swoje indywidualne jak i grupowe osiągnięcia, poprawia ogólną skuteczność oraz przyspiesza sam proces uczenia.

Podsumowując, przeprowadzone badania wskazują, że metodologia uczenia ze wzmocnieniem może być skutecznie zastosowana w dziedzinie jazdy autonomicznej, jednakże jej zastosowanie w środowisku produkcyjnym wymaga starannego zaprojektowania całego systemu. Jesteśmy jednak zdania, że przedstawione badania dowodzą, że metody uczenia przez wzmacnianie mogą zostać zastosowane w dziedzinie jazdy autonomicznej i potencjalnie mogą być konieczne do rozwiązania najbardziej wymagających scenariuszy drogowych.

26.10.2023 *Małgorzata Olszewska*

.....
data i czytelny podpis kandydata

Abstract

The autonomous driving (AD) field is currently one of the most advanced and active frontiers in technology development, which needs to address both perception and control problems. Today, AD cars are required to deal with more and more complex environments and scenarios, which often require a data-driven approach to solve. At the same time, reinforcement learning (RL) is a subfield of artificial intelligence which aims at developing intelligent agents capable of acting in predefined environments. This work summarises the research conducted in using reinforcement learning methodologies to control the motion of an autonomous car. By performing a series of experiments, we were able to test how different control approaches can be used in combination with the RL policy and what kind of road scenarios can be solved with such a methodology.

In the first experiment, we trained the agent to control the behaviour of the simulated car in a highway environment with the use of a high-level control interface, defining the manoeuvre and the velocity set point. Execution of this control has been in charge of deterministic, model-based methods. The agent's goal was to reach the lane-based goal, defined in a predefined distance in the shortest time while adhering to traffic rules and optimising comfort. We examined how different strategies for executing agent action impact both functional performance and training efficiency.

In the second experiment, an RL agent was trained to derive the path of a vehicle aiming to park itself at a predefined spot. With straightforward reward design and problem definition, the agent was able to park in complex parking scenarios, including parallel and perpendicular parking spots. In these experiments, we also tested the use of different neural network architectures and checked their impact on functional and computational performance.

In the last series of experiments, we applied RL to a multi-agent coordination problem, where multiple cars need to navigate complex road scenarios, such as bottleneck or cross-road. All of the vehicles in the scene were controlled with the same RL-trained policy and was able to derive successful strategies to navigate those challenging scenarios. We were able to show that using the reward-sharing mechanism, in which each agent was rewarded for its individual and group performance, improves the overall performance of the group and speeds up training.

In summary, we were able to demonstrate that reinforcement learning methodology can be successfully applied to the autonomous driving domain, although its application to the production environment requires a careful design of the whole system. However, we are of the opinion that the presented research proves that RL methodologies are applicable to the AD domain, and might be necessary to solve the most challenging road scenarios.

26.10.2023 *Rafael C. F. S.*

.....
data i czytelny podpis kandydata