

Abstract

Motion planning is a mature area of research in robotics with many well-established methods based on optimization or sampling the state space, suitable for solving a variety of motion planning problems. Recently, a new trend in the field of motion planning emerged, whose key feature is the utilization of the experience in order to improve future motion planning attempts, i.e., machine learning-based motion planning. In this dissertation, we propose advancements in this field, particularly by introducing new solutions to learning-based motion planning for car-like vehicles and constrained kinodynamic motion planning problems. We propose a method for rapid path planning for car-like vehicles that sequentially builds the solution from the locally defined polynomial segments inferred by a neural network, taking into account the geometry of the environment and the non-holonomic constraints. We also introduce another approach that is able to generate, in a single neural network inference, a feasible path that guarantees to reach the goal state exactly. Moreover, we propose a new method for constrained kinodynamic planning that utilizes a neural network to rapidly plan trajectories parametrized using two B-spline curves. Thanks to the proposed parametrization, which allows for imposing boundary constraints on the planned trajectory and its derivatives, and constant planning time, it allows for replanning the robot's motion on-the-fly. The proposed approach allows for incorporating not only boundary constraints but also kinodynamic ones over the whole trajectory, and minimizing some user-defined task loss, thanks to the use of the Lagrangian multipliers-inspired learning procedure. To train our proposed motion planning neural networks, we follow the reinforcement learning paradigm and utilize loss functions that penalize the unwanted behavior of the proposed planners, like a violation of the constraints, collisions with obstacles, long motion times, etc. In the proposed setting, we define the loss functions based on the geometry of the solution, such that they are differentiable and allow for efficient learning of how to plan feasible motions. We propose to use only weak supervision in order to guide the plans outside of the non-convex collision areas, which cannot be done using gradients. Finally, we performed an extensive experimental evaluation of the proposed solutions. All introduced approaches were quantitatively compared with the state-of-the-art motion planning algorithms and showed superb performance in solving local motion planning problems. Moreover, we showed that the proposed approaches also have qualitative advantages over the state-of-the-art algorithms, such as guarantees of boundary constraint satisfaction, constant and short planning time, or the ability to replan the motion on-the-fly. These evaluations were conducted both on the datasets and in a wide range of simulated and several real-world scenarios. This dissertation is concluded with a summary of the contributions made to the field of learning-based robotic motion planning and a list of the limitations of the proposed solutions, as well as the directions of the potential future work.

Streszczenie

Planowanie ruchu jest dojrzałym obszarem badań w robotyce z wieloma ugruntowanymi metodami opartymi na optymalizacji lub próbkowaniu przestrzeni stanów, odpowiednimi do rozwiązywania szerokiej gamy problemów planowania ruchu. Ostatnio pojawił się nowy trend w dziedzinie planowania ruchu, którego kluczową cechą jest wykorzystanie doświadczenia w celu poprawy przyszłych prób planowania ruchu, tj. planowanie ruchu oparte o uczenie maszynowe. W niniejszej rozprawie proponujemy innowacje w tej dziedzinie, w szczególności poprzez zaproponowanie nowych metod planowania ruchu dla pojazdów podobnych do samochodów i systemów z ograniczeniami kinodynamicznymi. Proponujemy metodę szybkiego planowania ścieżki dla pojazdów o kinematyce samochodu, która sekwencyjnie buduje rozwiązanie z lokalnie zdefiniowanych segmentów wielomianowych, wywnioskowanych przez sieć neuronową, która bierze pod uwagę geometrię środowiska i ograniczenia nieholonomiczne. Przedstawiamy również inne podejście, które jest w stanie wygenerować, przy pomocy pojedynczej ewaluacji sieci neuronowej, wykonalną ścieżkę, która gwarantuje dokładne osiągnięcie stanu docelowego. Ponadto proponujemy nową metodę ograniczonego planowania kinodynamicznego, która wykorzystuje sieć neuronową do szybkiego planowania trajektorii sparametryzowanych za pomocą dwóch krzywych B-sklejanych. Dzięki zaproponowanej parametryzacji, która pozwala na nałożenie ograniczeń brzegowych na planowaną trajektorię i jej pochodne, oraz stałemu czasowi planowania, możliwe jest replanowanie ruchu robota w locie. Proponowane podejście pozwala na uwzględnienie nie tylko ograniczeń brzegowych, ale także kinodynamicznych dla całej trajektorii oraz minimalizację funkcji kosztu związanej z zadaniem zdefiniowanym przez użytkownika, dzięki zastosowaniu procedury uczenia inspirowanej mnożnikami Lagrange'a. Aby wytrenować proponowane przez nas algorytmy planowania ruchu oparte o sieci neuronowe, stosujemy paradygmat uczenia ze wzmocnieniem i wykorzystujemy funkcje kosztów, które penalizują niepożądane zachowanie proponowanych planerów, takie jak naruszenie ograniczeń, kolizje z przeszkodami, długie czasy ruchu itp. W niniejszej rozprawie definiujemy funkcje kosztów w oparciu o geometrię rozwiązania, tak aby były one różniczkowalne i pozwalały na efektywne uczenie się planowania dopuszczalnych ruchów. Proponujemy użycie jedynie słabego nadzoru w celu skierowywania planów poza niewypukłe obszary kolizyjne, co nie jest możliwe do osiągnięcia korzystając z prostych gradientów. Na koniec przeprowadziliśmy obszerną ocenę eksperymentalną proponowanych rozwiązań. Wszystkie wprowadzone podejścia zostały ilościowo porównane z nowoczesnymi algorytmami planowania ruchu i wykazały doskonałą wydajność w rozwiązywaniu lokalnych problemów planowania ruchu. Co więcej, wykazaliśmy, że proponowane podejścia mają również zalety jakościowe w porównaniu do algorytmów wyznaczających aktualny stan wiedzy, takie jak gwarancja spełnienia ograniczeń brzegowych, stały i krótki czas planowania lub możliwość replanowania ruchu w locie. Wspomniane eksperymenty zostały przeprowadzone zarówno na zbiorach danych, jak i w szerokim zakresie symulowanych oraz kilku rzeczywistych scenariuszach. Niniejsza rozprawa zakończona jest podsumowaniem wkładu wniesionego w dziedzinę planowania ruchu robotów opartego na uczeniu maszynowym oraz listą ograniczeń proponowanych rozwiązań, a także kierunkami potencjalnych przyszłych prac.