

Abstract

In modern robotic navigation, efficiency is no longer defined solely by the optimality of the path, but by the robot's ability to make context-based decisions. This dissertation investigates the trade-offs between avoiding obstacles and tolerating controlled risk to improve operational performance in autonomous mobile robots. Although conventional systems treat all obstacles as hazards to be avoided, this work introduces a learning-based framework that enables robots to estimate potential collision damage and determine whether avoidance is truly necessary.

The methodology integrates supervised learning models trained on simulated collision data and couples them with classical path planning algorithms. The result is a system capable of adapting navigation behavior based on obstacle type, potential risk, and mission context. This hybrid approach not only minimizes unnecessary detours, but also conserves energy and time, resources that are critical in complex environments.

A key contribution of this thesis is the explicit integration of **damage-aware learning** into navigation, filling a gap in the literature where obstacle handling was traditionally risk-blind. Furthermore, the thesis proposes a flexible emergency planning framework designed to be adapted across various robotic domains. The framework emphasizes preparedness and operational continuity in unpredictable situations. Experimental validation, including multiple scenario simulations and statistical analysis, confirms the effectiveness of the proposed methods in improving both safety and efficiency.

This study enhances robotic autonomy in unpredictable and changing conditions by integrating conventional algorithms with data-centric risk assessments, providing effective tools for practical applications in fields like industrial logistics, agriculture, and disaster response.

Streszczenie

We współczesnej nawigacji robotów mobilnych efektywność nie jest już definiowana wyłącznie przez optymalność trasy, lecz przez zdolność robota do podejmowania decyzji w oparciu o kontekst. Niniejsza rozprawa analizuje kompromisy między omijaniem przeszkód a akceptacją kontrolowanego ryzyka w celu poprawy wydajności operacyjnej autonomicznych robotów mobilnych. Podczas gdy systemy konwencjonalne traktują wszystkie przeszkody jako zagrożenia, które należy omijać, w niniejszej pracy zaproponowano podejście oparte na uczeniu maszynowym, umożliwiające robotom oszacowanie potencjalnych szkód wynikających z kolizji i określenie, czy unikanie jest rzeczywiście konieczne.

Metodologia łączy modele uczenia nadzorowanego, wytrenowane na podstawie symulowanych danych kolizyjnych, z klasycznymi algorytmami planowania ścieżki. Wynikiem jest system zdolny do adaptacji zachowania nawigacyjnego w zależności od rodzaju przeszkody, potencjalnego ryzyka i kontekstu misji. Hybrydowe podejście nie tylko minimalizuje niepotrzebne objazdy, ale również oszczędza energię i czas, które są kluczowe w złożonych środowiskach.

Istotnym wkładem tej rozprawy jest jawna integracja **uczenia świadomego uszkodzeń** w procesie nawigacji, co wypełnia lukę w literaturze, w której dotychczas obsługa przeszkód była pozbawiona oceny ryzyka. Ponadto zaproponowano elastyczne ramy planowania awaryjnego, możliwe do adaptacji w różnych domenach robotycznych. Ramy te podkreślają znaczenie gotowości i ciągłości operacyjnej w nieprzewidywalnych sytuacjach. Walidacja eksperymentalna, obejmująca wiele scenariuszy symulacyjnych oraz analizę statystyczną, potwierdza skuteczność proponowanych metod w zakresie poprawy zarówno bezpieczeństwa, jak i efektywności.

Praca ta wzmacnia autonomię robotów w nieprzewidywalnych i dynamicznie zmieniających się warunkach poprzez integrację klasycznych algorytmów z oceną ryzyka opartą na danych, dostarczając praktycznych narzędzi dla zastosowań w logistyce przemysłowej, rolnictwie i reagowaniu kryzysowym.