



AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

Nauki inżynieryjno-techniczne

Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne

AUTOREFERAT ROZPRAWA DOKTORSKA

Inteligentny system sterowania robotem mobilnym

Autor: Ravi Raj

Promotor rozprawy: Prof. dr hab. inż. Andrzej Kos

Praca wykonana: Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie
Wydział Informatyki, Elektroniki i Telekomunikacji

Kraków, 2024

1. Streszczenie

Nowoczesne roboty mobilne opracowano, aby pomagać lub zastępować personel ludzki w złożonych operacjach kontrolnych i planistycznych oraz zadaniach, w tym manipulacji obiektami, pomocy eksperckiej w różnych sektorach, nawigacji zewnętrznej, nadzorze bezpieczeństwa, gaszeniu pożarów eksploracji nieznanego terenu i prowadzeniu pojazdów po obszarach miejskich. Nawet dla osób posiadających specjalistyczne przeszkolenie w zakresie kodowania robotów opracowanie struktury sterującej dla robotów używanych do wykonywania tych czynności jest często trudnym podejściem, wymagającym ręcznego wygenerowania unikalnego sterownika dla każdej konkretnej operacji. Twórca musi celowo wziąć pod uwagę szeroką gamę scenariuszy, których robot może doświadczyć w trudnych sytuacjach. Dla robota korzystniejsze może okazać się odkrycie, jak samodzielnie wykonywać określone czynności, zamiast konieczności programowania go do każdej czynności. Niniejsza rozprawa doktorska bada technikę uczenia się robotów, a także uwypukla trudności związane z inteligentnym systemem sterowania robotami mobilnymi do autonomicznej nawigacji. Badamy, jak robot mobilny zdobywa wiedzę poprzez prezentacje eksperckie. Podejście to opiera się na naturalnej ludzkiej skłonności do naśladowania. Kiedy robotom mobilnym oferuje się przykłady konwencjonalnych działań, mogą one uzyskać informacje z tych danych i zastosować swoją wiedzę do wszystkich możliwych scenariuszy, które nie są uwzględnione w tych przypadkach. Korzystając ze sztucznej sieci neuronowej, funkcję wnioskowania została zintegrowana ze sterownikami robota. Robot mobilny po odpowiedniej liczbie ćwiczeń nabędzie wiedzę dotyczącą samodzielnego poruszania się.

W tej rozprawie badana jest zdolność niezależnego uczenia się robotów mobilnych przy braku przeszkolonych demonstracji autonomicznej nawigacji. W tym badaniu wykorzystano nowoczesne algorytmy uczenia się przez wzmacnianie do szkolenia robotów mobilnych poprzez interakcje z robotami mobilnymi. Analizujemy robota mobilnego poprzez symulację, która wykorzystuje uczenie się przez wzmacnianie w celu uzyskania informacji o możliwych osiągnięciach w różnych kontekstach. Dodatkowo zintegrowano sztuczną sieć neuronową realizującą funkcję szybkiej generalizacji. Roboty muszą zrozumieć podstawowe zasady i efekty wynikające z demonstracji ekspertów w tym eksperymencie, a także nauczyć się kojarzenia ze stanami i czynnościami. W porównaniu do technik konwencjonalnych, wspomagamy konwergencję uczenia się w znacznie krótszej liczbie odcinków, wykorzystując wszystkie

poprzednie pary stanu i działania, które zostały zarejestrowane w procesie interakcji w celu szkolenia robota mobilnego. W oparciu o proponowaną technikę wyniki eksperymentów wykazały niezawodną i dokładną skuteczność w zadaniach autonomicznej nawigacji dla robotów mobilnych. Sugerujemy zatem, że rozwój technologii uczenia się robotów mobilnych, w porównaniu z konwencjonalnym programowaniem robotów, ma przed sobą obiecującą przyszłość.

2. Motywacja

Nowoczesne pojazdy autonomiczne w dużym stopniu opierają się na swojej zdolności do autonomicznej nawigacji. W 2003 r. Agencja Zaawansowanych Projektów Badawczych Obrony (DARPA) rządu Stanów Zjednoczonych zamierzała przyspieszyć postęp w zakresie technik niezbędnych do wyprodukowania pierwszych w pełni autonomicznych pojazdów lądowych, które mogłyby pokonać znaczną trasę terenową w krótszym czasie. Inicjatywa ta była znana jako „Grand Challenge”. Samochody robotyczne miały ukończyć wyzwanie w maksymalnie 10 godzin, pokonując dystans 142 mil nad pustynią Mojave. Inauguracyjny turniej odbył się 13 marca 2004 r. Jednak żaden z piętnastu samochodów biorących udział w zawodach nie ukończył nigdy więcej niż pięciu procent trasy. W rezultacie 8 października 2005 r. wystartował kolejny DARPA Grand Challenge. Ostatecznie pięć z dwudziestu trzech samochodów pomyślnie ukończyło wyścig. Ten pojazd robotyczny wykonał ważny krok w kierunku stworzenia dzisiejszych autonomicznych samochodów. Dwa lata później, 3 listopada 2007 r., autonomiczne samochody musiały ukończyć „DARPA Urban Challenge”, który polegał na przejechaniu 97 kilometrów w symulowanym środowisku miejskim w czasie krótszym niż sześć godzin, przy jednoczesnym nawiązywaniu kontaktu z nadjeżdżającym ruchem, omijaniu przeszkód i przestrzeganiu wszystkich przepisów ruchu drogowego. „Boss” został ogłoszony zwyciężkim samochodem, podczas gdy „Junior” zdobył drugie miejsce. Uważano również, że te pojazdy były pierwszą iteracją prototypu autonomicznego pojazdu Google.

Prawdziwy programista wykorzystałby swoją wiedzę na temat zamierzonego celu w standardowej instancji programowania i musiałby podejmować decyzje z wyprzedzeniem przez jakiś czas, aby zaprojektować kontroler robot mobilny (MR), który mógłby reagować na wszelkie warunki, na jakie MR mógłby natrafić, niezależnie od tego jak nieprawdopodobne by były. Chociaż ten typ dostosowanego programowania jest dość skuteczny, jest również kosztowny i

działa tylko w scenariuszach, które wymyślił operator. Całą kosztowną procedurę można by powielić, gdyby po wdrożeniu urządzenia robotycznego wystąpiły błędy lub nieprzewidziane zdarzenia. Chociaż wyżej wymienione wyzwania DARPA zostały ukończone w nieprzygotowanych programach, trudno uwierzyć, że jakakolwiek praca, która mogłaby zostać przydzielona, mogłaby zostać zaprogramowana. W rezultacie roboty muszą posiadać zdolność do zdobywania informacji samodzielnie lub z pomocą.

Ta rozprawa, która jest inspirowana autonomicznymi pojazdami Google i wyzwaniami DARPA, koncentruje się na umożliwieniu robotom MR podejmowania przemyślanych, logicznych osądów, a także na możliwości uczenia się zupełnie nowych umiejętności i inteligentnego rozwijania istniejących. Stosując tę metodę, roboty mogą być szkolone do radzenia sobie z niepewnymi i nieprzewidywalnymi warunkami, ucząc się, jak najlepiej radzić sobie z niepewnością i nieprzewidywanymi zmianami.

Zastosowanie robotów MR rozszerza się na wiele branż, w tym produkcję, logistykę, sektor rolniczy oraz poszukiwania i ratownictwo. Roboty te muszą być wysoce autonomiczne i adaptacyjne, aby dobrze funkcjonować w dynamicznym i nieprzewidywalnym otoczeniu. Nawigacja MR w rzeczywistych kontekstach może wymagać niezwykle skomplikowanych wyzwań kontrolnych z dynamicznymi przeszkodami, zmieniającą się topografią i nieregularnymi zakłóceniami. Bez wymogu specjalnego programowania lub zaangażowania człowieka, RL jest wykonalną metodą dającą robotom zdolność uczenia się na podstawie doświadczeń historycznych i modyfikowania swoich działań w odpowiedzi na bodźce środowiskowe.

Wymaganie, aby MR łączył się z ludźmi w sposób bezpieczny, skuteczny i prosty, rośnie w miarę jak te urządzenia robotyczne są coraz częściej włączane do scenariuszy ludzkich. MR można uczyć zachowań społecznie świadomych przy użyciu mechanizmów sterowania opartych na RL. Zachowania te obejmują przestrzeganie norm społecznych, rozszyfrowywanie ludzkich gestów i zmienianie swoich działań w odpowiedzi na bodźce od ludzi. Ponadto RL może pomóc wielu robotom pracującym w grupach, wraz z ludźmi współpracować, co skutkuje bardziej wydajnymi i dobrze skoordynowanymi systemami robotycznymi. Podsumowując, celem badania algorytmów inteligentnego sterowania opartych na uczeniu się przez wzmocnienie (RL) dla MR jest poprawa adaptacyjności, autonomii, skuteczności i elastyczności sprzętu robotycznego w codziennych sytuacjach. Przyczyni się to do rozwoju technologii robotów i jej możliwych zastosowań w różnych dziedzinach.


3. Najważniejsze wyniki pracy

Problem nawigacyjny jest opisany następująco: Wszystko, co jest wymagane do skutecznej nawigacji w nieznanym wcześniej środowisku z rozległym terenem, w tym długimi korytarzami i ślepyimi zaułkami to MR, który zawiera rozproszone lokalne czujniki zasięgu. Po przeprowadzeniu badań MR wygeneruje autonomiczny system środowiskowy, ponieważ na początku ma niewielką wiedzę o swoim otoczeniu. Złożoność środowisk z niestabilnymi przeszkodami jest znacznie zwiększona przez ich dynamiczny i nieoczekiwany charakter. Wdrożyliśmy działanie lokalnego planu który wykorzystuje RL, który przekłada widoczne percepcje na działania w celu bezpiecznej eksploracji i unikania przeszkód w dynamicznych, nieznanym środowiskach. Aby ulepszyć podstawowe techniki RL i umożliwić mobilność w złożonych scenariuszach, używamy wielu wspólnych wzorców. Wykorzystujemy model MR, który jest wyjaśniony w rozdziale 4.5, aby wykonywać autonomiczną nawigację w nieznanym środowiskach. Rozmiar mapy środowiska wynosi $250 \times 250 \text{m}^2$ dla symulacji. Przeszkody są rozproszone dowolnie w otoczeniu, a robot nie jest wcześniej świadomy ich ilości, wymiarów ani lokalizacji. Na mapie terenu, początkowa pozycja MR (10, 10) jest wyświetlana jako czerwony trójkąt, podczas gdy jego pozycja docelowa (240, 240) jest wyświetlana jako zielony okrąg. Zadaniem MR jest rozpoczęcie od lokalizacji początkowej i wybranie optymalnej ścieżki do przebycia, aby dotrzeć do celu, unikając zderzenia z przeszkodami, i powrót z pozycji docelowej do punktu początkowego, także unikając zderzenia z przeszkodami. Pełny zestaw hiperparametrów i ich opisów, które są wykorzystywane w niniejszych badaniach, przedstawiono w Tabeli 1.

TABELA 1.: LISTA HIPERPARAMETRÓW

Konfiguracja systemu	Opis/wersja
Version of Python	2.9.1
Version of MatLab	2023a
Version of Keras	2.15.0
Version of NumPy	1.24.3
Version of TensorFlow	2.9.1
Version of Matplotlib	3.7.0
RAM	8GB
Processor	Intel(R) core (TM) i3-4005U

Mając częściową świadomość otoczenia i docelowego miejsca lub grupy miejsc docelowych, inteligentna nawigacja odnosi się do zdolności robota do podejmowania decyzji zgodnie ze zdolnościami poznawczymi i informacjami zebranymi z czujników w celu dotarcia do miejsc docelowych tak szybko i wydajnie, jak to możliwe. Symulowany MR, który wykonuje wybrane zachowania w środowisku symulacji w każdej fazie epizodu. Procedurę uczenia się NN można również rozszerzyć na bazę danych dostępnych przykładów do szkolenia, co pozwala na zbieranie wykonalnych rozwiązań dla podobnych scenariuszy, które nie były wcześniej widoczne w eksperymentach. Cztery całkowicie różne operacje nawigacyjne wykorzystujące podobne wagi zostały pokazane na rys. 1.



Rys. 1: Ilustracja wyników autonomicznej nawigacji opartej na NNQL w różnych środowiskach.

Od jednego punktu początkowego do określonego miejsca docelowego robot próbował dotrzeć inną ścieżką na rys. 1. W każdym z czterech scenariuszy robotowi udało się dotrzeć do pożądanego miejsca bez napotykania przeszkód i utrzymywania bezpiecznej odległości od nich. Ponieważ robot nie miał dokładnego rozumienia mapy otoczenia, zauważono, że wybrane przez niego ścieżki mogły nie być najlepszymi, ale nawet w tak złożonym otoczeniu są one całkowicie akceptowalne i spełniają nasze oczekiwania. Ścieżki w kolorze niebieskim są uważane za nie optymalne w porównaniu ze ścieżką w kolorze zielonym, ponieważ ścieżka w kolorze zielonym jest najkrótsza i zużywa mniej energii, dlatego jest ścieżką optymalną w porównaniu ze ścieżkami w kolorze niebieskim. Przeprowadzono eksperymenty symulacyjne w celu oceny sugerowanej strategii. Robot został wysłany, aby ukończyć misję, która obejmuje nawigację po nowym i dziwnym obszarze. Głównym celem symulacji jest wygenerowanie optymalnej wartości Q .

W przeciwieństwie do prób, robot nie wie od razu, ile, jak duże i gdzie są przeszkody. Staje się również oczywiste, że pomimo faktu, że robot nie był w pełni zaznajomiony ze swoim otoczeniem, wybrane przez niego ścieżki mogły nie okazać się najbardziej korzystne, ale mimo to były całkowicie odpowiednie i spełniały standardy odniesienia. Algorytm używany do nawigacji MR za pomocą NNQL jest podany w algorytmie 1.

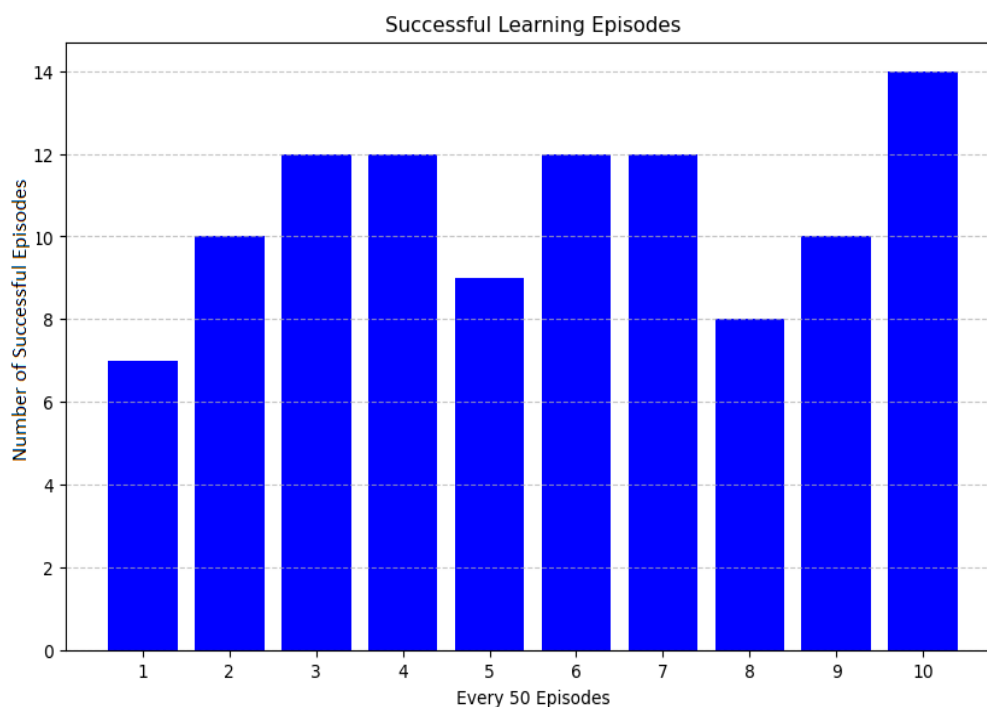
ALGORYTM 1: ALGORYTM NAWIGACJI ROBOTA OPARTY NA NNQL

Algorithm 1: NNQL-Based Robot Navigation Algorithm

- 1: Enter the pre-trained NN weights $W^{(1)}$ and $W^{(2)}$;
 - 2: Provide the goal and randomly generate obstacles;
 - 3: Set the initial position and orientation of MR at $[x_0, y_0]$ and θ_0 ;
 - 4: $t \leftarrow 1$;
 - 5: **For** every mobile step **do**
 - 6: Observe the present state and property of the state as s_t and p_t respectively;
 - 7: **If** s_t represents a winning state or a failing state, **then**
 - 8: Stop the navigation;
 - 9: **End if**
 - 10: Estimate every action value $\{Q(s_t, a_i)\}_i$ for state s_t using NN;
 - 11: Choose only one action a_t based on greedy policy and then proceed;
 - 12: **End for**
-

Robot jest w stanie podejmować nowe wyzwania i unikać utknięcia w nieskończonym cyklu gdy tylko przyzwyczai się do otoczenia, dzięki uczeniu się w różnych kontekstach. Jak zaobserwowaliśmy, robot eksperymentował z różnymi czynnościami, a nagrody oceniały jego


wybór działania. Te informacje pozwolą robotowi podejmować lepsze decyzje dotyczące działań w przyszłości. Biorąc pod uwagę, że proponowane podejście wykorzystuje metodę prób i błędów, ma sens, że wiele epizodów nie powiedzie się w wyniku kolizji. Odcinek, w którym robot pomyślnie dotrze do miejsca docelowego jest uważany za skuteczny epizod uczenia się. Rys. 2 przedstawia liczbę skutecznych epizodów uczenia się dla 50 epizodów. Mniej niż 50 oświata w początkowych 100 epizodach osiągnęło swoje cele, ale ponad 70 z końcowych 50 epizodów pokazało, że oświata dotarł do celu. Ten szybko rosnący trend udowodnił, że inteligencja robota została wzmocniona przez sugerowany algorytm NNQL.



Rys. 2: Ilustracja udanych epizodów uczenia się podczas symulacji.

Informacje te umożliwią robotowi podejmowanie lepszych decyzji dotyczących działań w przyszłości. Innymi słowy, robot stopniowo nabywał umiejętności radzenia sobie z otoczeniem. Robot nabywał wytyczne dotyczące tego, jak postępować w pobliżu przeszkód. Robot zasadniczo po prostu przyjmuje FFNN i wybiera optymalny sposób działania, aby wybrać optymalną ścieżkę dotarcia do pożądanego lokalizacji docelowej. Czasami roboty wybierają różne ścieżki, aby dotrzeć do lokalizacji docelowej. Ponieważ nie należą one do najefektywniejszych ścieżek sprawdzamy, jak różnią się od siebie. Następnie wybieramy najkrótszą ścieżkę. Proponowany system tworzy zbiór stanów z elastycznymi zmiennymi, dzięki czemu po prawidłowym przejściu przez konkretny

scenariusz może być przydatny w innym, niezależnie od lokalizacji, w której znajduje się każda przeszkoda i cel. Zdefiniowanie funkcji nagrody lub sposobu, w jaki środowisko reaguje na działania agenta behawioralnego stanowi dodatkowe kryteria podejmowania decyzji. Symulacja wykorzystuje algorytm epsilon-greedy do analizy autonomicznego zachowania nawigacyjnego. Krzywe nagrody w czasie symulacji i zmienności epsilon pokazano na rys. 3.



Rys. 3: Wyniki wariacji nagrody i epsilon dla każdego odcinka symulacji.

Zgodnie z powyższymi wynikami prób, NNQL wykazało, że jest w stanie wykonywać autonomiczne czynności nawigacyjne dobrze i spójnie, pomimo potrzeby wyraźnego programowania zachowań robota. Robot jest zdolny do autonomicznej nawigacji z niemal 100% dokładnością po zaledwie 500 epizodach. Porównano dwa dobrze znane algorytmy bezmodelowe i NNQL okazał się lepszy. Można rozsądnie wnioskować, że NNQL skutecznie wyposażył MR przy użyciu solidnych możliwości samouczenia się do obowiązków związanych z autonomiczną nawigacją. Jedną z wad strategii probabilistycznych jest to, że robot nie zawsze może wybrać najlepszą trasę i może się na jakiś czas zgubić, zanim odkryje drogę wyjścia. Robot musi zbadać swoje otoczenie w celu nauczenia się ograniczonej części swojego otoczenia, ponieważ brakuje mu kompleksowej perspektywy. Wykorzystanie metod jednoczesnej lokalizacji i mapowania (SLAM) stanowi możliwe rozwiązanie. Obszerna część tradycyjnej robotyki skoncentrowana na interpretacji czujników, myśleniu i optymalnej kontroli dostarczyła reprezentacji dotyczących

robota i otoczenia. Choć ta metoda sprawdza się w wielu zastosowaniach komercyjnych, nie jest tak ambitna jak wykorzystanie robotów jako poligonu doświadczalnego dla AI.

Technika samouczenia się robotów przy określonym wejściu została wprowadzona w tym rozdziale dla tych, którzy nie mają wcześniejszego doświadczenia. Badaliśmy wyzwanie nawigacji MR poprzez integrację NN i RL. Q-learning jest używany do poprawy zdolności MR do samouczenia się przy użyciu spotkań prób i błędów w nowym środowisku. Aby zachować i wykształcić istotne wartości Q oraz rozszerzyć nabytą skuteczność na istotne przestrzenie stanu i działania, stworzyliśmy unikalne wyrażenia nagrody i wdrożyliśmy architekturę NN. Wyniki eksperymentu dowodzą niezawodności i skuteczności przedstawionego podejścia. Poprzez bezpieczne realizowanie celów nawigacyjnych w nieprzewidywalnym i nieprzewidywalnym otoczeniu, robot rozwija się w wysoce inteligentny system zdolny do potężnego samouczenia się i adaptacji.

4. Podsumowanie

Potrzeba inteligentnego poruszania się robotów mobilnych w dynamicznych środowiskach jest niezbędna, ponieważ maszyny te stają się coraz bardziej powszechne w nowoczesnym świecie. Solidne i niezawodne kontrolery, które mogą poradzić sobie z nieprzewidywalnością świata zewnętrznego, zostały ustanowione w wyniku konieczności posiadania przez robota zdolności reagowania na zmiany okoliczności zewnętrznych. Wstępnie zaprogramowany MR nie jest w stanie sprostać potencjalnym wymaganiom, szczególnie gdy wymagana jest współpraca człowieka, ponieważ jest mało prawdopodobne, aby ludzie mogli dokładnie przewidzieć każdy możliwy scenariusz w świecie rzeczywistym. Próbkowanie wszystkich potencjalnych rozwiązań nie jest realistyczne w przypadku problemów ze stanem ciągłym, dlatego algorytmy RL stają się zalecanym podejściem w uczeniu nadzorowanym w polu DL, gdy nie ma instruktora. W tej metodzie MR wykorzystuje RL do uzyskania wcześniejszych informacji dotyczących środowiska przy użyciu danych z czujników w celu wykonania ruchu bezkolizyjnego. Sugerowana metoda wykorzystuje bardzo podstawową, ale wydajną platformę symulacyjną, która pokazuje szybkie i wydajne procesy szkoleniowe. Ta rozprawa przedstawia lepszą teoretyczną koncepcję MR, historyczne tło MR, rodzaje MR i proces uczenia się robota w pierwszym rozdziale. Rozdział 2 zawiera szeroki zakres informacji na temat AI, DL, ML, ANN, DNN i RL. Rozdział 3 zawiera

szeroki zakres przeglądów powiązanych prac. Rozdział czwarty szeroko opisuje MDP i POMDP, a na koniec ta rozprawa analizuje rolę RL w nawigacji robota w złożonych środowiskach poprzez symulację. Rozdział szósty szeroko opisuje koncepcję PSO i technik nawigacji termicznej. Ponadto w rozdziale szóstym omówiono zastosowanie podejścia nawigacji termicznej przy użyciu czujników podczerwieni w celu pomocy osobom niedowidzącym. Ocena wszystkich potencjalnych rozwiązań dla zadań o stanie ciągłym nie jest realistyczna, dlatego techniki RL służą jako zalecany sposób prowadzenia nadzorowanego uczenia się w całym polu DL, gdy nie ma trenera. Wyniki wykazały wyraźną poprawę niezawodności i bezpieczeństwa podczas nawigacji w złożonych środowiskach, ale przy dodatkowym koszcie zwiększonych wymagań energetycznych z powodu dłuższego okresu eksploracji. Symulacje udowodniły skuteczność całej naszej strategii uczenia się, ponieważ istnieje duże prawdopodobieństwo, że robot będzie mógł poruszać się autonomicznie w nieznanym środowisku.

Ta rozprawa koncentruje się na umożliwieniu robotom MR inteligentnego zdobywania wiedzy i dostosowywania się do dynamicznych środowisk. W tej rozprawie przedstawiliśmy podejście uczenia się robotów, które wykorzystuje oparte na sieciach neuronowych modele Q-learning do samodzielnego uczenia się podczas inteligentnej nawigacji w różnych scenariuszach. Inteligentny robot musi mieć możliwość zdobywania wiedzy, aby podejmować decyzje pomimo braku demonstracji. Interakcja ze środowiskiem zadania to umożliwia. W tej rozprawie przedstawiliśmy podejście Q-learning, wykorzystując sieci neuronowe oparte na tych założeniach. Poprawiliśmy jakość metody Q-learning, dodając tę reprezentację, ponieważ wykazaliśmy, że ANN może służyć jako odpowiednia formuła polityki.

Proponowana technika uczenia się robotów wykorzystuje algorytmy bezmodelowe, które są lepiej dostosowane do praktycznego zastosowania, ponieważ trudno jest zbudować model nowego środowiska. Zalecane podejście w tej rozprawie wykorzystuje stosunkowo prosty, ale wydajny system symulacyjny, który wykazuje szybką i wydajną szybkość uczenia się, oprócz możliwości wysyłania modeli do prawdziwych robotów. Podejście do nawigacji termicznej oparte na kamerach podczerwonych zostało szeroko omówione w tej rozprawie. Techniki nawigacji termicznej mogą pomóc w nawigacji samochodów, robotów mobilnych i ruchu osób niedowidzących. Technika nawigacji termicznej jest szeroko opisana. Na koniec porównawczo przeanalizowaliśmy związek między RL a innymi strategiami nawigacyjnymi, w tym PSO i nawigacją termiczną.

5. Wykaz publikacji i osiągnięć autora

- JCR artykuły

1. **R. Raj**, and A. Kos, “An improved human activity recognition technique based on convolutional neural network,” *Scientific Reports*, vol. 13, pp. 22581, Dec. 2023. <https://doi.org/10.1038/s41598-023-49739-1> (Published), (Q1-Scopus), [Ministry Point-140].
 2. **R. Raj**, and A. Kos, “Intelligent Mobile Robot Navigation in Unknown and Complex Environment Using Reinforcement Learning Technique,” *Scientific Reports*, vol. 14, pp. 22852, Oct. 2024. <https://doi.org/10.1038/s41598-024-72857-3>, (Q1-Scopus), [Ministry Point-140].
 3. **R. Raj** and A. Kos, “A Comprehensive Study of Mobile Robot: History, Developments, Applications, and Future Research Perspectives,” *Applied Sciences*, vol. 12, no. 14, p. 6951, Jul. 2022. <https://doi.org/10.3390/app12146951>, (Published), (Q1-Scopus), [Ministry Point-100].
 4. **R. Raj** and A. Kos, “An Optimized Energy and Time Constraints-Based Path Planning for the Navigation of Mobile Robots Using an Intelligent Particle Swarm Optimization Technique,” *Applied Sciences*, vol. 13, no. 17, p. 9667, Aug. 2023. <https://doi.org/10.3390/app13179667>, (Published), (Q1-Scopus), [Ministry Point-100].
 5. **R. Raj** and A. Kos, “Study of Human–Robot Interactions for Assistive Robots Using Machine Learning and Sensor Fusion Technologies,” *Electronics*, vol. 13, no. 16, p. 3285, Aug. 2024. <https://doi.org/10.3390/electronics13163285>, (Published), (Q2-Scopus), [Ministry Point-100].
 6. **R. Raj** and A. Kos, “Discussion on different controllers used for the navigation of mobile robot,” *International Journal of Electronics and Telecommunications*, vol. 70, no. 1, pp. 229-239, March 2024. <https://doi.org/10.24425/ijet.2024.149535>, (Published), (Q3-Scopus), [Ministry Point-70].
 7. **R. Raj**, and A. Kos, “Artificial Intelligence: Evolution, Developments, Applications, and Future Scope,” *Przegląd Elektrotechniczny*, vol. 2023, no. 2, pp. 1–13, Feb. 2023. <https://doi.org/10.15199/48.2023.02.01>, (Published), (Q4-Scopus), [Ministry Point-70].
 8. **R. Raj**, and A. Kos, “Study and Analysis of Discrete Event-Driven Autonomous System with a Case Study for a Robotics Task,” *Przegląd Elektrotechniczny*, vol. 2023, no. 9, pp. 50-56, Feb. 2023. <https://doi.org/10.15199/48.2023.02.01>, (Published), (Q4-Scopus), [Ministry Point-70].
 9. **R. Raj**, and A. Kos, “A Novel Method of Islanding Detection in a Distributed Power Generation System Integrated with Photovoltaic-Array,” *Przegląd Elektrotechniczny*, vol. 2022, no. 7, pp. 88–94, July 2022. <https://doi.org/10.15199/48.2022.07.15>, (Published), (Q4-Scopus), [Ministry Point-70].
-

• Nie- JCR artykuły

10. **R. Raj** and A. Kos, "Dynamic Obstacle Avoidance Technique for Mobile Robot Navigation Using Deep Reinforcement Learning," *International Journal of Emerging Trends in Engineering Research*, vol. 11, no. 9, pp. 307–314, Sep. 2023. <https://doi.org/10.30534/ijeter/2023/031192023>, (Published), [Ministry Point-20].
11. **R. Raj**, and A. Kos, "Designing and Analysis of an Architecture of Motion Control for a Mobile Robot Using Simulation," *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 12, no. 4, pp. 172–177, Aug. 2023. <https://doi.org/10.30534/ijatcse/2023/051242023>, (Published), [Ministry Point-20].
12. **R. Raj**, and A. Kos, "Recognition of Hindi Character Using OCR-Technology: A Review," *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 12, no. 4, pp. 196–201, Aug. 2023. <https://doi.org/10.30534/ijatcse/2023/071242023>, (Published), [Ministry Point-20].
13. R. Jakhar, and **R. Raj**, "A Review on the Impacts of Climate Change on the Power Systems," *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, vol. 12, no. 6, pp. 56-61, May 2023. <https://doi.org/10.35940/ijitee.F9572.0512623>, (Published), [Ministry Point-20].

• Lista artykułów w materiałach konferencyjnych

14. **R. Raj** and A. Kos, "A Comprehensive Study of Optical Character Recognition," *2022 29th International Conference on Mixed Design of Integrated Circuits and System (MIXDES)*, Wroclaw, Poland, 2022, pp. 151-154. <https://doi.org/10.23919/MIXDES55591.2022.9837974>, (Published), [Ministry Point-80].
 15. **R. Raj** and A. Kos, "Different Techniques for Human Activity Recognition," *2022 29th International Conference on Mixed Design of Integrated Circuits and System (MIXDES)*, Wroclaw, Poland, 2022, pp. 171-176. <https://doi.org/10.23919/MIXDES55591.2022.9838050>, (Published), [Ministry Point-80].
 16. **R. Raj** and A. Kos, "Learning the Dynamics of Human Patterns for Autonomous Navigation," *2024 IEEE 18th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG)*, Gdynia, Poland, 2024. <https://doi.org/10.1109/CPE-POWERENG60842.2024.10604363>, (Published), [Ministry Point-20].
-