

Streszczenie

Współczesne linie produkcyjne cechują się skomplikowanymi procesami przemysłowymi, które są spowodowane produkcją coraz to bardziej złożonych produktów. Dodatkowo coraz częściej wymaga się od linii produkcyjnych elastyczności, co oznacza, że muszą one być zdolne szybko adaptować się do zmieniających się warunków produkcyjnych. Sytuacja ta jest najbardziej widoczna w przypadku procesów montażu, gdzie złożoność procesu jest związana z koniecznością precyzyjnego pozycjonowania i łączenia różnych elementów. Obecnie coraz częściej stosuje się stanowiska zautomatyzowane, bazujące na robotach przemysłowych, jednak tak wyposażone linie produkcyjne są często niezdolne do szybkiego dostosowania się do montażu często zmieniających się produktów. Dodatkowo tradycyjne metody sterowania robotami (m.in. ręczna definicja trajektorii) często są niewystarczające w przypadku elastycznych linii produkcyjnych. Natomiast uzbrojenie stanowisk montażowych w zaawansowane czujniki, czy też systemy do zmiany narzędzi znacząco podnosi koszty stworzenia i konserwacji linii produkcyjnej. W związku z tym w ostatnich latach coraz większą popularność zdobywają metody oparte na algorytmach wykorzystujących sztuczną inteligencję, a w szczególności uczenie ze wzmocnieniem (ang. *Reinforcement Learning* (RL)).

Celem prezentowanych badań było uzyskanie metody bazującej na uczeniu ze wzmocnieniem, która pozwoli na efektywne rozwiązanie problemu montażu różnorodnych elementów na jednej linii produkcyjnej. W ramach przeprowadzonych badań stworzono wydajną procedurę uczenia agenta RL na rzeczywistym robocie przemysłowym, a także opracowano algorytm *Multimodal Variational DeepMDP* (MVDeepMDP). Algorytm ten pozwolił na szybką adaptację wstępnie wytrenowanego agenta RL do nowych produktów na liniach produkcyjnych. MVDeepMDP łączy algorytm Soft Actor-Critic (SAC), z rodziny algorytmów *off-policy actor-critic*, z multimodalnym wariacyjnym autoenkoderem. Zaproponowana metoda charakteryzuje się uczeniem wielomodalnej reprezentacji dynamiki środowiska, dzięki której agent RL uzyskuje istotne informacje o wykonywanym zadaniu. Dodatkowo wspomniana metodologia charakteryzuje się asynchronicznym procesem zbierania danych w stosunku do procesu uczenia, co znacząco usprawnia interakcję agenta RL ze środowiskiem. Co więcej, ramię robota sterowane jest admitancyjnie, dzięki czemu proces uczenia jest bezpieczny i płynny.



Proponowana metoda została przetestowana na problemie montażu elementów elektronicznych do odpowiednich miejsc na płycie drukowanej. Zadanie montażu elektronicznego stanowiło doskonałe środowisko do oceny ogólnej wydajności proponowanego rozwiązania oraz możliwości jego generalizacji, ze względu na różnorodność i złożoność elementów. Wstępne eksperymenty zakładały ewaluację proponowanej metodologii z wykorzystaniem algorytmu SAC. Analiza uzyskanych wyników sugerowała, że przedstawiona metodologia osiągnęła znacznie wyższe wskaźniki jakości niż powszechne techniki montażu. W następnej kolejności wykonano serię eksperymentów, których celem było sprawdzenie możliwości szybkiej adaptacji MVDeepMDP do nowych montowanych produktów. Wykazano, że metoda ta w większości przypadków jest w stanie montować nowe elementy bez konieczności dodatkowego trenowania. W pozostałych przypadkach, w których błyskawiczne przeniesienie nie powiodło się, douczenie trwało maksymalnie 5 minut.

Podsumowując, zaprezentowane rozwiązanie pozwala na szybkie dostosowanie się zrobotyzowanego stanowiska montażowego do ciągle zmieniających się produktów w elastycznym środowisku produkcyjnym. Funkcjonalność ta jest pożądana z punktu widzenia współczesnych standardów produkcyjnych, co sprawia, że potencjalnie może zastąpić powszechnie stosowane rozwiązania.

02.12.2024

Gregorz Bolger

Abstract

Modern production lines are characterized by a complex industrial process, driven by the demand for increasingly complex products. As a result, there is a growing need for flexibility, which requires these lines to quickly adapt to changing production conditions. This demand is especially evident in assembly processes, where the complexity comes from the need for precise positioning and integration of various components. Although automated stations using industrial robots are becoming more common, they face challenges in quickly adapting to the assembly of different products. Traditional robot control methods, such as following manually programmed trajectories, often fall short in flexible production lines. Furthermore, equipping robotic assembly cells with advanced sensors or tool-changing systems significantly increases the costs of developing and maintaining a production line. As a result, there has been a growing interest in methods based on algorithms using artificial intelligence, particularly reinforcement learning (RL), in recent years.

The aim of the presented dissertation was to develop an RL-based method to effectively assemble various elements on a single production line. Research involved developing an efficient framework to train an RL agent using a real industrial robot and introducing a novel algorithm called *Multimodal Variational DeepMDP* (MVDeepMDP). This algorithm allowed for a quick adaptation of the pre-trained RL agent to new products on production lines by combining the Soft Actor-Critic (SAC) algorithm, which belongs to the family of *off-policy actor-critic* algorithms, with a multimodal with a multimodal variational autoencoder. The proposed method focuses on learning a multimodal latent representation of the dynamics of the environment, allowing the RL agent to receive task-relevant features. Additionally, the framework is characterized by an asynchronous data collection process relative to the learning process, which improves the RL agent's interaction with the environment. Furthermore, the robot arm is controlled using the admittance control system, ensuring a safe and seamless learning process.

The proposed method was evaluated by testing its performance in inserting electronic parts into specific locations on a printed circuit board. This electronic assembly task served as an effective benchmark for assessing the overall effectiveness and generalization capability of



the proposed solution, given the diversity and complexity of the components. The initial experiments focused on evaluating the proposed framework using the SAC algorithm. Analysis of results indicated that the presented framework achieved significantly better quality metrics compared to conventional insertion techniques. Afterward, a series of experiments were performed to test the ability of MVDeepMDP to quickly adapt to newly assembled products. The results demonstrated that, in most cases, this method could perform zero-shot transfer to unseen components. In cases where zero-shot transfer failed, fine-tuning took a maximum of 5 minutes.

In summary, the presented solution allows for rapid adaptation of the robotic assembly station to constantly changing products in a flexible production environment. This functionality is desirable from the point of view of modern manufacturing standards, which makes it a potential replacement for commonly used solutions.

02.12.2024

Gregor B. J. Paul