

## **Streszczenie**

W zdecydowanej większości prac związanych z uczeniem maszynowym w systemach agentowych stosowana jest strategia uczenia ze wzmocnieniem oraz metody ewolucyjne. Jedynie niewielka liczba prac dotyczy uczenia pod nadzorem i uczenia się pojęć.

Uczenie ze wzmocnieniem to metoda pozwalająca na doskonalenie strategii działania agenta, jeśli dostępne są oceny jego działania (agent otrzymuje od środowiska liczbową ocenę jakości akcji). Algorytmy tego typu są stosunkowo proste, ale uczą się dosyć wolno i bez skomplikowanych rozszerzeń trudno radzą sobie w środowiskach o dużej przestrzeni stanów (opisywanych przez dużą liczbę atrybutów). Inną wadą tego podejścia jest trudność z analizowaniem wygenerowanej wiedzy przez człowieka. Alternatywne metody – obliczenia ewolucyjne, które polegają na generowaniu wielu pokoleń coraz lepszych agentów – mają tę wadę, że do działania potrzebna jest cała populacja i podejście to nie może być wprost stosowane przez pojedynczego, autonomicznego agenta.

Biorąc pod uwagę powyższe problemy, postawiono tezę, iż *zastosowanie uczenia się pojęć z symboliczną reprezentacją wiedzy może być z powodzeniem stosowane do bardziej efektywnego uczenia strategii agentów.*

W pierwszej części pracy zawarto przegląd najważniejszych wyników badań z obszaru systemów agentowych w kontekście uczenia maszynowego. Na tym tle zaprezentowano koncepcję zastosowania uczenia się pojęć do generowania strategii agentów. Podejście to pozwala na szybszą poprawę efektywności agentów i stwarza możliwość analizy wygenerowanej wiedzy przez człowieka. Następnie zaproponowano rozwiązanie integrujące uczenie się pojęć i wnioskowanie. Dzięki temu do sterowania działaniem agenta można użyć jednego algorytmu wnioskowania, który uruchomi proces uczenia, gdy zaistnieje taka potrzeba. Omówiono także algorytmy konwersji wiedzy probabilistycznej do reguł oraz wizualizację graficzną reguł. Opracowane rozwiązania sprawdzono, wykonując serię eksperymentów. Monografię kończą konkluzje i podsumowanie najistotniejszych elementów pracy. Wskazano również kierunki przyszłych badań nad rozwojem i zastosowaniami proponowanych koncepcji.

## **Abstract**

Reinforcement learning and evolutionary methods are the most common techniques used in agent-based systems to learn strategies. Only a small number of works consider application of supervised learning and concept learning.

Reinforcement learning is a method that allows to improve the agent strategy using feedback from the environment after agent's action execution. The feedback is a scalar value, which represents a quality of the action. Algorithms of this type are simple, but process of learning is relatively slow and without complicated extensions it is difficult to learn in environments having large state space (which are described by a large number of attributes or by attributes with large domains). Another disadvantage of this approach is the difficulty of analyzing the generated knowledge by humans. Another method – evolutionary computations relays on the processing of many agent generations improving its performance in subsequent iterations. Necessity of maintaining many populations of agents makes it difficult to use this approach directly by a single, autonomous agent to generate its strategy.

Given these observations, the main thesis of this monograph is that *the concept learning with a symbolic knowledge representation can be successfully applied by agents to generate strategy effectively.*

In the first part of the monograph an overview of the most important research results in the area of agent-based systems in the context of machine learning are provided. Against this background, the idea of concept learning application to generate agent strategy is presented. This approach allows for more rapid improvement of agent's efficiency and makes it possible to analyze the generated knowledge by humans. Then, integration method of concept learning and reasoning is proposed. This allows to control the agent in a homogeneous way: a single inference algorithm is used to process agent's knowledge to chose an appropriate action, and a learning algorithm is applied automatically when the need arises. Next, algorithms converting probabilistic models into rules are presented, and a method for graphical visualization of rules is described. Solutions proposed are verified by performing a series of experiments. The monograph ends with concluding remarks summarizing the results and the outline of the most important contributions. Finally, directions for future research are given.