

Deep Reinforcement Learning for algorithmic trading strategies in Finance

Das Ziel eines jeden Anlegers oder Händlers ist es, eine relevante Kennzahl des Handelsergebnisses wie Gewinn oder Rendite zu optimieren. Während der Aktienhandel als Anlageform an Popularität gewonnen hat, stellen das komplizierte Umfeld und die Kosten des Handels die Anleger vor viele Herausforderungen. Mit dem jüngsten Fortschritt in der Entwicklung adaptiver Systeme bietet Reinforcement Learning einen Rahmen, der diese Herausforderungen bewältigen und die Märkte nutzen kann, mit dem Ziel, konstante Gewinne zu erzielen und gleichzeitig das Risiko zu reduzieren.

In dieser Arbeit diskutieren wir die Anwendung von Deep Reinforcement Learning im Aktienhandel und untersuchen mögliche Strategien zur Maximierung der Anlagerendite. Zu Beginn behandeln wir unsere vorgeschlagene Methode zur Modellierung der Marktdynamik. Weiter stellen wir einen verbesserten Q-Learning-Algorithmus vor, der sowohl für den Handel mit einem einzelnen Wertpapier als auch mit Portfolios entwickelt wurde.

Reinforcement Learning beschäftigt sich mit dem Problem der Zuordnung von Situationen zu Handlungen, um ein numerisches Belohnungs-signal zu maximieren. Dem Agenten wird nicht vorgegeben, welche Massnahmen er ergreifen soll. Er muss durch einen eigenen Lernprozess herausfinden, welche Massnahmen den grössten Nutzen bringen. Im Fall von Aktienmärkten können diese Massnahmen nicht nur die unmittelbare Belohnung, sondern auch alle nachfolgenden Belohnungen beeinflussen. Diese beiden Merkmale, Optimierung durch trial-and-error sowie verzögerte Belohnung, sind die wichtigsten Merkmale von Reinforcement Learning.

Im Rahmen unseres Ansatzes wählen wir eine Teilmenge der beliebtesten internationalen Futures-Kontrakte aus und kombinieren sie zu Portfolios, um einen Vergleich verschiedener Branchen zu ermöglichen. Als Handelswerte werden Portfolios mit 33 Futures ausgewählt, deren Tageskurse, Trends und Handelsvolumen als Trainings- und Handelsumgebung verwendet werden. Als Lernarchitektur erweitern wir den hoch-modernen Q-Learning-Algorithmus, um ein Double Deep Q Network (DDQN) zu trainieren und seine Leistung in Bezug auf Sharpe Ratio und kumulierte Renditen zu bewerten.

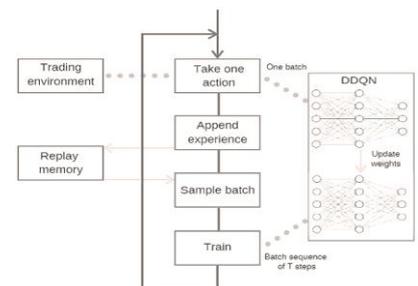


Diplomierende

Silas Rudolf
Daniel Wittwer

Dozent

Jörg Osterrieder



Diese Abbildung visualisiert den kompletten Trainingsprozess eines Double Deep Q-Learning-Netzwerks.



In dieser Abbildung wird die kumulierte Performance über alle Portfolios dargestellt und die Performance von Single- und Double-DQN mit der ausgewählten Baseline verglichen.