

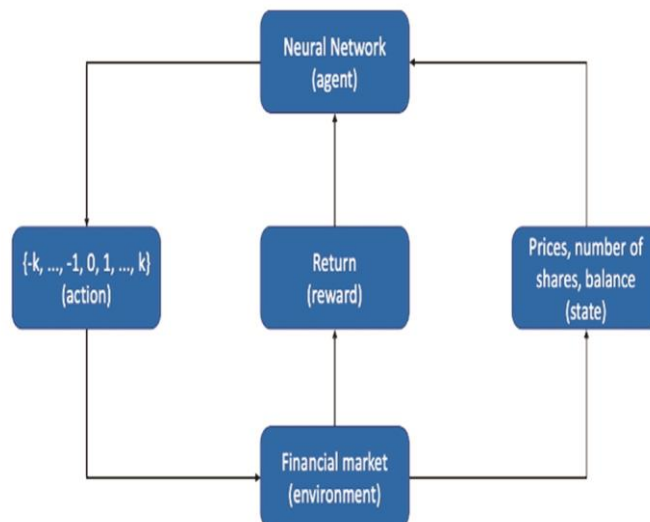
Reinforcement learning trading strategies

Gibt es einen Informationsgewinn durch das Training eines Deep-Reinforcement-Learning-Agenten für den automatisierten Aktienhandel mit anderen Zeitreihen als der zu handelnden? In dieser Arbeit implementieren wir einen DRL-Algorithmus und lernen ihn mit 21 globalen Multi-Assets, um den S&P 500 vorherzusagen und zu handeln. Die Markteffizienzhypothese besagt, dass es unmöglich ist, mehr Informationen aus dem breiteren Input zu gewinnen. Wir lernen einen DRL-Agenten auf diesen Index mit und ohne die zusätzlichen Informationen dieser verschiedenen Multi-Assets, um festzustellen, ob der Agent unsichtbare Abhängigkeiten erfassen kann, um am Ende einen Informationsgewinn und eine bessere Performance zu erzielen. Um mit den Unsicherheiten der neuronalen Netze umzugehen, haben wir 100 Agenten für jedes Szenario gelernt und beide Ergebnisse verglichen. Weder die Sharpe-Ratios noch die kumulativen Returns sind bei dem komplexeren Ansatz mit den zusätzlichen Informationen der Multi-Assets besser, der einfache Ansatz schnitt sogar marginal besser ab. Wir zeigen aber, dass der komplex gelernte Agent weniger Streuung über die 100 Simulationen in Bezug auf die risikobereinigten Renditen liefert, also gibt es einen Informationsgewinn durch Multi-Assets. Ein mit zusätzlichen Informationen gelernter DRL-Agent liefert robustere Ergebnisse im Vergleich zum eingegangenen Risiko.



Diplomierende
Jetmir Beqiraj
Leander Odermatt

Dozent
Jörg Osterrieder



Die Abbildung stellt dar, wie der DRL-Agent mit der Umgebung interagiert. Bei jedem Zeitschritt erhält der Agent von der Umgebung einen neuen Zustand und einen Reward für die vergangene Aktion. Der Agent speichert diese Rückmeldung und trifft auf Basis dieser Erfahrung eine weitere Handelsentscheidung. Der Agent lernt durch Versuch und Irrtum, um die Gesamtbelohnung zu maximieren.