

## Kurzfassung

*Multiagenten Reinforcement Learning* erweitert das klassische *Reinforcement Learning* auf Multiagenten Umgebungen. *Reinforcement Learning* erlaubt es, Agenten auf Basis von Belohnung und Bestrafung zu programmieren, ohne zu spezifizieren, wie die Aufgabe erledigt werden soll. Die Interaktion zwischen den Agenten und der Umgebung wird beim *Multiagenten Reinforcement Learning* formal als *discounted stochastic Game* angegeben. Die Aufgabe, die die Agenten zu Lösen haben, wird als Problem formalisiert ein Nash-Gleichgewicht zu finden.

Diese Arbeit widmet sich der Entwicklung von Algorithmen für das *Multiagenten Reinforcement Learning*. Wir präsentieren einen Algorithmus, der für viele *general-sum discounted stochastic Games* einem Nash-Gleichgewicht konvergiert. Der Ansatz basiert auf der Generalisierung von Replikatordynamiken bei *discounted stochastic Games*. Bisher gab es keinen Algorithmus, der zu einem Nash-Gleichgewicht für *general-sum discounted stochastic Games* konvergiert (nur für ganz spezielle Fälle). Der Ansatz übertrifft auch die Methoden zum Lösen von *general-sum discounted stochastic Games*, nämlich nichtlineare Optimierung und Tracingverfahren. Diese Algorithmen treffen die Annahme, dass die Spiele von Beginn an bekannt sind, was beim *Reinforcement Learning* nicht der Fall ist, da die Aufgabe eines Agenten das Erlernen optimalen Verhaltens in unbekannten Umgebungen ist. Ein weiterer Beitrag ist ein Algorithmus, der immer zu stationären Strategien konvergiert und zu Strategien, die immer die beste Antwort gegenüber stationären Gegnern liefern. Anders als im ersten Ansatz, setzt dieser Algorithmus nicht voraus, dass die Belohnungen des Gegners beobachtbar sind. Wir legen zudem die theoretischen Grundlagen für die Konvergenz der in dieser Arbeit vorgestellten Algorithmen.

Mögliche Anwendungsgebiete schließen traditionelle *Reinforcement Learning* Aufgaben in Multiagenten Umgebungen, wie Roboterfußball, ein, sowie die Entwicklung von Händleragenten nebst einer Vielzahl ökonomischer Probleme, wie einer Regel, die als differentielles Spiel im Umfeld von Kapitalbildung, Werbung, Kalkulation, Makroökonomie, Kriegsführung und Ressourcenökonomie modelliert wird. Wir schlagen vor, diese differentiellen Spiele durch *stochastic Games* zu approximieren und die vorgeschlagenen Lösungsverfahren einzusetzen.