

Ansprechpartner:

Beginn: ab sofort möglich

Dauer: 6 Monate



Pol Jané, M. Sc.

IRS, Raum 107
0721/608-43236
pol.jane@kit.edu



Armin Gießler, M. Sc.

IRS, Raum 202
0721/608-43179
armin.giessler@kit.edu

anwendungsorientiert

theorieorientiert

Ihre Interessen:

Passivität

Optimierung

Identifikation

Regler-/Beobachterentwurf

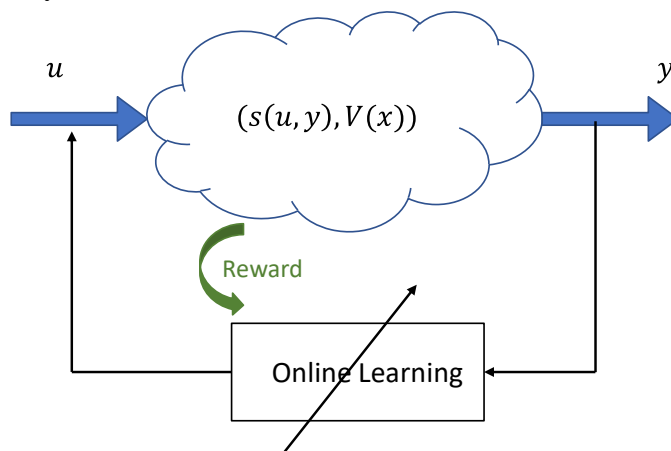


Masterarbeit

Passivity-based Reinforcement Learning

Motivation:

Viele Systeme in der Praxis bestehen aus einer Vielzahl von kleinen, gekoppelten Teilsystemen. Beispiele dafür sind erneuerbare Energiesysteme, die aus mehreren Microgrids mit lokaler Einspeisung bestehen, oder auch Multi-Roboter-Systeme oder Fertigungsanlagen. Die einzelnen Teilsysteme (Agenten) haben dabei egoistische Ziele, z. B. möglichst wenig Energie zu benutzen oder möglichst schnell Störungen auszuregulieren. Dabei ändern sich die Gesamtsysteme ständig; Teilsysteme kommen dazu oder verlassen das Gesamtsystem. In so einem Szenario erscheint es



sinnvoll, dass die einzelnen Teilsysteme lernen, wie sie möglichst gut ihren Gütemaß minimieren. Um Stabilität solcher vernetzte Systeme zu garantieren, existieren heutzutage kaum Ansätze¹. Eine mögliche Lösung dazu bieten neuartige Ansätze der Passivitätstheorie. Die Kopplung zweier Systeme ist immer stabil, wenn beide passiv sind. Zur Beurteilung des Stabilitätsverhaltens muss das Gesamtsystem nicht aufgestellt werden.

Aufgabenstellung:

Ziel der Arbeit ist der Entwurf von Reinforcement-Learning Regler¹, mit denen Teilsysteme lernen können, wie sie sich unter wechselhaften Bedingungen eines vernetzten Gesamtsystems optimal regeln. Diese sollen während des Regelungsprozesses selbständig lernen, mit welchen Regeleingriffen ihr Gütemaß minimiert werden kann. Es fällt also in die Klasse der Online-Regler. Die zentrale Fragestellung der Arbeit ist, wie der Learning-Prozess aussehen muss, damit ein Teilsystem passiv bzgl. dem Ein- und Ausgang bleibt. Passivität bei lernenden vernetzten Systemen ist noch ein unerforschtes aber vielversprechendes Gebiet was das Potential hat, Reinforcement Learning und Regelungstechnik im Punkto Stabilität zu vereinen. Die Methoden sollen am Ende an akademischen Beispielen der Energiewelt verifiziert werden.

¹ [L. Buşoniu et al. Reinforcement learning for control: Performance, stability, and deep approximators. Annual Reviews in Control, 2018](#)