



**Diplomand** Brun Joshua  
**Dozent** Prof. Dr. Müller Ulf Christian  
**Projektpartner** Institut IME, CC Fluidmechanik und numerische Methoden  
**Experte** Dr. Schlienger Joel  
**Themengebiet** Energie, Fluide und Prozesse

## Model-Based Reinforcement Learning mit dynamischen Systemmodellen

### Ausgangslage

Das Kompetenzzentrum für Fluidmechanik und numerische Methoden (FNUM) beschäftigt sich mit der dynamischen Modellierung von thermofluidodynamischen Anwendungen. Dazu wird die gleichungsbasierte und objektorientierte Programmiersprache Modelica verwendet. Mit dieser können physikalische Systemmodelle virtuell simuliert werden. Im Zuge der Bachelorarbeit soll ein Python-Programm geschrieben werden, welches in der Lage ist, die Regelung eines Modelica-Systemmodells selbstständig mit einem Model-Based Reinforcement Learning Algorithmus zu erlernen.

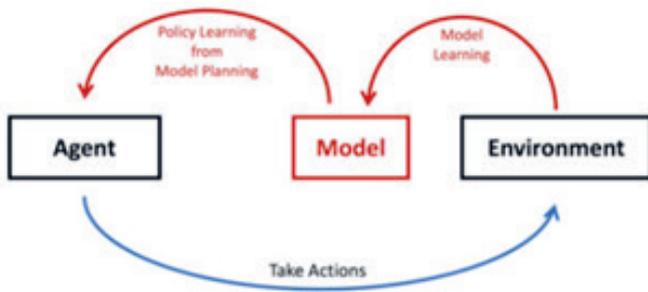


Abb. 1: Aufbau eines Model-Based Reinforcement Learning Algorithmus nach Dyna-Architektur

### Vorgehen

Nach einem ersten Versuch, ein Model-Based Reinforcement Learning Algorithmen anzuwenden, soll mithilfe einer Toolchain ein identischer Algorithmus zum Erlernen der Regelung eines simpleren Modelica Systemmodells verwendet werden. Folgend wird dies auch für einen Showcase mit dem Modelicamodell eines Doppelpendels gemacht. Da dies bereits mit anderen Algorithmen gemacht wurde, können anschliessend die beiden Ansätze Model-Based Reinforcement Learning und Model-Free Reinforcement Learning miteinander verglichen werden, um so zu eruieren, welcher Typ Algorithmus wann am besten eingesetzt wird.

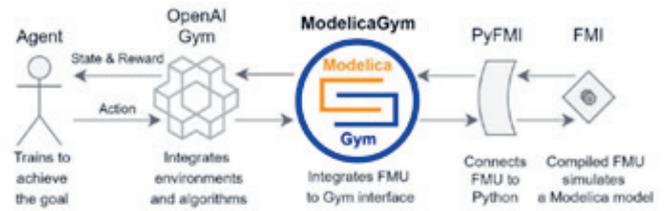


Abb. 2: Toolchain von der Modelicasimulation bis zum Model-Based Reinforcement Learning Algorithmus

### Ergebnis

Im Showcase musste der Algorithmus ein Doppelpendel durch Aufbringen eines Drehmoments so balancieren, dass es aufrecht steht. Ein Model-Based Reinforcement Learning Algorithmus ist dateneffizienter als ein Model-Free Reinforcement Learning Algorithmus. Dies führt zu einem schnelleren Lernerfolg in der Trainingsphase. Ein Model-Based Reinforcement Learning Algorithmus benötigt also weniger Zeitschritte, um eine gute Lösung zu generieren. Der Lernerfolg dieses Algorithmus stagniert allerdings im Verlauf der Trainingsphase auf einem tieferen Niveau als das mit einem Model-Free Reinforcement Learning Algorithmus erreicht werden kann. Es gilt nun abzuwägen, worauf der Fokus gelegt wird, falls es sich um ein komplexes Environment handelt. Der Model-Based Reinforcement Learning Algorithmus hat das Potenzial, ein Problem viel schneller zu lösen. Der Model-Free Reinforcement Learning Algorithmus aber kann mit einer ausführlicheren Trainingsphase eine bessere Performance erreichen.

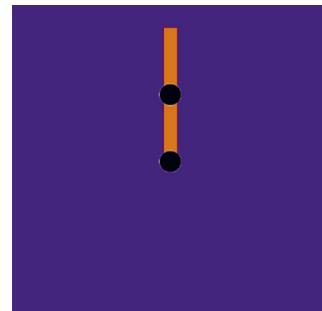


Abb. 3: Visualisierung der Zielposition aus dem Versuch mit einem Modelica-Doppelpendel