

5 Zusammenfassung

In dieser Arbeit ist ein Reinforcement Learning Agent mit Hilfe eines Simulink-Modells trainiert worden die Temperatur in einem Raum auf einen vorgegebenen Sollwert zu regeln. Um den trainierten Agent schließlich in der Realität testen zu können, wurde eine Nachbildung des Versuchsaufbaus, in welchem die Regelung verwendet werden sollte, in das Simulink-Modell eingebaut. Die Nachbildung des Versuchsaufbaus auf Basis geometrischer und materialtechnischer Informationen stellte sich dabei als aufwendig heraus. Bevor der Agent aber angewendet werden konnte, musste er erst einmal erstellt und angepasst werden. Dies umfasste die Entscheidung über den Agent-Typ sowie das Anpassen der verwendeten Künstlichen Neuronalen Netze, der Hyperparameter sowie der Belohnungsfunktion. Dies wurde manuell angegangen, wodurch beobachtet werden konnte, wie sich Veränderungen auf die Performance des Agents auswirken. Interessant dabei war, dass einige Veränderungen nicht das gewünschte Ergebnis lieferten, sondern sogar häufig genau das Gegenteil bewirkten. Oft waren die Auswirkungen auf die Performance des Agents also nicht oder nur schwer nachvollziehbar. Besonders dieser Bereich lässt noch sehr viel Raum für weitere Nachforschungen offen. Es könnten andere Typen an Agents getestet werden, weitere Parameterkombinationen, andere Aufbauten der Künstlichen Neuronalen Netze und die Belohnungsfunktion könnte auch noch auf viele andere Weisen gestaltet werden. In diesen Punkten hat man nämlich nahezu komplette Freiheit in der Gestaltung, wodurch sich unendlich viele Möglichkeiten ergeben. Die Schwierigkeit zeigt sich hier also in der Suche nach den passenden Einstellungen für den konkreten Anwendungsfall. Nachdem ein geeigneter Agent hervorgegangen war, wurde simulativ getestet, ob dieser auch dann anwendbar ist, wenn die Umgebung, in welcher er agiert, von der Umgebung abweicht, für und mit welcher er trainiert worden ist. Sehr interessant dabei zu beobachten war, dass der Agent tatsächlich auch dann sehr gutes Verhalten zeigte, wenn die simulierte Umgebung abgewandelt wurde, solange die Änderung nicht zu drastisch war. Schließlich wurde noch ein Vergleich der Reinforcement Learning-Lösung zu einem regulären PI-Regler angestellt und ein Test der Strategie im realen Versuchsaufbau durchgeführt. Im Vergleich zu einem gängigen PI-Regler wurde deutlich, dass sich das Potential vor allem dann zeigt, wenn das Intervall, in welchem neue Messdaten gesendet werden, sehr groß wird. Besonders der geringere Aufwand und die höhere Genauigkeit sprachen andernfalls für den PI-Regler. Der Realversuch zum Abschluss zeigte, dass die auf Reinforcement Learning basierende Regelungsstrategie anwendbar ist. Trotz dessen, dass sich der Versuchsaufbau tatsächlich etwas anders verhielt als das erstellte Simulink-Modell, wurde in zwei Durchläufen die jeweilige Solltemperatur sehr genau erreicht. Mit den in dieser Arbeit geschaffenen Grundlagen wären weitergehend mehr Simulationen und Realversuche zu vielen verschiedenen inbegriffenen Themen interessant. Es

könnten neben anderen Agent-Typen, Künstlichen Neuronalen Netzen, Hyperparametern und Belohnungsfunktionen auch andere oder unregelmäßige Sendeintervalle, andere Umgebungen, der Einfluss von Störungen, sogar noch ganz andere Ansätze, Künstliche Intelligenz in einen Regelkreis einzubauen, betrachtet werden. Die im Rahmen dieser Arbeit erstellte Regelungsstrategie hat also noch viel Optimierungspotential, konnte aber auf jeden Fall erfolgreich eingesetzt werden.