

Anomalitätsdetektion

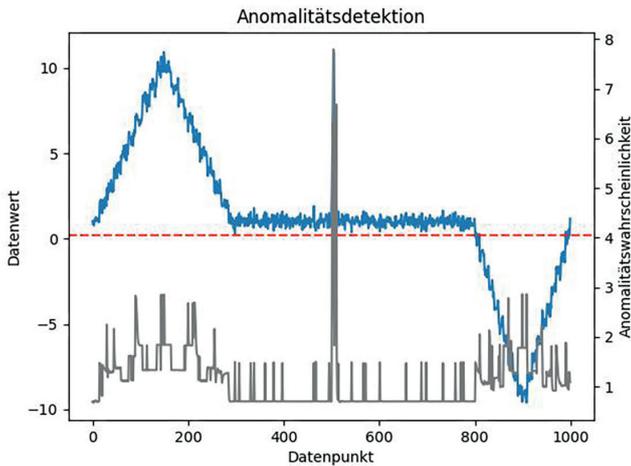


Abb. 1: Anomalitätsdetektion bei zusätzlichem Peak

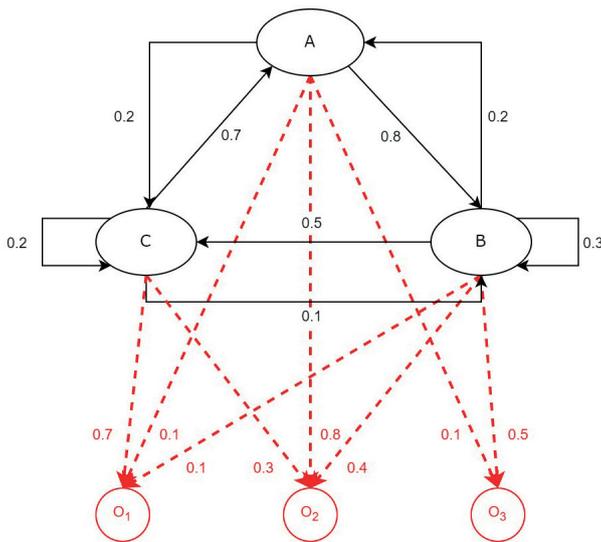


Abb. 2: Graphische Darstellung Hidden Markov Model

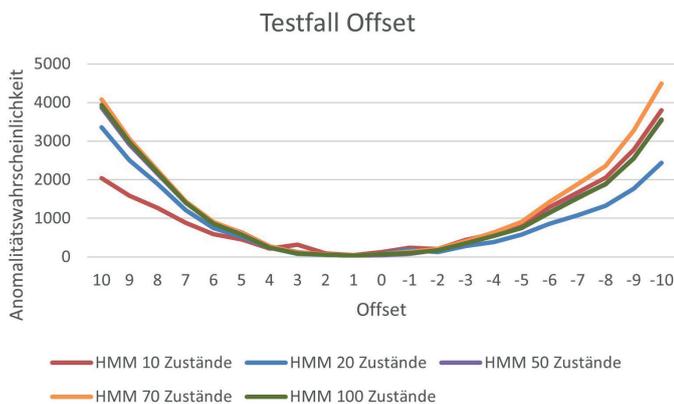


Abb. 3: Resultate für Testfall Offsetverschiebung

Problemstellung

Durch Erkennung von relativen Änderungen in Messdaten sollen Störungen in Maschinen automatisch detektiert werden können. Die Neurad GmbH ist dabei eine Anomalitätsdetektion bei einer automatischen Schiebetüre einzubauen. Dazu soll in dieser Arbeit das Hidden Markov Model geprüft werden, ob es für den gewünschten Einsatzbereich geeignet ist.

Lösungskonzept

Um diese Aufgabe zu lösen, soll zuerst das Verständnis vom Hidden Markov Model erlangt werden. Anschliessend soll eine Simulation- und Testumgebung aufgebaut werden, so dass die definierten Testfälle durchgespielt werden können. Damit die Tests gemacht werden können, braucht es einen einfachen Prototyp des Hidden Markov Modells, welches mit Bibliotheksfunktionen erstellt werden kann. Zum Schluss sollen die Resultate analysiert werden und eine Bewertung zum Hidden Markov Model erstellt werden.

Realisierung

Ein Bestandteil der Simulationsumgebung ist die Signalgenerierung. Aufgrund von zu wenig Messdaten vom realen System, wurde entschieden die Trainings- und Testdaten zu generieren. Dabei wurde als Basis der Stromverlauf vom Elektromotor bei der Schiebetüre genommen und vereinfacht. Durch die Generierung konnte ein grosses Trainingsset angelegt werden, wobei sich das Signal nur im Rauschen unterscheidet. Für die Testsignale konnte auf das Grundsignal noch die Anomalie addiert werden. Diese Datensets konnten dann verwendet werden, um das Hidden Markov Model zu trainieren und zu testen. Das Hidden Markov Model wurde mit dem Python Modul hmmlearn implementiert. So konnte einfach das Model umgesetzt werden und eine Anomalitätsdetektion erstellt werden. Mit diesen Implementierungen war es anschliessend möglich die definierten Testfälle durchzuführen und zu analysieren.

Ergebnisse

Aus den Resultaten der Testfälle geht hervor, dass einige Anomalien sehr gut erkannt werden und andere sehr stark von der Wahl der Parameter abhängt. Da das Trainieren des Modells mit grosser Datenmenge und grossen Parametern sehr viel Zeit benötigt, konnten die optimalen Parameter nicht evaluiert werden. Trotzdem wird der Einsatz des Hidden Markov Modells für diese Anwendung als möglich betrachtet, unter der Voraussetzung, dass die Parameter und somit die Anomalitätsdetektion optimiert werden können.



Diplomand
Felber Marco

Dozent
Prof. K. Schuster

Themengebiet
Nachrichtentechnik/Signal Processing,
Mechatronik/Automation/Robotik

Projektpartner
Neurad GmbH

