

4 Zusammenfassung und Ausblick

In dieser Arbeit wurde die elektrische Impedanzspektroskopie unter Zuhilfenahme von künstlichen neuronalen Netzen zur Klassifikation von Gießereisand untersucht. Es wurden neuronale Netze als Klassifikatoren trainiert und anschließend mit Hilfe von selbstorganisierenden Karten, einer Methode des unüberwachten Lernens, verbessert. Die finalen Klassifikatoren können verschiedene Sandgemische mit 100 % Genauigkeit voneinander trennen. Außerdem können verschiedene Messzeitpunkte in der Altsandregeneration mit 100 % Genauigkeit identifiziert werden.

Zunächst wurden die EIS-Daten abgeschnitten, dass sie in jedem Fall innerhalb des Messbereichs des LCR-Meters liegen. Das hat dazu geführt, dass nur die Impedanzen im Bereich von 3,8 kHz bis 1 MHz untersucht wurden.

Daraufhin wurde eine Merkmalstransformation durchgeführt, da die Übergabe der Rohdaten, also Impedanzen für einzelne Frequenzen, keine guten Ergebnisse geliefert hat. Die Datensätze wurden so übergeben, dass alle Beträge und Phasen der Impedanzen in Abhängigkeit der Frequenz als einzelne Merkmale übergeben werden. Das führt innerhalb des Messbereiches zu 220 Merkmalen für die Klassifikation. Die Merkmalstransformation war ein entscheidender Schritt zur Verbesserung der Klassifikationsergebnisse.

Im nächsten Schritt wurden mit Hilfe von unüberwachtem Lernen selbstorganisierende Karten trainiert. Die Weight Planes der SOM haben vermuten lassen, dass eine Merkmalsreduktion mit Hilfe der Eingangsgewichtsmatrix der SOM möglich ist. Aus den Informationen der Eingangsgewichtsmatrix wurden reduzierte Merkmalsräume zur Übergabe an die Klassifikatoren bestimmt und im nächsten Schritt zwei herkömmlichen Methoden zur Merkmalsreduktion (MRMR- und ReliefF-Algorithmus) gegenübergestellt.

Als Klassifikatoren wurden mehrschichtige Feedforward-Netze verwendet. Bei der Klassifikation von verschiedenen Sandgemischen wurde eine Genauigkeit von 100 % erreicht. Die Verwendung der mithilfe der SOM bestimmten Merkmalsräume hat bei gleichbleibender Genauigkeit zu einer Verbesserung der Trainingsdauer und der Klassifizierungen pro Sekunde geführt. Die mit herkömmlichen Algorithmen bestimmten Merkmale haben merkbar schlechtere Ergebnisse geliefert (MRMR: 90 % Genauigkeit, ReliefF: 81,52 % Genauigkeit) als die mit SOM bestimmten Merkmale. Die Trainingsdauer des Klassifikators konnte unter Verwendung von 5 SOM-Merkmalen gegenüber der Verwendung aller 220 Merkmale um den Faktor 7,3 reduziert und die Anzahl an Klassifizierungen pro Sekunde um den Faktor 10,5 erhöht werden.

Bei der Klassifikation verschiedener Messzeitpunkte in der Altsandregeneration wurde ebenfalls eine Genauigkeit von 100 % erreicht. Hier haben sowohl die mit den SOM als auch die mit herkömmlichen Methoden bestimmten Merkmale zu einer Verbesserung der Klassifizierungen pro Sekunde geführt. Allerdings ist das Training bei der Verwendung von 3 SOM-Merkmalen im besten Fall etwa 4 mal schneller gegenüber der Verwendung von 3 mit dem ReliefF-Algorithmus bestimmten Merkmalen und ca. 1,6 mal schneller als bei Verwendung aller Merkmale. Die Klassifikationen pro Sekunde steigen bei Verwendung von 3-SOM Merkmalen im besten Fall um den Faktor 4,4.

Abschließend wurde die Anwendung der Klassifikatoren in der Altsandregeneration geprüft. Betrachtet wurden zwei Chargen Altsand, welche über die gleiche Dauer bei unterschiedlicher Drehzahl des Schleifwerkzeuges regeneriert wurden. Dabei wurde zwischen 6 Messzeitpunkten unterschieden. Der Klassifikator wurde auf die Daten der Charge, welche bei erhöhter Drehzahl des Schleifwerkzeuges regeneriert wurde, trainiert. Anschließend wurden die Daten des letzten Messzeitpunktes (MZP 5) der langsamer regenerierten Charge übergeben. Dieser wurde, wie aus Labormessungen der Sandproben erwartet, dem MZP 2 der schneller regenerierten Charge zugeordnet. Daraus lässt sich schließen, dass es möglich ist, einen Klassifikator zu trainieren, welcher verschiedene Regenerationszustände unterscheiden und zugleich auf echte Daten angewendet werden kann.

Die elektrische Impedanzspektroskopie, in Verbindung mit künstlichen neuronalen Netzen, stellt eine Möglichkeit dar, Gießereisand zu klassifizieren. Ebenso hat die Verwendung von selbstorganisierenden Karten in diesem Anwendungsfall zu einer deutlichen Verbesserung der Klassifikatoren beigetragen. Um ein In-situ-Messsystem zu realisieren, sind weitere Untersuchungen notwendig. Eine automatisierte Messung von ausgewählten Impedanzen und die Anwendung von neuronalen Netzen auf im Feld verwendete Systeme wie speicherprogrammierbare Steuerungen oder Mikrocontrollern muss in den Regenerationsprozess integriert und anschließend evaluiert werden.