

Schätzung der Qualität von Laserschnitten aus Schnittflächenbildern

Studiengang: BSc in Elektrotechnik und Informationstechnologie | Vertiefung: Embedded Systems

Betreuer: Prof. Dr. Horst Heck

Industriepartner: Bystronic Laser AG, Niederösterreich

Beim Schneiden von Blechteilen mittels Laserschneidmaschinen arbeiten die Maschinen zunehmend völlig autonom. Es ist ein Bedürfnis, die Schneidqualität direkt während des Schneidprozesses zu überwachen. In dieser Bachelor-Thesis wurde, in Zusammenarbeit mit der Bystronic Laser AG, untersucht, wie gut sich Qualitätsmessgrößen aus Bildern der Schnittfläche schätzen lassen.

Ausgangslage und Ziele

Zum Schätzen der Qualitätsmessgrößen sollen neuronale Netze verwendet werden, welche mittels Deep Learning anhand von Bildern der Schnittfläche trainiert werden. Dies bietet den Vorteil, dass das Feature Engineering automatisiert wird und die Netzwerke für verschiedene Materialien und Materialdicken trainiert werden können. Die Datensets zum Trainieren der Netzwerke wurde von der Bystronic zur Verfügung gestellt. Diese beinhalten mehrere tausend hochaufgelöste Bilder von Schnittflächen, welche mit einem optischen Messgerät genau vermessen wurden. Ziel ist es, die Qualitätsmessgrößen Rauheit und Grat zu schätzen und den Einfluss der Bildauflösung auf die Schätzung zu untersuchen.

Umsetzung

Damit das Training der Netzwerke möglichst automatisiert werden kann, wurde zuerst eine Pipeline erstellt. Mit dieser können die Bilder vorverarbeitet und mehrere Netzwerke nacheinander in einer Trainingsloop trainiert und getestet werden. Für das Training wurden die Netzwerk-Architekturen VGG16, Inceptionv3 und ResNet101 verwendet. Da die Netzwerke einen kontinuierlichen Wert schätzen sollen, wurde der Klassifikator der Netzwerke durch einen Regressor ersetzt. Die Netzwerke wurden von Grund auf, wie auch mittels Transferlearning trainiert. Für


das Transferlearning wurden Netzwerke verwendet, welche auf dem ImageNet-Datenset vortrainiert wurden. Beim Transferlearning werden die bereits gelernten Features übernommen und auf die neuen Daten angewendet. Anschliessend wird nur noch der Regressor trainiert, der anhand der gefundenen Features versucht, die Messgrösse zu schätzen.

Fazit

Die Netzwerke konnten trainiert und getestet werden und es wurden gute Hyperparameter gefunden. Die Netzwerke können die Rauheit und Grathöhe bei prozessüblichen Schnitten gut schätzen. Bei Ausreissern haben die Netzwerke allerdings mehr Mühe und es resultieren grössere Fehler zwischen dem geschätzten Wert und dem tatsächlichen Wert. Dies macht auch Sinn, da beim Erstellen der Datensets ein üblicher Schneidparameterraum gewählt wurde und so extreme Werte nur minimal vertreten sind. Dies bietet allerdings auch den Nachteil, dass schlechte Schnitte nicht zuverlässig erkannt werden können und so keine Anpassung der Schneidparameter während des Schneidprozesses möglich ist. Es konnte auch gezeigt werden, dass es für die Schätzung keine hochaufgelösten Bilder braucht und die Auflösung verringert werden kann. Dies ist insbesondere für eine mögliche Industrialisierung eine wichtige Erkenntnis.



Roman Beck
roman.beck@besonet.ch



Schnittflächenbilder unterschiedlicher Materialien und Qualität