

## Bewertung von Schweissnahtschliffbildern mittels Deep Learning

### Diplomand



Pascal Dietsche

**Einleitung:** Die Herstellung von Präzisionsstahlrohren für sicherheitsrelevante Automobilbauteile erfordert hochpräzise Schweissverfahren, um die geforderte Lebensdauer der Produkte sicherzustellen. Bei Mubea in Arbon werden diese Rohre aus hochfesten Materialien wie 34MnB5 und 26MnB5 mittels induktivem Schweißen gefertigt. Die Qualität der Schweissnähte ist hierbei von entscheidender Bedeutung, da Fehlstellen zu vorzeitigem Versagen führen können. Traditionell wird die Überprüfung der Schweissnähte durch zeitaufwändige Freigabeschliffe durchgeführt, die qualifiziertes Laborpersonal erfordern, das jedoch nicht immer im Mehrschichtbetrieb verfügbar ist.

**Aufgabenstellung:** Um eine Vereinfachung des Freigabeprozesses zu erreichen, untersucht diese Studie die Machbarkeit einer automatisierten Erkennung von Schweissfehlern wie Schweissnahttrichtern und einfallenden Stauchlinien sowie die Messung des Stauchlinienwinkels mittels Deep Learning.

**Ergebnis:** Es wurden drei verschiedene VGG-19 Modelle mittels supervised learning trainiert: zwei Klassifizierungsmodelle für die Erkennung von Schweissnahttrichtern und einfallenden Stauchlinien sowie ein Regressionsmodell zur Bestimmung der Stauchwinkel.

Das erste Modell wird zur Erkennung von Schweissnahttrichtern trainiert. Hierbei wurde eine Pipeline entwickelt, die automatisch die Ferritlinie und die Schliffkante detektiert. Diese Informationen werden genutzt, um das Bild zuzuschneiden und in das Modell zu laden. Das Modell erreichte dabei einen F1-Score von 0.7778 und einen Recall von 1.0. Ein Recall von 1.0 war von entscheidender Bedeutung, da alle Schweissnahttrichter erkannt werden müssen. Zudem wurde die Interpretierbarkeit des Modells mithilfe von Grad-CAM untersucht, um zu überprüfen, ob tatsächlich der Schweissnahttrichterbereich bewertet wird.

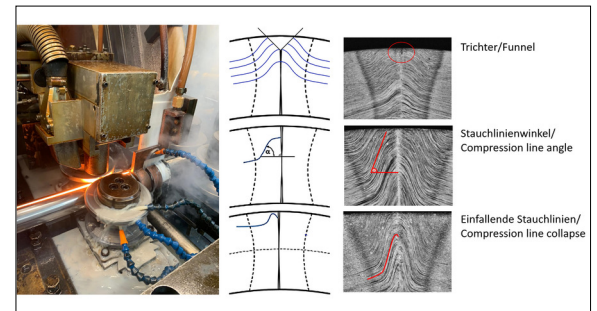
Das zweite Modell ist ein Regressionsmodell zur Bestimmung der Stauchwinkel. Die Ergebnisse zeigten, dass das Modell ein engeres 99.7 %-Konfidenzintervall von  $-4.2^\circ$  bis  $4.1^\circ$  im Vergleich zu manuellen Messungen ( $-6.4^\circ$  bis  $6.7^\circ$ ) aufweist. Anhand des Testdatensatzes konnte somit gezeigt werden, dass die Varianz des Modells um Faktor zwei kleiner ist als die manuelle Messung der Stauchwinkel mit der Keyencesoftware.

Das dritte Modell dient der Identifikation von einfallenden Stauchlinien im kritischen Bereich. Dafür wurde eine Pipeline eingesetzt, die mithilfe der automatischen Ferritlinien- und Kantenerkennung das Bild passend zuschneidet. Das Modell erreichte dabei einen F1-Score von 0.875 und einen Recall von 1.0,

was die zuverlässige Erkennung aller Stauchlinieneinfälle im kritischen Bereich bestätigt. Auch hier wurde die Interpretierbarkeit des Modells mithilfe von Grad-CAM untersucht.

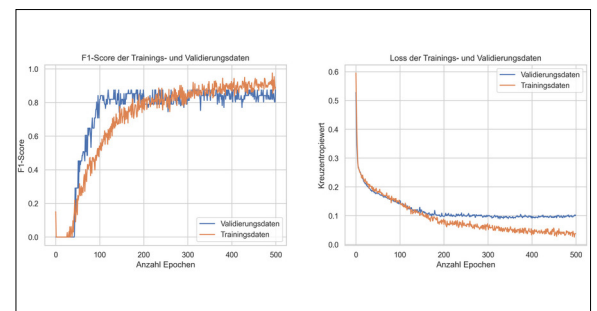
### Schweissnahtprozess inkl. Schweissnahtmerkmale im Schliff

Herberhold, D.: Schematische Darstellung Schweissnahtfehler




### Lern- und Validierungskurven des Schweissnahttrichtertrainings testset

Eigene Darstellung



### Grad-CAM der Schweissnahttrichterklassifikation: Das Modell identifiziert die relevanten Bereiche korrekt.

Eigene Darstellung



### Referent

Prof. Dr. Christoph Würsch

### Korreferent

M. Sc. Philipp Gerard Trémuel

### Themengebiet

Computational Engineering

### Projektpartner

Mubea Präzisionsstahlrohr AG, Arbon, Thurgau