

# AutoDR in der Magnetpulverprüfung

Helge RAST, Wolfram DEUTSCH – KARL DEUTSCH Prüf- und Messgerätebau GmbH + Co KG, Wuppertal

## Einleitung


Die Magnetpulverprüfung (MT) wird seit über 80 Jahren in der zerstörungsfreien Prüfung eingesetzt. Obwohl es bereits im letzten Jahrhundert Versuche gab diese zu automatisieren, wird sie auch heute noch weitestgehend manuell durchgeführt. Viele Schmieden und Gießereien weisen bereits einen sehr hohen Automatisierungsgrad in der Fertigung auf, aber die Endkontrolle erfordert bei zunehmendem Fachkräftemangel einen hohen Personaleinsatz. Gleichzeitig besteht der Wunsch den Human-Factor in der Prüfung zu reduzieren und die Prüfung durch digitale Dokumentation nachvollziehbar zu machen. So mehren sich zunehmend Anfragen bei den Prüfanlagenherstellern nach vollautomatischen MT-Systemen.

## AutoDR

Die Entwicklung neuronaler Netzwerke zeigt einen vielversprechenden Weg, um die automatisierte Erkennung von Anzeigen (ASTM E3327: AutoDR - automated defect recognition) in MT-Systemen zu realisieren. D.h. eine Software trifft die Prüfentscheidung ohne menschliche Hilfe. Für die wenigen existierenden Systeme, die es bereits gibt mussten bisher aufwendig bauteilspezifische Filter, Blenden und Masken programmiert werden. Die Prüfbereiche sind dann eingeschränkt und Bauteilwechsel oder -Änderungen nicht oder nur mit viel Aufwand möglich.

## Daten

Für die Entwicklung jedes KI-Systems basierend auf neuronalen Netzwerken sind Daten essenziell. Bei der Magnetpulverprüfung stellt dies ein großes Problem dar, da aufgrund der rein analogen Arbeitsweise typischerweise keine verwertbaren Daten existieren. Diese müssen also zunächst aufwendig erzeugt werden.




## Daten-Labeling

Damit das neuronale Netzwerk im Training lernen kann, wie Rissanzeigen aussehen, müssen diese zunächst in den Bilddaten gekennzeichnet (gelabelt) werden. Dies geschieht bei Netzwerken zur Bildsegmentierung durch manuelles Nachzeichnen der Risskonturen. So entstehen die Ground-Truth-Masken, an denen sich das neuronale Netz misst.




## Prüfmittel

Speziell für die Kamerabetrachtung entwickelte FLUXA-Prüfmittel nach DIN EN ISO 9923-2 und ASTM E 1444 sorgen dafür, dass Anzeigen besonders hell leuchten, und dennoch wenig Hintergrundfluoreszenz hervorrufen.



## Fluoreszierende Magnetpulverprüfung

- Ziel: Präparation der Prüfteile
  - kontrastreiche Rissanzeigen
- Prinzip:
  - Prüfung ferromagnetischer Werkstücke bei AC/DC-Magnetisierung
  - Streuflussbildung an oberflächennahen Rissen
    - Prüfmittel haftet nur am Streufluss
- Höchster Kontrast mit UV-Prüfmittel
  - Betrachtung unter UV-Licht  $>10W/m^2$  bei Restlicht  $<20$  Lux




## Neuronale Netzwerke

Die KI-Methode des Deep Learning verwendet neuronale Netze, die das Funktionsprinzip eines menschlichen Gehirns simulieren. Diese werden durch eine große Datenmenge trainiert, in diesem Fall mit gelabelten Bildern von Rissanzeigen. Nach dem Training ist das Netzwerk in der Lage, Rissanzeigen unabhängig von der Bauteilgeometrie oder der Rissposition am Bauteil selbst zu erkennen.



## Bilderfassung

- Die Qualität der Bilddaten ist entscheidend
- Qualitätsklasse 4 nach DIN EN 10228-1
    - Registriergrenze:  $\geq 1$  mm
  - Faustregel:
    - Erkennen: 5–10 Pixel
    - Klassifizieren: 10–20 Pixel
    - Präzise messen:  $\geq 50$  Pixel
  - KI-Erkennung möglich bei ca. 15px/mm
    - Datenbasis für Statistik gering




## Training

Das Netzwerk erhält die Trainingsbilder zusammen mit den Ground-Truth-Masken und erzeugt Segmentierungsvorhersagen, die mittels einer Verlustfunktion mit den echten Masken verglichen werden. Über viele Epochen, also vollständige Durchläufe durch den Trainingsdatensatz, werden die Gewichte mithilfe der Rückpropagation iterativ so angepasst, dass das Modell Rissanzeigen pixelgenau und zuverlässig unterscheiden lernt. Nach Abschluss des Trainings wird das Modell mit getrennten Testbildern unabhängig bewertet. Die resultierenden Leistungskennzahlen werden anschließend gemäß ASTM E3327 statistisch validiert, bevor das Modell für die automatische Segmentierung in der Anwendung eingesetzt wird.

## Anwendung - Segmentierungsinferenz

Bei der Inferenz verarbeitet das trainierte Modell neue Bilder und erzeugt daraus automatisch eine pixelweise Klassenzuordnung. Aus diesen Vorhersagen entsteht eine Segmentierungsmaske, die relevanten Anzeigen im Bild sichtbar macht. Die Ausgabe erfolgt schnell, konsistent und ohne manuelle Eingriffe.



**KARL DEUTSCH**

Kontakt

