

Photonics-Workshop: Artificial Intelligence in Photonics – 03.09.2019

# Bildverarbeitung beim Laserstrahlschweißen

---

Julia Hartung – TRUMPF Laser GmbH

# Agenda

**01** Einleitung und Motivation

---

**02** Applikation auf Kupferpins

---

**03** Applikation auf Lichtschnitt

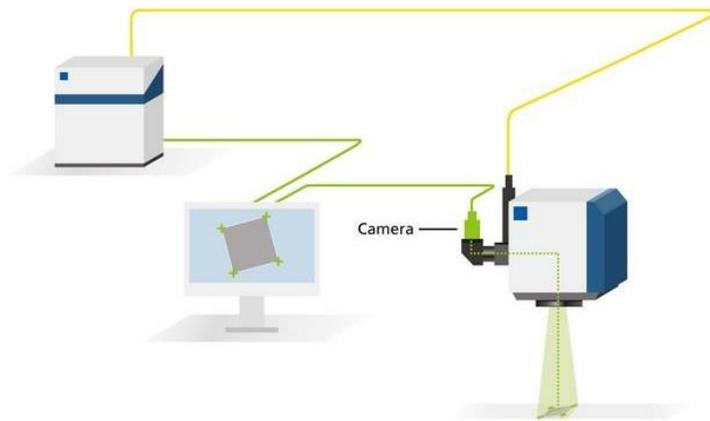
---

**04** Applikation auf Schweißmaske

---

# Einleitung

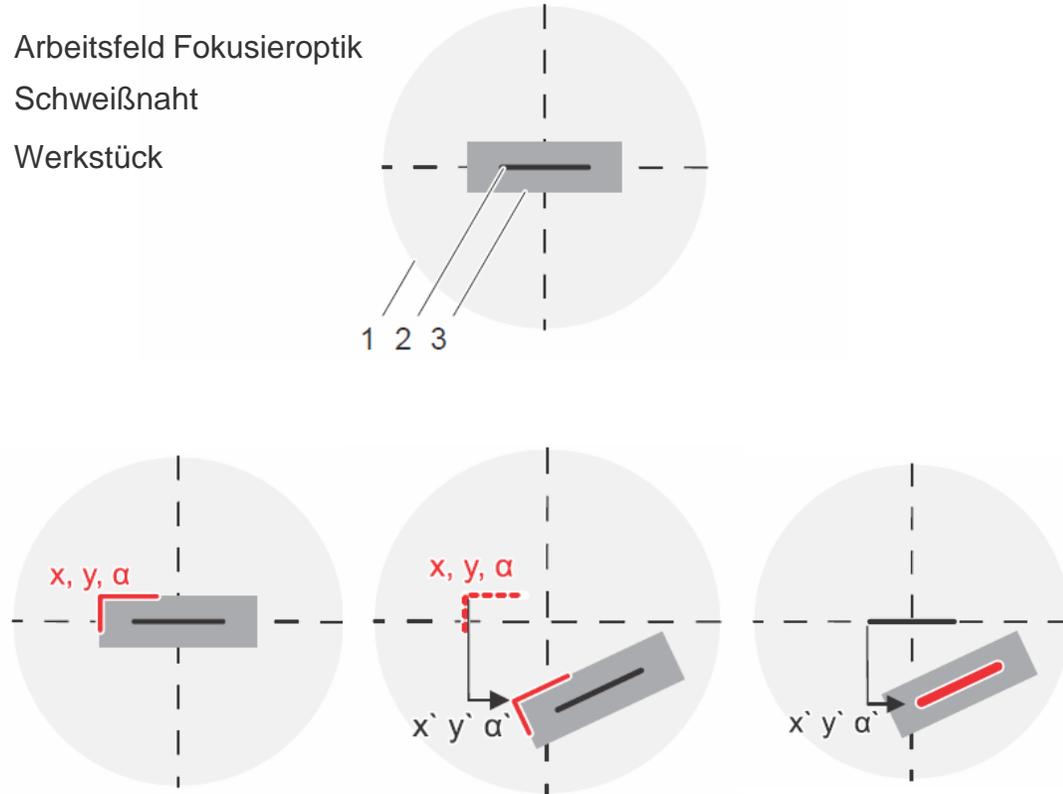
## Hardware bei Laserschweißprozessen



# Einleitung

## Bauteillagererkennung und Korrektur

1. Arbeitsfeld Fokussieroptik
2. Schweißnaht
3. Werkstück



The screenshot shows a software interface for configuring algorithms. The main window displays a live image of a weld with a yellow box highlighting a region. The interface includes a toolbar on the left, a top menu bar, and a bottom control panel.

Algorithmus konfigurieren  
0003 Ergebnis, Long Line Intersection

Livebild  
1.TypeX: 4.679, Y: 0.660, Quality: 100.000

Found Long Line Intersection  
Col/x: -7.731, Row/y: 0.814  
Result  $\alpha$  z: -0.711°, Quality: 100.0%  
1st Line  $\alpha$ : -0.711°, Intersection  $\alpha$ : 90.598°  
1st Line value: 109.3, 2nd: 28.2, 3rd: 51.2

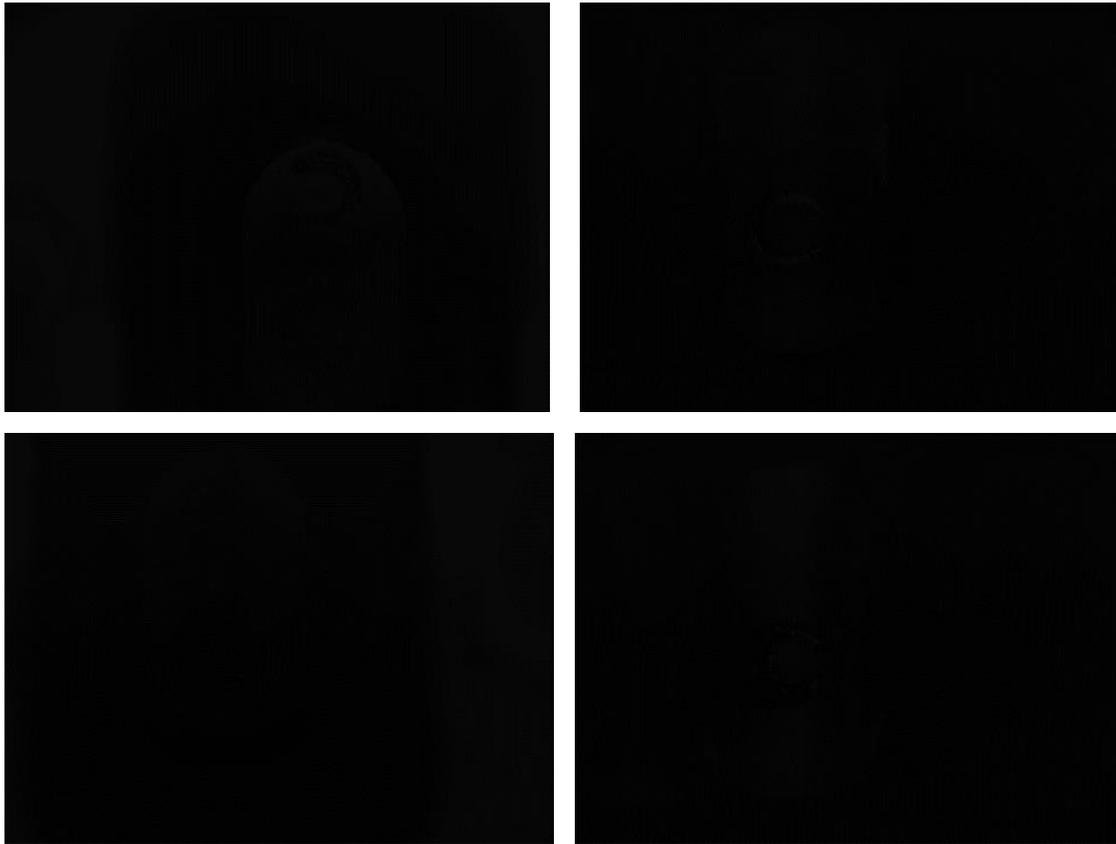
1/5: Input Arrays and Programs

1st Program	-	+	1st Line First XVAR	-	+
2			21		

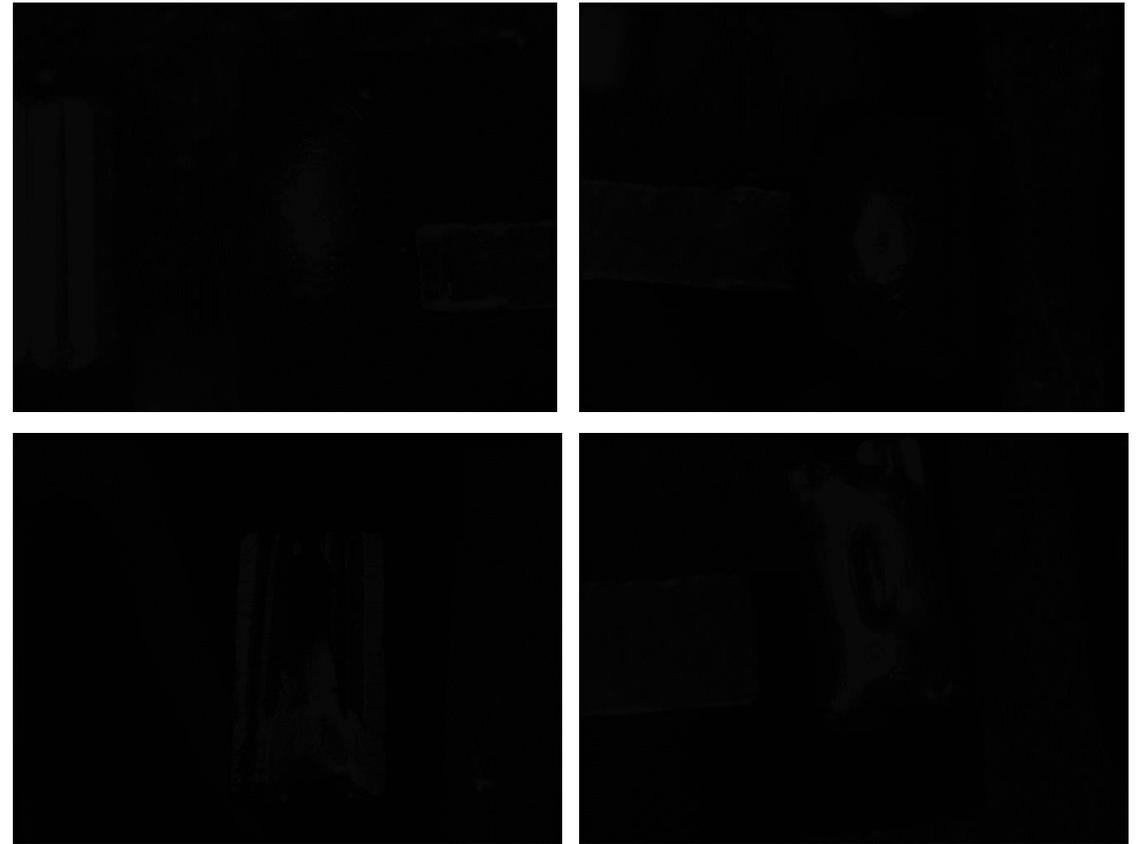
# Motivation

## Fragen der Kunden

*„Ist meine C-Klammer verbrannt?“*

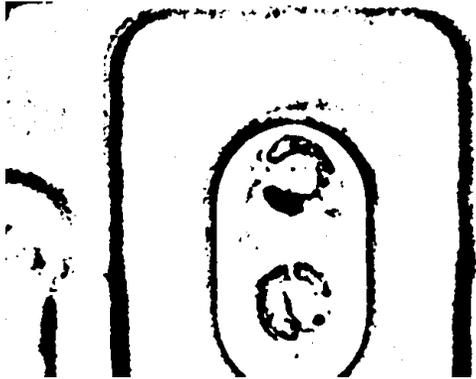


*„Hat mein Pin eine stabile Verbindung?“*

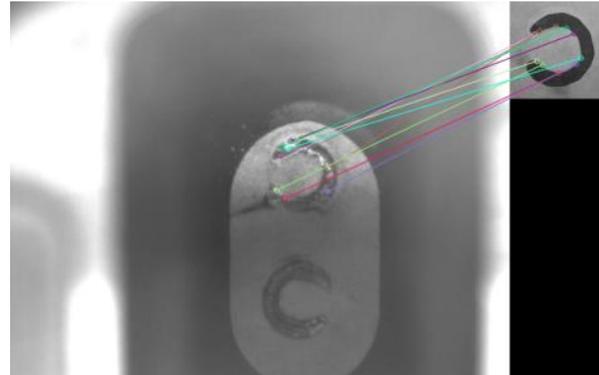


# Motivation

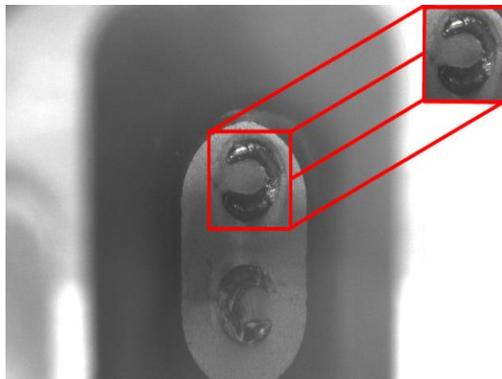
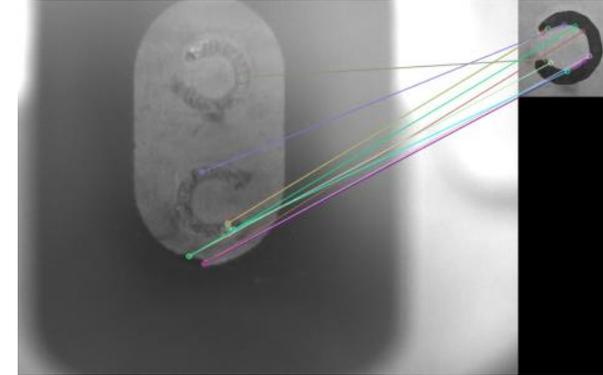
## Grenzen der Bildverarbeitung



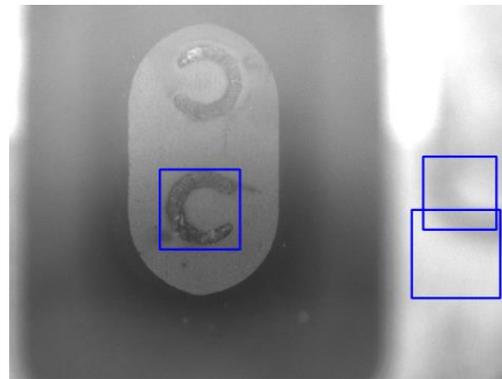
Adaptive Binarisierung



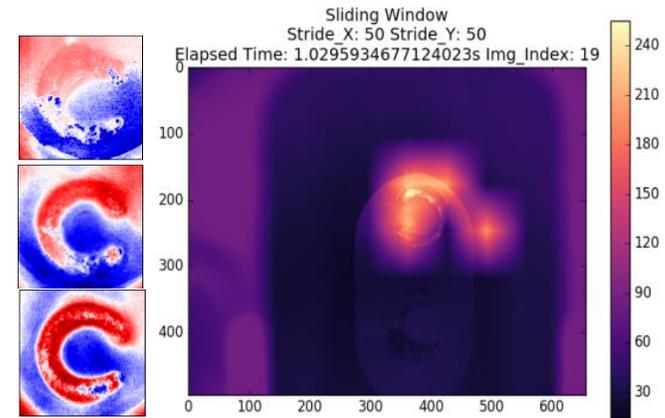
ORB Features



Template Matching



Haarcascade Classifier

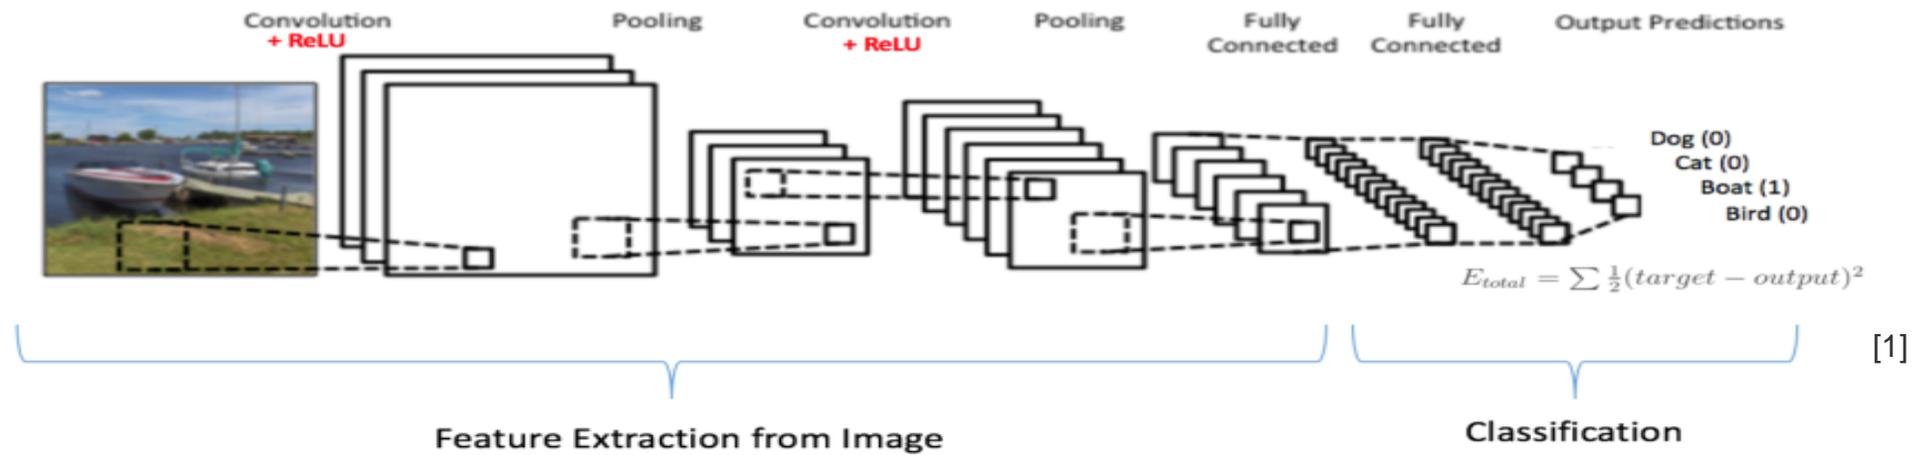


Einfache Neuronale Netze

# Grundlagen CNNs

## Übersicht

- Sehr gute Klassifikationsergebnisse auf Bilddaten
- Kein Feature-Engineering notwendig → Features werden gelernt
- Möglicher „Game Changer“

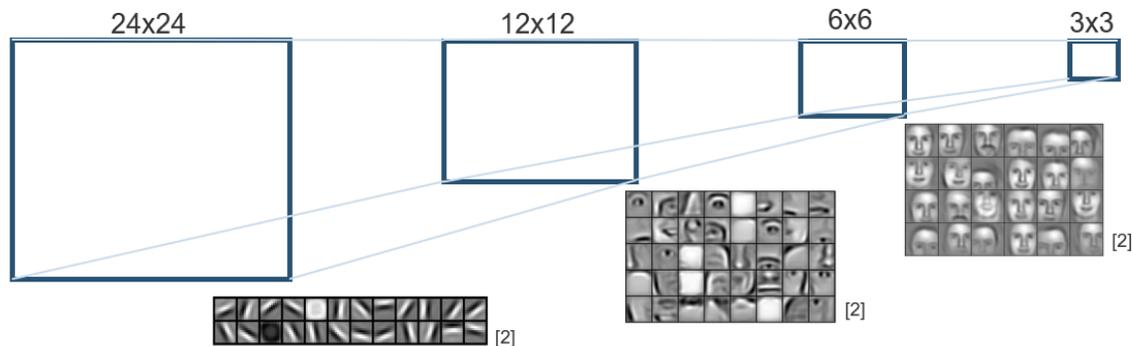


# Motivation

## Herausforderung bei CNNs

### ▪ Tiefe Netze für komplexe Features

- Mit zunehmender Tiefe können komplexere Features erkannt werden.
- Indirektes rezeptives Feld der Faltungsschichten wird mit zunehmender Tiefe größer (Dimensionsreduktion der Pooling- bzw. Faltungsoperationen)



### ▪ Daten

- MNIST: 70.000 Bilder / 10 Klassen
- MS-COCO: 330.000 Bilder / 80 Klassen
- OpenImage: ~9.000.000 Bilder / 600 Klassen

### ▪ Rechenleistung

- AlexNet ~61M Parameter / 724M MACs
- VGG16 ~138M Parameter / 15,5G MACs
- ResNet 50 ~25,5M Parameter / 3,9G MACs

### ▪ Interpretation / Fehlersuche

# Applikation Kupferpin

## Anforderung

- **Mechanisch und elektrisch stabile Verbindung zwischen zwei Kupferpins**
  - Hohe Varianz in der niO Klasse
  - Kunde stellte Datensatz mit 1.270 Bilder zur Verfügung (635 iO / 635 niO)
  - System soll mehrere Pins in einem Kamerabild bewerten können



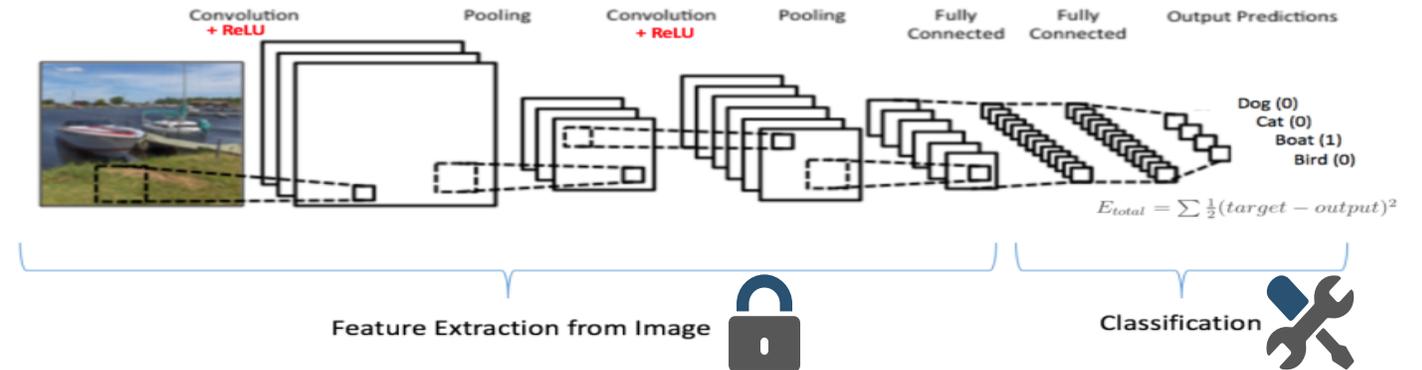
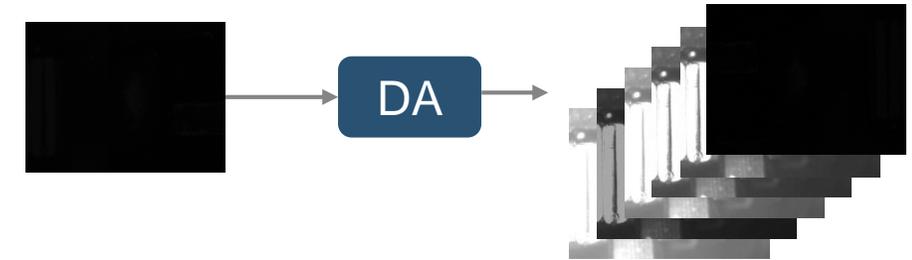
# Applikation Kupferpin

## Datenproblem

- 1.270 Bilder vs. 70.000+ Bilder
- Data-Augmentation
  - Erzeugung weiterer Bilder durch Translation, Rotation, Skalierung, ...
  - Transformation sollte realistische Varianz abdecken – keine neue einführen
- Transfer-Learning
  - Verwendung von vortrainierten Netzen
  - Feature-Extraktion Layer werden „eingefroren“
  - Klassifikationslayer werden trainiert



vs.



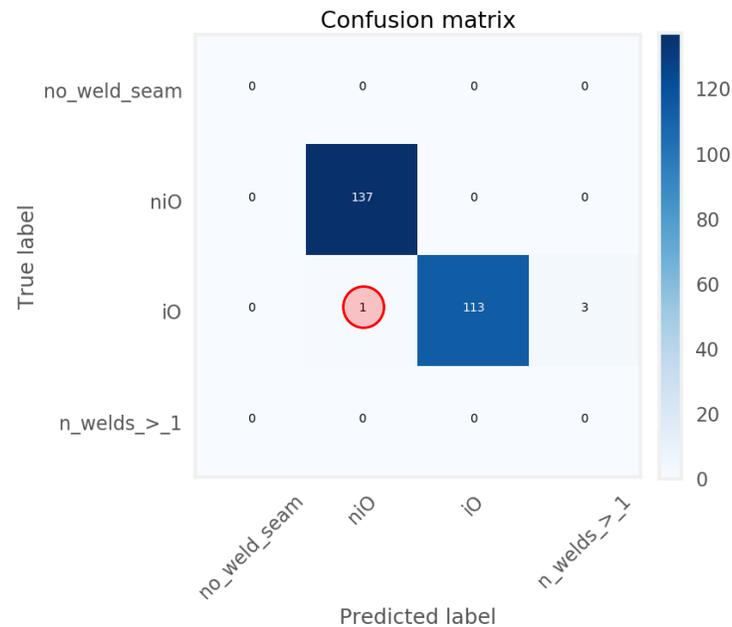
# Applikation Kupferpin

## Ergebnisse

### ▪ Setup

- 80% Daten für Training & Validierung (1016 Bilder)
- 20% externer Test für finales Modell (254 Bilder)

### ▪ Ergebnisse

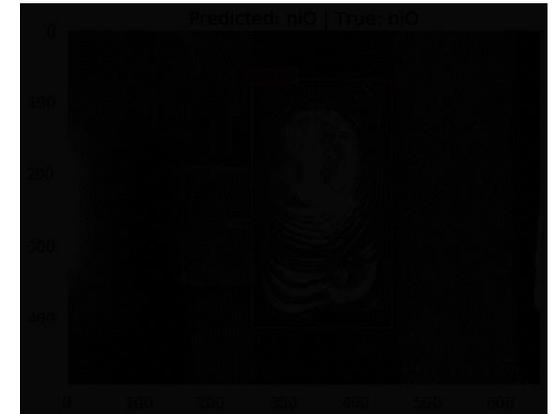


Accuracy: 99,6%

Precision: 100%

Sensitivity: 99,1%

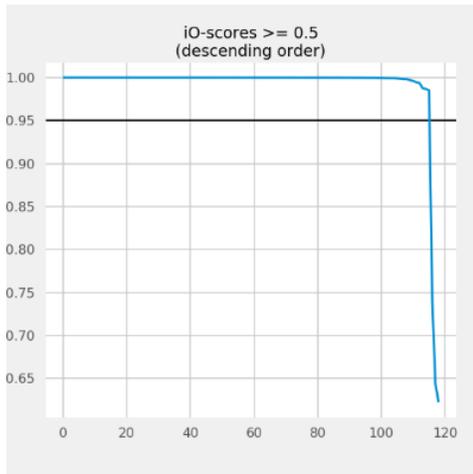
F1-Score: 99,56%



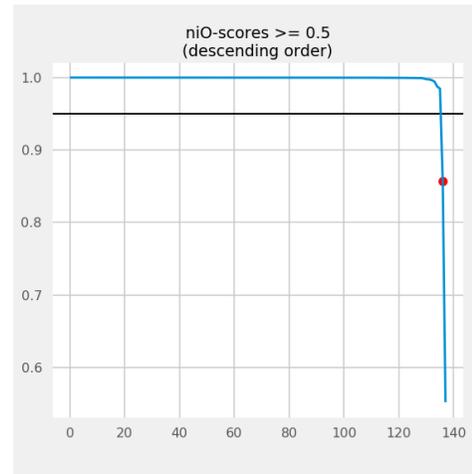
# Applikation Kupferpin

## Fehleranalyse

- Kunde bewertet dieses Bild als Grenzfall
- Konfidenzwert für niO niedrig
- Analyse der Konfidenzwerte



98,3%  $p > 0,95$



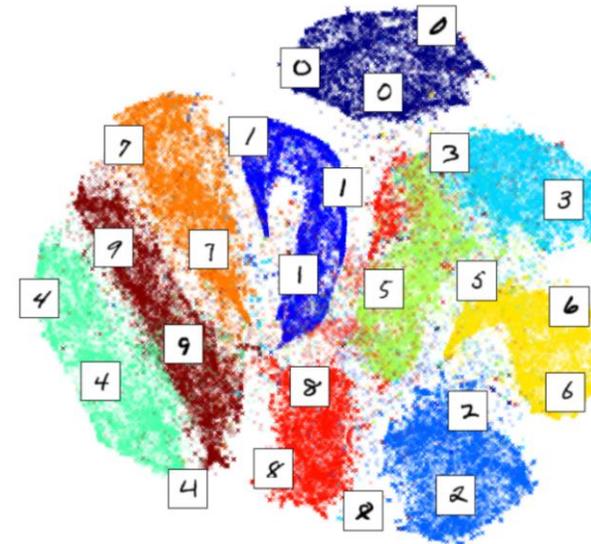
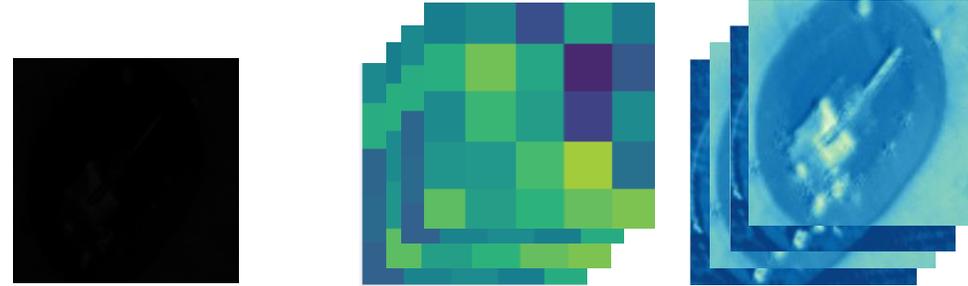
97,5%  $p > 0,95$



# Applikation Kupferpin

## Interpretation der Vorhersagen

- **Visualisierung der Aktivierung oder Filter**
  - Viele Bilder in jeder Faltungsschicht
  - Schwierig zu interpretieren
  - Backpropagation / Guided Backpropagation [6]
- **Repräsentation der Features mit t-SNE [7]**
  - 2D Repräsentation des hochdimensionalen Featurespace
  - Distanzerhaltende Einbettung
- **Detektion relevanter Bildbereiche [8]**
  - Bildbereiche werden entfernt
  - Veränderung der Vorhersage als Maß der Relevanz eines Bildbereichs
  - Visualisierung als Heatmap



# Applikation Kupferpin

## Warum ist Pin niO?

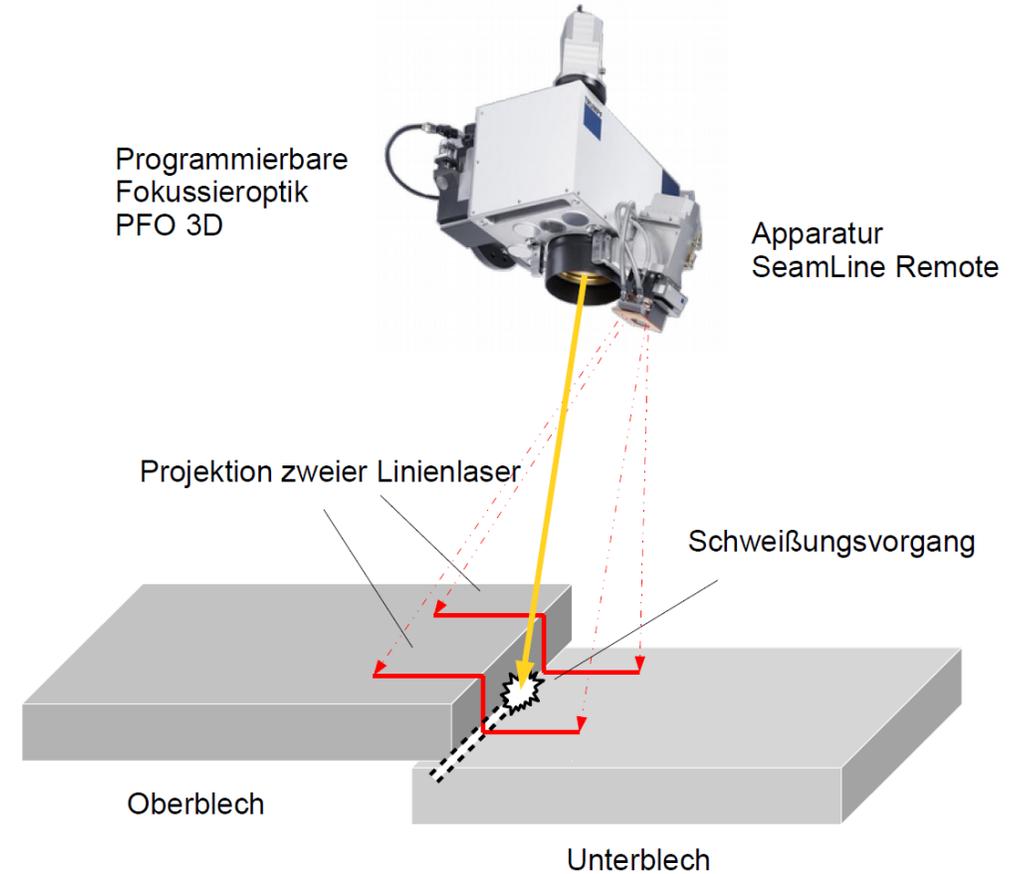
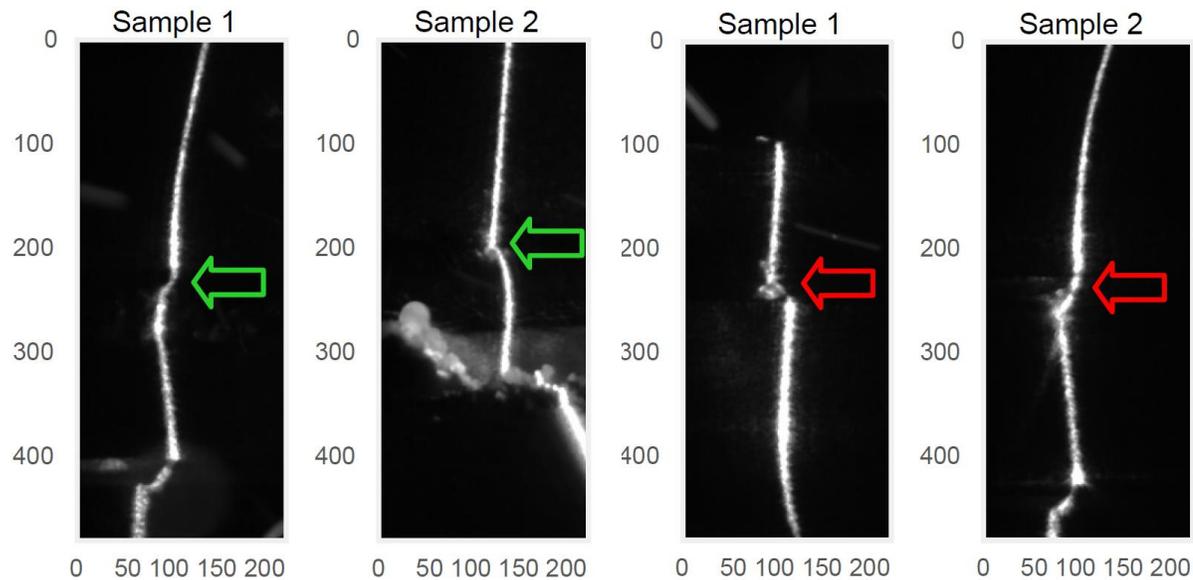
- **Heatmap Visualisierung auf Eingabebild**
  - Signifikante Bereiche für die niO Entscheidung können Visualisiert werden
  - Einfache Überprüfung, ob das Modell richtig gelernt hat
  - Interpretation ohne Machine Learning Kenntnisse möglich



# Applikation Kehlnaht

## Sensoraufbau und Funktion

- **Zweifaches Lichtschnittverfahren**
  - Nahtlagerregelung (PRE)
  - Überprüfung der Naht (POST)
- **Harte Echtzeitanforderung da online**
  - Maximale Berechnungszeit 2 ms auf Core i5 CPU



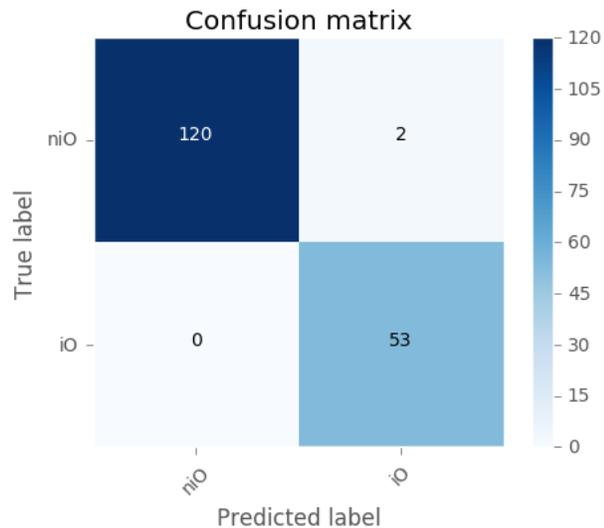
# Applikation Kehlnaht

## Ergebnisse

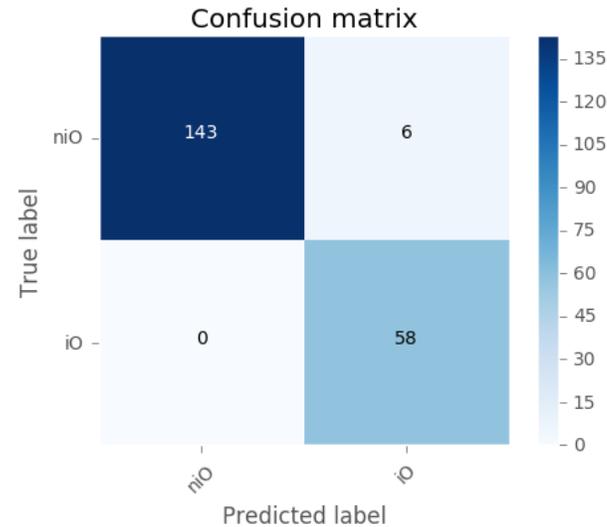
### ▪ Setup

- 8.000 Bilder für Training und Validierung (4.000 iO / 4.000 niO)
- Bilder von 2 Schweißsequenzen als externer Test

### ▪ Ergebnisse



Sequenz 414: 175 Bilder  
Genauigkeit: 98,86 %



Sequenz 416: 207 Bilder  
Genauigkeit: 97,10%

### Klassifikationszeit

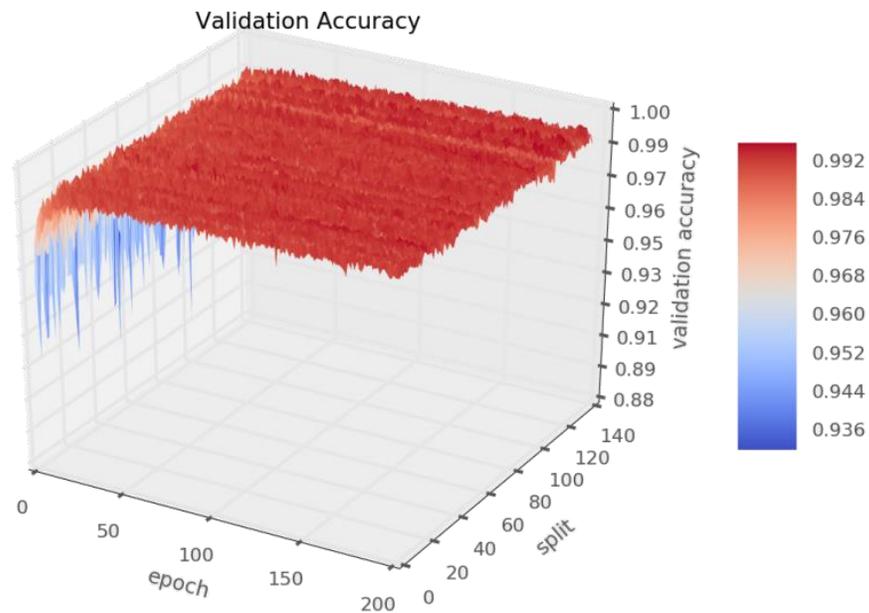
CPU: 1,13 ms

GPU: 1,65 ms

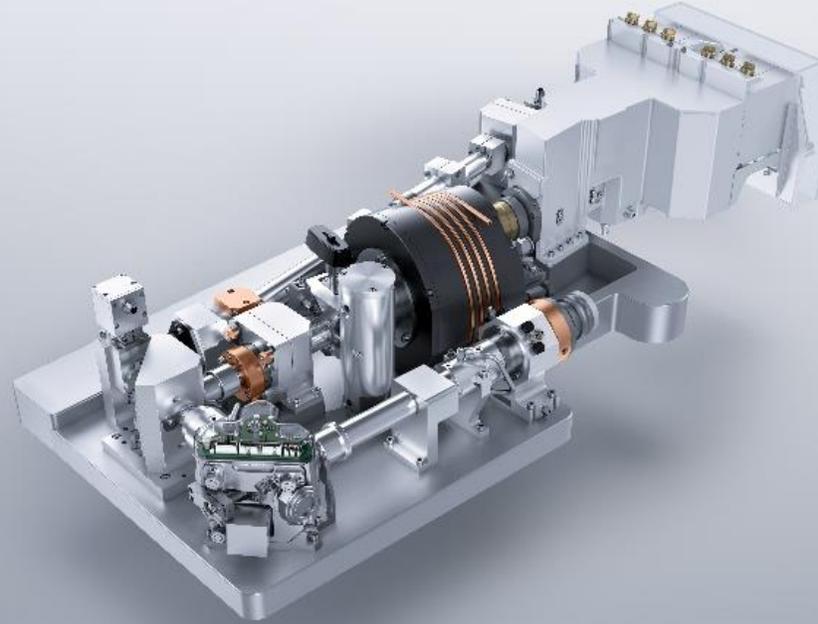
# Applikation Kehlnaht

## Cross Validation

- **Validierung der Netztopologie**
  - 8.000 Bilder für Training und Validierung (80% / 20%)
  - 130 randomisierte Splits
- **Ergebnisse**



Mittelwert:	<b>99.22%</b>
Standardabweichung:	<b>0.21%</b>
Minimum:	98.38%
Maximum:	99.69%



---

**Vielen Dank für Ihre Aufmerksamkeit**

**Fragen?**

# Referenzen

- [1] <http://www.clarifai.com>
- [2] Lee et al. - Convolutional Deep Belief Networks for Scalable Unsupervised Learning of Hierarchical Representations
- [3] Springenberg et al. - Striving For Simplicity: The All Convolutional Net
- [4] Van der Maaten et al. - Visualizing High-Dimensional Data Using t-SNE
- [5] Zeiler et al. - Visualizing and Understanding Convolutional Networks
- [6] Mitschke et al. – An evolutionary approach to automatically determine the topology of a neural network
- [7] Ronneberger et al. – U-Net: Convolutional Networks for Biomedical Image Segmentation