

Steinbeis
Qualitätssicherung und
Bildverarbeitung GmbH

Machine Learning für die Sichtprüfung - mit synthetischen Bilddaten

Dominik Schraml

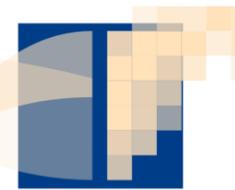
SQB GmbH



GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung



Motivation

- Qualitätsprüfung von Spritzgussteilen
- Verschiedene Fehlertypen: zu wenig Material, zu viel Material, Farbschlieren...
- Für einige Fehlerklassen gibt es sehr wenige Beispiele aus der realen Welt
- Es wäre teuer, absichtlich eine große Menge fehlerhafter Teile zu produzieren. Es besteht die Möglichkeit, synthetische Trainingsdaten für KI zur Qualitätsprüfung zu verwenden.

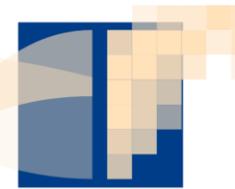
1. Wie gut kann eine auf virtuellen Bildern trainierte KI auf realen Daten funktionieren?

2. Wie wirken sich die Schlüsselparameter für die Erzeugung synthetischer Trainingsdaten auf die Performance der KI aus?



Experiment: Kann man mit synthetischen Bilddaten eine KI für reale Prüfaufgaben trainieren?

1. Erzeugen einer Blender-Szene mit einem Spritzgießbauteil (Schale)
 - Defekttyp Überspritzung mit zufälligen Variationen in Größe und Lage
 - Zufällig variierende Farbe der Teile (4 Varianten)
 - Verändern der Parameter Rauschen, Kameraposition, Beleuchtung (je 2 Varianten)
 2. KI für einfache binäre Klassifizierungsaufgaben trainieren → EfficientNetV2
 - 6.000 Bilder mit allen Variationen (50% IO / 50% NIO) → 80% train / 20% validation split
6000 Bilder für jedes Experiment gerendert, ohne den betreffenden Parameter zu verändern, z. B. wurden für „starkes Rauschen“ 3000 Bilder ohne Defekt und 3000 mit Defekt gerendert, wobei alle anderen Parameter variiert wurden
 - Testdatensatz 2.000 Bilder (50% IO / 50% NIO)
- Auswertung mit den wenigen NIO-Testobjekten, die uns zur Verfügung stehen, aber mit unterschiedlichen Lichtverhältnissen.



Erstellen der Szene

- Relativ "einfache" Szene in Blender:
- Tisch → Tischplatte hat Materialeigenschaften von dunklem Holz
- Schüssel steht auf dem Tisch
- Kamera von oben oder zufällig im Würfel darüber Licht von oben
- Hintergrund entweder grau oder HDRI-Bild

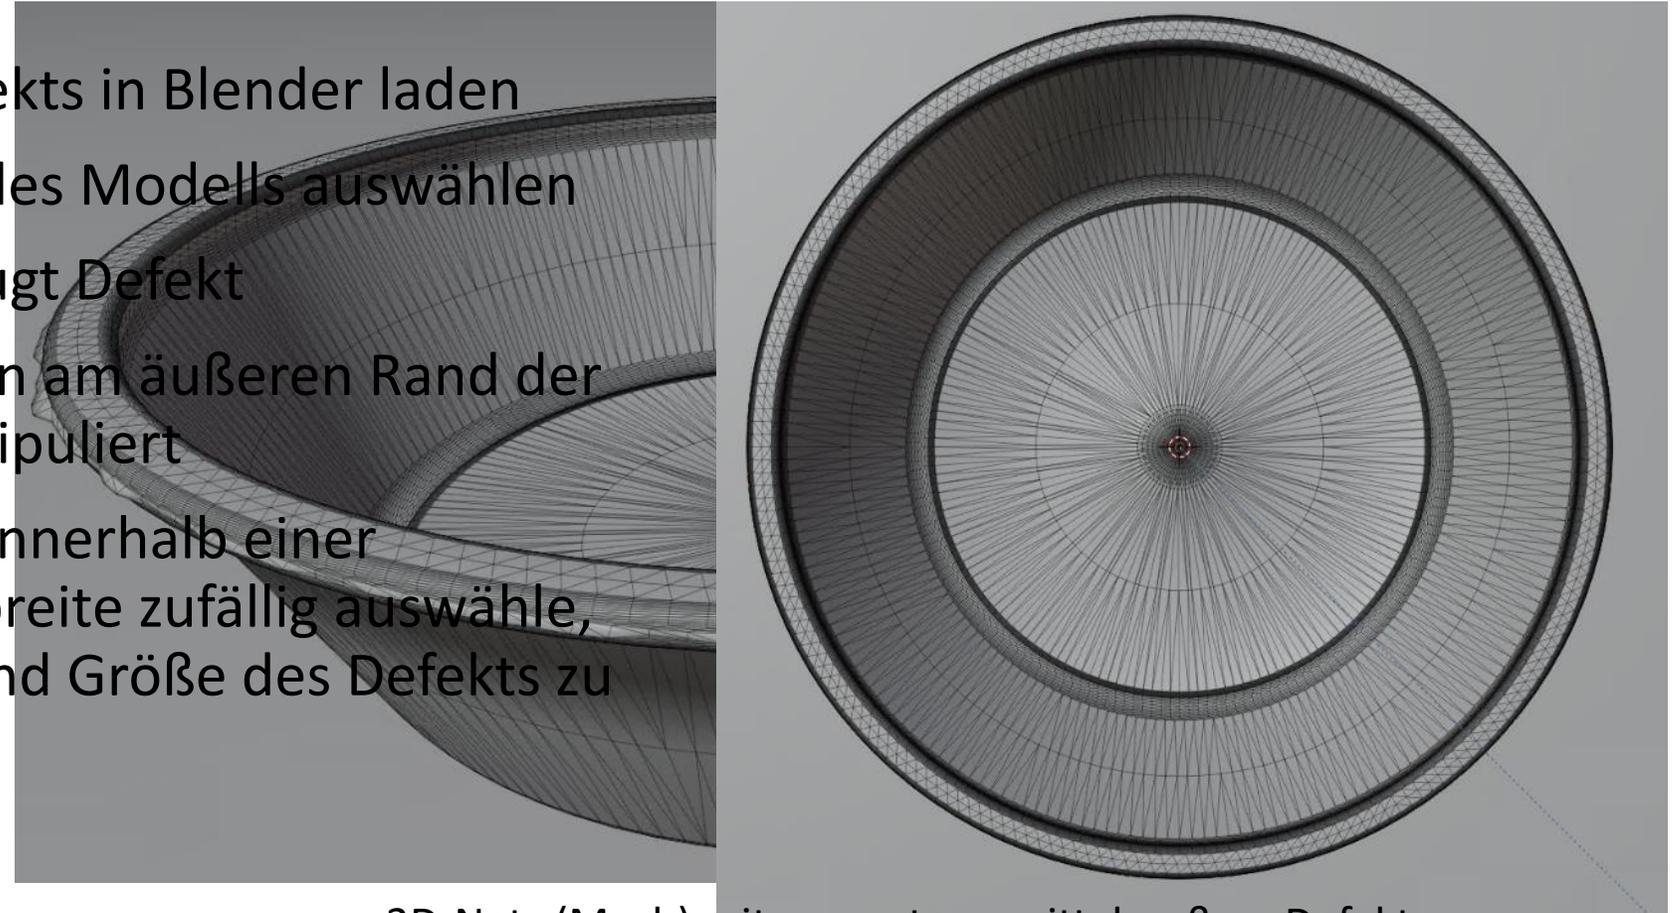


Szene in gerenderter Ansicht mit HDRI-Hintergrund

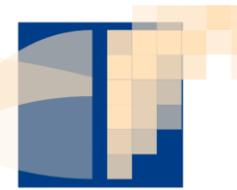


Defekterstellung

- .stl-Datei des Objekts in Blender laden
- Punkte am Rand des Modells auswählen
- Algorithmus erzeugt Defekt
- Punktkoordinaten am äußeren Rand der Schale werden manipuliert
- zwei Parameter innerhalb einer gegebenen Bandbreite zufällig auswähle, um die Position und Größe des Defekts zu verändern



3D-Netz (Mesh) mit erzeugtem, mittelgroßem Defekt
original 3D-Netz (von oben)



Bandbreite der erzeugten Defektgrößen



Minimal

Mittelgroß

Maximal

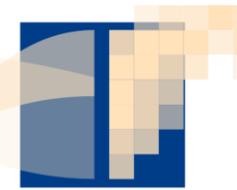


Viel vs. wenig Rauschen - Beispiele



mit starkem Rauschen gerendertes Bild
(wenige „Samples“ pro Pixel)

mit geringem Rauschen gerendertes Bild
(viele Samples)



Kamera senkrecht von oben vs. mit Variation - Beispiele



Kamera mit zufälliger Position
(Innerhalb eines Rechtecks oberhalb des Bauteils)

Kamera senkrecht von oben

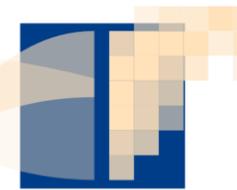


Top light vs. light from HDRI - Examples

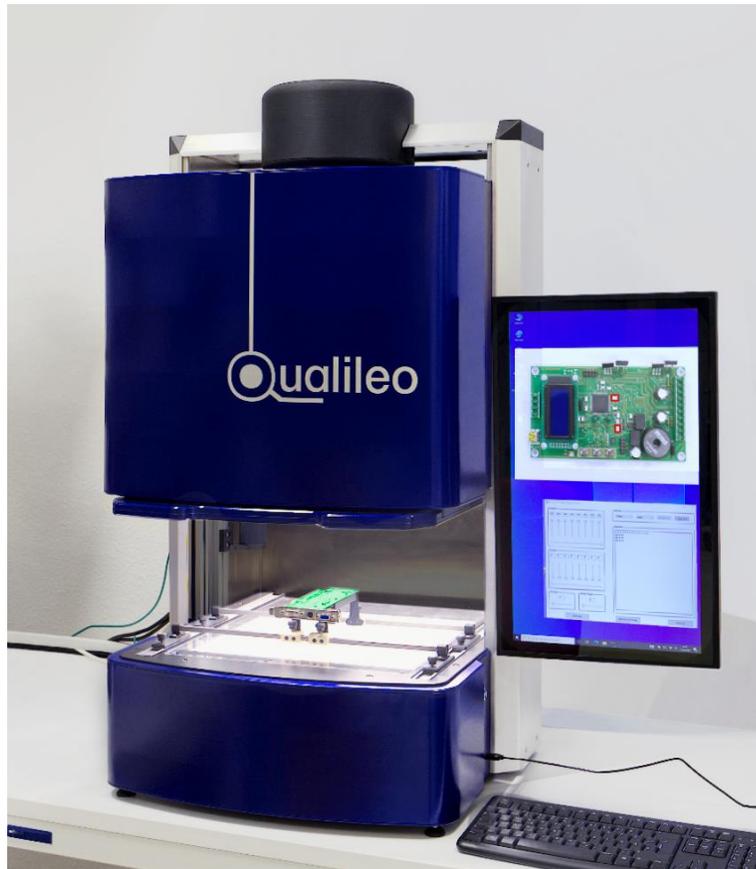


Beleuchtet durch HDRI

Beleuchtet senkrecht von oben



Qualileo Inspektionsgerät

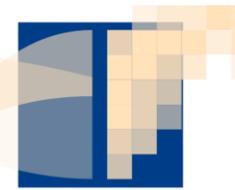


Automatisierte Sichtprüfung

- Steuerbare Beleuchtung Durchlicht, Flächenleuchte und Ringlicht (segmentweise kombinierbar)
- Automatisierte Bauteilerkennung
- Variable (anwendungsspezifische) Prüfprogramme
- Anpassung an spezielle Prüfaufgaben
- Für Datensatzgenerierung und Versuchsreihen zum finden der optimalen Beleuchtung für eine bekannte Prüfaufgabe

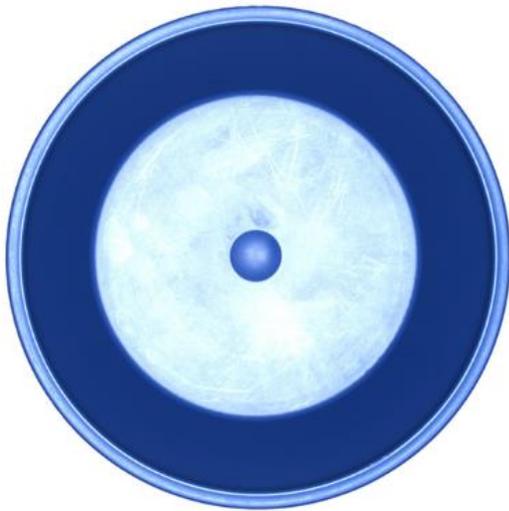
Anwendungsbereiche:

- Bei breitem Produktspektrum mit geringem
- Anwesenheitsprüfung (z.B. SMD-Bauteile auf Leiterplatten)
- Prüfung von Oberflächendefekte (Kratzer, Dellen ...)
- Geometrieprüfung (im Arbeitsbereich von 400 x 300 mm)

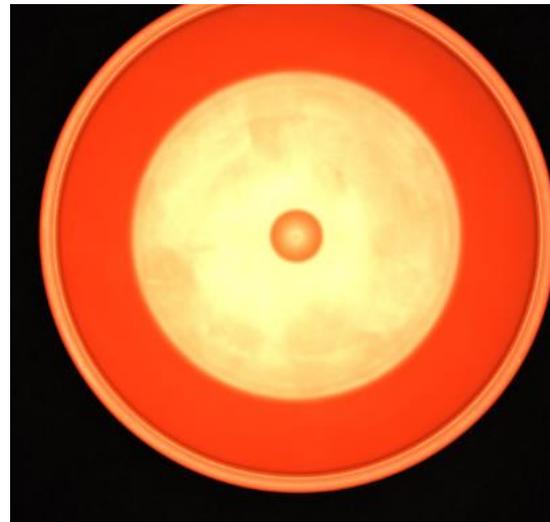


Real parts

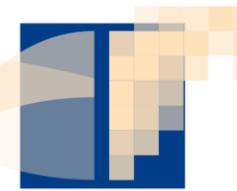
- 72 Bilder von 9 Objekten (5 IO / 4 NIO):
 - a) Heller Hintergrund
 - b) Dunkler Hintergrund
 - c) Jeweils helle und schwache Beleuchtung



IOs (hell)



Größter Defekt



Ergebnisse des Modelles mit allen Varianten auf realen Teilen

→ Beste Ergebnisse aller Modelle bei Testdaten und Bildern von realen Objekten bei

Auswirkung der Renderparameter:

- Hohes Rauschen schneidet bei (rauscharmen) realen Daten immer noch recht gut ab, aber niedriges Rauschen kann sich nicht gut an verrauschte Bilder anpassen (hohe FP-Rate)
- Top-Kamera passt sich sehr schlecht an Variationen an
- Variationen in der Beleuchtung sind sehr vorteilhaft - zumindest für diese Klassifizierungsaufgabe
- Die daraus resultierenden falsch klassifizierten Teile sind diejenigen mit dem kleinsten Defekt oder ungünstiger Beleuchtung

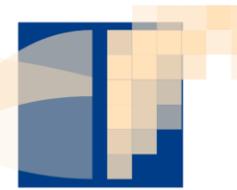
Alle Variationen Testdaten	Bewertung IO	Bewertung Defekt
IO	1840	160
Defekt	166	1834

Alle Variationen Reale Teile	Bewertung IO	Bewertung Defekt
IO	40	0
Defekt	8	24

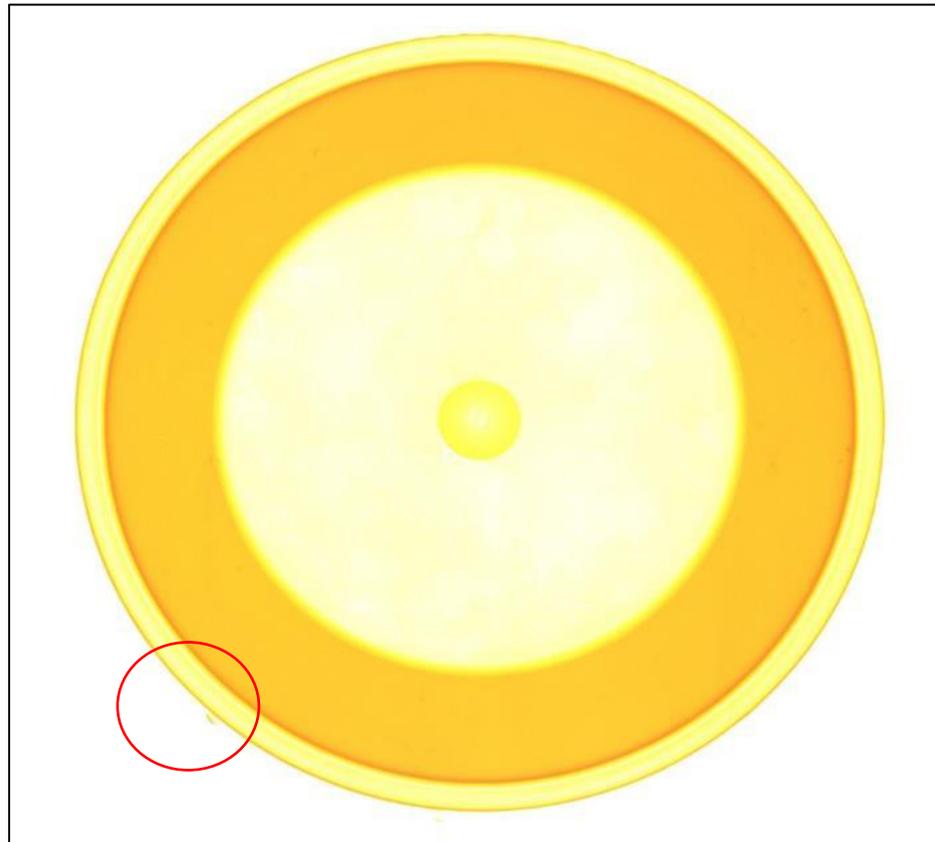
→ Alle Defekte wurden auf Bildern mit dunklem Hintergrund richtig erkannt

→ Nicht erkannt wurden kleinste Defekte vor hellem Hintergrund

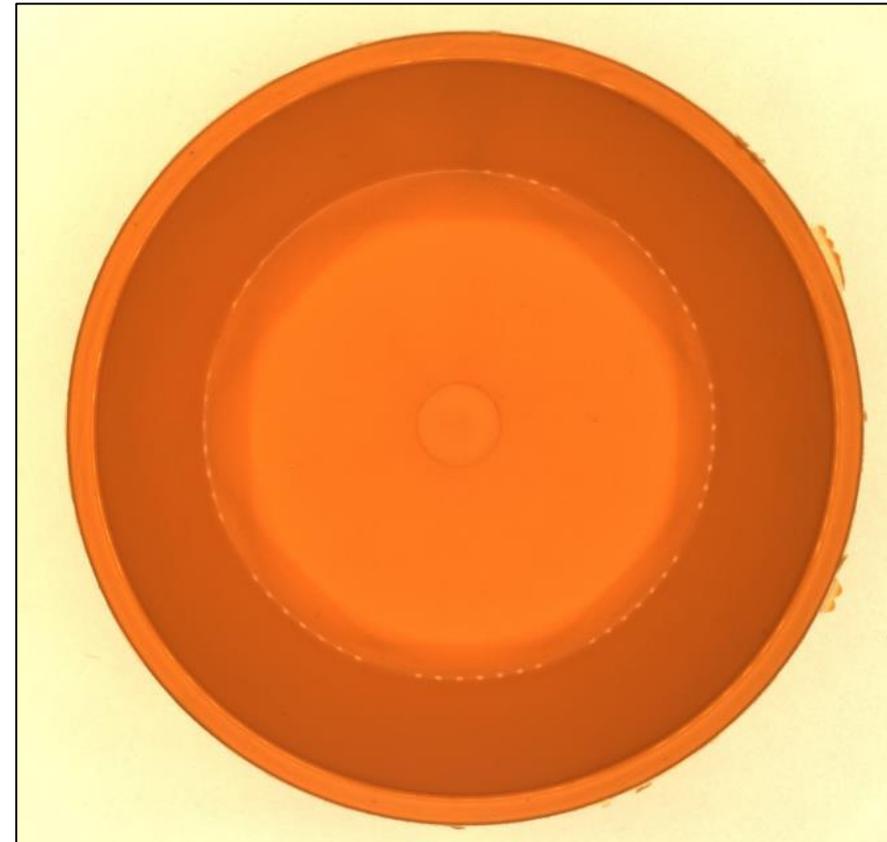
→ Mit realen Bilddaten zusätzlich im Trainingsdatensatz ist noch von besserer Performance auszugehen



Nicht erkannte Defekte



Kleiner Defekt – Beleuchtung



Größter nicht erkannter Defekt

GEFÖRDERT VOM



Steinbeis
Qualitätssicherung und
Bildverarbeitung GmbH

Steinbeis Qualitätssicherung und Bildverarbeitung GmbH

Werner-von-Siemens-Straße 9, 98693 Ilmenau

Tel.: 036 77 / 46 90 59 10 | Web: www.sqb-ilmenau.de



GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung