

TEC HNOLOGIE
NET ZWERK
EFF IZIENTE
PRO DUKTIONSTECHNIK

Anwendung von lernenden Algorithmen in der industrielle Bildverarbeitung

Prof. Dr. Bernd Pinzer
M. Eng. Maximilian Lorenz
M. Eng. Michael Beck

EffPro Technologietag. 17.06.2021

01 "Lernen" in der Bildverarbeitung

02 Case study 1:
Glattschnittsegmentierung bei Stanzteilen


03 Case study 2:
Auslesen von Gussteilmarkierungen

04 Quo vadis: Lernen nur mit Gut-Bildern?


Typische industrielle Bildverarbeitung

Häufige Merkmale industrieller Bildverarbeitung:


- klare Aufgabenstellung
- vollständige Kontrolle über Beleuchtung- / Aufnahmesettings
- einfache Algorithmen führen oft an's Ziel




Formkontrolle
Spritzguss




Gewindetiefe messen




DataMatrix-Code
finden und lesen



Kontrolle Stanzteil



Prüfung Gewinde



Winkelmessung
Zahnriemen

Beispiele aus: Demant et al., "Industrielle Bildverarbeitung", Springer

Komplexere Aufgaben → komplexere Algorithmen

Zunehmend neue Aspekte:

- Flexible Bildverarbeitungs-Stationen (neue Produkte, neue Fehler)
- Höhere Ansprüche an Produkte (z.B. kleinste Farbänderungen?)
- Fehler an den Produkten ändern sich im Laufe der Zeit

Die Bildverarbeitung sollte “dazulernen” können; das Lernen erfolgt durch Zeigen von Beispielen!



01 "Lernen" in der Bildverarbeitung

02 Case study 1:
Glattschnittsegmentierung bei Stanzteilen

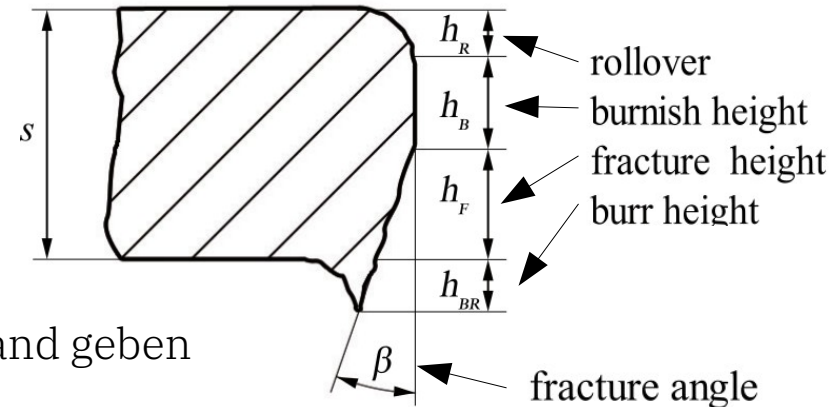
03 Case study 2:
Auslesen von Gussteilmarkierungen

04 Quo vadis: Lernen nur mit Gut-Bildern?


Case study 1: Segmentierung Glattschnittanteil

Schnittflächenkenngrößen beim Stanzen

- bisher nur stichprobenartig
- nur entlang einer Linie definiert und betrachtet
- als Qualitätsmerkmale genutzt
- können Aufschluss über Werkzeugzustand geben




Installation eines real-time Bilderfassungssystems in der Maschine:



aus: M. Lorenz et al., "Towards data driven stamping process modelling by optical inline monitoring of cutting surface parameters",
submitted to Advanced Manufacturing Technology

Bildaufnahme im Fertigungstakt




Maschinentakt:
bis zu
250 Hub /Minute

Klassische Bildauswertung (Glattschnittfläche)

Klassische Bildverarbeitung schwierig:

- Textur der Glattschnittfläche variiert; vertikale Riefen mit variierender Frequenz
- Hintergrundgrauwerte auch in der Glattschnittfläche vorhanden
- Auf welcher Skala soll der ausgefranste untere Rand eingefasst werden?

Beispiel 1




Klassische Bildauswertung (Glattschnittfläche)

Klassische Bildverarbeitung schwierig:


- Textur der Glattschnittfläche variiert; vertikale Riefen mit variierender Frequenz
- Hintergrundgrauwerte auch in der Glattschnittfläche vorhanden
- Auf welcher Skala soll der ausgefranste untere Rand eingefasst werden?

Beispiel 1



Ansatz mit aktiver Kontour

- iterativer Algorithmus zur Minimierung eines Funktionals: 40 Sekunden
1 iterations



CNN zur Segmentierung


Netzwerkarchitektur:


- UNet++

Trainingsdaten:


- 300 Ergebnisse des (langsamen) active contour Algorithmus als Trainingsdaten verwendet (z.T. händisch nachbearbeitet)
- Data augmentation: scaling, verschiedene ROIs → 900 Datensätze

Beispiele für Trainingsdaten:





Ergebnis:



Laufzeit pro Bild:
(Workstation)

8 ms


In Stanzmaschine integrierbar?

Test mit Jetson Xavier NX (Nvidia ARM64 mit GPU)

- CNN Inferenz benötigt im Mittel 80ms
- Komplette Aufnahmesteuerung mit Xavier:
 - Aufnahme Bild mit Flächenbeleuchtung
 - Aufnahme Bild mit Laserline (Lichtschnitt)
 - Inferenz CNN
 - 3D-Profil berechnen

dauert 220 ms.

- Maschinenzyklus bei Volllast: 240 ms



Real-time Analyse auf Edge-Device im Maschinentakt möglich!

01 "Lernen" in der Bildverarbeitung

02 Case study 1:
Glattschnittsegmentierung bei Stanzteilen

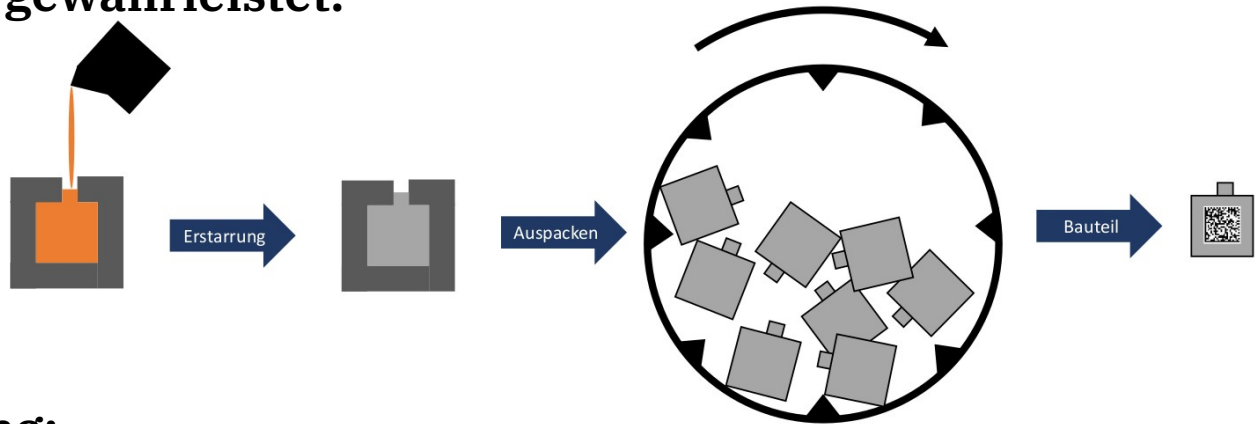
03 Case study 2:
Auslesen von Gussteilmarkierungen

04 Quo vadis: Lernen nur mit Gut-Bildern?

Case-study 2: Auslesen von Gussteilmarkierungen

Problem:

Rückverfolgbarkeit von Gussteilen durch gängige Markierverfahren nicht gewährleistet:



Lösung:




individuelle Markierung in der Sandform:



Sandt et al. (2020), "CastCode – Gussteilrückverfolgbarkeit an automatischen Formanlagen", Giesserei-Special, (1), 30-39

Automatisches Auslesen der Codes


Prototyp eines
Handscanners:



Einige
Beispiele

Verwendung von Neuronalen Netzen für zwei Aufgaben:

- Schritt 1: Lokalisierung der Pins im Bild (object detection)
- Schritt 2: Feststellung des Orientierungswinkels (classification)




Schritt 1: Pin Detection


Object detector liefert die Orientierung des Gesamtcodes:

- Manuelles labeling von Pin-Regionen auf 20 Bildern mit jeweils ca. 10 Pins
- Single shot multibox detector (SSD) wird trainiert mit ca. 200 Bildern
- Inferenz liefert ROIs der Pins und Konfidenz-Wert; kein Fehler im Validierungsset


Input



Output

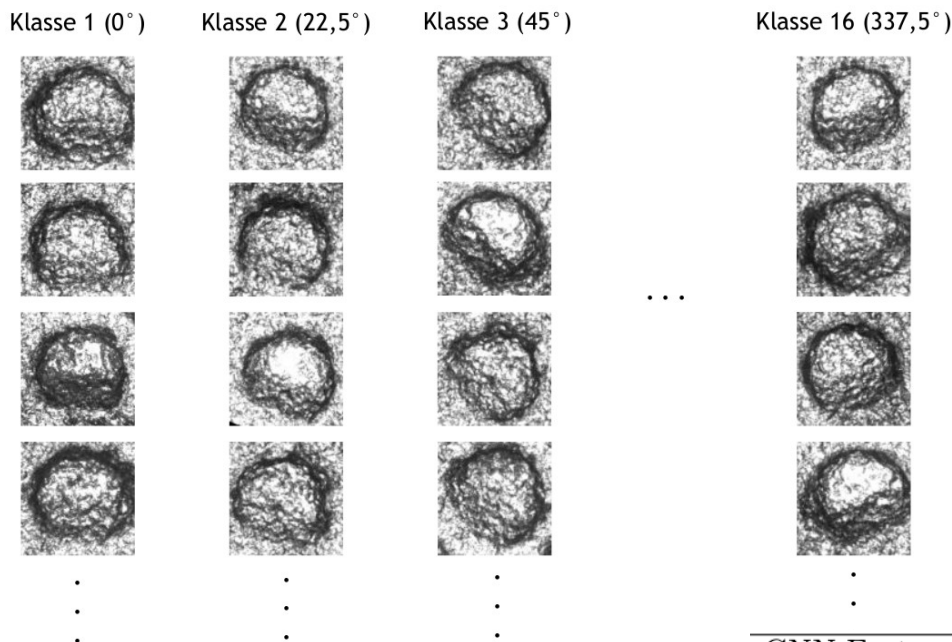


Schritt 2: Pin Klassifizierung



CNN für die Klassifizierung der einzelnen Orientierungen:

- 16 Klassen, entsprechend der 16 möglichen Winkelorientierungen
- ca. 6000 Trainingsbilder pro Klasse

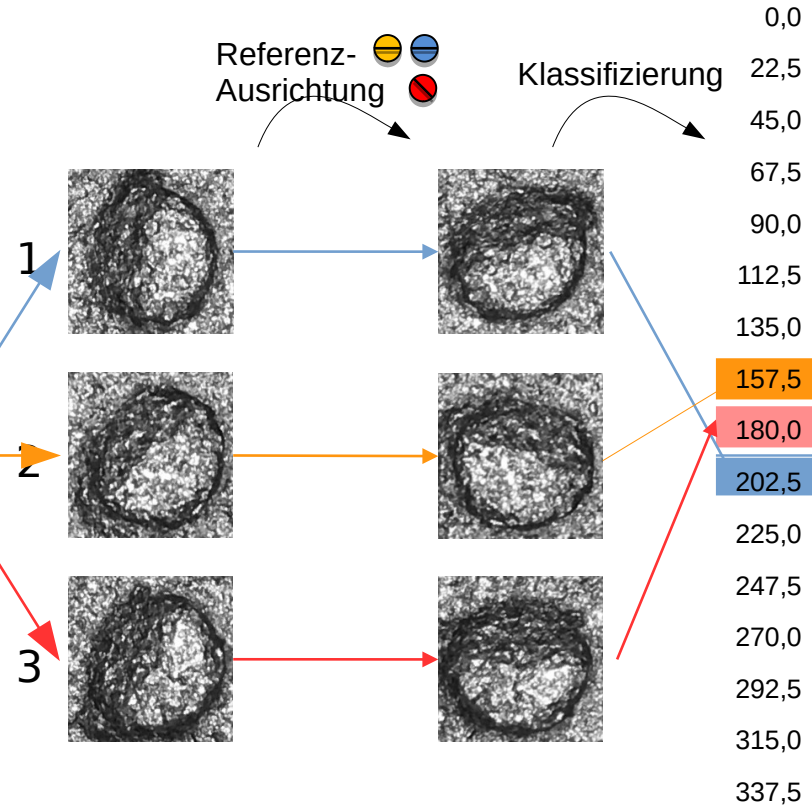




- Feineinstellung der Hyperparameter zeigt: beste Klassifizierung wird erreicht mit dieser Netzwerk-Architektur:

CNN Feature maps:	32, 64, 128, 256, 512
CNN Kernel size:	3 x 3
Max pooling size:	2 x 2
Dense layers:	2049, 1024, 526, 128, 64
Score:	99.07 ± 0.10 %
Ranking:	1

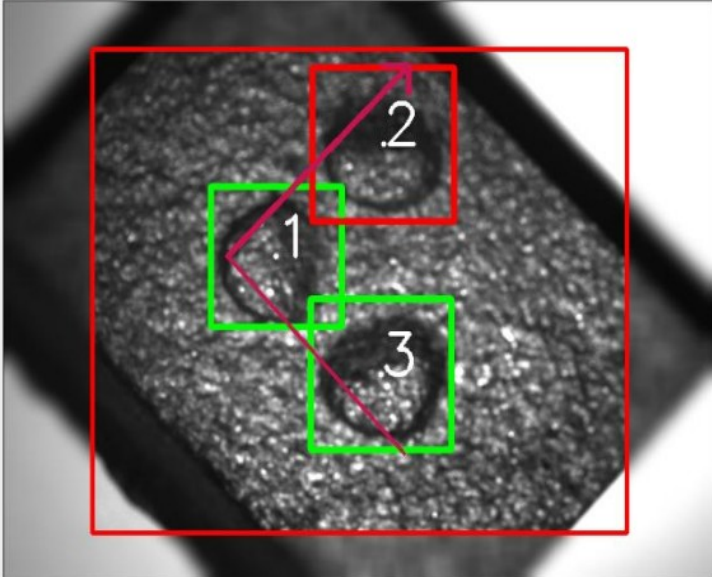
Schritt 2: Pin Klassifizierung

Ablauf der Pin Klassifizierung



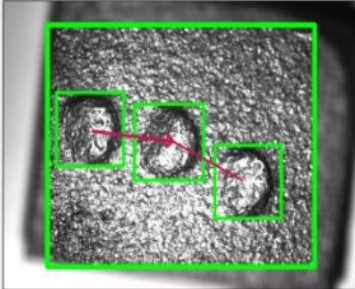
Umsetzung und Validierung

Live Image



Start Aquisition Stop Aquisition Close **FPS: 7.5**

Code Image



Code: ----

Pins:	Conf.	Pos.
Pin 1:	99.9%	2
Pin 2:	-	-
Pin 3:	100.0%	13

Logging:

```
Code: 3554 || Positions: [ 2, 14, 13 ] || Confidence: [ 0.9997384, 0.982428, 0.9999975 ] || Time: 15/04/2020 14:59:06
Code: 1529 || Positions: [ 5, 8, 7 ] || Confidence: [ 0.99991715, 0.95247585, 0.9354149 ] || Time: 15/04/2020 15:01:34
```

Camera Settings

Exposure: [ms]

Code Settings

Conf. Thresh.: [%]

Rep. Ac.:


Camera

Width: 800


Height: 600

Serial: 4103224225

Model: UI313xCP-M







TEC
NET
EFF
PRO

HNLOGIE
ZWERK
IZIEN
DUKTIONSTECHNIK

Forschungszentrum
Allgäu (FZA)

Validierung des Komplett-Systems durch Test-Personen:

→ basierend auf 240 scans

Parameter	Erfahrene Testperson	Erst- Benutzer
	Tp ₁	Tp ₂
Pinscore (P _{Pin}):	99.86 %	99.17 %
Score 3 Pins (P _{Total}):	99.58 %	98.13 %
Min. position difference:	1	1
Max. position difference:	1	1
Av. scanning time:	0.43 sec	0.93 sec

01 "Lernen" in der Bildverarbeitung

02 Case study 1:
Glattschnittsegmentierung bei Stanzteilen

03 Case study 2:
Auslesen von Gussteilmarkierungen


04 Quo vadis: Lernen nur mit Gut-Bildern?

Ausschuss-Detektion durch Anlernen von Gut-Bildern

Schwierigkeit in der Praxis ist oft die Erstellung eines guten Trainingsdatensatzes. Mögliche Gründe:

- Fehler sind selten, so dass sie in den Bilddaten unterrepräsentiert sind
- Neue, unbekannte Fehler treten im laufenden Betrieb auf
- Datensammeln dauert zu lange

Gut-Daten vorhanden:



Trainingsdaten: ausschließlich gut-Bilder
(mit prozessbedingter Variation)

aus: Bergmann et al. (2019). "MVTec AD — A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection", in Proceedings of the CVPR

Anomaly detection

Ziel: Finden von Anomalien (Abweichungen von Gut-Bildern)



Verschmutzung



Abplatzung +
Schrift
beschädigt




falscher Typ



Kratzer

Anomaly detection mit Gut-Bildern ist aktuell Gegenstand der Forschung, eröffnet neue Möglichkeiten bei Qualitätsprüfung!



Ich freue mich auf Ihre Fragen!

Kontakt:

michael.layh@hs-kempten.de
bernd.pinzer@hs-kempten.de

WISSEN / SCHAFFT / VORSPRUNG

