

Künstliche Intelligenz in der Produktion der Zukunft


Quelle: Siarhei - stock.adobe.com

Prof. Dr.-Ing. Marco Huber
marco.huber@ipa.fraunhofer.de



Fraunhofer
IPA



Zentrum für Cyber Cognitive Intelligence (CCI)
Abteilung Bild- und Signalverarbeitung
Fraunhofer IPA, Stuttgart
<https://www.cyber-cognitive-intelligence.de>




Universität Stuttgart

Kognitive Produktionssysteme
Institut für Industrielle Fertigung und Fabrikbetrieb
Universität Stuttgart
<https://www.iff.uni-stuttgart.de>


Künstliche Intelligenz (KI) in den Medien



KI Meilensteine



Genauigkeit zählt



Zentrum für Cyber Cognitive Intelligence (CCI)

Zentrale Anlaufstelle für Maschinelles Lernen & Künstliche Intelligenz

- **Anwendungs- und Expertenzentrum** für die Nutzung von ML/KI in der (mittelständischen) Industrie – für produzierende Unternehmen, Ausrüster
- **Forschung, Entwicklung, Realisierung:** Grundlagen und Anwendungen von ML/KI für die Produktionstechnik, Logistik und Automatisierung
- **Technologie-Transfer:** Demonstrationen, Veranstaltungen, Weiterbildung



Open Lab Days



Quick Checks




Technologie-
Entwicklung



Pilot-
anwendungen

Forschungs- und Anwendungsschwerpunkte



Machine Learning

Erklärbare KI (xAI)

Automated ML

Decision Making
& ML unter
Unsicherheit



BILD- & SIGNAL- VERARBEITUNG

Qualitätssicherung

Bildsimulation

Ereignisdaten-
analyse

Sensorplanung



PRODUKTION

Produktions- /
Maschinen-
steuerung

Track & Trace

Generatives
Produktdesign



ROBOTIK

Mensch-Roboter-
Kooperation

Reinforcement
Learning

Meta / Transfer
Learning

Schulungen

CCI Etappen

Opportuni-
tät identi-
fizieren

Idee und
Business
Case
entwickeln

Validieren
in
„Exploring
Projects“

Verwerten
in Produkt
oder
Produktion

**Open
Lab
Days**

**40
Quick
Checks**

**12
Transfer-
analysen**

**6
Demon-
stratoren**

2018

2018 bis 2019

2019 bis 2020

2020 bis 2021

Quick Checks und Exploring Projects

Aktueller Stand der Arbeiten am CCI

1. Open Lab Day am 5. Juli 2018

- 27 Bewerbungen führten zu
18 Quick Checks, Weiterführung von
5 Exploring Projects

2. Open Lab Day am 17. Januar 2019

- 36 Bewerbungen führten zu
24 Quick Checks, Weiterführung von
7 Exploring Projects

3. Open Lab Day in der Arena2036 am 5. Juli 2019

- 18 Bewerbungen führten zu
17 Quick Checks

Weiterführung in beauftragten
Industrieprojekten



Testimonials

Quick Checks



»Das Fraunhofer IPA stellte uns durch den Quick Check beeindruckende neue Methoden vor, die eine schnelle Objektlokalisierung ohne lange Einlernzeiten ermöglicht. Unter den vorgestellten Methoden sind vielversprechende Ansätze, um diese in der Industrie zu verwirklichen.«



glass made of ideas

»Das Fraunhofer IPA hat in sehr kurzer Zeit beeindruckende Ergebnisse erzielt. Insbesondere hat der Quick Check uns neue Möglichkeiten aufgezeigt, Defekte in Bilddaten besser zu detektieren und zu klassifizieren.«



»Das Fraunhofer Institut hat unsere komplexe Aufgabenstellung im Quick Check in beeindruckender Weise erfasst und analysiert. Die präsentierten Ergebnisse zeigen uns bereits jetzt, dass durch den Einsatz von ML Verfahren großes Potential besteht die Produktionskosten zu senken und gleichzeitig die Qualität der Münzanalyse zu verbessern.«



»Die Zusammenarbeit mit dem Fraunhofer IPA war sehr angenehm, konstruktiv und produktiv. Der QuickCheck hat es uns ermöglicht, die Chancen und Grenzen aktueller Ansätze aus dem Bereich der künstlichen Intelligenz besser abschätzen zu können.«

Künstliche Intelligenz, Maschinelles Lernen, Deep Learning

Einordnung

Künstliche Intelligenz (KI)

Lösen von Problemen, welche vom Menschen intelligentes Handeln erfordern




Maschinelles Lernen (ML)

Lernen anhand von Mustern in Daten








Deep Learning (DL)

Lernen mittels tiefer neuronaler Netze



Praxisfälle des Maschinellen Lernens für kognitive Produktionssysteme

Praxisfall	Klassifizierung	Merkmalsunterscheidung ■ Ist das A, B, C ...?		
	Erkennung von Anomalien	Ausreißer-Erkennung: ■ Ist das i.O.; gehört das hierhin?		
	Regression	Vorhersagen: ■ Wie viele? Welcher Zustand?		
	Verstärkungs- lernen	Passende Strategie lernen ■ War das o.k. so?		

Klassifizierung: Prüfung Kammerbelegung eines Steckers



- Neuronales Netz
- Ein Trainingsdatensatz pro Kabelfarbe

Ergebnis:

- Kabel werden identifiziert, Kammerbelegung verifiziert
- Training: ca. 5 Sek. CPU
- Segmentierung: ca. 0,3 Sek.

Nutzen:

- Kontaktprüfung hochpoliger Stecker während der Montage (Qualität)



Vorstellung ausgewählter Quick Checks

Fehlerklassifikation an einer Glasschmelzwanne – Schott AG

Aufgabe

- Industrielle Glasschmelzwannen sind mit Totzeiten von bis zu 50 Stunden behaftet
- Die Ursachenanalyse veränderter Prozesseinstellungen auf die Glasqualität ist deshalb schwierig
- **Glasdefekte** sollen daher bereits unmittelbar im Schmelzprozess detektiert und **klassifiziert** werden; hochauflösende Kameras zur Bildaufnahme werden bereits eingesetzt

Ziel

- Entwicklung eines **selbstlernenden Algorithmus**, der Defekte in Einzelbildern des kontinuierlich aufgezeichneten Bodenablaufs in unterschiedliche Fehlerkategorien klassifiziert
- Beurteilung der Nutzbarkeit von maschinellen Lernverfahren zur Fehlerdetektion und Klassifikation aus vorliegendem Bildmaterial


Vorstellung ausgewählter Quick Checks

Fehlerklassifikation an einer Glasschmelzwanne – Schott AG

»Das Fraunhofer IPA hat in sehr kurzer Zeit beeindruckende Ergebnisse erzielt. Insbesondere hat der Quick Check uns neue Möglichkeiten aufgezeigt, Defekte in Bilddaten besser zu detektieren und zu klassifizieren.«


Ergebnis des Quick Checks

- ML-Methoden sind viel versprechend für die Fehlerklassifikation an einer Glasschmelzwanne
- Bereits erste Tests mit einer „Selbstlernenden Defekterkennung“ liefern Ergebnisse mit einer Fehlerquote $< 5\%$








Weiteres Vorgehen

- Erstellung eines anwendungsspezifischen selbstlernenden Defekterkennung und Klassifikation; Kombination mit Bilddatenvorverarbeitungsstrategie
- Bewerbung für Transferanalyse am CCI oder alternativ Beauftragung Machbarkeitsuntersuchung




Praxisfälle des Maschinellen Lernens für kognitive Produktionssysteme

Praxisfall	Klassifizierung	Merkmalsunterscheidung ■ Ist das A, B, C ...?		
	Erkennung von Anomalien	Ausreißer-Erkennung: ■ Ist das i.O.; gehört das hierhin?		
	Regression	Vorhersagen: ■ Wie viele? Welcher Zustand?		
	Verstärkungs- lernen	Passende Strategie lernen ■ War das o.k. so?		


Erkennung von Anomalien: Beschädigungen auf strukturierten Oberflächen

- **Selbstlernende Prüfung an 2D-Bildern**
- **Schritt 1:** Eigenständiges Einlernen der dominierenden Hintergrundstruktur
- **Schritt 2:** Markierung von statistischen Abweichungen als Fehlerbereiche
- **100 %-Prüfung im Fertigungstakt im 1/10 Sekunden-Takt**



Kundennutzen

- Schnelle Inline-Prüfung von Oberflächen
- Keine Fehlerbeschreibung erforderlich



Automatische Identifizierung von Schlagstellen

Beispiel Prozessintegration

Vorstellung ausgewählter Quick Checks

Autonome Anomaliedetektion zur Qualitätssicherung - IDS Imaging Development Systems GmbH

Aufgabe

- Autonome Erkennung von Anomalien in gegebenen Bildbereichen zum Zweck der Qualitätssicherung
- Anomalien: Oberflächendefekte, An- oder Abwesenheit von Features etc.
- Klassisches Training von **künstlichen Neuronalen Netzen** anhand von Beispielen ist **aufwändig** und oft mangels ausreichenden Bildmaterials insbesondere von Defekten und Fehlern **nicht möglich**

Ziel

- Entwicklung von geeigneten Konzepten und Verfahren der KI zur selbständigen Erkennung, Charakterisierung, Lokalisierung und Visualisierung der Anomalien
- Abschätzung des Potenzials und der Grenzen solcher Verfahren
- Embedded Computing, Edge Devices

Vorstellung ausgewählter Quick Checks



Autonome Anomaliedetektion zur Qualitätssicherung - IDS Imaging Development Systems GmbH

Ergebnis des Quick Checks







- Vielversprechende Ansätze in der jüngeren Literatur vorhanden
- Entwicklung von tragfähigen Konzepten zur Anomaliedetektion auf der Zielplattform
- Festlegung von ersten Anwendungsszenarien
- Zielplattform: Smart Kamera NXT

Weiteres Vorgehen

- Transferanalyse
- Umsetzung von alternativen Konzepten in Form von Studienarbeiten



Praxisfälle des Maschinellen Lernens für kognitive Produktionssysteme

Praxisfall	Klassifizierung	Merkmalsunterscheidung ■ Ist das A, B, C ...?		
	Erkennung von Anomalien	Ausreißer-Erkennung: ■ Ist das i.O.; gehört das hierhin?		
	Regression	Vorhersagen: ■ Wie viele? Welcher Zustand?		
	Verstärkungs- lernen	Passende Strategie lernen ■ War das o.k. so?		

Regression: Qualitätsprognose beim Ultraschallschweißen

Aufgabenstellung


- Herstellung von hochwertigen Ultraschall-Schweißverbindungen

Lösung

- Qualitätsprognose basierend auf Kenngrößen aus der Maschinensteuerung und weiterer Sensorik (z.B. Körperschall)
- Nachweis der Leistungsfähigkeit des Ansatzes anhand von Probekörper

Kundennutzen

- Prognose zu Fehlstellen der Schweißnaht, Dicke der Schweißnaht, Dichtheit



Test-Probekörper am IPA



Ultraschallschweißen in der Praxis

Vorstellung ausgewählter Quick Checks

Kognitive intuitive Robotersensorik – robomotion GmbH

Aufgabe

- Automatisierte Handhabung, wie z.B. das Kommissionieren, stellt hohe Ansprüche an die Wahrnehmung
- Ohne Modell muss die **Position und Orientierung** der Artikel bestimmt werden
- **Bisher wird** die Erkennung im Bildverarbeitungssystem für jeden einzelnen Artikel **individuell konfiguriert**
- 2D- und 3D-Sensordaten sind vorhanden, Abmessungen und Form der Artikel ist bekannt

Ziel

- **Potenzial von Deep Learning** für die Segmentierung und Lageerkennung der einzelnen Produkte ermitteln
- **Kürzere Einlernzeiten** für Handhabungsaufgaben

Vorstellung ausgewählter Quick Checks

Kognitive intuitive Robotersensorik – robomotion GmbH


»Das Fraunhofer IPA stellte uns durch den Quick Check beeindruckende neue Methoden vor, die eine schnelle Objektlokalisierung ohne lange Einlernzeiten ermöglicht. Unter den vorgestellten Methoden sind vielversprechende Ansätze, um diese in der Industrie zu verwirklichen.«

Ergebnis des Quick Checks






- Recherche verschiedener Verfahren
- Z.B. You-Only-Look-Once-Verfahren
 - Echtzeitfähiges Objekterkennungssystem
 - Teilt Bild in Regionen und bestimmt für diese Bounding Boxen mit Wahrscheinlichkeiten, welches Objekt erkennbar ist
→ Übertragung auf relevante Artikel
- Sichtung von Bilddaten

Weiteres Vorgehen

- Konzeptentwurf über Transferanalyse
- Erstes Labeling und Training



Praxisfälle des Maschinellen Lernens für kognitive Produktionssysteme

Praxisfall	Klassifizierung	Merkmalsunterscheidung ■ Ist das A, B, C ...?	 
	Erkennung von Anomalien	Ausreißer-Erkennung: ■ Ist das i.O.; gehört das hierhin?	 
	Regression	Vorhersagen: ■ Wie viele? Welcher Zustand?	 
	Verstärkungs- lernen	Passende Strategie lernen ■ War das o.k. so?	 

Deep Q-Learning

Google DeepMind: Atari Spiele

- Ziel: Gewinne das Spiel mit höchstem Score
- Zustand: Pixel des Spiels (mehrere Frames)
- Aktionen: Pfeiltasten z.B. links, rechts
- Belohnung: Veränderung des Scores in jedem Zeitschritt
- DeepMind: "pixels to actions"



Screen shots from four Atari 2600 Games: (Left-to-right) Pong, Breakout, Space Invaders, Seaquest



Verstärkungslernen: Griff in die Kiste

- Vereinzelung chaotisch gelagerter Werkstücke
- Objekterkennung in 3D-Punktwolke der Kiste
- CloudPicking: Algorithmen laufen auf einem Cloud-Server
→ höhere Rechenkapazität, vereinfachte Wartbarkeit



Laufzeitmessung	Phasenlagemessung	Lasertriangulation	Stereovision
			
MESA SR4000	Sick LMS400	Leuze LPS36	Ensenso N10


Typische Sensoren für Griff in die Kiste

Der »Griff in die Kiste« als Industrie-4.0-Anwendung

Cloud Picking

Hand-Auge-Koordination bei Robotern (Google)


- 14 Roboter lernten simultan in ~800.000 Greifversuchen unterschiedliche Objekte aus einer Kiste zu greifen, verwendet wird je eine monokulare Kamera
- Roboter tauschen ihre Erfahrung aus
- Auch unbekannte Objekte werden gegriffen. Abweichungen in Kamerapositionen werden ausgeglichen durch die Robustheit der Algorithmen



Quelle: <https://i.ytimg.com/vi/H4V6NZLNu-c/hqdefault.jpg>


Verstärkungslernen: Griff in die Kiste

Datenerzeugung: Virtuelle Lernumgebung (V-REP)



Verstärkungslernen: Erweiterung um „Transfer Learning“


Virtuelle Lernumgebung
(z.B. Handhabungssimulation)




Transfer auf realen Roboter
(mit ähnlichen Werkstücken)



Rauschmodell



Prozess-
modell



Prozess-
modell

Wissen



- Lernumgebung dient der Datengenerierung zum Trainieren neuronaler Netze
- Rauschmodelle von realen Systemen → Modellparameter im Physik-Simulator
- Generiertes Wissen (Prozessmodell) wird auf den realen Robotertask transferiert

Künstliche Intelligenz (KI)



Maschinelles Lernen (ML)

Deep Learning (DL)


Klassifizierung




Anomalieerkennung



Regression



Reinforcement Learning



Vielen Dank!



Prof. Dr.-Ing. habil. Marco Huber

marco.huber@ipa.fraunhofer.de

+49 711 970 1960

www.cyber-cognitive-intelligence.de