

## Evaluation des Reinigungsfortschrittes bei der CIP- Behälterreinigung mittels eines optischen Messsystems

### Evaluation of cleaning progress for a reactor CIP system using optical measurements

**C. Ostwald<sup>1</sup>, M. Hesse<sup>2</sup>, A. Boye<sup>2</sup>, F. Groß<sup>1</sup>, J.-P. Majschak<sup>2</sup>, A. Delgado<sup>1</sup>**

<sup>1</sup> Lehrstuhl für Strömungsmechanik, Friedrich-Alexander-Universität Erlangen-Nürnberg, Erlangen

<sup>2</sup> Fraunhofer IVV, -Dresden

Bildverarbeitung, künstliche neuronale Netze, Automatisierung, CIP-Reinigung  
image processing, artificial neural networks, automation, CIP cleaning

#### Zusammenfassung

Die vorgestellten Forschungsarbeiten zielen auf die Entwicklung eines automatischen, selbstlernenden Inline-Systems für eine zeit- und ressourceneffiziente CIP-Reinigung am Beispiel eines (Industrie-) Behälters mit motorisch angetriebenem Zielstrahlreiniger. Dazu werden Informationen über einen Reinigungsprozess mittels künstlicher neuronaler Netze aus Bilddaten generiert. Darauf aufbauend erfolgt eine optimierte Parameterplanung, die entlang einer orts- und zeitgebundenen Bahnplanung des Reinigungsverlaufes realisiert werden soll. Relevante Prozessparameter für eine Reinigung sind der Druck, bei der die Reinigung durchgeführt wird, die Geschwindigkeit des Zielstrahls, die Temperatur des Reinigungsmediums und die Anzahl der Wiederholungen der Reinigung.

Darüber hinaus beeinflussen weitere Faktoren, das Reinigungsverhalten (kohäsiv oder adhäsiv) (Liu et al. 2003), der Schmutzschicht maßgeblich. Einer dieser Faktoren ist die Antrocknungszeit der Verschmutzung. Die Antrocknungszeit ist als die Zeit definiert, die bis zum Beginn der Reinigung vergangen ist, nachdem die Schmutzschicht auf die Behälteroberfläche aufgetragen wurde. Im Wesentlichen können in Bezug auf die Antrocknungszeit der Verunreinigungen zwei unterschiedliche Verhaltensweisen bei der Reinigung beobachtet werden. Bei kurzer Antrocknungszeit, beispielsweise 1h, wird für die Reinigung ein geringerer Druck benötigt und es kann eine höhere Geschwindigkeit des Zielstrahlreinigers gewählt werden. Bei langer Antrocknungszeit, beispielsweise nach 24h, sollte die Reinigung bei einem höheren Druck und einer niedrigeren Geschwindigkeit durchgeführt werden, um ein optimales Reinigungsergebnis zu erzielen (Liu et al. 2003).

Ein spezifisch angelernter Bildklassifikator kann beispielsweise mit einer Trainingsgenauigkeit von über 70% eine Einteilung der Bilddaten anhand ihrer Antrocknungszeit vornehmen. Für eine lange Antrocknungszeit kann eine Einzelbildgenauigkeit bezüglich dem Klassifikator unbekanntem Bilddaten von 80% erreicht werden. Aktuell erfolgt die Einzelbildfassung des Reinigungsprozesses im Sekundentakt, so dass die erreichte Genauigkeit des Klassifikators ausreichend sein sollte, um eine Einteilung in lange oder kurze Antrocknungszeit für das Abtrageverhalten der Schmutzschicht abzuschätzen. Darauf aufbauend sollen dann resultierende Informationen über den Reinigungsvorgang dem automatischen selbstlernenden Inline-System übergeben werden.

## Einleitung

In der lebensmittel- und biotechnologischen, aber auch der pharmazeutischen, medizinischen und chemischen Industrie müssen Maschinen und Anlagen regelmäßig gereinigt werden, um die hygienischen Vorgaben bei der Produktion erfüllen zu können. Erst eine automatisierte Reinigungsüberwachung ermöglicht dabei eine gezielte, nachhaltige und ressourceneffiziente Prozessgestaltung auch bei Qualitätsschwankungen bezüglich unterschiedlicher Verschmutzungszustände vor Reinigungsbeginn. Im Rahmen des vorgestellten Projektes werden als zu untersuchende kohäsive Verschmutzungen Senf und Ketchup gewählt. Zudem soll, als Vertreter von fetthaltigen Produkten, Mayonnaise als Verschmutzung untersucht werden.

Im Rahmen der vorgestellten Forschungsarbeiten erfolgt eine Reinigungsüberwachung mittels einer visuellen (kameraoptischen) Detektion unterschiedlicher Verschmutzungszustände vor und während der Reinigung eines Produktionsbehälters aus der Lebensmittelindustrie. Die betrachtete Methode beruht dabei auf dem Prinzip der Cleaning in Place (CIP) Reinigung von Lebensmittelschmutzschichten durch einen Fluidstrahl (Zielstrahlreiniger). Bei der Behälterreinigung in der Lebensmittelindustrie wird üblicherweise ein dynamischer Reiniger, wie der Zielstrahlreiniger (siehe Abbildung 1) verwendet, da dieser eine hohe Reinigungswirkung und -effizienz besitzt (siehe Boye 2013). Die Reinigung durch den Zielstrahl erfolgt, indem der Fluidstrahl die Schmutzschicht von der Behälterwand abträgt. Die Detektion der Restverschmutzung und damit des Prozessfortschritts erfolgt zunächst an einem Versuchsstand mit einer linearen Anordnung und unter UV-Licht mit einer Kamera mit sensitivem Farbsensor (Sony IMX264 CMOS Farbsensor, 2.464 x 2.056 Pixel).

Anhand von derzeit mehr als 23.500 Bildaufnahmen aus Reinigungsversuchen an einer linearen Versuchsanordnung wurden Algorithmen künstlicher neuronaler Netzstrukturen (KNN) angelern, um den Verschmutzungszustand und den Reinigungsfortschritt zu detektieren. Vorgestellt wird ein Klassifikator, der anhand von Bilddaten der Beispielverschmutzung Senf erkennt, ob es sich um eine kurze oder eine lange Antrocknungszeit der Schmutzschicht handelt. Die Antrocknungszeit wird dabei als die Zeit definiert, die bis zum Reinigungsbeginn vergeht, nachdem die Verschmutzung auf eine Oberfläche aufgerakelt wurde.

Im Sinne einer adaptiven Reinigung in Abhängigkeit u.a. der Antrocknungszeit der Ablagerungen, dient die Detektion des Prozessfortschrittes zur Entwicklung einer modellbasierten Vorhersage eines effizienten individuellen Reinigungsprogramms. Aufbauend auf diesem Vorhersagemodell und der Inline-Erfassung des Verschmutzungszustands soll eine adaptive Prozessführung zur Automatisierung des Reinigungsprozesses umgesetzt werden. Diesbezüglich werden erste Zusammenhänge zwischen Bildinformationen und Prozessinformationen vorgestellt, die eine Prozessoptimierung durch leistungsfähige Inline-Diagnosesysteme, a priori Wissen und Methoden des maschinellen Lernens ermöglichen. Zukünftig wird darauf aufbauend ein selbstlernendes Automatisierungssystem realisiert, das verschiedene Reinigungsmodi (beispielsweise zeitsparend, energieschonend oder ressourcenschonend) berücksichtigt und mit ökologischem und technologischem Nutzen umsetzt.

## Versuchsaufbau und Systembeschreibung

In der aktuellen Projektphase wird der Zielstrahlreiniger zunächst durch einen vereinfachten linearen Aufbau ersetzt, um erste Bilder des Reinigungsprozesses in Abhängigkeit unterschiedlicher Prozessparameter zu erstellen. Der Vorteil des linearen Versuchsaufbaus ist, dass zunächst Einflüsse wie Behälterwandkrümmung oder Sprühnebel unbeachtet bleiben können. In Abbildung 1 (links) ist schematisch der Versuchsaufbau abgebildet. Abbildung 1 verdeutlicht, an welcher Position die Bilddaten aufgenommen werden sollen und zeigt (rechts) die visuelle Darstellung einer Reinigungsspur. Der gereinigte Teil der Schmutzschicht ist dabei

weiß und die verbliebene Verschmutzung schwarz abgebildet. Um den Bilddaten unterschiedliche Prozessdaten zuordnen zu können, wurden Versuche mit unterschiedlichen Parametern durchgeführt. So wurden der Druck und die Translationsgeschwindigkeit des Flüssigkeitsstrahls bei einer Antrocknungszeit von einer Stunde und von 24 Stunden variiert (siehe Tabelle 1). Die Versuche wurden dabei jeweils doppelt durchgeführt.




Abb. 1: Ausprägung der Reinigungsränder einer Reinigungsspur als mögliches charakteristisches Merkmal zur Erfassung des Reinigungsfortschritts durch einen Reinigungsstrahl bezogen auf die Antrocknungszeit (Ostwald et al. 2017).

Tabelle 1 Versuchsmatrix der durchgeführten Reinigungsversuche an einer linearen Versuchsanordnung. Die Angaben entsprechen den Prozessinformationen, die den Bilddaten zugeordnet werden

	1 h Antrocknungszeit	24 h Antrocknungszeit
Druck	2 bar und 5 bar	2 bar und 5 bar
Translationsgeschwindigkeit Flüssigkeitsstrahl	5 mm/s, 50 mm/s, 100 mm/s	5 mm/s, 50 mm/s, 100 mm/s

Für die Verschmutzungsart Senf wurden am linearen Versuchsstand 4.786 Bildaufnahmen der Reinigungsversuche aufgenommen. Zu den Bildaufnahmen wurden jeweils ebenfalls die Prozessinformationen erfasst, um jeder Bildaufnahme die entsprechenden Prozessinformationen zuweisen zu können. Für die Regelung und die anschließende Optimierung eines Systems sind die Eingangsgrößen und Randbedingungen, die das System beeinflussen, relevant. Die Prozessinformationen, die in das System, den zu reinigenden Behälter, als Eingangsgrößen eingehen, können über eine Regelung gesteuert (geregelt) werden. Weitere zu berücksichtigende Einflussgrößen sind Randbedingungen auf die nur indirekt Einfluss genommen werden kann, die das System aber wesentlich beeinflussen. Folglich wird in diesem Forschungsprojekt ein entsprechendes Detektionssystem angestrebt, welches auch Einflüsse der Randbedingungen detektieren kann. Somit sollen aus den Bilddaten mittels eines künstlichen neuronalen Netzes über den vorgestellten Klassifikator Informationen gewonnen werden, um optimierte Prozessparameter entlang der orts- und zeitgebundenen **Bahn des Zielstrahls in der Verschmutzungsschicht** zu generieren und darauf aufbauend eine optimierte Regelung der Reinigung zu entwickeln. Diese örtliche und zeitliche Auflösung des Reinigungsprozesses, der für eine optimierte Regelung oder für eine Automatisierung des Reinigungsvorgangs geeignet ist, erfolgt anhand einer Bahnplanung, des

theoretischen Verlaufes der Reinigungspur. Aufgrund der Bahnplanung ist eine Vorhersage möglich, wann und an welcher Position gereinigt wird. Hinzu kommen Informationen aus den Bilddaten, sodass eine Vorhersage getroffen werden kann, welcher Verschmutzungszustand, z.B. Antrocknungszeit, am jeweiligen Ort vorliegt. Somit entsteht ein Modell der Reinigung. Das Schema wird in Abb. 2 gezeigt.

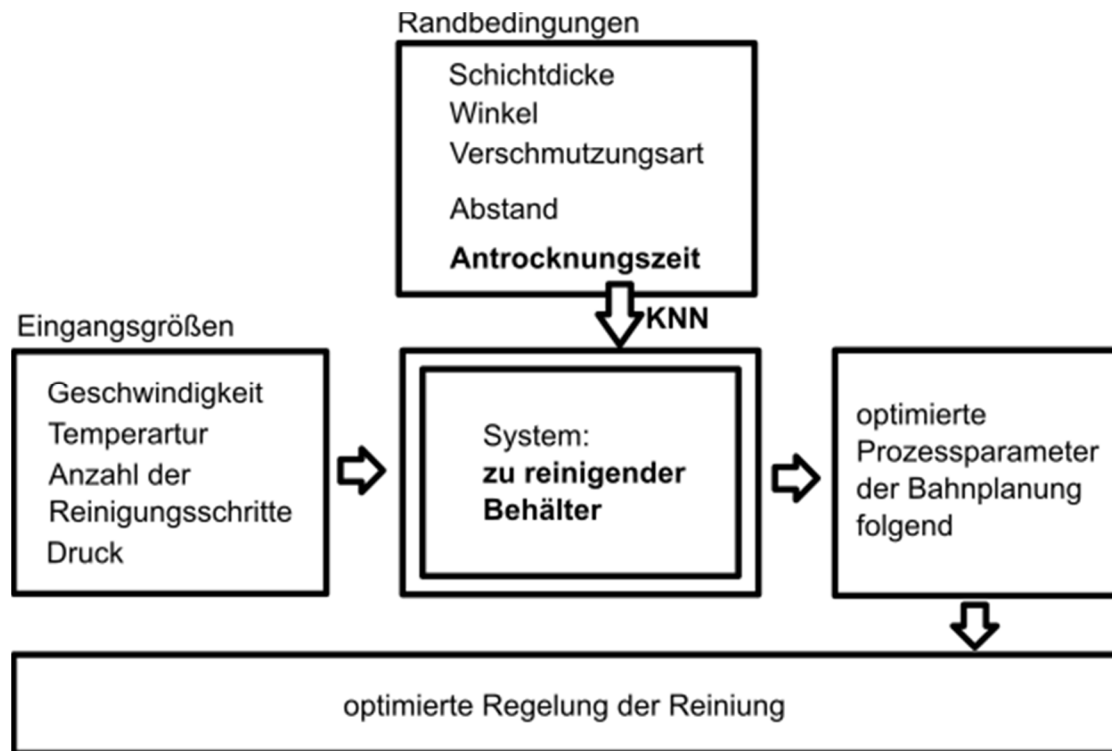


Abb. 2 Übersicht eines System für eine zeit- und ressourcenoptimierte CIP-Reinigung mit Eingangsgrößen, Randbedingungen und Ansatzpunkt für ein KNN (künstliches neuronales Netz). Über das KNN soll dem System weitere Informationen den Prozess gesammelt werden, um mittels einer optimierten Prozessparameter Planung, die der Bahnplanung folgt, eine optimierte Regelung der Reinigung zu erhalten

### Merkmalsextraktion aus Bilddaten mittels KNN

Zur Mustererkennung in Kameraaufnahmen und zum Anlernen eines Klassifikators eignen sich künstliche neuronale Netze (KNN) in ganz besonderer Art und Weise, da diese bezüglich der erreichten Genauigkeit bzw. Fehlerrate, z.B. bei der Klassifizierung verschiedener Strukturen, im Bereich der menschlichen Leistungsfähigkeit liegen (Sun et al. 2014).

Somit sind künstliche neuronale Netze im Bereich der Bildanalyse derzeit eines der effektivsten und robustesten Verfahren, solange genügend große Mengen an Trainingsdaten zur Verfügung stehen (siehe Domingos 2016). Typischerweise werden bei der Bildanalyse tiefe neuronale Netze (Convolutional Neural Network = CNN oder ConvNet) verwendet, die aus einer Eingangsschicht, einer Ausgangsschicht und mehreren verborgenen Schichten bestehen (LeCun et al. 2015).

Zum Anlernen des Klassifikators wurde die Methode des sogenannten überwachten Lernens verwendet. Beim überwachten Lernen beobachtet der Klassifikator einige Eingabe/Ausgabe-Paare und lernt eine Funktion, die Eingaben auf Ausgaben abbildet, aus den Trainingsdaten (LeCun et al. 2015). Nachdem der Algorithmus angelernet wurde, wird das Modell mittels Validierungsdaten überprüft. In dem hier vorgestellten Fall besteht die Eingabe aus Kamerabildern der Reinigung und die Ausgabe entspricht der Antrocknungszeit der

Schmutzschicht vor Reinigungsbeginn. Da es sich hierbei um eine endliche Menge von Ausgabewerten handelt, wird dieses Lernproblem als Klassifizierung von Bilddaten bezeichnet.

Im Zusammenhang der Merkmalsextraktion spielt die Vorverarbeitung der Bilddaten eine essentielle Rolle, um sicherstellen können, dass die gelernte Funktion einen repräsentativen Zusammenhang zwischen Eingabe und Ausgabe herstellt. Ohne Vorverarbeitung kann einerseits das Lernproblem zu groß werden und andererseits die Gefahr besteht, dass der Klassifikator aus den Trainingsdaten korrelierte Bildinhalte abbildet. Bei der Vorverarbeitung muss selbstverständlich gewährleistet werden, dass die wesentlichen Merkmale im Bild bleiben.

So wurden im vorgestellten Beispiel ein erster Vorverarbeitungsschritt definiert, bei dem aus den Kameraaufnahmen ein passender Bildausschnitt gewählt, in ein Graubild umgewandelt wird, verschiedene Filter (Median- und Gaußfilter) angewendet werden und abschließend normiert wird. Im zweiten Vorverarbeitungsschritt folgen weitere Filter, eine Kantendetektion über den Sobel-Filter und das finale Zuschneiden der Bildausschnitte. In Abb. 3 ist die Vorverarbeitung der Kameraaufnahmen zusammengefasst dargestellt.

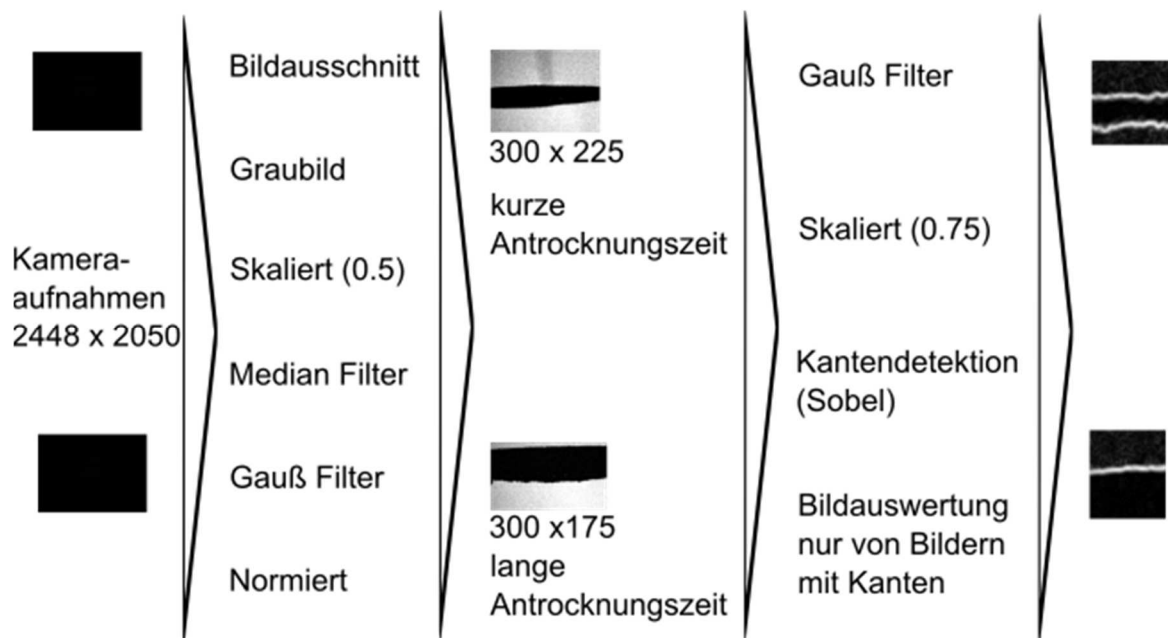


Abb. 3 Vorverarbeitung der Kameraaufnahmen

Da jeder Reinigungsversuch zweimal durchgeführt wurde, ergab sich die Aufteilung der Bilddaten in Trainings- und Validierungsdaten auf jeweils einen Versuchsdurchlauf. Mittels der Trainingsdaten wurde der Algorithmus angelern und mittels der Validierungsdaten überprüft. Dazu wurden jeweils 30.000 Trainings- und Validierungsbildausschnitte mit einer und 24 Stunden Antrocknungszeit generiert, also insgesamt 120.000 Bildausschnitte, indem aus den vorhandenen Kameraaufnahmen zufällige Bildausschnitte herausgeschnitten wurden. Zum Anlernen wurden nur Kameraaufnahmen verwendet, bei denen eine Kante detektiert wurde.

## Ergebnisse

Die Netzwerkarchitektur (LeCun et al. 2010) des angelernten Bildklassifikators besteht aus mehreren verborgenen Schichten (Conv2D, maxPooling), einer Eingangsschicht und einer Ausgangsschicht. Die Eingangsschicht entspricht den Pixeln der Bildausschnitte nach der Vorverarbeitung, während die Ausgangsschicht den Vorhersagewert darstellt und somit

ausgibt, ob entweder eine kurze (1h) oder eine lange (24h) Antrocknungszeit der Verschmutzungsschicht vorliegt. Die detaillierte Architektur kann Tabelle 2 entnommen werden.

Tabelle 2: künstliche neuronale Netzwerkarchitektur

Layer	Output Shape
gaussian_noise	48, 48, 1
Conv2D	46, 46, 8
Conv2D	44, 44, 8
Conv2D	42, 42, 8
MaxPooling	21, 21, 8
Conv2D	19, 19, 8
Conv2D	17, 17, 8
Flatten	2312
Dense	2

Der angelernte Bildklassifikator kann mit einer Trainingsgenauigkeit von über 70 % eine Einteilung von Bilddaten anhand ihrer Antrocknungszeit vornehmen. Um den Klassifikator zu validieren, wird die Sicherheit bestimmt, mit der ein Einzelbild vorhergesagt wird. Die Sicherheit wird bestimmt durch die Anzahl der richtig eingeteilten Bildausschnitte durch die Gesamtanzahl der Bildausschnitte für ein Bild. Um die Sicherheit für ein einzelnes Gesamtbild zu bestimmen, wurden Beispielbilder, siehe Abbildung 4 und 5, die dem Klassifikator beim Trainieren nicht zur Verfügung standen, verwendet. Diese Beispielbilder wurden auf die gleiche Weise vorverarbeitet wie die Kameraaufnahmen mit denen die Funktion des künstlichen neuronalen Netzes angelernt wurde. Aus einem Beispielbild wurden auf diese Weise 100 Bildausschnitte generiert, die vom Klassifikator bewertet wurden.




Abb. 4: Bildausschnitte der aufgenommenen Reinigungsspuren in Senfverschmutzungen nach 1-stündiger Antrocknungszeit; Vorhersagegenauigkeit von links nach rechts: 67%, 60%, 70%, 70%




Abb. 5: : Bildausschnitte der aufgenommenen Reinigungsspuren in Senfverschmutzungen nach 24-stündiger Antrocknungszeit; Vorhersagegenauigkeit von links nach rechts: 79%, 60%, 74%, 81%

Für eine Antrocknungszeit von 24h kann eine Einzelbildsicherheit für dem Klassifikator unbekannte Bilddaten von 80% erreicht werden. Die Einzelbildsicherheit wurde über die 100 generierten Bildausschnitte, die aus einem Beispielbild generiert wurden, bestimmt. Diese Sicherheit ist ausreichend, um das Abtrageverhalten der Schmutzschicht abzuschätzen und vorhersagen zu können, ob es sich um die Verhaltensweise einer Verschmutzung nach einer langen oder einer kurzen Antrocknungszeit handelt. Somit können dem automatischen, selbstlernenden Inline-System Informationen über den Prozess übergeben werden, die zur

Optimierung der Prozesseigenschaften herangezogen werden können. Folglich können die Prozessinformationen, die mittels künstlicher neuronaler Netze aus den Bilddaten gewonnen wurden, über eine orts- und zeitgebundene Bahnplanung in eine optimierte Parameterplanung umgesetzt werden.

### **Dankesworte**

Die Autoren danken der Forschungsvereinigung Forschungskreis der Ernährungsindustrie e.V. (FEI) für die Förderung der vorgestellten Projektarbeiten über die AiF im Rahmen des Programms zur Förderung der Industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Energie. AiF-Projekt Nr. 18820 N

### **Literatur**

**Liu, W., Zhang, Z., Christian, G.K., Fryer, P. J., 2003:** „Direct Measurement of the Forces Required to Disrupt and Remove Fouling Deposits,“ Heat Exchanger Fouling and Cleaning: Fundamentals and Applications, Bd. Art. 25, pp. 1-8, 2003.

**Boye, A. 2013:** Empfehlungen zur Auslegung effektiver Behälterreinigungssysteme. Merkblätter für Mikrobiologie und Hygiene, Merkblatt No. 111/2013, Hrsg.: Industrievereinigung für für lebensmitteltechnologie und Verpackung e.V. (IVLV), 2013.

**Ostwald, C., Hesse M., Boye A., Groß F., Majschak J., Delgado A., 2017:** „Automatisierung einer adaptiven Behälter-CIP- Reinigung in der Lebensmittelindustrie“, ProcessNet; 13. – 17. Februar 2017

**Sun, Y., Wang X., Tang X., 2014:** Deep Learning Face Representation from Predicting 10,000 Classes, (CVPR2014)

**Domingos P., 2016:**“ A Few Useful Things to Know about Machine Learning”; Department of Computer Science and Engineering;University of Washington;Seattle, WA 98195-2350, U.S.A., pedrod@cs.washington.edu

**LeCun Y., Bengio Y., Hinton G., 2015:** “Deep learning”, 444 | NATURE | VOL521 | 28MAY2015

**LeCun Y., Kavukcuoglu K., Farabet C., 2010:** “Convolutional Networks and Applications in Vision“ Computer Science Department, Courant Institute of Mathematical Sciences, New York University; Proceedings of 2010 IEEE International Symposium on Circuits and Systems