

## Schaum- und Füllstanderkennung mittels optischer Systeme mit neuronalen Algorithmen

### Foam and filling level detection with optical systems using neural algorithms

**Tobias Beck<sup>1</sup>, Bernhard Gattermig<sup>1</sup>, Antonio Delgado<sup>1</sup>**

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

Schlagworte: Neuronale Algorithmen, Image Processing

Key words: neural algorithm, image processing


#### **Zusammenfassung**

Es wurde gezeigt, wie aus der Kombination einer vertikalen und horizontalen Anwendung eines Mittelwertfilters auf die vertikale Achse der Flasche auf der Kameraaufnahme die Pixel in Schaum und Flüssigkeit klassifiziert werden können. Der Einfluss der Größen der Filterkerne bzw. Maskengröße wurde ebenfalls untersucht. Es lässt sich ein Einfluss von 0,6 – 3% erkennen. Den größten Einfluss hat die Wahl des geeigneten Verfahrens zur Hintergrund Subtraktion. Das adaptive Verfahren hat eine deutliche Verbesserung gegenüber der festen Werte für die Hintergrundfilter ergeben. Bei der Klassifikation zwischen Schaum und Flüssigkeit liegen die Spitzenwerte für die Schaumpixel bei 80% und bei Flüssigkeit von 75%. Es hat sich vor allem gezeigt, dass die Auswertungen zu Beginn des Abfüllvorgangs große Störungen aufweisen. Ebenfalls wurde zur Klassifikation der Pixel ein künstliches Neuronales Netz der Matlab Toolbox „Neural Net Pattern Recognition“ verwendet. Bei der Klassifikation der Pixel schneidet das künstliche neuronale Netz mit einer Fehlerquote von 13% geringfügig besser ab.

#### **Einleitung**

In der Getränkeindustrie können saisonal bedingt erhöhte Nachfragen auftreten. Um diesen gerecht zu werden, können Getränkehersteller die Abfüllgeschwindigkeiten ihrer Abfüllanlagen anpassen. Eine höhere Abfüllgeschwindigkeit hat allerdings bei Schaumfähigen Getränken sowohl bei karbonisierten als auch nicht-karbonisierten Getränken eine erhöhte Schaumproduktion zur Folge. Ein Überschäumen der Getränke stellt dabei in mehrerer Hinsicht einen enormen Störfaktor dar. Zum einen wird bei einer zu hohen Schaumentwicklung die Flasche fälschlicherweise als vollständig Gefüllt erkannt werden und zum anderen sorgt das Überschäumen durch eine Kontamination der Produkthanlage und der Flaschen. Diese Kontamination bildet einen Nährboden für Keime die sowohl auf das Produkt als auch die Abfüllanlage im Hinblick auf die Hygiene negative Auswirkungen haben.

Daher ist eine zuverlässige Unterscheidung zwischen der flüssigen Phase und dem Schaum notwendig. Zum einen wird der Messfehler, der durch eine Füllstandmessung ohne Unterscheidung zwischen Schaum und Flüssigkeit zu einem falschen Getränkevolumen führt eliminiert. Zum anderen wird durch die separate Messung der Flüssigkeits- und Schaumhöhe eine Kontrolle der Schaumentwicklung möglich. Die Schaumentwicklung kann zum einen durch eine kurzzeitige Anpassung der Füllgeschwindigkeit als auch durch physikalische Aktoren gesteuert werden. Mit Hilfe von optischen Sensoren kann der Füllstand bzw. das Füllvolumen einer Flaschen während des Prozesses mit modernen Methoden der Bilderkennung ermittelt werden. Durch Erkennung des Bildbereichs, der dem Innenraum der Flasche entspricht, können schon mit einfachen Schwellwertverfahren Pixel klassifiziert werden. Die Pixel werden hierbei in die Klassen Hintergrund, Schaum und Flüssigkeit eingeteilt. Die Schwierigkeit bei solchen Verfahren liegt bei den meist stark variablen Umgebungsbedingungen innerhalb von Abfüllanlagen (z.B. Reflexionen auf Flaschen). Um diese Einflüsse alle bei einem Algorithmus der digitalen Bildverarbeitung kompensieren zu können kommt daher ein neuronaler Algorithmus zum Einsatz. Dieser ist im Vorfeld auf der Grundlage vieler Aufzeichnungen von Abfüllungen verschiedenster Säfte auf die unterschiedlichen Umgebungseinflüsse antrainiert und optimiert worden. Der neuronale Algorithmus stellt daher eine adaptive Möglichkeit zur Erkennung von Saft – und Schaumhöhe dar.



**Abbildung 1:** (links) Anlagenschema der Versuchsanlage mit Leitreehner, Kamera und Flasche. Beispiele für die Kameraaufnahmen (mitte) und mögliche Netzarchitektur (rechts)

## Material und Methoden

Zur schnellen Prozessüberwachung während des Abfüllvorgangs sollen im Folgenden zwei Methoden gegenüber gestellt werden. Das Image Processing bedient sich der Kombination aus Mittelwert-Filtern und untersucht die Abhängigkeit der Filterwahl und der Hintergrundfilterung. Der Abschnitt zu künstlichen Neuronalen Netzen soll die Möglichkeit prüfen, ob mit wenigen Testdaten vergleichbare Resultate wie mit der Filteranwendung und Schwellwertsegmentierung erreicht werden könne.

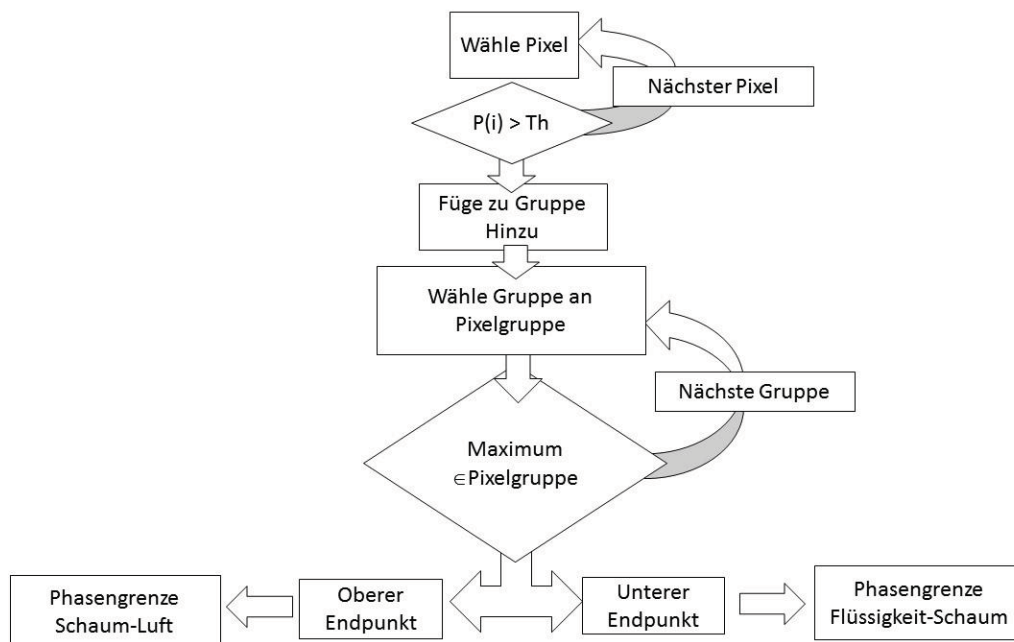
### Image Processing

Für die optischen Messung des Füllstands und der Schaumdicke über dem Flüssigkeitspegel wird jeder Frame einer Aufzeichnung des Abfüllvorgangs ausgewertet. Die Aufnahmen werden zunächst mit einem Mittelwertfilter (Filtergröße in Pixel: 5, 10, 15) entrauscht. Die Graustufenwerte entlang der vertikalen Achse der Flasche werden anschließend in der horizontalen mit einer Mittelwertmaske (Maskengröße in Pixel: 5, 10, 15) zusammengefasst.

Die *interframe difference* soll zum einen Bewegung erkennen, sowie den Hintergrund für die weitere Verarbeitung eliminieren [1]. Die *interframe difference* stellt die zeitliche Ableitung der Pixelintensitäten über die Zeit, bei konstanten Ort dar. Für ein Bild wird aus allen Pixeln der *root mean square interframe difference* Wert herangezogen, um anhand eines Schwellwert-

Verfahrens eine Grenze festzulegen, ab wann der Abfüllvorgang als „Begonnen“ angesehen wird. Für die Eliminierung von Hintergrundeinflüssen und statischen Pixeln werden die Frames, erst ab einem Schwellwert für die *RMS interframe difference* für die Berechnung abzüglich der vor den Schwellwert aufgenommenen Bilde weiterbearbeitet.

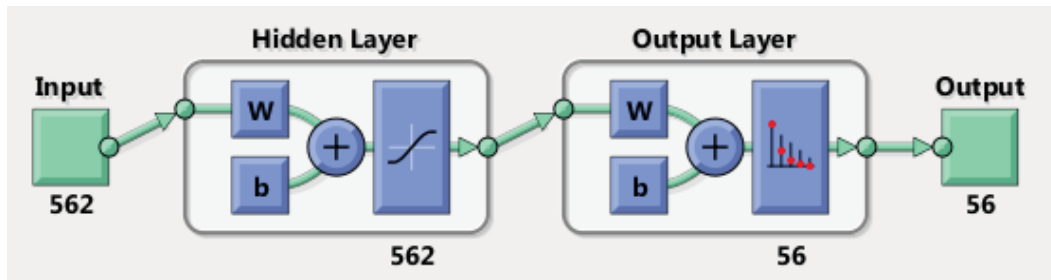
Die Weiterverarbeitung erfolgt nach dem Schema, welches in Abbildung 2 abgebildet ist. Die Pixel werden zunächst Gruppen zugeordnet, sofern sie den Schwellwert  $Th$  übersteigen. Im nächsten Schritt wird die Gruppe, der die Maximale Schaumzugehörigkeit am nächsten ist ausgewählt. Die Endpunkte der Pixelgruppe werden dabei den Phasengrenzen zugeordnet. Oberhalb des Maximums befindet sich die Oberkante des Schaums und unterhalb des Maximums die Unterkante des Schaums.



**Abbildung 2:** Klassifizierungsschema der Bildpunkte entlang der Achse. Für die finale Einsortierung in die Klassen „Phasengrenze Schaum-Luft“ bzw. „Phasengrenze Flüssigkeit-Schaum“ werden die jeweiligen Endpunkte der Pixelgruppe „Schaum“ verwendet.

## Neuronale Netze

Zur Bestimmung der Phasengrenzflächen zwischen Saft/Schaum und Schaum/Luft kann auch ein neuronales Netz herangezogen werden. Als Netzarchitektur wurde das neuronale Netz der in Matlab implementierten Toolbox „Neural Net Pattern Recognition“ herangezogen, welches ein sogenanntes „*feed forward back propagation*“ Netz darstellt [2]. Das Netz besteht aus 2 Lagen, welche mit einer flexiblen Anzahl an Neuronen ausgestattet werden kann. Diesem Netz wird eine Eingangsmatrix übergeben, welche verschiedene Attribute enthält. Zu dieser Matrix wird auch eine Ausgangsmatrix bereitgestellt, die bereits Vorklassifizierte Schaumdicken auf Basis der gegebenen Daten enthält. Die Klassifizierung erfolgt manuell durch den Nutzer. Durch unterschiedliche Gewichtungen der Neuronen, wird das Netz solange an die Datensets angepasst, bis der Fehler ein Minimum erreicht.



**Abbildung 3** Grafische Darstellung des neuronalen Netzes mit 562 Eingangsparametern, 562 Neuronen in der 1ten Schicht, 56 Neuronen in der 2ten Schicht und 56 Klassen.

Als Inputdaten werden Linienprofile der Pixel bereitgestellt, die an der Rotationsachse der Flasche verlaufen. Die Grauwerte der insgesamt 562 Pixel pro Linienprofil werden jeweils als eigene Attribute in das Neuronale Netz eingespeist, um es anzulernen. Je nach Netzarchitektur kann der Schaum in eine unterschiedliche Anzahl an Klassen eingeteilt werden, die jeweils unterschiedliche Schaumdickenbereiche abdecken. In diesem Fall wurden 56 verschiedene Klassen vorgegeben, die manuell vorsortiert wurden. Zum Anlernen des Netzes wurden 371 Linienprofile genutzt: 70% wurden für das Training verwendet; 15% für die Validierung und 15% für den finalen Test.

### Bewertung der Genauigkeit

Zur Bewertung der Genauigkeit der Algorithmen sind alle zugrunde liegenden Bilder bei verschiedenen Abfüllgeschwindigkeiten zunächst per Hand segmentiert. Für jedes Bild existiert ein Datensatz der die Klassifizierung der Pixel als Kontrollwert enthält. Die Genauigkeit wird mit dem Verhältnis der Falsch zugeordneten Pixel bezogen auf die gesamte Zahl der Pixel dargestellt.

### Versuchsstand


Für die Abfüllversuche kam eine Messkammer zum Einsatz, die einer VDF-Flasche nachempfunden ist. Zur Verbesserung der Schaumanalyse befindet sich an drei Seiten der Versuchskammer eine plane Glasfläche. Der Konus der Flasche ist auswechselbar. Ein Abfüllröhrchen mit einem Innendurchmesser von 10 mm befüllt die Flasche mit einem Freistrahldirekt über dem Mundstück. Mit einem Labornetzteil wird die Leistung der Tauchpumpe im Vorlagebehälter eingestellt und der Durchfluss zwischen 22 und 44 L/min variiert. Den Abfüllvorgang nimmt eine CMOS Kamera UI-3280CP-C-HQ Rev.2 der Firma IDS (Ettlingen, Deutschland) auf. Die softwareseitige Umsetzung der Kamera erfolgte mit dem SDK der Kamera sowie den Einlese Routinen der OpenCV (3.4.0) Bibliothek. Die Programmierung basiert auf einer eigens konzipierten Software auf C/C++-Basis und Windows SDK Version 10.0.16299.0.

### **Ergebnisse und Diskussion**

Die Ergebnisse aus den vorgestellten Methoden werden zunächst für die Auswertung der Abfüllaufnahmen mittels der Kombination der Filter-Algorithmen dargestellt. Die Ergebnisse in graphischer Form für eine Aufnahme und der Einfluss der Parameter sind im Folgenden aufgeführt. Die Ergebnisse der Filter-Kombinationen werden anschließend den Ergebnissen des künstlichen neuronalen Netzes gegenübergestellt.

## Ergebnisse des Image Processing

Die Erkennung der Pixelzugehörigkeit zu den Klassen Saft und Schaum erfolgte zunächst für drei Kameraaufnahmen eines Abfüllvorgangs. Die Dauer der Aufnahmen variierte Programmbedingt. Durch die Korrekturen des Hintergrunds, wurden die Frames vor Start des Abfüllvorgangs nicht für die Klassifizierung behandelt. Für einen Schwellwert für den zeitlichen Verlauf des RMS-Gradienten hat sich ein Wert von 158 als praktikabel erwiesen. Es ergibt sich für ihren jeweiligen Abfüllvorgang einen Peak bei Frame 32 bei Abfüllvorgang 1, bei 125 für Abfüllvorgang 2 und für den dritten Abfüllvorgang bei Frame 62.



**Abbildung 4:** Zugehörigkeit der Pixel zur Klasse „Schaum“ entlang der vertikalen Bildachse ohne Schwellwertverfahren. Für den kompletten Abfüllgang den Abfüllvorgang 1 (oben). Die resultierenden Verläufe über alle Frames aufgetragen über die Aufnahmedauer zeigen den steigenden Verlauf der Schaum- und Füllstandlevel (unten).

Nach Abzug der Hintergrundeffekte ergibt sich für Abfüllvorgang eins für die Frames 50, 100 und 150 eine Pixelzugehörigkeit zur Klasse „Schaum“. Der Schwellwert für die Wahl der Pixelgruppen ist der globale Mittelwert. In Abbildung 4 sind oben die Zugehörigkeiten der Pixelwerte zur Klasse „Schaum“ abgebildet. Wobei sich erkennen lässt, dass die Maxima mit steigender Frame Anzahl nach links wandern. Die Pixel werden von der Oberkante der Flasche gezählt, und somit ergibt sich bei der Betrachtung entlang der Zeitachse ein steigender Verlauf für den Saft und für den Schaum.

Die Variierung der Mittelwertfiltergröße in der vertikalen und der Mittelwertmaske in der horizontalen und der sich daraus ergebenden Kombination sind für die Positionen der Phasengrenzen in Bezug auf die Behältergröße ausgewertet worden. Aus den Sets für die Filter- bzw. Maskengrößen ergeben sich 9 mögliche Kombinationen. Die Anzahl der zugeordneten Pixel ist für drei verschiedene Toleranzbänder um die händisch vermessenen Positionen der Phasengrenzen ausgewertet. Für die Phasengrenze Saft-Schaum sind die Trefferquoten für die verschiedenen Kombinationen in Tabelle 1 dargestellt. Tabelle 2 enthält die Ergebnisse der Phasengrenze Schaum-Luft.

Maskengröße x-Richtung	Maskengröße y-Richtung	Toleranzband ±1%	Toleranzband ±5%	Toleranzband ±10%
5	5	38,6	65,6	75,0
5	10	38,6	65,3	74,6
5	15	38,6	65,3	75,0
10	5	38,0	65,0	74,6
15	5	38,3	65,0	75,0
10	10	38,0	65,0	75,0
15	10	38,3	65,0	75,0
10	15	38,0	65,0	75,0
15	15	38,3	65,0	75,0

**Tabelle 1:** Quote der korrekt zur flüssigen Phase zugeordneten Pixel über die Wertemenge entlang der vertikalen Bildachse

Maskengröße x-Richtung	Maskengröße y-Richtung	Toleranzband ±1%	Toleranzband ±5%	Toleranzband ±10%
5	5	34,0	51,3	80,3
5	10	34,0	51,0	80,0
5	15	33,6	51,0	79,6
10	5	34,0	49,3	78,3
15	5	33,3	49,3	77,0
10	10	34,0	49,3	78,0
15	10	33,0	49,0	77,0
10	15	33,3	49,3	77,6
15	15	33,0	49,0	77,0

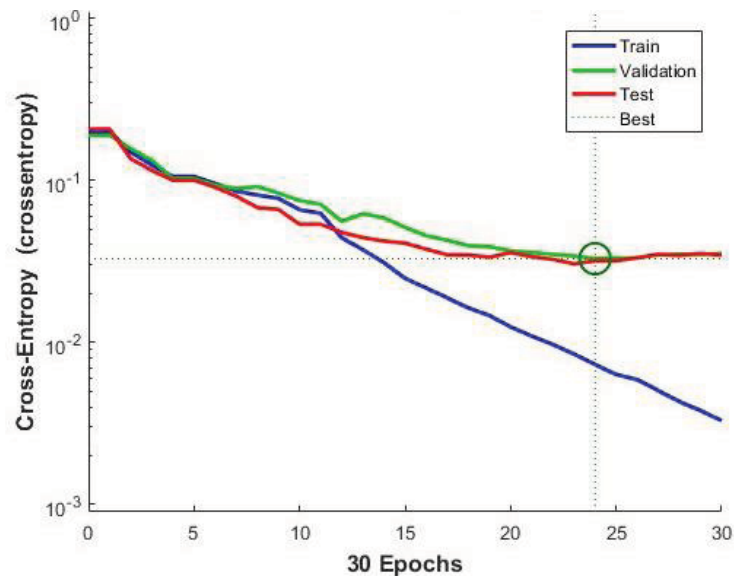
**Tabelle 2:** Quote der korrekt zur Schaumphase zugeordneten Pixel über die Wertemenge entlang der vertikalen Bildachse

### Ergebnisse des Neuronalen Netzes

Bereits nach 24 Epochen bzw. Lernzyklen wurde ein Fehlerminimum erreicht, der bei Abfüllvorgang 1,13 % liegt. Die Fehlerquote beim Testdatenset liegt allerdings bei 28,57%. Das Testdatenset besteht aus Daten, die nicht für das Training genutzt wurden und somit für das Netz unbekannt sind.

Um die Fehlerquote zu verringern, ist die Verwendung weiterer Attribute nötig. Infrage kommen unter anderem maximale und minimale Grauwerte in einem Linienprofil, die Steigungen des Profilverlaufes und der Abstand zwischen den Steigungen. Zusätzlich sollte auch ein größeres Ausgangsdatenset verwendet werden, um die Fehlerquote zu verringern. Des Weiteren können auch andere Netzarchitekturen verwendet werden, die mehr als 2 Lagen besitzen, um eine komplexere Netzarchitektur zu schaffen.





**Abbildung 4** Verlauf der Cross-Entropy über 30 Epochen. Bei Epoche 24 erreicht die Validierung den geringsten Fehler mit 33,93%. Das Testdatenset erreicht einen Fehler von 28,57%

## Zusammenfassung und Ausblick

Es wurde gezeigt, wie aus der Kombination einer vertikalen und horizontalen Anwendung eines Mittelwertfilters auf die vertikale Achse der Flasche auf der Kameraaufnahme die Pixel in Schaum und Flüssigkeit klassifiziert werden können. Der Einfluss der Größen der Filterkerne bzw. Maskengröße wurde ebenfalls untersucht. Es lässt sich ein Einfluss von 0,6 – 3% erkennen. Den größten Einfluss hat die Wahl des geeigneten Verfahrens zur Hintergrund Subtraktion. Das adaptive Verfahren hat eine deutliche Verbesserung gegenüber der festen Werte für die Hintergrundfilter ergeben. Bei der Klassifikation zwischen Schaum und Flüssigkeit liegen die Spitzenwerte für die Schaumpixel bei 80% und bei Flüssigkeit von 75%. Es hat sich vor allem gezeigt, dass die Auswertungen zu Beginn des Abfüllvorgangs große Störungen aufweisen. Ebenfalls wurde zur Klassifikation der Pixel ein künstliches Neuronales Netz der Matlab Toolbox „Neural Net Pattern Recognition“ verwendet. Bei der Klassifikation der Pixel schneidet das künstliche neuronale Netz mit einer Fehlerquote von 13% geringfügig besser ab. Die Implementierung in einen online-Messstand soll die nötige Datenbasis für das Antrainieren des Netzes bieten. Ebenso ist eine Kombination aus Filter-Kombination und kNN denkbar um mit vorprozessierten Daten Rechen- und Experimentierzeit zu sparen.

## Danksagungen

Ein Dank gilt den Projektpartnern im Rahmen des Projektes *Prozessführungsstrategie Getränkeabfüllung* (AiF 197211). Außerdem Herrn Andreas Baur, M. Sc. für die Unterstützung im Bereich der kNN.

## Literaturverzeichnis

1. S. Brutzer, B. Höferlin und G. Heidemann, „Evaluation of background subtraction techniques for surveillance,“ *CVPR*, pp. 1937-1944, 2011.
2. J. Nazari und OK. Ersoy, "Implementation of back-propagation neural networks with MatLab", *ECE Technical Reports*, Paper 275, 1992.