

Validierung und Weiterentwicklung einer neuen Auswertemethode zur Erkennung überlappender Blasen basierend auf dem Konzept von machine learning


Y. Atassi, A. Lange, S. Odenbach

Einleitung

Machine Learning ist eine Anwendung der künstlichen Intelligenz (KI). IT-Systeme lernen automatisch Muster und Zusammenhänge aus Daten und verbessern sich, ohne explizit programmiert zu sein. Machine Learning unterstützt uns seit vielen Jahren erfolgreich in Wirtschaft, Forschung und Entwicklung. Machine Learning kann automatisiert Wissen generieren, Algorithmen trainieren, Zusammenhänge identifizieren und unbekannte Muster erkennen. Diese identifizierten Muster und Zusammenhänge lassen sich auf einem neuen, unbekanntem Datensatz anwenden, um so Vorhersagen zu treffen und Prozesse zu optimieren.

Blasenströmungen treten in einer Vielzahl technischer Anwendungen aus dem Bereich der Energie- und Verfahrenstechnik auf und sind gekennzeichnet durch eine kontinuierliche Flüssigphase, in der eine dispergierte Gasphase in Form von Gasblasen vorliegt. Für die Entwicklung von Modellen, die zur Berechnung der Strömung mit numerischen Strömungssimulationen notwendig sind, werden präzise und zuverlässige experimentelle Daten benötigt. Als eine der gängigsten Messmethoden von Blasenströmungen mit geringer Blasenbelastung haben sich optische Messungen mit Hochgeschwindigkeitskameras bewährt. Wichtig ist hierbei eine genaue Unterscheidung von sich überlappenden Gasblasen aus den gewonnenen Bilddaten. Da für eine ausreichende Statistik die Auswertung von größeren Bilddatenmengen notwendig ist, ist eine manuelle Auswertung nicht zielführend. Deshalb soll eine automatische Blasenenerkennung basierend auf einem existierenden Segmentierungsalgorithmus umgesetzt werden, die universell in Gas-Flüssig-Zweiphasenströmungen eingesetzt werden kann.

Abb. 1: Der Aufbau des Experiments



Vorgehen

Mask R-CNN ist ein Convolutional Neural Network (CNN) und auf dem neuesten Stand der Technik in Bezug auf Bildsegmentierung und Instanzsegmentierung. Mask R-CNN wurde auf der Grundlage von Faster R-CNN, einem Region-Based Convolutional Neural Network, entwickelt. Der erste Schritt zum Verständnis der Funktionsweise von Mask R-CNN erfordert ein Verständnis des Konzepts der Bildsegmentierung. Die Bildsegmentierung ist der Prozess der Aufteilung eines digitalen Bildes in mehrere Segmente (Gruppen von Pixeln, auch als Bildobjekte bezeichnet). Diese Segmentierung wird verwendet, um Objekte und Grenzen (Linien, Kurven usw.) zu lokalisieren. Es gibt 2 Hauptarten der Bildsegmentierung, die unter die Maske R-CNN fallen: semantische Segmentierung und Instanzsegmentierung




Abb. 2: Architektur des Mask R-CNN

Bei der semantischen Segmentierung wird jedes Pixel in einen festen Bereich von Kategorien eingeteilt, ohne dass die Objektinstanzen unterschieden werden. Mit anderen Worten: Bei der semantischen Segmentierung geht es um die Identifizierung/Klassifizierung ähnlicher Objekte als eine einzige Klasse auf Pixelebene.




Abb. 3: Unterschied zwischen semantischer Segmentierung und Instanzsegmentierung

Ergebnisse

Zur Bewertung der Ergebnisse der Segmentierung werden die Qualitätsmetriken Intersection over Union (IoU) verwendet. Die IoU zwischen einer vom Objekterkennungsmodell bestimmten Bounding-Box und der ground-truth Bounding-Box kann aus deren Überlappungsfläche geteilt durch die vereinigte Fläche errechnet werden.




Abb. 4: Intersection over Union (IoU) als Maß für die Ähnlichkeit bei der Objekterkennung auf Bildern

Zunächst wurde die Abhängigkeit der Modellleistung vom Überlappungsschwellwert τ analysiert, einem der wichtigsten Parameter hinsichtlich der Segmentierung von Blasen in Blasenströmungen. In den Abbildung sind die Veränderung von mAP-90% in Abhängigkeit vom Überlappungsschwellwert τ dargestellt (mAP-90%: mean average precision (mittlere durchschnittliche Genauigkeit) in der Objekterkennung ist 90%). Um die drei Modelle (Kim, Bub-auto und Mask R-CNN) vergleichbar bewerten zu können, ist die ground-truth (hier: die getrennte Blasenränder) für überlappende Blasen erforderlich. Die Bewertung wurde anhand von synthetischen Blasenbildern durchgeführt.

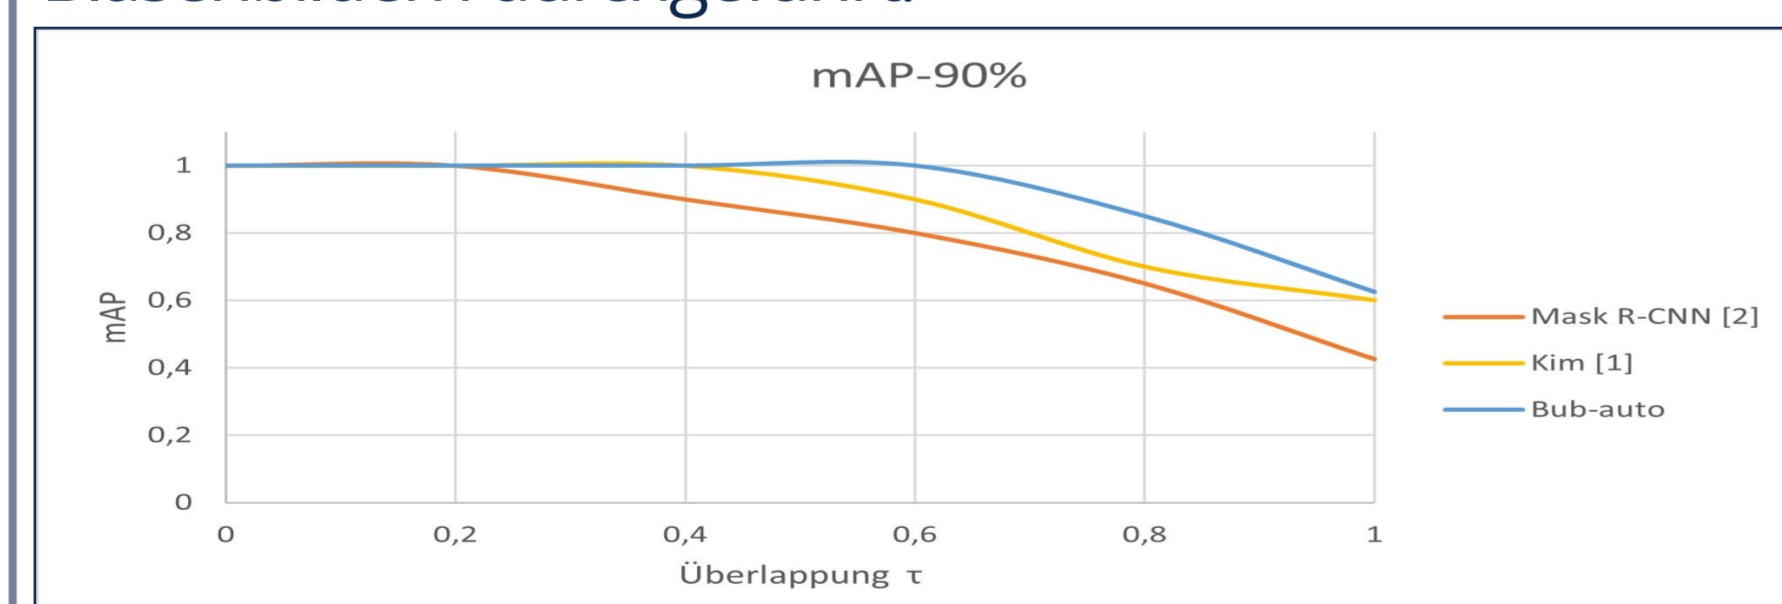


Abb. 5: Darstellung der Veränderung von mAP-90% in Abhängigkeit vom Überlappungsschwellwert τ

Bei mAP-90% erreicht das Modell Kim [1] bis zu Überlappungsschwellwerten von $\tau = 0,4$ gleiche Ergebnisse wie das hier entwickelte Modell Bub-auto. Ab einem Überlappungsschwellwert von $\tau = 0,4$ werden die Ergebnisse schlechter als bei Bub-auto. Das Modell Bub-auto liefert im Durchschnitt über alle Überlappungsschwellenwerte um 11,7% bessere Ergebnisse als das Modell Matterport Mask R-CNN [2] und um 4,6% bessere Ergebnisse als das Modell Kim [1]. Die maximale Verbesserung durch das Modell Bub-auto ist bei $\tau = 0,8$ bzgl. mAP-90% mit 15% im Vergleich zum Modell Kim [1] zu beobachten.




Abb. 6: Bsp. für synthetische Bilder mit Überlappungsschwellwert $\tau = 0,6$

Zusammenfassung und Ausblick

Die Abbildung zeigt die mittlere durchschnittliche Genauigkeit (mAP) des hier entwickelten Modells Bub-auto in Abhängigkeit vom IoU-Schwellenwert, bewertet anhand von drei Testdatensätzen.




Abb. 7: Die Veränderung der mittlerer durchschnittliche Genauigkeit (mAP) in Abhängigkeit vom IoU-Schwellenwert

Das hier entwickelte Modell Bub-auto zeigt eine hohe Genauigkeit bei allen mAP und war deutlich besser als das Modell U-Net. Das liegt daran, dass Bub-auto vom Typus Mask R-CNN ist, während die U-Net-Architektur auf einem Fully Convolutional Network basiert, das bei der medizinischen Bildgebung bessere Segmentierungsergebnisse liefert. Dagegen ist bei U-Net die Erkennungsgenauigkeit reduziert, was sich in den gezeigten Ergebnissen widerspiegelt




Abb. 8: Beispiele für die Erkennung von Blasen für Bub-auto

In der vorliegenden Arbeit wurde eine Studie mit synthetischen Bildern durchgeführt, um zu testen, inwieweit Mask R-CNN in der Lage ist, überlappende Blasen zu segmentieren. Es konnte festgestellt werden, dass bei Überlappungen bis zu 60% Mask R-CNN sehr gut in der Lage ist, diese überlappende Blasen zu segmentieren. Über Überlappungen von mehr als 60% verringert sich die Genauigkeit.

Referenzen

- [1]. Y. Kim and H. Park, "Deep learning-based automated and universal bubble detection and mask extraction in complex two-phase flows," *Scientific reports*, vol. 11, no. 1, p. 8940, Apr. 2021, doi: 10.1038/s41598-021-88334-0.
[2]. K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask R-CNN," Mar. 2017, [Online]. Available: <http://arxiv.org/abs/1703.06870>