

СИНТЕЗ ОБУЧАЮЩИХ ДАННЫХ ФЛОТАЦИОННОЙ ПЕНЫ ДЛЯ ПОВЫШЕНИЯ КАЧЕСТВА СЕГМЕНТАЦИИ

Камилов Э.М. (Университет ИТМО)

Научный руководитель – к.ф.-м.н., Фильченков А.А. (Университет ИТМО)

Введение. Методы синтеза обучающих данных для моделей глубокого обучения являются представляют большой интерес, особенно в связи с достижениями последнего десятилетия в создании искусственных изображений при помощи генеративных моделей. В текущем докладе будет рассмотрена возможность синтеза обучающих данных в задачах сегментации флотационной пены.

Основная часть. В настоящий момент для минимизации расходов на промышленных предприятия активно внедряются автоматизированные системы управления и системы поддержки принятия решений с использованием систем компьютерного зрения и методов машинного обучения. Достижения последних десятилетий в области глубокого обучения, а также совершенствование аппаратного и программного обеспечения, способствовали переходу от классических методов компьютерного зрения к алгоритмам на основе глубокого обучения. Однако, системы компьютерного зрения на основе глубокого обучения требовательны к качеству и количеству данных для обучения.

В частности, системы анализа флотационной пены направлены на определение физических характеристик пены, таких как: распределение размеров пузырьков, распределение форм пузырьков, цвет пены, подвижность и стабильность пены [1]. До недавнего времени, для вычисления этих характеристик в основном использовались классические методы компьютерного зрения [2], но такие методы имеют невысокую точность из-за недетерминированной задачи, учитывая, что кроме различий в работе флотационной машины, могут быть и различные условия освещенности и запыленности на производственном объекте.

Методы компьютерного зрения на основе глубокого обучения призваны устранить недостаток классических методов в виде низкой вариативности изображений, при которых сохраняется приемлемая точность. В случае разработки системы определения распределения размеров задача сводится к классификации [3, 4] или сегментации изображений [5, 6]. При контролируемой классификации распределения пузырьков зачастую используется набор из пяти классов, предложенный в [7].

Метки классов для обучения глубоких моделей подготавливаются с использованием сочетания классических методов компьютерного зрения и ручной разметки. Разметка классов является ресурсоемкой задачей, учитывая типично большое количество изображений для обучения сверточных нейронных сетей и особенно при разметке масок для сегментации, где необходимо обработать каждый пиксель изображения. Недостаточность обучающих данных, их низкая репрезентативность зачастую приводит к переобучению модели и низкому качеству на тестовой выборке. Искусственный синтез обучающих данных является одним из потенциальных решений проблемы труднодоступности обучающих данных и уже нашёл широкое применение в анализе медицинских данных и разработке автопилотов. Для синтеза данных в задаче пенной флотации можно рассмотреть как генеративные нейронные сети, такие как VAE, GAN, так и 3D-моделирование с использованием математических моделей гидродинамики.

Заключение. Методы на основе глубокого обучения лучше справляются с недетерминированными задачами, однако для них необходима более объемная и репрезентативная база изображений для обучения. В связи с переходом промышленных предприятий с классических систем компьютерного зрения на системы на основе методов глубокого обучения повышается спрос на обучающие данные для моделей глубокого

обучения в специфических областях. Искусственный синтез данных способен решить проблему нехватки данных и улучшить точность предсказания существующих моделей.

Список использованных источников

1. Aldrich C., Avelar E., Liu X. Recent advances in flotation froth image analysis // Minerals engineering. – 2022. – Т. 188. – С. 107823.
2. Le Roux J. D. et al. A survey on the status of industrial flotation control // IFAC-PapersOnLine. – 2020. – Т. 53. – №. 2. – С. 11854-11859.
3. Zarie M., Jahedsaravani A., Massinaei M. Flotation froth image classification using convolutional neural networks // Minerals Engineering. – 2020. – Т. 155. – С. 106443.
4. Fu Y., Aldrich C. Using convolutional neural networks to develop state-of-the-art flotation froth image sensors // IFAC-PapersOnLine. – 2018. – Т. 51. – №. 21. – С. 152-157.
5. Gharehchobogh B. K. et al. Flotation froth image segmentation using Mask R-CNN // Minerals Engineering. – 2023. – Т. 192. – С. 107959.
6. Zhang L., Xu D. Flotation bubble size distribution detection based on semantic segmentation // IFAC-PapersOnLine. – 2020. – Т. 53. – №. 2. – С. 11842-11847.
7. Moolman D. W. et al. The interpretation of flotation froth surfaces by using digital image analysis and neural networks // Chemical Engineering Science. – 1995. – Т. 50. – №. 22. – С. 3501-3513.

Камилов Э. М. (автор)

Подпись

Фильченков А. А. (научный руководитель)

Подпись