УДК 620.179:004.8

ИСПОЛЬЗОВАНИЕ СИНТЕТИЧЕСКИХ ДАННЫХ ДЛЯ ПОВЫШЕНИЯ ТОЧНОСТИ СЕГМЕНТАЦИИ ДЕФЕКТОВ ВНУТРЕННЕЙ ПОВЕРХНОСТИ ТРУБ

Голичников Д.А. – аспирант, Кашников Д.А. – аспирант,
Шакин Д.А. – аспирант, Манцеров С.А. – д.т.н., доцент,
ФГБОУ ВО «Нижегородский государственный технический университет имени Р.Е. Алексеева»,
Россия, г. Нижний Новгород

Одной из ключевых задач технического диагностирования трубопроводных систем является выявление и количественная оценка дефектов внутренней поверхности труб [1]. В условиях эксплуатации промышленного оборудования получение репрезентативного и достаточно большого массива реальных изображений дефектов затруднено: съёмка проводится в сложных условиях, часть объектов недоступна для прямого наблюдения, а разметка изображений требует значительных трудозатрат квалифицированных специалистов [2]. Это ограничивает возможности применения современных методов глубокого обучения, чувствительных к объёму и разнообразию обучающих данных.

Одним из подходов к решению данной проблемы является использование синтетических данных, позволяющих искусственно расширить обучающую выборку без проведения дорогостоящих натурных экспериментов [3]. Такие данные формируются с помощью средств 3D-моделирования и фотореалистичного рендеринга, что обеспечивает контролируемое варьирование геометрии сцены, параметров освещения, текстур поверхностей и характеристик самих дефектов. При этом для каждого синтетического изображения автоматически доступна точная пиксельная разметка, что особенно важно для задач семантической сегментации.

В данной работе для генерации синтетических данных использовалось программное обеспечение Blender. Данная среда позволяет строить трёхмерные модели фрагментов труб, задавать различные варианты дефектов (коррозионные повреждения, раковины, трещины, наплывы материала и пр.), а также моделировать реальные условия освещения и работы системы технического зрения [4]. Виртуальная камера настраивалась таким образом, чтобы имитировать параметры применяемого в стендовых испытаниях оборудования. Для каждого синтетического кадра формировались два изображения: визуализация внутренней поверхности трубы и соответствующая маска сегментации дефектов. Пример пары «изображение – маска» приведён на рисунке 1.

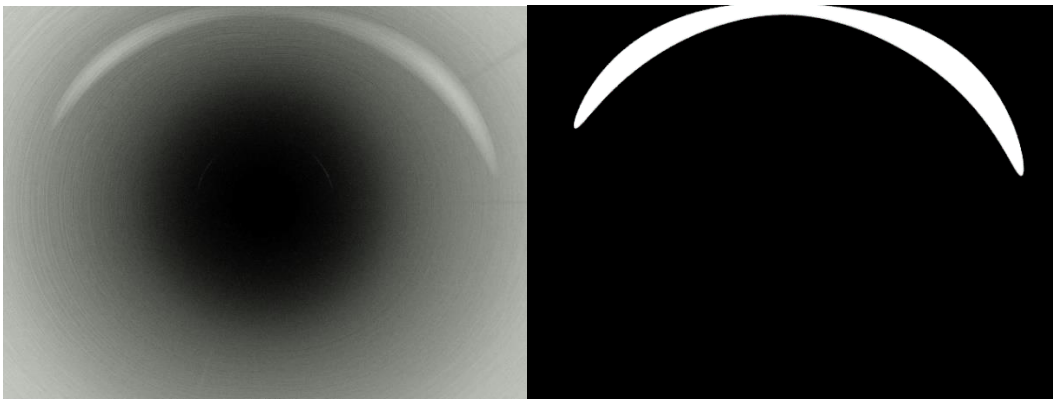

Рисунок 1 – сгенерированное изображение дефекта(слева) и маска(справа)

Сформированная синтетическая выборка использовалась совместно с реальными данными, полученными в ходе экспериментов. В качестве базовой рассматривалась модель, обученная только на реальных изображениях дефектов. Далее выполнялась серия экспериментов, в которых в обучающую выборку последовательно добавлялось различное количество синтетических данных: 10, 20, 30, 40 и 50 % от общего числа обучающих примеров. При этом объём валидационной и тестовой выборок оставался неизменным, что обеспечивало сопоставимость полученных результатов.

Для обучения модели использовалась сверточная архитектура сегментации (Efficientnetb7 + FPN [5]) с одинаковыми гиперпараметрами во всех сериях экспериментов. Входное разрешение изображений и набор аугментаций были предварительно определены в ходе исследований. В качестве функции потерь применялся Jaccard Loss, что обусловлено ориентацией задачи на максимизацию метрики IoU [6]. Обучение каждой модели проводилось до сходимости функции потерь или достижения ограничения по количеству эпох, после чего на тестовой выборке вычислялись целевые метрики качества.

Сводные результаты тестирования моделей приведены в таблице 1. Для каждой доли синтетических данных указаны размер модели, количество параметров, затраченное время обучения, номер последней эпохи, а также значения метрик IoU, Recall, Dice-коэффициент, F1-score, Precision, ошибка Jaccard Loss и среднее время обработки одного кадра.

Таблица 1 – Сравнение результатов тестирования моделей при различной доле синтетических данных

Процент синтетических данных, %	0 %	10 %	20 %	30 %	40 %	50 %
Время обучения	1ч 16мин 47 с	1ч 23мин 49 с	1ч 30мин 32 с	1ч 39мин 56 с	1ч 50мин 55 с	2ч 09мин 21 с

Последняя эпоха	36	40	43	31	30	29
Метрика IoU	0,663	0,673	0,677	0,678	0,674	0,664
Метрика Recall	0,397	0,418	0,432	0,439	0,446	0,438
Метрика Dice-коэффициент	0,656	0,673	0,676	0,673	0,679	0,665
Метрика F1-score	0,062	0,069	0,073	0,072	0,074	0,067
Метрика Precision	0,902	0,878	0,872	0,874	0,870	0,872
Ошибка Jaccard Loss	0,231	0,225	0,218	0,227	0,237	0,246
Время обработки кадра, мс	60	60	60	60	60	60

Анализ данных таблицы 1 показывает, что при добавлении умеренного количества синтетических данных (20–30 %) наблюдается небольшое улучшение ключевых метрик по сравнению с обучением только на реальных изображениях. Так, максимальное значение IoU (0,678) достигается при доле синтетических данных 30 %, а минимальное значение ошибки Jaccard Loss (0,218) – при доле 20 %. При дальнейшем увеличении доли синтетических данных до 40–50 % качество по метрикам IoU и Jaccard Loss начинает снижаться, что можно связать с ростом расхождения распределений реальных и синтетических изображений.

Отдельного внимания заслуживает поведение метрик полноты (Recall) и точности (Precision). С ростом доли синтетических данных Recall монотонно увеличивается вплоть до значения 0,446 при 40 % синтетических данных, что говорит о более полном нахождении дефектов моделью. Однако одновременно уменьшается Precision, то есть возрастает число ложных срабатываний. Это указывает на необходимость выбора компромисса между пропуском дефектов и избыточным количеством ложных предупреждений в зависимости от требований конкретной прикладной задачи.

Время обучения модели возрастает по мере увеличения доли синтетических данных, что связано с ростом общего числа обучающих примеров. При этом среднее время обработки одного кадра на тестовой выборке остаётся постоянным и составляет около 60 мс для всех вариантов, что обусловлено одинаковой архитектурой нейросети и идентичной реализации вычислительного конвейера. Следовательно, введение синтетических данных влияет в первую очередь на длительность этапа обучения, но практически не сказывается на производительности модели в режиме реального времени.

Таким образом, проведённое исследование демонстрирует целесообразность использования синтетических данных при решении задач сегментации дефектов внутренней поверхности труб. Добавление 20–30 % синтетических изображений к реальному датасету позволяет достичь лучшего сочетания метрик качества по сравнению с моделью, обученной исключительно на реальных данных, при умеренном увеличении времени обучения. При дальнейшем увеличении доли синтетических данных наблюдается ухудшение ряда показателей, что свидетельствует о необходимости аккуратного подбора объёма и структуры синтетической выборки. Дальнейшие исследования могут быть направлены на повышение фотореалистичности сгенерированных сцен, адаптацию распределений синтетических данных к реальным условиям съёмки, а также на изучение влияния различных стратегий совместного обучения на основе реальных и синтетических изображений.

Список литературы:

1. Nguyen C. L., Nguyen A., Brown J., Dang L. M. Sewer pipeline condition assessment and defect detection using computer vision // Automation in Construction. – 2025. – Vol. 158. – 106479.

2. Haurum J. B., Moeslund T. B. Sewer-ML: A Multi-Label Sewer Defect Classification Dataset and Benchmark // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). – 2021. – P. 13456–13467.

3. Tobin J. et al. Domain randomization for transferring deep neural networks from simulation to the real world // 2017 IEEE/RSJ international conference on intelligent robots and systems (IROS). – IEEE, 2017. – P. 23–30.

4. Denninger M. et al. BlenderProc: A procedural blender pipeline for photorealistic training image generation // Journal of Open Source Software. – 2020. – Vol. 5. – No. 54. – P. 2726.

5. Tan M., Le Q. V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks // International Conference on Machine Learning (ICML). – PMLR, 2019. – P. 6105–6114.

6. Rahman M. A., Wang Y. Automated Sewer Pipe Defect Detection Using Deep Learning Techniques // Automation in Construction. – 2020. – Vol. 119. – P. 103355.