

Повышение качества обнаружения и выделения дефектов на изображениях стальных конструкций

В.Е. Дементьев¹, М.А. Гапонова¹, М.Н. Суетин¹

¹Ульяновский государственный технический университет, Северный Венец 32, Ульяновск, Россия, 432027

Аннотация

В работе рассматриваются варианты повышения качества выделения дефектов на изображениях стальных конструкций на основе модификации процедур обучения с использованием технологии Transfer Learning. При этом вначале предлагается выполнять обучение кодирующего фрагмента сети (кодировщика) на известных наборах данных, а затем дообучать декодирующий фрагмент сети (декодировщика) на размеченном вручную специализированном наборе изображений поверхностных дефектов стальных конструкций. В работе делается вывод о сокращении времени обучения и повышения точности распознавания дефектов.

Ключевые слова

Семантическая сегментация, нейронные сети, дообучение, перенос обучения

1. Введение

Одной из важных задач компьютерного зрения является семантическая сегментация изображений [1-4], связанная с определением формы и положения объекта на изображении. Особую важность решение такой задачи имеет для определения характеристик тех или иных аномальных областей, например, наблюдаемых дефектов на изображениях стальных конструкций. Опыт показывает [5,6], что среди методов выделения подобных дефектов наилучшие результаты показывают методы глубокого обучения, связанные с использованием модификаций сверточных нейронных сетей семейства U-Net. Однако существенным препятствием на пути эффективного обучения становится сравнительно небольшой объем обучающей выборки.

В настоящей работе предлагается метод дообучения нейронной сети U-Net, позволяющий с помощью технологии переноса обучения (Transfer Learning) компенсировать недостаток размеченных изображений с дефектами наборами данных из смежных областей.

2. Перенос обучения в сверточных нейронных сетях

Пиксельная разметка изображений, необходимая для обучения нейронной сети U-Net, как правило, требует большой точности и связана со значительными временными затратами. Выходом в такой ситуации может быть комбинирование известных наборов размеченных данных в близких к исходной задаче областях и ограниченного объема размеченных вручную изображений (рис. 1).

Такое комбинирование может быть выполнено в рамках технологии переноса обучения (Transfer Learning). Процедура переноса обучения предполагает [3, 4], в частности, деление нейронной сети на две части (базовую и специализированную). Базовая часть, как правило, представляет собой первые слои нейронной сети, содержащие общие признаки детектируемых объектов независимо от типа решаемой задачи. Поэтому параметры нейронной сети на таких слоях можно переносить для решения других типов задач.




Рисунок 1: Разметка исходного изображения (рис. 1а) при детектировании объектов (рис. 1б) и семантической сегментации (рис 1в)

3. Описание эксперимента и результаты

В рамках представленного подхода фрагмент сети U-Net, соответствующий шифровальщика был дополнен классификатором из последовательности полно-связных слоев и обучен на изображениях трещин в бетоне (Surface Cracks Detection Database, Kaggle). Фрагмент сети U-Net, реализующий функции дешифровальщика дообучался на специализированном наборе из 175 размеченных фотоизображений. Обучение выполнялось в течении 100 эпох с шагом 10^{-4} . В качестве метрики при выборе оптимальных параметров специализированной части нейронной сети применяется коэффициент Сёрнсена (Dice Coefficient, DC). В таблице 1 приведены некоторые полученные в ходе дообучения результаты.

Таблица 1

Результаты обучения нейронной сети UNet

Обучение нейронной сети UNet	Число обучаемых параметров	Обучающая выборка (только отдельный дефект)		Обучающая выборка от РЖД (дефекты различных типов)	
		DC по набору для валидации	DC по набору для теста	DC по набору для валидации	DC по набору для теста
Обучение «с нуля»	7846657	0,73	0,71	0,72	0,71
Дообучение	3134433	0,81	0,79	0,8	0,77

Анализ представленных данных показывает, что подобный подход позволяет получить устойчивый выигрыш в 8-10% по коэффициенту Сёрнсена при выделении области дефекта.

4. Благодарности

Работа поддержана грантами РФФИ №18-47-730009 и 19-29-09048.

5. Литература

- [1] Ronneberger, O. U-Net: Convolutional networks for biomedical image segmentation / O. Ronneberger, F. Fischer, T. Brox // International Conference on Medical Image Computing and Computer-Assisted Intervention – MICCAI. Lecture Notes in Computer Science. – 2015. – Vol. 9351. – P. 1097-1105.
- [2] Горбачев, В.А. Семантическая сегментация спутниковых снимков аэропортов с помощью сверточных нейронных сетей / В.А. Горбачев, И.А. Криворотов, А.О. Маркелов, Е.В. Котлярова // Компьютерная оптика. – 2018. – Т. 44, № 4. – С. 636-645. DOI: 10.18287/2412-6179-CO-636.
- [3] Yosinski, J. How transferable are features in deep neural networks / J. Yosinski, J. Clune, Y. Bengio, H. Lipson. – 2014 [Electronical Resource]. – URL: <https://arxiv.org/pdf/1411.1792.pdf> (request date 11.01.2021).

- [4] Arua, D. Transfer Learning-based Road Damage Detection for Multiple Countries [Electronical Resource] / D. Arua, H. Maeda, S.K. Ghosh, D. Toshnival, A. Marz, T. Kashiya, Y. Sekimoto. – 2020. – URL: <https://arxiv.org/pdf/2008.13101.pdf> (request date 11.01.2021).
- [5] Дементьев, В.Е. Особенности разработки программного обеспечения для решения задач мониторинга состояния стальных и железобетонных изделий / В.Е. Дементьев, М.А. Гапонова, М.Н. Суетин // Современные проблемы проектирования, производства и эксплуатации радиотехнических систем. Сборник научных трудов. – Ульяновск, 2020. – С. 100-103.