

Снижение трудоемкости технологических операций с использованием систем компьютерного зрения

В.А. Печенин¹, Е.Ю. Печенина¹, А.В. Куприянов^{1,2}

¹Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

²Институт систем обработки изображений РАН - филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

Аннотация

Рассматривается ключевая часть системы компьютерного зрения предприятия – семантическая сегментация изображений – проекций моделей STL реальных деталей. Проведено сравнение точности работы трех архитектур сверточных нейронных сетей для пяти видов деталей.

Ключевые слова

Семантическая сегментация, компьютерное зрение, сверточная нейронная сеть, stl

1. Введение

В результате измерения деталей и сборок на оптических сканерах появляется фасетная модель в формате *.stl, к которой нельзя применять традиционные инструменты CAD-моделирования. Актуальной задачей является автоматизация и повышения точности обработки измеренных данных и создания виртуальных моделей деталей. Кроме того, для цифрового управления процессами на производстве в реальном времени требуется создание и внедрение системы компьютерного зрения. Такая система должна определять тип детали, поступающей на сборку и распознавать составляющие ее поверхности с целью ориентирования в пространстве и использования нужных данных для виртуальных расчетов. В работе рассматривается применение сверточных нейронных сетей для автоматизированной сегментации 2D-проекций STL моделей деталей.

2. Результаты исследований

Для проведения семантической сегментации были использовано пять деталей, для каждой детали была выполнена разметка четырех целевых граней, остальные грани деталей были закрашены одним отличающимся цветом. На рисунке 1 приведены размеченные 3D модели.




Рисунок 1: Разметка STL-объектов а) Лопатка ротора турбины; б) деталь №1 ; в) деталь №3 г) деталь №2; д) деталь №4

Для обучения нейронных сетей было проведено моделирование 1000 случаев различных положений и пространстве каждой детали. Размеры тестовых выборок составили по 50 случаев на каждую деталь. Для каждого экземпляра выборок (пара входные данные и выходные данные, в которые требуется преобразовать входные) было выполнено сохранение шести картинок-проекций (рисунок 2, а). Размер каждого изображения – проекции составил 480x480 пикселей. Для распознавания граней у каждого отдельного объекта была обучена своя

нейронная сеть. Для выполнения распознавания были использованы архитектуры U-net [20], SegNet [21] и Enet [22]. Выходные данные представляют собой проекции размеченных stl, где разными цветами обозначены целевые грани для распознавания (рисунок 2, б).




Рисунок 2: а) исходная проекция stl; б) размеченная проекция; распознавание с использованием в) U-net; г) Enet; д) SegNet

Нейронные сети для семантической сегментации были реализованы на языке Python с помощью библиотек keras и tensorflow. Все расчеты (обработка данных, подготовка обучающих и тестовых наборов, обучение нейронных сетей и расчет результирующих показателей) выполнялись на компьютере с процессором AMD Ryzen 7 2700 Eight-Core (8 ядер), с тактовой частотой 3,2 ГГц, объемом ОЗУ в 32 Гб и видеокартой NVIDIA GeForce GTX 1080 Ti с 12Gb видеопамяти. Время обучения нейронной сети U-net на используемом компьютере при 10 эпохах обучения составило 614,65 с. (на одну проекцию), Enet – 1334,43 с. и SegNet – 2210,02 с.

Для оценки качества сегментации тестовых выборок использовались показатели попиксельной точности и средней точности каждого сегмента (класса). Выявлено, что U-net не распознает часть проекций. Точность распознавания проекций, которые были распознаны U-net, выше чем у сетей Enet и SegNet. Сети Enet и SegNet распознали все проекции всех деталей, при этом точность Enet по многим проекциям составила выше 90%, а точность SegNet в лучшем случае достигает 73% (для лопатки). Таким образом, делается выбор в пользу использования для распознавания сети Enet.

3. Заключение

В результате проведенных исследований выявлено, что архитектура Enet является наиболее подходящей для решения поставленной задачи распознавания граней изделий. Обученная нейронная сеть является важной частью системы компьютерного зрения, которая позволит выполнять роботизацию сборки сложных высокоточных изделий, а также поможет существенно снизить трудоемкость и повысить точность расчета контрольных операций.

4. Благодарности

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках стипендии Президента Российской Федерации (номер СП-262.2019.5).

5. Литература

- [1] Ronneberger, O. U-net: Convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // Lect. Notes Comput. Sci. – 2015. – Vol. 9351. – P. 234-241.

- [2] Badrinarayanan, V. Segnet: A deep convolutional encoder-decoder architecture for image segmentation / V. Badrinarayanan, A. Kendall, R. Cipolla // IEEE transactions on pattern analysis and machine intelligence. – 2017. – Vol. 39(12). – P. 2481-2495.
- [3] Paszke, A. ENet: A Deep Neural Network Architecture for Real-Time Semantic Segmentation / A. Paszke, A. Chaurasia, S. Kim, E. Culurciello // CoRR. – 2016. – Vol. 1606. – P. 02147.