

## МЕТОДИКА ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ ДЛЯ СИСТЕМ МАШИННОГО ЗРЕНИЯ НА АЭРОКОСМИЧЕСКИХ ПРЕДПРИЯТИЯХ

*Печенина Е.Ю., Печенин В.А., Болотов М.А.*

*Самарский национальный исследовательский университет  
имени академика С.П. Королева, г. Самара*

**Ключевые слова:** машинное зрение, классификация, сверточная нейронная сеть, stl.

**Аннотация.** В статье рассмотрена важная часть создания и внедрения системы машинного зрения на промышленном предприятии – создание обучающей выборки и подбор нейронной сети классификации объектов. Предложена методика создания обучающего набора данных для классификации. Приведены две современные архитектуры нейронных сетей и сравнение точности классификации.

## TECHNIQUE FOR TRAINING NEURAL NETWORKS FOR MACHINE VISION SYSTEMS IN AEROSPACE FACTORIES

*Pechenina E.Yu., Pechenin V.A., Bolotov M.A.*

*Samara National Research University, Samara*

**Keywords:** machine vision, classification, convolutional neural network, stl.

**Abstract.** The article discusses an important part of creating and implementing a machine vision system at an industrial enterprise - creating a training sample and selecting a neural network for object classification. The proposed method for creating a training dataset for classification. Two modern architectures of neural networks are presented, the classification accuracy is compared.

### Введение

В силу ряда причин (плохая повторяемость достигаемых в производстве геометрических параметров, наличие пересборок после предварительных испытаний) до 50% трудоемкости изготовления двигателя занимает сборка. Несмотря на то, что сегодня в университетах и конструкторских отделах предприятий выполняется большой объем качественных исследовательских и инженерных расчетов, этап сборки является наименее автоматизированным и присущие ему проблемы зависимости качества и трудоемкости от квалификации персонала остаются во многом не решенными. Сборка является ресурсоёмкой комбинаторной задачей, детали подбираются по их индивидуальным геометрическим характеристикам, полученным в производстве.

Детали на предприятиях измеряются с использованием координатных средств измерений, информация по измерениям таким образом храниться и обрабатывается в электронном виде [1]. В то же время на складах и в цехах мелких и крупных предприятий скапливается значительное количество материальных ценностей. В процессе ревизий с целью проверки наличия, а также учёта движения материальных ценностей необходимо идентифицировать их соответствие учётным позициям, которые регистрируются в системе.

Эффективным решением для отслеживания деталей в производстве и предоставления необходимой информации по ним на этапе финальной сборки

являются системы машинного зрения, дополнительную гибкость которым добавит использование машинного обучения.

В настоящее время машинное зрение основывается на использовании высокопроизводительных видеокарт (аппаратная часть) и сверточных сетей [2, 3] (математическая и программная часть), последние набирают популярность в промышленности, в качестве инструмента идентификации геометрии деталей [4]. Таким образом, уникальной и важной составляющей систем машинного зрения являются нейронные сети, выполняющие задачи детектирования, классификации и сегментации. Важной частью создания работающей нейронной сети является ее обучение, целью данной статьи является создание методики эффективного обучения нейронной сети для классификации деталей авиационного машиностроения.

### Методика обучения и используемые архитектуры нейронных сетей

Для обучения нейронных сетей требуется большие объемы данных. Для повышения точности классификации [5], уменьшения эффекта перетренированности выполняется аугментация исходных данных. Если речь идет только о наборе изображений, то аугментация выполняется с помощью использования аффинных преобразований [6], изменения яркости, контрастности изображения, его цветности. Так как исходными данными являются объекты stl, проекции которых представляют собой набор изображений для входа в нейронную сеть, то при выполнении аугментации были использованы перемещения, развороты и изменение масштаба для координат вершин STL. Таким образом имитируется различное положение деталей относительно системы координат после измерения. При аугментации использовались как stl-сетки, полученные после сканирования деталей, так и stl, созданные по твердотельным моделям этих деталей.

Измерение деталей для обучения и тестирования нейросетей проводилось на сканере Range Vision Pro2M. На рисунке 1 приведены размеченные 3D STL модели деталей (деталь №1-4 и лопатка рабочего колеса турбины)




Рис. 1. STL-модели деталей а) Лопатка ротора турбины; б) деталь №1; в) деталь №3 г) деталь №2; д) деталь №4

Для создания входных данных, по которым будет классифицироваться деталь, создаётся три проекции модели stl на координатные плоскости:  $XOY$ ,  $YOZ$  и  $XOZ$ , пример изображён на рисунке 2. Таким образом, на вход в сеть подаются три изображения в оттенках серого, то есть три матрицы чисел, являющиеся входными «слоями». В целом на входе может быть из 1, 2 и более «слоев». Данные нормированы в диапазоне от 0 до 1.




Рис. 2. Stl-модель детали и три её проекции

Для оценки ошибок в задаче классификации можно использовать показатель доли правильно классифицированных объектов  $N_{\text{прав\_к}}$  в общем количестве объектов  $N_{\text{общ\_к}}$  выборки:

$$\delta_{\text{класс}} = N_{\text{прав\_к}} / N_{\text{общ\_к}}. \quad (1)$$

Соответственно если коэффициент равен 1, то получается 100% эффективность работы сети.

Архитектура первого варианта нейронной сети для классификации состоит из трех сверточных слоев [7], полносвязного слоя заканчивающейся слоем SoftMax. Данный слой выполняет нормализацию результатов предыдущего слоя таким образом, что на его выходе будут формироваться вероятности отношения объекта к рассматриваемым классам [8]. То есть на выходе из слоя softmax появляется  $n$ -чисел, равных числу классов, задаваемых при создании сети (в нашем случае три), изменяющихся 0 до 1. Порядковый номер наибольшего числа определяет класс, к которому относится объект.

В качестве конкурирующей архитектуры была рассмотрена модель VGG-19 Оксфордской лаборатории [9]. Модель VGG-19 состоит из 144 миллионов параметров.

### Результаты исследования

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.

В результате аугментации была создана обучающая выборка, составляющая 4000 объектов для пяти видов деталей, а также тестовая выборка, содержащая 400 объектов.

Для каждого из объектов было составлено 3 проекции-изображения в оттенках серого, размером 112×112 пикселей, пример проекций деталей изображен на рисунке 3. Создание выборок stl-объектов и проекций было

выполнено с использованием алгоритма, реализованного в среде MATLAB. Нейронные сети для классификации и дальнейшей семантической сегментации были реализованы на языке Python с помощью библиотек keras и tensorflow.




Рис. 3. Выборка проекций из тренировочных данных для классификации

В таблице 1 приведены результаты по точности классификации  $\delta_{\text{класс}}$  (1) на обучающей и тестовой выборки для двух архитектур сверточных нейронных сетей.

Табл. 1. Точность классификации для обучающей и тестовой выборок

Архитектура	$\delta_{\text{класс}}$ при обучении	$\delta_{\text{класс}}$ при тесте
1 Архитектура	1	0,7675
2 Архитектура (VGG19)	1	0,9975

Можно отметить, что обе архитектуры показали 100% точность при обучении, однако на тестовых данных достаточную точность в 99,75% показала лишь сеть VGG19, потому эта архитектура выбирается как подходящая для решения задач классификации деталей.

### Заключение

Предложенная в статье методика позволит упростить создание систем машинного зрения на аэрокосмических предприятиях, имеющих довольно малую по объему производства и уникальную с точки зрения внешнего вида продукцию. Система машинного зрения, в свою очередь, позволит повысить эффективность самого производства.

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

### Список литературы

1. Гречников Ф.В., Резчиков А.Ф., Захаров О.В. Итерационный метод коррекции радиуса сферического шупа мобильных координатно-измерительных машин при контроле поверхностей вращения // Измерительная техника. 2018. № 4. С. 21-24.

2. LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient-based learning applied to document recognition // Proceedings of the IEEE. 1998. Vol. 86. No. 11. P. 2278-2323.
3. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks // Advances in neural information processing systems. 2012. Vol. 25, no. 2. P. 1097-1105. DOI: 10.1145/3065386
4. Jinjiang W., Fu P., Gao R. Machine vision intelligence for product defect inspection based on deep learning and Hough transform // Journal of Manufacturing Systems. 2019. No. 51. P. 52-60.
5. Mikołajczyk A. Grochowski M. Data augmentation for improving deep learning in image classification problem // International Interdisciplinary PhD Workshop (IIPhDW). 2018. P. 117-122.
6. Fawzi A., Samulowitz H., Turaga D., Frossard P. Adaptive data augmentation for image classification // Proceedings – International Conference on Image Processing, ICIP. 2016. 7533048. P. 3688-3692.
7. Николенко С.И., Кадурин А., Архангельская Е. Глубокое обучение. СПб.: Питер, 2018. 480с.
8. Прончук К.А. Якимов П.Ю. Разработка веб-сервиса по распознаванию знаков дорожного движения на основе сверточных нейронных сетей // В сборнике: Информационные технологии и нанотехнологии Сборник трудов ИТНТ-2018. IV Международная конференция и молодёжная школа «Информационный технологии и нанотехнологии» (ИТНТ-2018). 2018. С. 2319-2326.
9. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition // arXiv. 2015. Vol. 1409. 1556.

Сведения об авторах:

*Печенина Екатерина Юрьевна* – аспирант кафедры технологий производства двигателей, Самарский университет, Самара;

*Печенин Вадим Андреевич* – к.т.н., доцент кафедры технологий производства двигателей, Самарский университет, Самара;

*Болотов Михаил Александрович* – к.т.н., доцент, доцент кафедры технологий производства двигателей, Самарский университет, Самара.