

## Автоматизация подготовки данных для систем видеонаблюдения в производстве

В.А. Зотов

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

**Обоснование.** В условиях цифровой трансформации экономики автоматизация контроля качества и управление производственными процессами становятся ключевыми аспектами конкурентоспособности предприятий. Для этого используются современные технологии, такие как ЧПУ и алгоритмы машинного обучения. MDC- и MES-системы интегрируются с производственной инфраструктурой для мониторинга и оптимизации процессов. Глубокие нейронные сети, такие как YOLO, эффективно детектируют объекты и анализируют данные, особенно в условиях многономенклатурного производства [1, 2].

**Цель** — разработать приложение для автоматизации разметки видеоматериалов в условиях ограниченного производства и широкой номенклатуры для обучения нейронных сетей в системах компьютерного зрения.

**Методы.** При разработке приложения использовались две нейронные сети, работающие последовательно в рамках одного алгоритма: YOLOv5 для детектирования ячеек тары, в которой перемещаются детали в производстве, и VGG19 для классификации деталей внутри ранее детектированных ячеек. Такой подход позволяет снизить ошибки второго рода и повысить значение mAP, но увеличивает время обучения практически в четыре раза. Эксперименты проводились с деталями в таре с обрешеткой: каждая ячейка содержала одну деталь или ничего. На углах тары нанесены ArUco-маркеры и QR-коды для активации нужных нейронных сетей, обученной под конкретную тару и типы деталей. Задачами приложения являлись: выделение и классификация пустых или заполненных ячеек, определение типа детали и детектирование QR- и ArUco-кодов [3, 4].




Рис. 1. График точности и функции потерь

**Результаты.** На начальном этапе экспериментов были исследованы различные варианты обучения, отличающиеся входным набором параметров. В рамках исследования изучалось влияние типа изображения (цветное или серое) на эффективность процесса обучения. Было установлено, что цветное изображение благоприятнее для обучения. Были рассмотрены два вида оптимизаторов SGD [5] и Adam [6], а также различные размеры батча и количества эпох. Оптимальными выбраны параметры: Оптимизатор — SGD, размер батча 2–16, количество эпох 20–100. Данный этап позволил сократить варьируемые параметры в два раза.

Дальнейшие изыскания были направлены на поиск оптимальных параметров обучения нейронной сети. Наилучшие результаты дал размер батча 8 и количество эпох 40. Сбалансированность количества изображений двух классов также влияет на точность, а кроме того, размер обучающей выборки желательно не ниже 1100 изображений. График точности и функции потерь детали № 5, для которой эти параметры на тестовой выборке достигли лучших значений, представлен на рис. 1.

**Выводы.** Разработанное приложение для разметки видеоматериала упрощает обучение нейронных сетей, используя предварительно обученные модели, требующие увеличения выборки. Хотя применение трех сетей YOLO и одной VGG замедляет обработку, это быстрее, чем ручная разметка, что важно для серийного многономенклатурного производства. Подобные приложения позволят приблизить переход к Индустрии 4.0 и в целом повысить экономическую эффективность на отечественных машиностроительных предприятиях.

Работа выполнена по проекту FSSS-2024-0019, реализуемому в рамках федерального проекта «Развитие человеческого капитала в интересах регионов, отраслей и сектора исследований и разработок». Результат — создание новых лабораторий, в том числе под руководством молодых перспективных исследователей.

**Ключевые слова:** управление производственными процессами; компьютерное зрение; нейронная сеть; MDC-система; детектирование объектов.

## Список литературы

1. Zakharov O.V., Lysenko V.G., Ivanova T.N. Asymmetric morphological filter for roughness evaluation of multifunctional surfaces // ISA Transactions. 2024. Vol. 146. P. 403–420. doi: 10.1016/j.isatra.2023.12.016 EDN: WIBCLQ
2. van Mourik S., van der Tol R., Linker R., et al. Introductory overview: Systems and control methods for operational management support in agricultural production systems // Environmental Modelling & Software. 2021. Vol. 139. P. 105031. doi: 10.1016/j.envsoft.2021.105031 EDN: UPFGTQ
3. Zagitov A., Chebotareva E., Toshev A., Magid E. Comparative analysis of neural network models performance on low-power devices for a real-time object detection task // Computer Optics. 2024. Vol. 48, N 2. P. 242–252. doi: 10.18287/2412-6179-CO-1343 EDN: RDQVQY
4. Bhuma C.M., Kongara R. A novel technique for image retrieval based on concatenated features extracted from big dataset pre-trained CNNs // International Journal of Image, Graphics and Signal Processing. 2023. Vol. 2. P. 1–12. doi: 10.5815/ijigsp.2023.02.01 EDN: FGDWXX
5. Bottou L., Bousquet O. The Tradeoffs of Large Scale Learning // Optimization for Machine Learning / ed. by S. Sra, S. Nowozin, S.J. Wright. Cambridge: MIT Press, 2012. P. 351–368. ISBN 978-0-262-01646-9
6. Kingma D., Ba J. Adam: A Method for Stochastic Optimization. arXiv:1412.6980 [cs.LG]. 2014.

## Сведения об авторе:

**Владислав Александрович Зотов** — студент, группа 3413-240305D, институт двигателей и энергетических установок; Самарский национальный исследовательский университет имени академика С.П. Королева, Самара, Россия. E-mail: vlad198189@gmail.com

## Сведения о научном руководителе:

**Вадим Андреевич Печенин** — кандидат технических наук, доцент, заведующий лабораторией НИЛ-211, доцент кафедры технологий производства двигателей; Самарский национальный исследовательский университет имени академика С.П. Королева, Самара, Россия. E-mail: pechenin.va@ssau.ru