

УДК 004

**РАЗРАБОТКА АЛГОРИТМИЧЕСКОГО ОБЕСПЕЧЕНИЯ
СИСТЕМЫ КОНТРОЛЯ ПЛОТНОСТИ ПЛЕТЕНИЯ 3D-ТАКАНЫХ
ПРЕФОРМ ИЗ УГЛЕРОДНОГО ВОЛОКНА**

Баженова А.П., студент гр. ИВМ-24, 2 курс
Научный руководитель: Гусаров А.В., к.т.н., доцент
Рыбинский государственный авиационный технический университет
имени П.А. Соловьева
г. Рыбинск

Плетеные материалы, такие как 3D-тканая преформа (далее – преформа) из углеродного волокна, широко используются в различных отраслях промышленности, включая авиастроение и автомобилестроение, благодаря их высокой прочности и легкости. Процесс плетения представляет собой способ получения изделий, при котором несколько нитей (не менее трех) под натяжением подаются в общую рабочую зону с одновременным перемещением в пространстве паковок. Нити (каркасная, прошивная и уточная), переплетаясь друг с другом, образуют компактную структуру, и их положение в изделии стабилизируется. Типовая схема расположения нитей в преформе с ортогональной схемой армирования показана на рисунке 1. Готовое изделие постоянно отводится из рабочей зоны.




Рис. 1. Модель трехмерного плетения

Однако при производстве таких изделий могут возникать отклонения в плотности плетения, что может привести к снижению качества и прочности изделий, а также к нарушению эксплуатационных характеристик. Для

измерения плотности плетения традиционно используются методы, основанные на визуальном осмотре и ручном подсчете нитей. Однако эти методы имеют свои ограничения, связанные с субъективностью человеческого восприятия, высокими временными затратами и сложностью обработки больших объемов данных в условиях поточного производства.

Сверточные нейронные сети (СНС) представляют собой мощный инструмент для автоматизации процесса измерения плотности плетения. Они способны анализировать изображения плетеных материалов, определять местоположение нитей основы и утка и вычислять плотность плетения с высокой точностью. Кроме того, СНС могут работать без усталости и ошибок, которые характерны для человека при длительном и монотонном процессе анализа. В данной работе рассматривается разработка алгоритмического обеспечения системы, реализующей данный подход на базе архитектуры ResUNet-34.

Процесс обработки данных в системе автоматизированного контроля реализован в виде конвейера последовательных шагов преобразования данных. Для обеспечения гибкости, масштабируемости и возможности независимого тестирования компонентов программный комплекс разделен на семь функциональных модулей. Логическая структура системы организована по принципу последовательного выполнения (конструкция «Следование»), где выходные данные одного модуля являются входными для следующего.

Алгоритм макроуровня программы проектируемой системы в одноуровневом представлении приведен на рисунке 2. Для повышения информативности ГСА на ней изображены входные и выходные данные, обрабатываемые каждым программным модулем. Это позволяет проследить, что каждый модуль располагается в той точке программного кольца, в которой существуют все обрабатываемые им данные.

Организация процесса автоматического анализа начинается с подготовки вычислительного ядра системы. Модель базируется на принципе U-Net, используя в качестве энкодера предобученную сверточную сеть ResNet34. Параметры энкодера фиксируются для обеспечения корректного нормирования входных данных согласно стандартному распределению ImageNet. Критически важным этапом является восстановление тензоров состояния из файла контрольной точки формата PyTorch Lightning, что гарантирует воспроизводимость результатов. После загрузки весов система переводит модель в оценочный режим (eval), отключая механизмы Dropout и Batch Normalization для детерминированного получения масок.

Исходные данные поступают с веб-камеры или файловой системы и могут иметь произвольное разрешение. Алгоритм подготовки изображения обеспечивает приведение данных к формату, строго соответствующему ожиданиям входных слоев нейросети. Выполняется удаление избыточных областей кадра методом пороговой бинаризации серого пространства цветов. Границы значимой области определяются по яркости пикселей: строки и столбцы, превышающие заданный порог, отсекаются с добавлением поля

запаса для сохранения целостности краевых элементов преформы. Затем выполняется ресайзинг изображения до фиксированных размеров сети (1280×1280 пикселей) с использованием фильтра Ланцоша. Данные преобразуются в тензор PyTorch с финальной нормализацией в интервал [0, 255].




Рис. 2. Алгоритм макроуровня программы

Модуль обработки в нейросети представляет собой центр принятия решения о принадлежности каждого пикселя к классам «основа» или «утка».

Для увеличения скорости выполнения операции отключается механизм обратного распространения ошибки (`torch.no_grad`). Входящий тензор изображения передается через функциональную часть модели (`forward pass`), где проходит многослойная фильтрация признаков. На выходе получаются логиты, которые проходят через функцию активации сигмоиды, преобразующую значения в вероятностный интервал от 0.0 до 1.0.

После получения вероятностных карт осуществляется бинаризация для последующего подсчета дискретных объектов. Применяется пороговая обработка, где значения выше заданного уровня приводятся к максимуму (255), а остальные к нулю. Это формирует четкую маску, где область покрытия нити окрашена в белый цвет, а пустое пространство – в черный. Параллельно выполняется создание цветных представлений каждой маски для визуального контроля: канал основы окрашивается в красный цвет, а канал утка – в зеленый.

В соответствии с технологической спецификой тканой структуры, направление основы характеризуется вертикальной ориентацией нитей. Для статистически достоверного определения плотности применяется метод сканирования горизонтальных линий среза изображения. Выбирается фиксированное количество тестовых строк (10), равномерно распределенных вокруг центральной оси изображения, чтобы учесть возможные локальные дефекты или неидеальность сегментации нейросети. Для каждой строки извлекаются пиксели только из канала маски, соответствующего основе. Запускается цикл перебора пикселей с целью обнаружения переходов цвета из черного (0) в белый (255). Каждый такой переход сигнализирует о начале новой нити в данном сечении. Суммарное количество переходов для каждой строки аккумулируется, и вычисляется среднее арифметическое значение по всем линиям.

Определение плотности утка требует анализа направления, перпендикулярного нитям основы. Поскольку уток имеет горизонтальную ориентацию, анализ производится вдоль вертикальных срезов изображения. Логика алгоритма зеркальна подходу подсчета основы: формируется пул из 10 вертикальных столбцов, распределенных симметрично относительно центра. Математическое усреднение является необходимым этапом пост-обработки для снижения дисперсии измерений, вызванной микродефектами плетения, шумом изображения или неидеальностью сегментации.

Для обеспечения экспертного контроля производится генерация результирующих изображений, объединяющих исходную фотографию преформы с цветными масками. Используется метод смешивания весов (`cv2.addWeighted`), позволяющий наложить полупрозрачные цветовые слои на оригинальное изображение. Коэффициент прозрачности для слоя основы установлен выше, чем для утка, чтобы избежать визуальной коллизии цветов в местах перекрытия нитей.

Финальный этап взаимодействия между серверной частью и фронтенд-приложением заключается в структурировании всех полученных данных в единый ответ формата JSON. Объект ответа содержит URL-ссылки на

изображения с визуализацией и текстовые строки с итоговыми числовыми результатами подсчета. Такое представление удобно для парсинга клиентским приложением и последующей архивации данных. Сервер проверяет существование файлов перед возвратом путей, предотвращая формирование битых ссылок.

Разработанное алгоритмическое обеспечение позволяет автоматизировать процесс измерения плотности плетения преформ. Внедрение данной разработки позволит снизить роль человеческого фактора, сократить время анализа и повысить эффективность производственных процессов, обеспечивая стабильное качество плетеных преформ из углеродного волокна.

Список литературы:

1. Meng, S., Pan, R., Gao, W., Zhou, J., Wang, J., He, W. Woven Fabric Density Measurement by Using Multi-Scale Convolutional Neural Networks / S. Meng, R. Pan, W. Gao, J. Zhou, J. Wang, W. He // IEEE Access [Электронный ресурс] URL: <https://ieeexplore.ieee.org/document/8735841/> (дата обращения: 10.03.2026).
2. Ronneberger, O., Fischer, P., Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation / O. Ronneberger, P. Fischer, T. Brox // MICCAI 2015 [Электронный ресурс] URL: https://link.springer.com/chapter/10.1007/978-3-319-24574-4_28 (дата обращения: 01.03.2026).
3. He, K., Zhang, X., Ren, S., Sun, J. Deep Residual Learning for Image Recognition / K. He, X. Zhang, S. Ren, J. Sun // CVPR 2016 [Электронный ресурс] URL: https://openaccess.thecvf.com/content_cvpr_2016/papers/He_Deep_Residual_Learning_CVPR_2016_paper.pdf (дата обращения: 15.03.2026).
4. PyTorch Lightning. Documentation / PyTorch Lightning Team // PyTorch Lightning Official Documentation [Электронный ресурс] URL: <https://lightning.ai/docs/pytorch/stable/> (дата обращения: 17.03.2026).
5. Django REST Framework. Documentation / Django REST Framework Team // Django REST Framework Official Documentation [Электронный ресурс] URL: <https://www.django-rest-framework.org/> (дата обращения: 17.03.2026).