

## Определение объёмного содержания волокон в слоистых композитах оптическими методами

В.А. Комаров<sup>1</sup>, А.А. Павлов<sup>1</sup>

<sup>1</sup> Самарский национальный исследовательский университет имени академика С.П. Королёва, 443086, Россия, г. Самара, Московское шоссе, д. 34

### Аннотация

Рассматривается задача определения объёмного содержания армирующего волокна в нитях слоистых композитов с тканевыми наполнителями. В качестве источника информации о структуре материала используются цифровые микроизображения шлифованной поверхности поперечных сечений композитов. Обсуждаются методы и особенности анализа растровых микроскопических снимков гетерогенного материала, связанные с переменной яркостью пикселей и размытостью границ «волокно-связующее». В целях сокращения трудоёмкости и повышения объективности обработки изображений предлагается и строится специальный автоэнкодер. Изложение сопровождается сквозным демонстрационным примером исследования структуры типового конструкционного углепластика. Показано существенное ускорение процесса обработки изображений с использованием свёрточного автоэнкодера и хорошее согласование результатов с тщательным ручным анализом.

**Ключевые слова:** композит, волокно, объёмная доля, микроснимок, обработка, автоэнкодер.

**Цитирование:** Комаров, В.А. Определение объёмного содержания волокон в слоистых композитах оптическими методами / В.А. Комаров, А.А. Павлов // Компьютерная оптика. – 2022. – Т. 46, № 3. – С. 473–478. – DOI: 10.18287/2412-6179-CO-1068.

**Citation:** Komarov VA, Pavlov AA. Determination of fibers volume fraction in layered composite materials by optical methods. Computer Optics 2022; 46(3): 473–478. DOI: 10.18287/2412-6179-CO-1068.

### Введение

Одним из эффективных путей использования высоких удельных характеристик угле- и стекловолокон во многих практических задачах является применение слоистых структур композитов с тканевым наполнителем [1]. Расчёт напряженно-деформированного состояния и проектирование конструкций из таких материалов, например, в САЕ-системе ANSYS, требует в качестве исходных данных достаточно большого количества упругих констант слоистого композита. Часть из этих констант в плоскости ткани –  $E_{xx}$ ,  $E_{yy}$ ,  $\mu_{xy}$ ,  $G_{xy}$  – определяется с использованием относительно простых методик испытаний, другая часть – в основном трансверсальные механические характеристики  $E_{zz}$ ,  $\mu_{xz}$ ,  $\mu_{yz}$ ,  $G_{xz}$ ,  $G_{yz}$  – требуют сложных экспериментов, и поэтому для их определения развиваются экспериментально-аналитические методы. Ключевую роль в них играют так называемые «представительные ячейки» композита для соответствующих структур армирования [2]. Одной из важных характеристик материала для генерации представительной ячейки является объёмная доля армирующих волокон в переплетающихся нитях ткани, пропитанных связующим. Определить эту характеристику можно путём обработки цифровых полутоновых микроизображений элементарных образцов тканевого композита [3].

Изображение среза нити волокнистого композиционного материала на микроскопическом уровне состоит из фона, в роли которого выступает связующее, и эллипсоидных объектов, которые представляют

собой поперечные сечения армирующих волокон. Обработка таких изображений сводится к отделению фона от объектов и относится к задачам бинаризации полутонового изображения.

Классическим методом бинаризации является метод, предложенный Otsu [4]. В данном методе вычисляется порог яркости всего изображения, из-за чего он не применим к изображениям с неравномерным освещением. Одно из развитий этого метода описано в [5], где предложены алгоритмы локальной адаптивной нормализации фона с использованием предварительно аппроксимированной кусочно-линейной или нелинейной функции.

Другим направлением бинаризации изображений стали локальные методы, в которых порог яркости каждого пикселя вычисляется с учётом особенностей его окружения. Наиболее распространённым является метод Sauvola [6]. В методе [7] используется контраст изображения, определяемый локальным максимумом и минимумом, на основе которого происходит его сегментация.

В последние годы для решения задач бинаризации и предварительной обработки изображений предлагаются методы, использующие глубокие нейронные сети [8–11]. Данные подходы показывают высокую надёжность при работе с бинаризацией изображений, которые содержат не обязательно только текстовую информацию.

Цель данной статьи – разработка методики определения объёмной доли армирующих волокон через анализ цифровых микрофотографий шлифо-

ванных поперечных сечений нитей композиционного материала.

**1. Определение объёмного содержания компонентов композиционного материала через цифровые микрофотографии**

Упругие и прочностные характеристики слоистого композиционного материала зависят от соотношения долей компонентов. Обозначим объёмную долю волокна нити, пропитанной связующим, через  $\overline{V_f}$  и определим её как отношение объёма волокна  $V_f$  к общему объёму композиционного материала  $V_g$ :

$$\overline{V_f} = \frac{V_f}{V_g}. \tag{1}$$

Аналогично определяются относительные объёмы матрицы (связующего)  $\overline{V_m}$  и объёмы пустот  $\overline{V_e}$ . При этом

$$\overline{V_f} + \overline{V_m} + \overline{V_e} = 1. \tag{2}$$

В качестве типового источника информации для определения введённых безразмерных величин будем рассматривать изображение шлифованного поперечного сечения слоистой структуры композита, получаемого механической нарезкой образца перпендикулярно армирующим нитям. Соответствующая грань образца подвергается шлифовке и полировке до получения высокого качества поверхности среза. На хорошо подготовленной поверхности образца должны быть различимы все структурные составляющие композита, что позволяет определить границы поперечных сечений нитей армирующего материала и пустот в наполнителе с помощью микроскопа.

Границы поперечных сечений волокон на изображении позволяют подсчитать их суммарную площадь  $A_f$ ; площадь, занимаемую связующим  $A_m$ ; площадь сечений пор или раковин  $A_e$  при их наличии.

Объёмное содержание волокон в связующем будем определять по соотношению

$$\overline{V_f} = \frac{A_f}{A_f + A_m + A_e}. \tag{3}$$

Величина  $\overline{V_f}$  безразмерна, поэтому определять истинные размеры волокон на цифровом микроскопическом снимке нет необходимости.

Определённая сложность заключается в определении «истинных» границ поперечных сечений волокон. Зачастую на растровых изображениях цифровых снимков границы «волокно-связующее» размыты. Это происходит вследствие того, что компоненты композита обладают различной твёрдостью и в процессе шлифования и полировки поверхности микрошлифа материал связующего удаляется раньше материала волокон, тем самым образуются микронеровности конечной поверхности образца и некоторое искажение изображения.

Для пояснения предлагаемой методики определения объёмных долей компонентов слоистого композиционного материала будем рассматривать, не снижая общности подходов к решению поставленной задачи, исследование микроструктуры углепластика, полученного на основе углеродной ткани CC201 и двухкомпонентного эпоксидного связующего SR8100/SD8824 методом вакуумной инфузии. Образцы размером  $20 \times 40 \times 5$  мм изготавливались и шлифовались в лаборатории композиционных материалов и конструкций Самарского университета. Исследования проводились с использованием микроскопа Nikon Eclipse MA 200 с кратностью увеличения от 50 до 1000.

На рис. 1 представлен микроскопический снимок шлифованного поперечного сечения рассматриваемого углепластика.




Рис. 1. Микроскопический снимок поперечного сечения углепластика CC201/SR8100-SD8824

На рис. 2 представлена диаграмма распределения яркости пикселей рассматриваемого микроскопического снимка (рис. 1), полученная путём ранжирования яркости пикселей изображения по диапазонам. Уровень яркости представлен в диапазоне от 0 до 1, где 0 – чёрный пиксел, 1 – белый, 0,5 – серый, шаг диапазона ранжирования – 0,05.




Рис. 2. График распределения яркости в микроскопическом снимке поперечного сечения углепластика CC201/SR8100-SD8824

Диаграмма распределения яркости пикселей на микроскопическом снимке поперечного сечения углепластика имеет бимодальную форму. Правая вершина характеризует яркость поперечных сечений волокон, а левая – поперечное сечение связующего и

дефектов. Площадь под левой частью кривой, показанная на рис. 2 чёрным цветом, соответствует суммарной площади поперечного сечения связующего  $A_m$  и дефектов  $A_e$ . Площадь под правой частью кривой распределения, показанная на рис. 2 белым цветом, соответствует площади поперечных сечений волокон  $A_f$ . Центральная зона графика распределения, выделенная серым цветом, соответствует площади поперечных сечений размытых участков на границе «волокно-связующее».

Основную сложность при анализе цифровых снимков вызывает определение границ серой области графика. Решение данной задачи можно упростить, изменив форму бимодального распределения и повысив коэффициент эксцесса, что позволит приблизить цветовую гамму снимка к бинарной.

Повысить коэффициент эксцесса можно путём разметки границ волокон на микроскопических снимках образцов структуры при помощи программных пакетов, позволяющих создавать векторные изображения.

На рис. 3 показана векторная разметка микроскопического снимка поперечного сечения углепластика, показанного на рис. 1. Разметка границ поперечных сечений волокон осуществлялась в программном пакете Компас-3D и «вручную» преобразовывалась в монохромное растровое изображение. Белым цветом показаны сечения волокон, чёрным – связующее.




Рис. 3. Графическая интерпретация микроскопического снимка углепластика CC201/SR8100-SD8824 «вручную»

На рис. 4 показано распределение показателя яркости пикселей полученного изображения (рис. 3) в сравнении с исходным (рис. 1). Для расчёта объёмного содержания волокон  $V_f$ , площади под графиком распределения яркости пикселей интерпретируемого изображения целесообразно разбить на две части по уровню яркости, равному 0,5, в предположении, что площадь под левой частью графика от 0 до 0,5 соответствует  $A_m$ , а площадь под правой частью (от 0,5 до 1,0) –  $A_f$ . При таком подходе объёмное содержание волокон  $V_f$ , рассчитанное по (3), для рассматриваемого изображения составляет 0,588.

**2. Повышение контрастности цифрового микроскопического снимка поперечного сечения композита при помощи автоэнкодера**

Для адекватной оценки объёмного содержания волокон  $V_f$  необходимо анализировать большое коли-

чество микроскопических изображений и преобразовывать каждое в бинарный вид. Однако ручная разметка большого количества изображений является существенно трудоёмким и длительным процессом. Как один из возможных путей автоматизации обработки микроскопических изображений рассмотрим применение автоэнкодера [12]. Автоэнкодеры являются частным случаем искусственной нейронной сети и состоят, как правило, из двух частей – кодера и декодера (рис. 5).

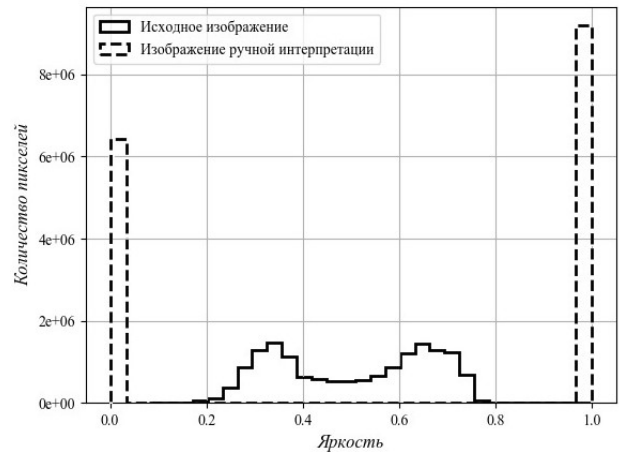


Рис. 4. Гистограмма распределения яркости пикселей в исходном и интерпретированном изображениях поперечного сечения углепластика CC201/SR8100-SD8824

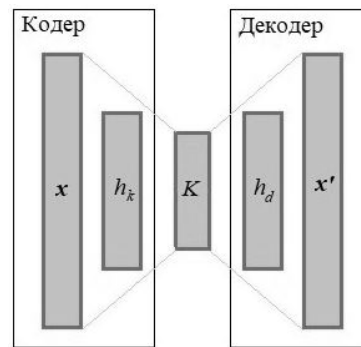


Рис. 5. Схема автоэнкодера

Кодер принимает и сжимает входные данные  $x$  с помощью скрытого слоя  $h_k$ , создающего код  $K$ . Данный код необходим для восстановления входного изображения  $x$ . Поскольку код  $K$  имеет значительно меньшую размерность, чем исходное изображение, то в процессе обучения кодер пытается создать функцию, выделяющую наиболее важные черты в обучающей выборке.

Декодер принимает код  $K$  и пытается восстановить изображение  $x$ . Если в процессе обучения в качестве целевого изображения использовать не  $x$ , а модифицированное  $x'$ , то автоэнкодер сформирует функцию преобразования  $x$  в  $x'$ .

Таким образом, для создания автоэнкодера необходимо сформировать обучающую выборку, содержащую входное изображение  $x$  и выходное  $x'$ .

### 3. Формирование обучающей выборки

Для обучения автоэнкодера целесообразно использовать изображения микроскопических снимков слоистого композита, для которых сделана ручная разметка границ поперечных сечений волокон. Вследствие того, что в рассматриваемой задаче изображения имеют однородную структуру, их можно разбить на фрагменты, тем самым снизив размерность автоэнкодера.

Входные данные автоэнкодера представляют собой фрагменты микроскопического снимка с размерами 200 × 200 пикселей, а выходные данные – фрагмент микроскопического снимка после ручной интерпретации. Яркость пикселей изображений приводится к диапазону от 0 до 1 (рис. 6).




Рис. 6. Входные (а) и целевые (б) изображения:

а) фрагмент цифрового снимка;

б) фрагмент изображения после ручной интерпретации

В демонстрационном примере первоначально обучающая выборка составляла 360 пар изображений. Она была расширена путём добавления исходных изображений, повернутых на 90, 180 и 270 градусов, а также отражённых по вертикали и горизонтали. В итоге размер выборки составил 1800 пар изображений. Половина выборки использовалась для обучения автоэнкодера (тренировочная), вторая – в обучении не участвовала и использовалась для оценки точности (тестовая).

### 4. Разработка архитектуры свёрточного автоэнкодера

Блок-схема разработанного автоэнкодера свёрточного типа представлена на рис. 7.

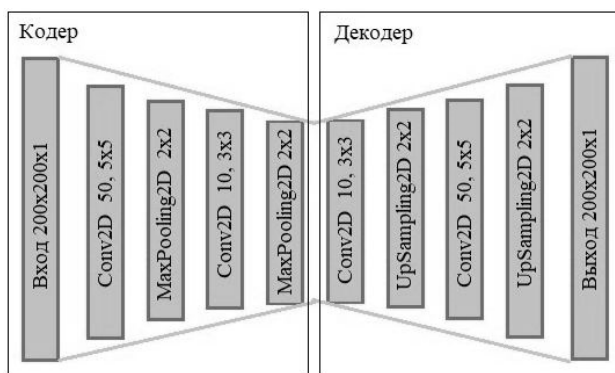


Рис. 7. Схема свёрточного автоэнкодера

Автоэнкодер написан на языке программирования Python. Архитектура кодера и декодера принималась симметричной.

При построении автоэнкодера использовались следующие программные модули из интерфейса глубокого обучения API Keras [13]:

- двумерные свёрточные слои Conv2D [14], которые в отличие от полносвязных позволяют повысить качество реконструкции целевого изображения [15];
- слои субдискретизации двумерного ввода MaxPooling2D, которые позволяют снизить размерность внутреннего пространства кодера [16];
- слои передискретизации UpSampling2D для увеличения размерности внутреннего пространства декодера [17].

Так как в работе не ставилась задача получения сжатого представления изображения, из архитектуры автоэнкодера исключены слои кодера и декодера, формирующие и принимающие код сжатого представления. Такие параметры, как количество скрытых свёрточных слоёв, количество слоёв субдискретизации и передискретизации, размеры окон свёрток, количество выходных фильтров свёрточного слоя, подбирались эмпирически.

### 5. Обучение разработанного автоэнкодера

Обучение искусственной нейронной сети по своей сути представляет процесс решения многопараметрической задачи нелинейной оптимизации. Для обучения созданного свёрточного автоэнкодера выбран оптимизатор Adam [18], реализующий метод стохастической оптимизации [19].

В процессе обучения автоэнкодера в рассматриваемой задаче минимизируется функция потерь, в качестве которой выбрана функция среднеквадратичной ошибки MSE [13]

$$MSE = \frac{1}{n} \sum_{i=1}^n (y'_i - x'_i)^2, \tag{4}$$

где  $y'_i$  – прогнозируемое значение яркости пикселя,  $x'_i$  – значение яркости пикселя на изображении ручной интерпретации,  $n$  – количество пикселей. Функция потерь вычисляется для тренировочной и тестовой выборок.

Выполнено 400 эпох (циклов) обучения автоэнкодера. На рис. 8 показан график изменения функций потерь тренировочной и тестовой выборок.

Из данного графика следует, что после 300-й эпохи обучения функция потерь тестовой выборки практически не изменяется, поэтому для дальнейшей работы выбиралась модель именно этой эпохи.

### 6. Повышение контрастности цифрового микроскопического снимка и расчёт объёмного содержания волокон

Для повышения контрастности исходное изображение микроскопического снимка поперечного сече-

ния слоистого композита с помощью обученного автоэнкодера разделялось на участки размером  $200 \times 200$  пикселей с шагом 200 пикселей по вертикали и горизонтали (рис. 9а). Каждый фрагмент общего снимка подавался в автоэнкодер.

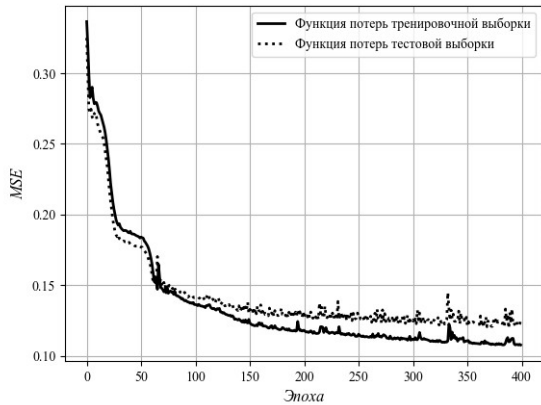


Рис. 8. Изменение функции потерь для тренировочной и тестовой выборок в процессе обучения автоэнкодера




Рис. 9. Этапы реконструкции изображений: исходное изображение (а), реконструированное изображение (б) с шагом фрагментации 200 пикселей, итоговое реконструированное изображение (в) с шагом фрагментации 190 пикселей




Рис. 10. Микроскопический снимок углепластика CC201/SR8100-SD8824 после обработки автоэнкодером

Из рис. 11 следует, что форма распределения яркости пикселей итогового реконструированного изображения близка к форме распределения изображения после ручной интерпретации (рис. 4).

Расчёт объёмного содержания волокон  $\bar{V}_f$  по итоговому реконструированному изображению целесообразно делать автоматизированно с использованием специально разработанной программы подсчёта площади пикселей, относящихся к поперечному сечению волокон и связующего.

В рассматриваемом примере  $\bar{V}_f$  итогового реконструированного изображения поперечного сечения слоистого углепластика, полученного с использова-

нием предложенного автоэнкодера, составило 0,557. Соответствующее значение  $\bar{V}_f$ , рассчитанное вручную по исходному снимку и принятое за эталон для сравнения, составило 0,588. При этом использование автоэнкодера позволяет существенно сократить затраты времени эксперта на обработку исходного изображения более, чем в 5 раз.

Затем полученные реконструированные фрагменты собирались в единое итоговое изображение. Однако из-за особенностей обработки изображений свёрточными нейросетями пиксели на границе фрагментов имеют значения яркости, близкие к значениям яркости исходного изображения. Как следствие, на итоговом изображении на стыках фрагментов снимка образуются светлые линии (рис. 9б).

Для того, чтобы убрать линии на реконструированном изображении (рис. 9б), при формировании итогового изображения исключались 5 пикселей по контуру каждого фрагмента реконструированного изображения, т.е. шаг формирования задавался 190 пикселей. В итоге на полученном изображении полностью исключены линии стыка фрагментов (рис. 9в).

На рис. 10 показано итоговое реконструированное микроскопическое изображение поперечного сечения рассматриваемого углепластика, полученное с использованием разработанного свёрточного автоэнкодера.

На рис. 11 показана диаграмма распределения яркости пикселей для исходного изображения, а также после ручной и программной интерпретации.




Рис. 11. График распределения яркости пикселей в исходном и интерпретированном изображениях поперечного сечения углепластика CC201/SR8100-SD8824

### Заключение

Расхождение значений объёмного содержания волокон, полученное по микроснимку структуры нити слоистого тканевого углепластика и её реконструируемым изображениям, в рассмотренном примере составило 5,2%, что можно считать вполне приемлемым результатом, учитывая возможную технологическую стохастичность волокнистых композитов.

Полученные результаты свидетельствуют о достоверности реконструкции исходного изображения с помощью разработанного автоэнкодера. Таким образом, предлагаемая автоматизированная методика определения объёмного содержания волокна в нитях слоистого композита может быть рекомендована для использования в научных и прикладных задачах.

### Благодарности

Работа выполнена при поддержке Министерства науки и высшего образования в рамках выполнения работ по Государственному заданию в части «Экспериментально-численный анализ напряжённо-деформированного состояния композитных проушин» (проект FSSS-2020-0016).

### References

- [1] Niu MCY. Composite airframe structures: Practical design information and data. 3<sup>rd</sup> ed. Granada Hills: Adaso/Adastra Engineering Center; 2000. ISBN: 978-962-7128-06-6.
- [2] Lomov S, Ivanov DS, Verpoest I, Zako M. Full-field strain measurements for validation of meso-FE analysis of textile composites. *Compos Part A Appl Sci Manuf* 2008; 39(8): 1218-1231. DOI: 10.1016/j.compositesa.2007.09.011.
- [3] Gommer F, Endruweit A, Long A. Quantification of micro-scale variability in fibre bundles. *Compos Part A Appl Sci Manuf* 2016; 87: 131-137. DOI: 10.1016/j.compositesa.2016.04.019.
- [4] Otsu N. A threshold selection method from gray-level histograms. *IEEE Trans Syst Man Cybern* 1979; 9(1): 62-66. DOI: 10.1109/tsmc.1979.4310076.
- [5] Shi Z, Setlur S, Govindaraju V. Digital image enhancement using normalization techniques and their application to palm leaf manuscripts. 2005. Source: [https://cedar.buffalo.edu/~zshi/Papers/kbcs04\\_261.pdf](https://cedar.buffalo.edu/~zshi/Papers/kbcs04_261.pdf).
- [6] Sauvola J, Pietikäinen M. Adaptive document image binarization. *Pattern Recognit* 2000; 33(2): 225-236. DOI: 10.1016/s0031-3203(99)00055-2.
- [7] Su B, Lu S, Tan C. Binarization of historical document images using the local maximum and minimum. *Proc 9th IAPR Int Workshop on Document Analysis Systems* 2010: 159-165. DOI: 10.1145/1815330.1815351.
- [8] Castellanos FJ, Gallego AJ. A selectional auto-encoder approach for document image binarization. *Pattern Recognit* 2019; 86: 37-47. DOI: 10.1016/j.patcog.2018.08.011.
- [9] Pastor-Pellicer J, España-Boquera S, Zamora-Martínez F, Zeshan Afzal M, Castro-Bleda MJ. Insights on the use of convolutional neural networks for document image binarization. In Book: Rojas I, Joya G, Catala A, eds. *Advances in Computational Intelligence. Part II*. Springer International Publishing; 2015: 115-126. DOI: 10.1007/978-3-319-19222-2\_10.
- [10] Peng X, Cao H, Natarajan P. Using convolutional encoder-decoder for document image binarization. *14th IAPR Int Conf on Document Analysis and Recognition* 2017: 708-713. DOI: 10.1016/j.patcog.2018.08.011.
- [11] Rehman A, Saba T. Neural networks for document image preprocessing: State of the art. *Artif Intell Rev* 2014; 42(2): 253-273. DOI: 10.1007/s10462-012-9337-z.
- [12] Bank D, Koenigstein N, Giryes R. Autoencoders. Source: [https://www.researchgate.net/publication/339945889\\_Autoencoders](https://www.researchgate.net/publication/339945889_Autoencoders).
- [13] About Keras. The Functional API. Source: [https://keras.io/guides/functional\\_api/](https://keras.io/guides/functional_api/).
- [14] About Keras. Keras API reference: Convolution 2D layers. Source: [https://keras.io/api/layers/convolution\\_layers/convolution2d/](https://keras.io/api/layers/convolution_layers/convolution2d/).
- [15] Turchenko V, Luczak A. Creation of a deep convolutional auto-encoder in caffe. Source: [https://www.researchgate.net/publication/286302172\\_Creation\\_of\\_a\\_Deep\\_Convolutional\\_Auto-Encoder\\_in\\_Caffe](https://www.researchgate.net/publication/286302172_Creation_of_a_Deep_Convolutional_Auto-Encoder_in_Caffe).
- [16] About Keras. Keras API reference: MaxPooling2D layer. Source: [https://keras.io/api/layers/pooling\\_layers/max\\_pooling2d/](https://keras.io/api/layers/pooling_layers/max_pooling2d/).
- [17] About Keras. Keras API reference: UpSampling2D layer. Source: [https://keras.io/api/layers/reshaping\\_layers/up\\_sampling2d/](https://keras.io/api/layers/reshaping_layers/up_sampling2d/).
- [18] About Keras. Keras API reference: Optimizers\_Adam. Source: <https://keras.io/api/optimizers/adam/>.
- [19] Kingma D, Ba J. Adam: A method for stochastic optimization. Source: [https://www.researchgate.net/publication/269935079\\_Adam\\_A\\_Method\\_for\\_Stochastic\\_Optimization](https://www.researchgate.net/publication/269935079_Adam_A_Method_for_Stochastic_Optimization).

### Сведения об авторах

**Комаров Валерий Андреевич**, 1941 года рождения, в 1964 году окончил Куйбышевский авиационный институт имени академика С.П. Королёва (ныне – Самарский национальный исследовательский университет имени академика С.П. Королёва). В настоящее время является директором научно-образовательного центра авиационных конструкций (НОЦ-202) и профессором кафедры конструкции и проектирования летательных аппаратов Самарского университета. Область научных интересов: оптимальное проектирование, математическое моделирование, численные методы и комплексы, композиционные материалы. E-mail: [vkomarov@ssau.ru](mailto:vkomarov@ssau.ru).

**Павлов Александр Александрович**, 1992 года рождения, в 2021 году окончил аспирантуру федерального государственного автономного образовательного учреждения высшего образования «Самарский национальный исследовательский университет имени академика С.П. Королёва» (Самарский университет) по специальности 05.07.02 «Проектирование, конструкция и производство летательных аппаратов». В настоящее время работает в должности инженера научно-образовательного центра авиационных конструкций НОЦ-202. Область научных интересов: проектирование, оптимизация, композиционные материалы, обработка и анализ изображений. E-mail: [alex-alex.pavlov@yandex.ru](mailto:alex-alex.pavlov@yandex.ru).

ГРНТИ: 28.23.15

Поступила в редакцию 14 января 2022 г. Окончательный вариант – 15 марта 2022 г.

---

# Determination of fibers volume fraction in layered composite materials by optical methods

V.A. Komarov<sup>1</sup>, A.A. Pavlov<sup>1</sup>

<sup>1</sup> Samara National Research University, 443086, Samara, Russia, Moskovskoye Shosse 34

## Abstract

A problem of determining the fiber volume fraction in fiber-reinforced strands of fabric-based laminated composites is considered. As a source of information about the structure of the material, digital micrographs of the ground surface of the cross-sections of the composites are used. Methods and features of the analysis of raster microscopic images of heterogeneous material associated with variable pixel brightness and blurring of the "fiber-binder" boundaries are discussed. To make the image processing less labor-intensive and more objective, a special autoencoder is proposed and built. The study of the structure of a typical structural carbon fiber-reinforced plastic is illustrated by an end-to-end demonstration example. A significant acceleration of the image processing process using the convolutional autoencoder and a good agreement of the results with a careful manual analysis are shown.

**Keywords:** composite, fiber, volume fraction, micrograph, image processing, autoencoder.

**Citation:** Komarov VA, Pavlov AA. Determination of fibers volume fraction in layered composite materials by optical methods. *Computer Optics* 2022; 46(3): 473-478. DOI: 10.18287/2412-6179-CO-1068.

**Acknowledgements:** This work was financially supported by the RF Ministry of Science and Higher Education of the Russian Federation under the project FSSS-2020-0016.

---

## Authors' information

**Valerii Andreevich Komarov** (b. 1941) graduated from the Kuibyshev Aviation Institute named after academician S.P. Korolyov (now Samara National Research University) in 1964. In 1969 he defended his Ph.D. on the topic "Some issues of rational design and calculation of power structures of low aspect ratio wings", in 1976 – his doctoral thesis on the topic "Rational design of power aircraft structures". The Director of the Scientific and Educational Center for Aircraft Structures (AVICON) and professor of Aircraft Construction and Design department at Samara University. Research interests: optimal design, mathematical modeling, numerical methods and complexes, composite materials.

E-mail: [vkomarov@ssau.ru](mailto:vkomarov@ssau.ru).

**Aleksandr Aleksandrovich Pavlov** (b. 1992) graduated from the graduate school of Samara National Research University, specialty 05.07.02 "Design, construction and manufacturing of aircraft". An engineer at the Scientific and Educational Center for Aircraft Structures (AVICON). Research interests: design, optimization, composite materials, image processing and analysis.

E-mail: [alex-alex.pavlov@yandex.tu](mailto:alex-alex.pavlov@yandex.tu).

---

Received January 14, 2022. The final version – March 15, 2022.

---