

Оригинальная статья / Original article

<https://doi.org/10.21869/2223-1560-2021-25-2-93-106>

Композиция моделей классификации для распознавания скорости течения жидкостей в капиллярах

Е. П. Корнаева¹ ✉, И. Н. Стебаков¹, Д. Д. Ставцев¹,
В. В. Дремин¹, А. В. Корнаев¹

¹ Орловский государственный университет имени И.С. Тургенева
Наугорское шоссе 20, г. Орёл 302020, Российская Федерация

✉ e-mail: lenoks_box@mail.ru

Резюме

Цель исследования. Разработка методики оценки средней скорости течения физиологических жидкостей в капиллярах по изображениям, полученным с помощью лазерной спекл-контрастной визуализации. Методика включает получение экспериментальных данных в виде изображения течения жидкости в тонкой трубке, их предварительную обработку, включая отсеивание и сжатие данных, а также обучение и тестирование приближенных моделей с использованием современных методов машинного обучения.

Методы. Экспериментальное исследование течения жидкости в трубке основано на применении метода лазерной спекл-контрастной визуализации, по полученным изображениям рассчитываются значения пространственного спекл-контраста. Полученные данные подвергаются предварительной обработке, включающей отсеивание данных до установившегося режима течения, а также сжатие полученных изображений с помощью метода главных компонент, что позволяет снизить размерность признакового пространства. Задача прогнозирования средней скорости по изображению течения жидкости решается как задача классификации на основе композиции решающих деревьев, построенных с помощью процедуры бэггинга, а также в виде «случайного» леса.

Результаты. Разработана методика предсказания средней скорости течения жидкости в капилляре по изображениям, полученным с помощью метода лазерной спекл-контрастной визуализации. Точность предсказания средней скорости (или расхода) на обучающей выборке составила около 91%, на валидационной и тестовой выборках - не менее 81,5%.

Заключение. На основе разработанной методики планируется определять кинематические характеристики параметров течения физиологических жидкостей, что позволит улучшить разработанный ранее авторами инерционный способ измерения вязкости испытуемых жидкостей, избавившись от ряда допущений относительно профиля скорости.

Ключевые слова: капилляр; лазерная спекл-контрастная визуализация; средняя скорость течения; вязкость; машинное обучение; решающие деревья, бэггинг.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Финансирование: Настоящее исследование выполнено в рамках выполнения проекта РНФ №20-79-00332.

Для цитирования: Композиция моделей классификации для распознавания скорости течения жидкостей в капиллярах / Е. П. Корнаева, И. Н. Стебаков, Д. Д. Ставцев, В. В. Дремин, А. В. Корнаев // Известия Юго-Западного государственного университета. 2021; 25(2): 93-106. <https://doi.org/10.21869/2223-1560-2021-25-2-93-106>.

Поступила в редакцию 25.03.2021

Подписана в печать 29.04.2021

Опубликована 24.08.2021

Composition of Classification Models for Recognizing the Flow Velocity of Liquids in Capillaries

Elena P. Kornaeva ¹ ✉, Ivan N. Stebakov ¹, Dmitry D. Stavtsev ¹,
Viktor V. Dremin ¹, Alexey V. Kornaev ¹

¹ Orel State University named after I.S. Turgenev
20, Naugorskoe highway, Orel 302020, Russian Federation

✉ e-mail: lenoks_box@mail.ru

Abstract

Purpose of research. Development of a technique for estimating the average flow rate of physiological fluids in capillaries from images obtained using laser speckle-contrast imaging. The technique includes obtaining experimental data in the form of an image of the fluid flow in a thin tube, their preliminary processing, including filtering and compressing data, as well as training and testing approximate models using modern machine learning methods.

Methods. The experimental study of the fluid flow in the tube is based on the application of the laser speckle-contrast imaging method. The spatial speckle-contrast values are calculated from the obtained images. The obtained data are subjected to preliminary processing, including the data filtering out and extending to a steady flow mode, as well as compressing the obtained images using the principal component method, which allows reducing the dimension of the feature space. The problem of predicting the average velocity from the image of the fluid flow is solved as a classification problem based on the composition of decision trees constructed through the bagging procedure, as well as in the form of a random forest.

Results. A technique for predicting the average velocity of liquid flow in a capillary from images obtained using the laser speckle-contrast imaging method has been developed. The accuracy of predicting the average velocity (or flow rate) based on the training sample was about 91%, on the validation and test samples - at least 81.5%.

Conclusion. Based on the developed technique, it is planned to determine the kinematic characteristics of the parameters of physiological fluids flow, which will improve the inertial method of measuring the viscosity of the tested liquids developed earlier by the authors, getting rid of a number of assumptions about the velocity profile.

Keywords: capillary; laser speckle-contrast visualization; average flow velocity; viscosity; machine learning; decision trees, bagging.

Conflict of interest. The authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

Financing: The present study was carried out within the framework of the RGNF project No. 20-79-00332.

For citation: Kornaeva E.P., Stebakov I.N., Stavtsev D.D., Dremin V.V., Kornaev A.V. Composition of Classification Models for Recognizing the Flow Velocity of Liquids in Capillaries. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta* = *Proceedings of the Southwest State University*. 2021; 25(2): 93-106 (In Russ.). <https://doi.org/10.21869/2223-1560-2021-25-2-93-106>.

Received 25.03.2021

Accepted 29.04.2021

Published 24.08.2021

Введение

Анализ изменения свойств физиологических жидкостей, в частности крови, может использоваться в качестве диагностики различных заболеваний, включая сердечно-сосудистые патологии, рак, ламинопатию, диабет, ряд инфекционных заболеваний, и даже старения. В работах [1-4] показано, что изменение вязкости крови связано с регуляцией иммунных реакций. В работе [5] представлены данные о том, что повышение вязкости крови ассоциировано с рядом заболеваний: острый нелимфоцитарный лейкоз, хронический лимфолейкоз, хронический миелоидный лейкоз, серповидно-клеточная анемия. Таким образом, исследование реологических и кинематических свойств физиологических жидкостей является актуальной задачей. Особый интерес представляют малоинвазивные методы. Существенные успехи достигнуты в развитии методов регистрации динамического рассеяния света для анализа параметров кровотока, в частности в лазерной доплеровской флоуметрии и лазерной спекл-контрастной визуализации (ЛСКВ), которые позволяют производить исследования в режиме «in vivo» [6-9]. Оценка микроциркуляции с помощью ЛСКВ применяется в ревматологии, дерматологии, офтальмологии, неврологии и многих других областях медицины [10-12]. ЛСКВ метод позволяет в режиме реального времени получать визуализацию микроциркуляции в

тканях. В указанных выше работах демонстрируется качественная оценка изменения потока в капилляре, показано, что существует корреляционная связь спекл-контраста от скорости. Однако существует проблема определения количественных параметров кровотока. Так для измерения вязкости жидкости необходимо определять кинематические параметры потока. С развитием современных методов машинного обучения и доступностью мощных средств GPU становится возможным построение сложных приближенных моделей по большим массивам экспериментальных данных.

В данной работе разработаны приближенные модели, позволяющие распознавать среднюю скорость течения физиологических жидкостей по изображениям, полученным с помощью метода ЛСКВ. Эксперимент проводился при фиксированных значениях скорости подачи жидкости в трубке, поэтому средняя скорость течения может рассматриваться как дискретная величина. Модели классификации средней скорости построены на основе композиции решающих деревьев [13]. Разработанная в данной работе методика в дальнейшем будет применима для обработки экспериментов по измерению вязкости физиологических жидкостей с применением инерционного способа измерения [13], в котором предварительно необходимо определять кинематические характеристики течения жидкости.

Материалы и методы

Проведение эксперимента и предварительная подготовка данных для обучения

Эксперимент проводился на установке (рис.1) Центра биомедицинской фотоники ОГУ имени И.С. Тургенева [8]. Исследовалось напорное течение физиологической жидкости через медицинский стеклянный капилляр диаметром 1,6 мм. В качестве жидкости использовался интралипид 20% (Fresenius

Kaby, США) в концентрации 8 %. Для обеспечения постоянного расхода заданной величины использовался электронасос ДШ-08 (Висма, Беларусь). Регистрация потока, освещенного лазером LDM785 (Thorlabs Inc.), осуществлялась с помощью КМОП-камеры UI-3360CP-NIR-GL Rev.2 (IDS GmbH, Германия) в сочетании с адаптером-удлинителем и объективом MVL25TM23 (Thorlabs, Inc., США). Лазер работает на длине волны 785 нм.




Рис. 1. Фотография экспериментальной установки

Fig.1. Photograph of the experimental setup

Объёмный расход раствора в насосе был пересчитан с учётом диаметра капилляра таким образом, чтобы создавать в нем потоки со средней скоростью 0,5; 1; 1,5; 2 мм/с соответственно. Изменение скорости движения жидкости регистрировалось камерой со временем выдержки 5, 15 и 33 мс. Частота записи изображений составляла 30 кадр/с.

Эксперимент включал в себя по пять параллельных опытов для каждой средней скорости для каждого соотношения времени выдержки и концентрации. Все опыты выполнялись в случайном порядке. Время записи составляло около 1 минуты.

Оценка скорости течения жидкости основана на расчете величины пространственного контраста [14]:

$$K = \frac{\sigma_n}{\langle I_n \rangle},$$

где n – размер области расчета;

σ_n – стандартное отклонение интенсивности;

$\langle I_n \rangle$ – средняя интенсивность.

При расчете пространственного спекл-контраста используется область из нескольких пикселей в одном кадре, чаще всего принимают размер окна равным 7×7 пикселей. Если время экспозиции детектора бесконечно мало или меньше времени флуктуации интенсивности спеклов, то стандартное отклонение σ будет равно средней интенсивности, что теоретически приводит к значению speckle contrast равному единице. Если присутствует движение и время экспозиции детектора порядка или больше времени флуктуации, то изображение будет размытым. Это означает, что стандартное отклонение будет меньшим по сравнению со средней интен-

сивностью, что приведет к потере контраста. Таким образом, K находится в пределах от 0 до 1.

На рис. 2 представлено изменение среднего пространственного спекл-контраста от скорости движения жидкости по капилляру. Парный коэффициент корреляции равен $-0,91$ и при уровне значимости $0,05$ наблюдаемое значение критерия Стьюдента по модулю не значительно превосходит критическое (разница в третьем знаке). В таком случае данных для принятия значимости парного коэффициента корреляции недостаточно, что в данном случае говорит о том, что связь между средней скоростью и пространственным спекл-контрастом скорее нелинейная. Значение спекл-контраста при скорости больше $1,5$ мм/с предположительно асимптотически приближается к некоторой константе.




Рис. 2. Изменение пространственного спекл-контраста от средней скорости

Fig. 2. The box-plot for spatial speckle contrast at different flow rates

По графикам также видно, что в данных присутствуют выбросы, которые обусловлены наличием низких и высоких спекл-контрастов до установившегося режима подачи жидкости. При скорости 1,5 и 2,0 мм/с можно заметить большой разброс значений относительно среднего, что объясняется нестабильной работой насоса. Такие данные были удалены из выборки.

Модели прогноза средней скорости жидкости в капилляре

Задачу определения средней скорости течения жидкости в капиллярах с учетом полученных данных можно рассматривать как задачу классификации и аппроксимировать не сами значения скорости, а их вероятности. В самом деле, переменную скорости со значени-

ями $\{0, 0.5, 1, 1.5, 2\}$ можно рассматривать как дискретную случайную величину, соответствующую номерам классов $\{0, 1, 2, 3, 4\}$. В качестве обучающей выборки выступает множество пар типа {изображение, номер класса}, количество экземпляров каждого класса примерно одинаковое. Фрагмент случайно выбранных экземпляров представлен на рис. 3. В качестве матрицы признаков рассматривается значение контраста в каждом пикселе изображения размером $[150 \times 150]$, таким образом, матрица признаков для выборки объема n имеет размер $n \times 150 \times 150$, а соответствующая матрица меток – размер $n \times 1$. Матрица признаков преобразуется в двумерную размером $n \times 22500$, т.е. количество признаков получается равным 22500.




Рис. 3. Случайные экземпляры выборки

Fig. 3. Random sample from the training set

Ввиду большой мерности пространства признаков можно предположить, что какие-то признаки (контрасты на изображении) могут оказаться незначимыми. На основе этого предположения к признакам был применен метод главных компонент [14, 15], что позволило сократить мерность признакового пространства. В результате вычислительного эксперимента на разработанных моделях было установлено, что включение в матрицу признаков более 100 главных компонент не дает дальнейшего увеличения точности модели при прочих равных условиях.

Полученная выборка объемом 20 000 изображений разделена на три части: на тестирование взято 20%, на обучение и валидацию оставшиеся 80%, которые были разделены в отношении 70/30.

Задача прогнозирования средней скорости по виду контрастного изображения может быть решена как задача классификации с помощью композиции решающих деревьев. С одной стороны, решающие деревья представляют собой простые в понимании модели, позволяющие выявлять сложные закономерности, однако такие модели способны легко переобучаться [14, 16]. Т.е. каждое дерево в отдельности имеет низкое смещение и высокий разброс, т.к. с увеличением глубины склонно запоминать шумы в обучающей выборке. Этот недостаток способны решить композиции решающих деревьев при условии, что они построены на независимых выборках.

Одним из вариантов построения композиции решающих деревьев является обучение каждого дерева на бутстрапированной выборке, т.е. выборке, полученной из исходной с повторениями. Показано, что уникальных объектов в таких выборках около 63% [16]. Таким образом, каждое дерево, имеющее низкое смещение и высокий разброс, в композиции даст сложную, но не переобученную модель. В качестве предсказанного отклика для каждого изображения предполагается использовать модальное значение по предсказаниям всех деревьев.

При построении предикатов в каждой вершине Q_m , содержащей N_m объектов, использовался критерий минимума неопределенности (хаотичности [16, 17]):

$$\frac{N_l}{N_m} H(Q_l(\Theta)) + \frac{N_r}{N_m} H(Q_r(\Theta)) \xrightarrow{\Theta} \min,$$

где $\Theta = (j, t_m)$ – номер признака X_j и порог для предиката $X_j \leq t_m$ в вершине m ;

N_l, N_r – количество объектов в левой и правой вершине;

$Q_l(\Theta) = \{(X, y) | x_j \leq t_m\}$ – объекты в левую вершину;

$Q_r(\Theta) = Q_m \setminus Q_l(\Theta)$ – объекты в правую вершину;

$H(Q_i) = \sum_{k=1}^K p_{ik}(1 - p_{ik})$ – критерий Джини [15] как мера неопределенности в $i^{\text{ой}}$ вершине;

$p_{ik} = \frac{1}{N_i} \sum_{y \in Q_i} [y == k]$ – доля объектов $k^{\text{го}}$ класса, попавших в $i^{\text{ю}}$ вершину.

Другим вариантом композиции деревьев является «случайный лес» [14]. При разбиении вершины каждого дере-

ва выбирается случайным образом часть признаков, что позволяет сократить время поиска оптимального предиката. Таким образом, каждое дерево обучается все равно на всех признаках, но в каждой вершине рассматривается только их часть.

В следующем пункте представлены результаты классификации, основанные на композиции решающих деревьев, построенных с помощью процедуры бутстрапа и в виде «случайные леса».

Результаты и их обсуждение

Так как выборки являются сбалансированными по классам, то для оценки точности можно использовать долю вер-

ных ответов (accuracy). В табл. 1 представлена средняя доля верных ответов при обучении, валидации и тестировании для композиции решающих деревьев. Композиция моделей, построенных на основе бэггинга, оптимизировалась по следующим гиперпараметрам: количество деревьев в композиции $n_est=[30\ 50\ 100]$ и максимальная глубина каждого дерева $max_depth[6\ 8\ 10\ 12\ 14]$.

Значения средней точности модели представлены по 10 прогонам при фиксированном сочетании параметров. С ростом глубины деревьев ожидаемо растет разница между точностью обучения и точностью валидации.

Таблица 1. Точность композиции решающих деревьев на основе бэггинга

Table.1. The accuracy of the decision trees ensemble

Гиперпараметры / Hyperparameters		Точность, % / Accuracy, %		
n_est	« max_depth »	Обучения	Валидации	Тестирования
30	6	83,39	80,50	80,70
	8	87,96	80,50	80,80
	10	92,21	80,58	80,30
	12	94,89	80,67	80,20
	14	96,25	80,67	80,10
50	6	84,32	82,25	81,70
	8	87,32	82,50	81,30
	10	91,25	82,58	81,80
	12	94,14	82,17	81,70
	14	96,04	82,00	81,30
100	6	84,50	82,08	81,20
	8	87,43	82,25	81,20
	10	91,50	82,58	82,20
	12	94,75	82,25	81,90
	14	96,75	82,00	81,80

Максимальное значение точности на валидационной выборке в среднем составляет примерно 82,5%, что соответствует 50 деревьям в композиции и максимальной глубине, равной 10. Учитывая, что каждый прогон модели осуществляется на случайной подвыборке, незначительные колебания в точности не имеют значения, поэтому разница между 50 и 100 деревьями в композиции не

существенна. Также при количестве деревьев больше 50 максимальная глубина может выбираться в диапазоне от 6 до 10. Точность композиции на тестовой выборке составляет не менее 81,7%.

На рис.4 представлены значения средней точности «случайного леса» по 10 прогонам, деревья в лесе строились также на бутстрапированных выборках.




Рис. 4. Доля верных ответов «случайного леса»

Fig. 4. The 'random forest' true responses

Точность обучения и тестирования при тех же гиперпараметрах сопоставима с точность композиции решающих деревьев, обученных с помощью бэггинга. Небольшие различия можно объяснить случайным выбором подмножества признаков в каждой вершине дерева «случайного дерева».

Таким образом, в работе представлена методика распознавания средней скорости (или расхода) течения физиологических жидкостей в капилляре. Методика содержит несколько этапов. По экспериментальным данным, полученным в виде изображений течения физиологических жидкостей методом ла-

зерной спекл-контрастной визуализации, предварительно рассчитывается пространственный спекл-контраст. Далее для понижения размерности признакового пространства используется метод главных компонент, который позволяет отбросить пиксели, несущие несущественную информацию. По полученным в результате сжатия данным строятся композиции решающих деревьев с помощью процедуры бэггинга.

Построенные модели с тестовой точностью не менее 81,5% позволяют предсказывать среднюю скорость течения жидкости в капилляре по изображениям, полученным с помощью лазерной спекл-контрастной визуализации. Ранее в работе [18] авторами была представлена приближенная методика расчета вязкости жидкости, основанной на экспериментальных исследованиях течения с помощью инерционного вискозиметра. Представленные в данной работе модели расчета средней скорости (или объемного расхода) позволят модифицировать методику расчета вязкости жидкости в капилляре [18]. Также для совершенствования указанной методики предполагается модификация экспериментальной установки [18]: уменьшение ее размеров, добавление лазерного модуля для освещения трубки,

объектива и камеры, фиксирующей изображение. Также предполагается использование компьютера Jetson Nano, что обусловлено его небольшим размером и наличием ядер CUDA, которые позволяют обрабатывать изображения с камеры непосредственно на устройстве [19, 20].

Выводы

Разработана методика предсказания средней скорости течения жидкости в капилляре по изображениям течения. Предварительный анализ данных, связанный с отсеиванием их части до установившегося режима, а также использование бутстрапированных выборок позволило построить композиции моделей с точностью предсказания на обучающей выборке около 91% и на тестовой выборке - не менее 81,5%. Также предварительное снижение размерности признакового пространства позволило существенно сократить время обучения моделей, при достаточно большом объеме обучающей выборки. Разработанная методика позволит в дальнейшем определять кинематические характеристики параметров течения, что позволит проводить приближенный расчет вязкости жидкости с помощью ранее разработанного авторами инерционного способа определения вязкости.

Список литературы

1. Xu J., Vilanova G., Gomez H. Phase-field model of vascular tumor growth: Three-dimensional geometry of the vascular network and integration with imaging data // *Comput. Methods Appl. Mech. Engrg.* 2020; Vol. 359: 1-19.

2. Applying Methods of Diffuse Light Scattering and Optical Trapping for Assessing Blood Rheological Parameters: Erythrocytes Aggregation in Diabetes Mellitus / A.N. Semenov, A.E. Lugovtsov, K. Lee, and et. al. // *Izv. Saratov Univ. (N.S.), Ser. Physics*. Vol. 17. Iss. 2. P. 85–97 (in Russian). 2017; <http://doi.org/10.18500/1817-3020-2017-17-2-85-97>.
3. Yeow N. , Tabor R., Garnier G. Atomic force microscopy: From red blood cells to immunohematology // *Advances in Colloid and Interface Science*. 2017. Vol. 249. P. 149–162. <http://dx.doi.org/10.1016/j.cis.2017.05.011>.
4. Harris M. J., Wirtz D., Wu P. Dissecting cellular mechanics: Implications for aging, cancer, and immunity // *Seminars in Cell & Developmental Biology*. 2018. P. 1 – 10.
5. Gertz M. A.. Acute hyperviscosity: syndromes and management // *Blood*. 2018. Vol. 132. Iss. 13. P. 1379-1385. <https://doi.org/10.1182/blood-2018-06-846816>.
6. Goodman J.W. Speckle Phenomena in Optics: Theory and Applications. Robert and Company Publisher. 2007.
7. Laser Doppler flowmetry in blood and lymph monitoring, technical aspects and analysis / V.V. Dremin, E.A. Zherebtsov, I.N. Makovik, and et al. // *Proceedings of SPIE*. 2017. Vol. 10063. P. 1006303. <http://doi.org/10.1117/12.2252427>.
8. Laser speckle contrast imaging of blood microcirculation in pancreatic tissues during laparoscopic interventions / E. Potapova, E. Seryogina., V. Dremin and et. al. // *Quantum Electronics*. 2020. Vol. 50. P. 33-14, <http://doi.org/10.1070/QEL17207>.
9. Image-guided simulation in comparison with laser speckle contrast imaging for full-field observation of blood flow in a microvasculature model / Y. Yang, J. Geng, H. Zhang, and et. al. // *Microvasc Res*. 2021. Vol. 133. <http://doi.org/10.1016/j.mvr.2020.104092>.
10. Wavelet Analysis of the Temporal Dynamics of the Laser Speckle Contrast in Human Skin / I. Mizeva, V. Dremin, E. Potapova and et al. // *IEEE Transactions on Biomedical Engineering*. 2020. Vol. 67. No. 7. P. 1882-1889. <http://doi.org/10.1109/TBME.2019.2950323>.
11. Monitoring oxidative metabolism while modeling pancreatic ischemia in mice using a multimodal spectroscopy technique / V. Dremin, E. Potapova, A. Mamoshin and et al. // *Laser Physics Letters*. 2020. Vol. 11. No. 17. P. 115605. <http://doi.org/10.1088/1612-202X/abbefa>.
12. Clinical applications of laser speckle contrast imaging: a review / W. Heeman W. Steenbergen, Gooitzen M. van Dam et al. // *Journal of biomedical optics*. 2019. Vol. 24. No. 8. P. 1-11. <http://doi.org/10.1117/1.JBO.24.8.080901>.
13. Goodfellow Y. Y, Bengio Y., Courville A.. Deep learning. MIT Press. 2016.
14. Review of laser speckle contrast techniques for visualizing tissue perfusion / M. Draijer, E. Hondebrink, T. van Leeuwen, W. Steenbergen // *Lasers in medical science*. 2009; Vol. 24. No. 4: 639-651. <http://doi.org/10.1007/s10103-008-0626-3>.

15. Sarah Guido, Andreas Muller. Introduction to Machine Learning with Python: A Guide for data scientists. O'Reilly & Associates. 2017.
16. Geron A. Hands-On Machine Learning with Scikit-Learn and TensorFlow. Tokyo, 2019.
17. Scikit-learn. Machine Learning in Python. URL: <https://scikit-learn.org/stable/modules/tree.html#tree>
18. Kornaeva E., Kornaev A., Savin L., and et al. Theoretical premises of a vibro-inertial method of viscosity measurement // *Vibroengineering Procedia*. 2016. Vol. 8. P. 440 – 445.
19. NVidia Jetson Nano Datasheet // [nvidia.com](https://developer.download.nvidia.com/assets/embedded/secure/jetson/Nano/docs/JetsonNano_DataSheet_DS09366001v1.0.pdf). URL: [https:// developer.download.nvidia.com/assets/embedded/secure/jetson/Nano/docs/JetsonNano_DataSheet_DS09366001v1.0.pdf](https://developer.download.nvidia.com/assets/embedded/secure/jetson/Nano/docs/JetsonNano_DataSheet_DS09366001v1.0.pdf)? (дата обращения: 15.03.2021).
20. Süzen A. A., Duman B., Şen B.. Benchmark Analysis of Jetson TX2, Jetson Nano and Raspberry PI using Deep-CNN // *2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*. 2020. P.1-5.

References

1. Xu J., Vilanova G., Gomez H. Phase-field model of vascular tumor growth: Three-dimensional geometry of the vascular network and integration with imaging data. *Comput. Methods Appl. Mech. Engrg*, 2020, vol. 359, pp. 1-19.
2. Semenov A.N., Lugovtsov A.E., Lee K. and et. al. Applying Methods of Diffuse Light Scattering and Optical Trapping for Assessing Blood Rheological Parameters: Erythrocytes Aggregation in Diabetes Mellitus. *Izv. Saratov Univ. (N.S.), Ser. Physics*, 2017, vol. 17, is. 2, pp. 85–97 (in Russian).; <http://doi.org/10.18500/1817-3020-2017-17-2-85-97>.
3. Yeow N. , Tabor R., Garnier G. Atomic force microscopy: From red blood cells to immunohematology. *Advances in Colloid and Interface Science*. 2017, vol. 249, pp. 149–162. <http://dx.doi.org/10.1016/j.cis.2017.05.011>.
4. Harris M. J., Wirtz D., Wu P. Dissecting cellular mechanics: Implications for aging, cancer, and immunity. *Seminars in Cell & Developmental Biology*, 2018, pp. 1 – 10.
5. Gertz M. A. Acute hyperviscosity: syndromes and management. *Blood*. 2018, vol. 132, iss. 13, pp. 1379-1385. <https://doi.org/10.1182/blood-2018-06-846816>.
6. Goodman J.W. Speckle Phenomena in Optics: Theory and Applications. Robert and Company Publisher. 2007.
7. Dremin V.V., Zhrebtssov E.A., Makovik I.N. and et al. Laser Doppler flowmetry in blood and lymph monitoring, technical aspects and analysis. *Proceedings of SPIE*, 2017, vol. 10063: 1006303. <http://doi.org/10.1117/12.2252427>.

8. Potapova E., Seryogina E., Dremine V. and et. al. Laser speckle contrast imaging of blood microcirculation in pancreatic tissues during laparoscopic interventions. *Quantum Electronics*, 2020, vol. 50, pp. 33-14. <http://doi.org/10.1070/QEL17207>.
9. Yang Y., Geng J., Zhang H. and et. al. Image-guided simulation in comparison with laser speckle contrast imaging for full-field observation of blood flow in a microvasculature model. *Microvasc Res*, 2021, vol. 133. <http://doi.org/10.1016/j.mvr.2020.104092>.
10. Mizeva I., Dremine V., Potapova E. and et al. Wavelet Analysis of the Temporal Dynamics of the Laser Speckle Contrast in Human Skin. *IEEE Transactions on Biomedical Engineering*, 2020, vol. 67, no. 7, pp. 1882-1889. <http://doi.org/10.1109/TBME.2019.2950323>.
11. Dremine V., Potapova E., Mamoshin A. and et al. Monitoring oxidative metabolism while modeling pancreatic ischemia in mice using a multimodal spectroscopy technique. *Laser Physics Letters*, 2020, vol. 11, no. 17, p. 115605. <http://doi.org/10.1088/1612-202X/abbefa>.
12. Heeman W., Steenbergen W., Gooitzen M. van Dam et al. Clinical applications of laser speckle contrast imaging: a review. *Journal of biomedical optics*, 2019, vol. 24, no. 8, pp. 1-11. <http://doi.org/10.1117/1.JBO.24.8.080901>.
13. Goodfellow Y. Y, Bengio Y., Courville A.. Deep learning. MIT Press. 2016.
14. Draijer M., Hondebrink E., van Leeuwen T., Steenbergen W.. Review of laser speckle contrast techniques for visualizing tissue perfusion. *Lasers in medical science*, 2009, vol. 24, no. 4, pp. 639-651. <http://doi.org/10.1007/s10103-008-0626-3>.
15. Sarah Guido, Andreas Muller. Introduction to Machine Learning with Python: A Guide for data scientists. O'Reilly & Associates. 2017.
16. Geron A. Hands-On Machine Learning with Scikit-Learn and TensorFlow. Tokyo, 2019.
17. Scikit-learn. Machine Learning in Python. Available at: <https://scikit-learn.org/stable/modules/tree.html#tree>
18. Kornaeva E., Kornaev A., Savin L., et al. Theoretical premises of a vibro-inertial method of viscosity measurement. *Vibroengineering Procedia*, 2016, vol. 8, pp. 440 – 445.
19. NVidia Jetson Nano Datasheet // nvidia.com Available at: [https:// developer.download.nvidia.com/assets/embedded/secure/jetson/Nano/docs/JetsonNano_DataSheet_DS09366001v1.0.pdf](https://developer.download.nvidia.com/assets/embedded/secure/jetson/Nano/docs/JetsonNano_DataSheet_DS09366001v1.0.pdf)? (accessed: 15.03.2021).
20. Süzen A. A., Duman B., Şen B.. Benchmark Analysis of Jetson TX2, Jetson Nano and Raspberry PI using Deep-CNN. *2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*, 2020, pp.1-5.

Информация об авторах / Information about the Authors

Корнаева Елена Петровна, кандидат физико-математических наук, доцент кафедры информационных систем и цифровых технологий, Орловский государственный университет имени И.С. Тургенева, г. Орел, Российская Федерация, e-mail: lenoks_box@mail.ru, ORCID:<https://orcid.org/0000-0003-0123-4004>

Elena P. Kornaeva, Cand. of Sci. (Phisico-Mathematical), Associate Professor, Information Systems Department, Orel State University named after I.S. Turgenev, Orel, Russian Federation, e-mail: lenoks_box@mail.ru, ORCID:<https://orcid.org/0000-0003-0123-4004>

Стебаков Иван Николаевич, аспирант кафедры мехатроники, механики и робототехники, Орловский государственный университет имени И.С. Тургенева, г. Орел, Российская Федерация e-mail: chester50796@yandex.ru

Ivan N. Stebakov, Post-Graduate Student, Mechatronics, Mechanics and Robotics Department, Orel State University named after I.S. Turgenev, Orel, Russian Federation, e-mail: chester50796@yandex.ru

Ставцев Дмитрий Дмитриевич, стажер-исследователь научно-технологического центра биомедицинской фотоники, Орловский государственный университет имени И.С. Тургенева, г. Орел, Российская Федерация, e-mail: stavtsev.dmitry@gmail.com

Dmitry D. Stavtsev, Research Trainee, Research and Development Center of Biomedical Photonics, Orel State University named after I.S. Turgenev, Orel, Russian Federation, e-mail: stavtsev.dmitry@gmail.com

Дрёмин Виктор Владимирович, кандидат технических наук, научный сотрудник научно-технологического центра биомедицинской фотоники, Орловский государственный университет имени И.С. Тургенева, г. Орел, Российская Федерация, e-mail: dremin_viktor@mail.ru

Viktor V. Dremin, Cand. of Sci. (Engineering), Researcher, Research and Development Center of Biomedical Photonics, Orel State University named after I.S. Turgenev, Orel, Russian Federation, e-mail: stavtsev.dmitry@gmail.com

Корнаев Алексей Валерьевич, доктор технических наук, профессор кафедры мехатроники, механики и робототехники, Орловский государственный университет имени И.С. Тургенева, г. Орел, Российская Федерация e-mail: rusakor@inbox.ru

Alexey V. Kornaev, Dr. of Sci. (Engineering), Professor of Mechatronics, Mechanics and Robotics Department, Orel State University named after I.S. Turgenev, Orel, Russian Federation e-mail: rusakor@inbox.ru