Разработка алгоритма машинного обучения для оценки жизнеспособности ткани кишечной стенки с применением метода гиперспектральной визуализации

Шуплецов В.В.[1], Горюнов И.А.[1], Адаменков Н.А.[1,2], Мамошин А.В.[1,2], Потапова Е.В.[1], Дунаев А.В.[1], Дрёмин В.В.[1]

[1]Научно-технологический центр биомедицинской фотоники, Орловский государственный университет имени И.С. Тургенева, Орел, Россия
[2]БУЗ Орловской области «Орловская областная клиническая больница», Орел, Россия
SPIN-коды: 5964-9055, 7068-9339, 3348-8250, 2553-1200, 9315-8770, 8128-3093, 8990-5396
valery.shupletsov@bmecenter.ru

В данной работе представлен алгоритм машинного обучения для оценки жизнеспособности ткани кишечной стенки с использованием метода гиперспектральной визуализации. Алгоритм машинного обучения построен на основе экстремального градиентного бустинга, позволяющего с высокой точностью определять степень жизнеспособности тканей кишечной стенки. Результаты исследования могут найти применение в хирургической практике, позволяя повысить эффективность интраоперационной диагностики состояния тканей кишечника.

Ключевые слова: машинное обучение, градиентный бустинг, гиперспектральная визуализация, жизнеспособность кишечной стенки, кишечная ишемия

Введение

В данной работе представляется алгоритм машинного обучения для массивов данных, получаемых методом гиперспектральной визуализации, описанных в наших предыдущих исследованиях [1]. На сегодняшний день применение методов машинного обучения и глубокого обучения позволило добиться значительных успехов в анализе и распознавании медицинских изображений, что подтолкнуло исследователей к использованию этих методов для обработки данных гиперспектральной визуализации [2]. Благодаря высокому спектральному разрешению современных гиперспектральных систем становится возможным реализовать высокоточные модели классификации на основе классических методов сегментации [3] и продвинутых нейросетевых подходов [4]. Более того, некоторые ученые уже сделали первые шаги по внедрению метода гиперспектральной визуализации для определения жизнеспособности тканей кишечника, используя методы машинного обучения для классификации неизменных и ишемизированных участков [5], а также для уточнения краев резекции некротической ткани во время операции [6].

В настоящем исследовании мы представляем алгоритм машинного обучения с использованием экстремального градиентного бустинга, подходящего для задач сегментации и визуализации многомерных массивов данных [7], ожидая высокие показатели точности классификации. Таким образом целью данной работы явилось разработка алгоритма машинного обучения с использованием экстремального градиентного бустинга для сегментации гиперспектральных изображений кишечной стенки с последующим определением степени её жизнеспособности.

1. Описание измерительной системы и методики эксперимента

Для осуществления поставленной цели была реализована система гиперспектральной визуализации, возможности которой описаны в наших предыдущих работах [8]. Системы

включает в себя: гиперспектральную камеру SpecimIQ (Spectral Imaging Ltd., Финляндия), обеспечивающую спектральное разрешение 7 нм в диапазоне 400-1000 нм.; волоконно-кольцевой осветитель FRI61F50 (ThorLabs, США); источник широкополосного излучения OSL2 (ThorLabs, США). Система была установлена на усиленный штатив, объект измерения располагался под объективом камеры на расстоянии 20 см.

Экспериментальные исследования были проведены на девяти лабораторных крысах линии Вистар (самцы), возраст которых составлял 3 месяца. Рассматривалась модель ишемии кишечника, вызванной наложением лигатур на аркадные сосуды кишки и, как следствие, нарушением мезентериального кровотока, через различные промежутки времени (1, 6 и 12 ч.). Каждое животное через соответствующий промежуток времени подвергалось лапаротомии, с целью интраоперационной оценки кишечника. Все манипуляции с животными были проведены опытным хирургом, выполнены в соответствии с правилами GLP и одобрены этическим комитетом БУЗ Орловской области (протокол №2 от 18.09.23).

2. Алгоритм машинного обучения

Разработанный алгоритм машинного обучения можно разделить на 4 основных этапа. Первым этапом является предварительная обработка гиперспектральных массивов, заключающаяся в нормировке изображений на эталон диффузного отражения (пластина из фторопласта Ф4) и последующем применении фильтра Савицкого-Голея с полиномом 2 степени с размером окна 7.

Вторым этапом является маркировка гиперспектральных изображений на основе гистологической классификации Парка/Чуи. Были выделены три класса данных: интактная ткань кишечной стенки, возможно обратимая ишемия (Grade 1-5) и необратимая ишемия (Grade 6-8). В каждой группе для каждого гиперспектрального массива выделялась область, соответствующая определенному классу, путем применения полигональной маски в пространственных координатах. Далее из выделенной пространственной области извлекались спектральные данные для каждого пикселя, для создания обучающей выборки. В результате сегментации был получен набор спектральных данных для интактных тканей (45377 точек, 9 животных в обучающем наборе), возможно обратимой ишемии (32715 точек, 6 животных в обучающем наборе) и необратимой ишемии (11764 точки, 2 животных в обучающем наборе).

Третьим этапом является выбор наиболее важных спектральных признаков для работы модели с применением метода анализа главных компонент (PCA). Для оптимального выбора количества компонентов использовался метод объясненной дисперсии, целью которого было достижение порога в 99% объясненной дисперсии, что позволило сократить размерность до 10 компонент.

Четвертым этапом является применение экстремального градиентного бустинга в качестве метода машинного обучения. Для детальной настройки модели использовались: оптимизация общих параметров, параметров бустера и параметров задачи обучения. Далее, на основе оптимального количества раундов бустинга проводилась кросс-валидация.

3. Результаты

Следуя разработанному алгоритму машинного обучения, были созданы классификационные маски, наложенные на измеренные изображения кишечника, и проведено сравнение с картами тканевой сатурации, рассчитанные с использованием двухволнового подхода [9], для возможной обратимой ишемии, показанной на рис. 1а, 1б и необратимой ишемии, показанной на рис. 1в, 1г. Классификационные маски были построены с точностью принадлежности к классу >99%.

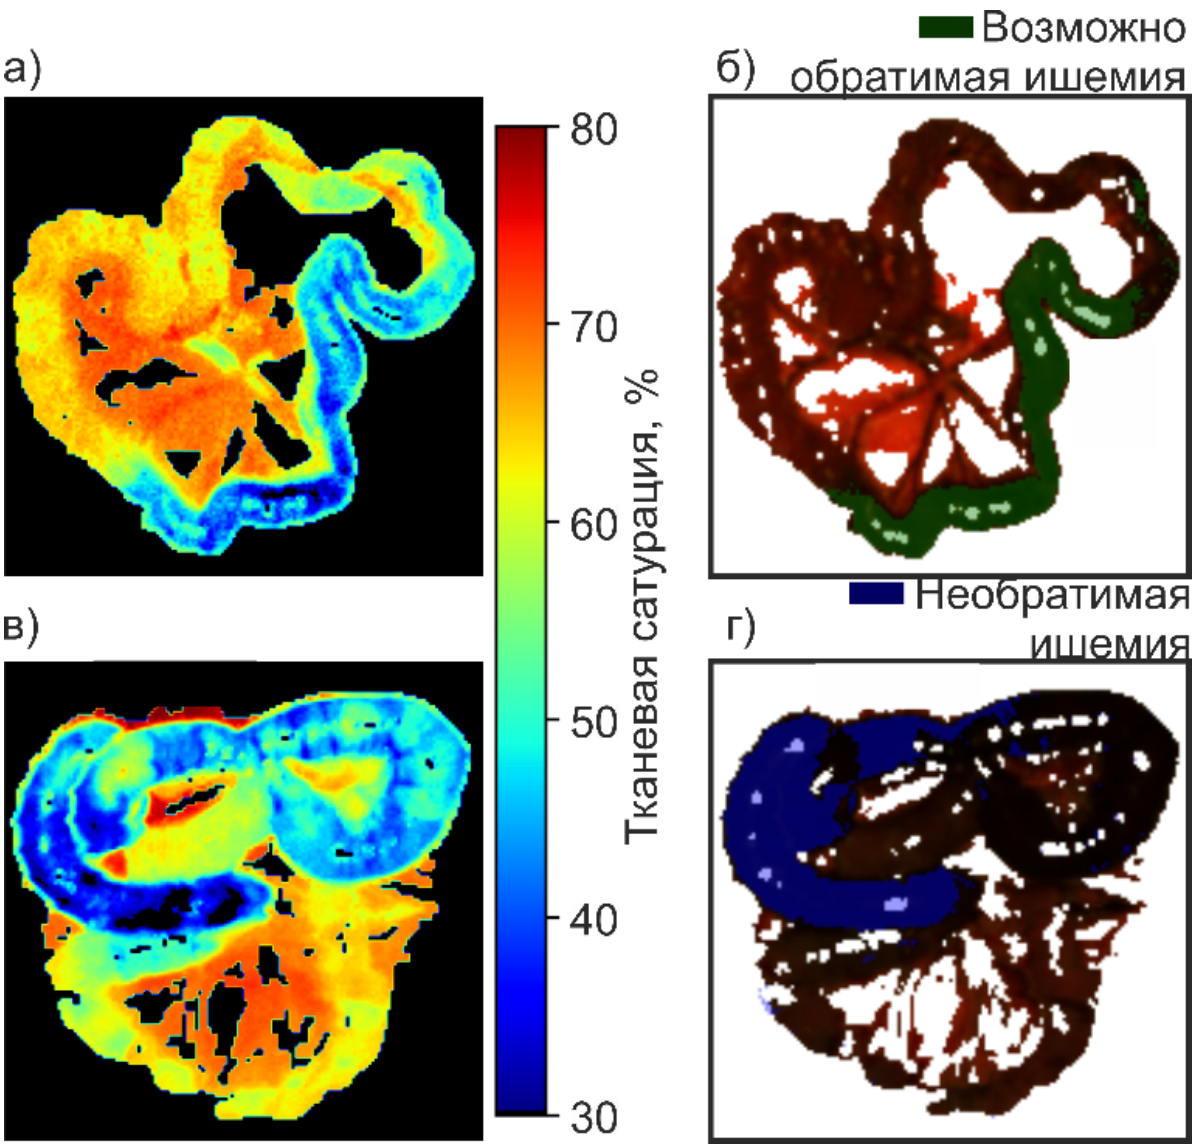

Рис. 1. Двумерные карты тканевой сатурации для возможной обратимой ишемии (а), для необратимой ишемии (в); классификационные карты для возможной обратимой ишемии (б), для необратимой ишемии (г).

Результаты показывают визуальное сходство между картами тканевой сатурации и классификационными картами. Однако использование классификационных карт для определения края резекции представляется более информативным, чем карты насыщения тканей кислородом. Как видно из результатов на карте насыщения на рис. 1в, область ишемии занимает большую часть петли кишки, показанную синим псевдоцветом и имеет различные уровни насыщения на своем участке. Однако на классификационной карте на рис. 1г только левая часть этой петли кишки, имеющая более темный синий псевдоцвет и значение насыщения, соответствующее необратимой ишемии, классифицируется как необратимая ишемия, в отличие от правой части петли, имеющей значение насыщения тканей, более подходящее для класса возможно обратимой ишемии.

Рассчитанные показатели точности для алгоритма машинного обучения, полученные на тестовой выборке (1 лабораторное животное для возможно обратимой ишемии, 1 лабораторное животное для необратимой ишемии), представлены в табл. 1.

Табл. 1. Показатели точности для разработанного алгоритма машинного обучения

	Точность	AUC	Чувствительность	Специфичность
Интактная ткань	0.98	0.99	0.98	0.94
Возможно обратимая ишемия	0.95	0.99	0.95	0.96
Необратимая ишемия	0.97	0.99	0.97	0.97

Выводы

Наше исследование показало, что применение методов машинного обучения позволяет уточнить область ишемических изменений, что дает более точную информацию врачу об обратимости ишемии и крае резекции ткани кишечника. Полученные результаты служат основой для применения гиперспектральной визуализации в интраоперационной диагностике состояния кишечника, связанного с нарушением кровоснабжения (ущемленная грыжа, перекрут кишки, странгуляционная кишечная непроходимость и т. д.), наряду с общепринятыми визуальными клиническими рекомендациями.

Работа выполнена при финансовой поддержке гранта РНФ №22-75-10088.

Список литературы

1. Адаменков Н.А., Мамошин А.В., Дремин В.В., Потапова Е.В., Шуплецов В.В., Горюнов И.А., Палалов А.А., Дунаев А.В. Оценка перфузии кишечной стенки в условиях ишемии с применением метода гиперспектральной визуализации // Оперативная хирургия и клиническая анатомия. 2024. Т. 8. № 1. С. 5–13.
2. Zherebtsov E., Dremin V., Popov A., Doronin A., Kurakina D., Kirillin M., Bykov A. Hyperspectral imaging of human skin aided by artificial neural networks // Biomed. Opt. Express. 2019. № 10. P. 3545.
3. Myasnikov E. V. Hyperspectral image segmentation using dimensionality reduction and classical segmentation approaches // Computer Optics. 2017. V. 41. №. 4. P. 564-572.
4. Vinokurov V., Khristoforova Y., Myakinin O., Bratchenko I., Moryatov A., Machikhin A., Zakharov V. Neural network classifier for hyperspectral images of skin pathologies //Journal of Physics: Conference Series. – IOP Publishing, 2021. V. 2127. №. 1. P. 012026.
5. Zhang L., Huang D., Chen X., Zhu L., Xie Z., Chen X., Shi W. Discrimination between normal and necrotic small intestinal tissue using hyperspectral imaging and unsupervised classification // Journal of Biophotonics. 2023. V. 16. №. 7. P. e202300020.
6. Zhang L. et al. Hyperspectral Imaging Combined with Deep Learning to Detect Ischemic Necrosis in Small Intestinal Tissue // Photonics. 2023. V. 10. №. 7. P. 708.
7. Chen T., Guestrin C. Xgboost: A scalable tree boosting system // Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining. 2016. P. 785-794.
8. Шуплецов В.В., Горюнов И.А., Адаменков Н.А., Журило И.П., Потапова Е.В., Дрёмин В.В. Применение метода гиперспектральной визуализации для определения микроциркуляторных нарушений биологических тканей // Оптические методы исследования потоков: Труды XVII Международной научно-технической конференции, 26–30 июня 2023. 2023. С.650-655.
9. Potapova E.V., Dremin V.V., Zherebtsov E. A., Makovik I.N., Zherebtsova A.I., Dunaev A.V., Podmasteryev K.V., Sidorov V.V., Krupatkin A.I., Khakhicheva L.S. Muradyan V.F. Evaluation of microcirculatory disturbances in patients with rheumatic diseases by the method of diffuse reflectance spectroscopy // Human Physiology. 2017. V. 43. P. 222-228.

Development of a machine learning algorithm for assessing intestinal wall tissue viability using hyperspectral imaging method

Shupletsov V.V.[1], Goryunov I.A.[1], Adamenkov N.A.[2], Mamoshin A.V.[2],
Potapova E.V.[1], Dunaev A.V.[1], Dremin V.V.[1]

[1]Research and Development Center of Biomedical Photonics,Turgenev Orel State University, Orel, Russia
[2]Orel Regional Clinical Hospital, Orel, Russia
SPIN-codes: 5964-9055, 7068-9339, 3348-8250, 2553-1200, 9315-8770, 8128-3093, 8990-5396
valery.shupletsov@bmecenter.ru

This paper presents a machine learning algorithm for assessing intestinal wall tissue viability using hyperspectral imaging. The machine learning algorithm is based on extreme gradient bousting, which allows to determine the degree of intestinal wall tissue viability with high accuracy. The results of the study can be applied in surgical practice, allowing to increase the efficiency of intraoperative diagnostics of intestinal tissue state.

Keywords: machine learning, gradient boosting, hyperspectral imaging, intestinal wall viability, intestinal ischemia.