

# Нейросетевой классификатор гиперспектральных изображений

Б.В. Гречкин

Самарский национальный  
исследовательский университет им.  
академика С.П. Королева  
Самара, Россия  
bgre4kin@yandex.ru

В.О. Винокуров

Самарский национальный  
исследовательский университет им.  
академика С.П. Королева  
Самара, Россия  
shleppel@yandex.ru

И.А. Матвеева

Самарский национальный  
исследовательский университет им.  
академика С.П. Королева  
Самара, Россия  
m-irene-a@yandex.ru

В последние годы для исследования биологических тканей все чаще используются различные оптические методы. Целью работы является изучение возможностей нейросетевого классификатора диагностировать онкологические заболевания кожи. Проведено исследование гиперспектральных снимков злокачественной меланомы и пигментного невуса. Разработан классификатор гиперспектральных изображений на основе нейронных сетей глубокого обучения. Результаты демонстрируют возможность применения машинного обучения при классификации гиперспектральных изображений различных новообразований кожного покрова. Классификация гиперспектров разных нозологий (злокачественные и доброкачественные новообразования, злокачественная меланома и пигментные новообразования) показывает точность классификации 95%.

**Ключевые слова**—гиперспектральная визуализация, злокачественная меланома, классификация, медицинская диагностика, нейронные сети, пигментный невус, рак кожи.

## 1. ВВЕДЕНИЕ

Рак кожи является одним из самых распространенных онкологических заболеваний в мире. По данным Всемирной организации здравоохранения, в 2020 году было выявлено 1 200 000 новых случаев рака кожи [1]. Причиной подавляющего большинства смертей от рака кожи за последние десятилетия является меланома, несмотря на то что на нее приходится лишь один процент от всех случаев рака кожи [2]. Меланома – это опасный, редкий и смертельный тип рака кожи. Повысить шансы пациента на выживание при меланомном типе рака можно путем ранней диагностики. Однако основной трудностью в качественном выявлении опухолей меланомы является ее внешняя схожесть с таким доброкачественным новообразованием, как пигментный невус.

В последнее время набирают популярность оптические методы диагностики. Одним из таких методов является гиперспектральная визуализация [3, 4], которая позволяет не только получать оптические изображения исследуемых участков, но и спектральные данные о рассеивании или поглощении излучения этим участком.

Гиперспектральная визуализация для исследований патологий кожи позволяет решить сразу две проблемы: (1) исследование поверхности кожи для обнаружения границ пораженных участков и (2) исследование морфологических и химических свойств кожи для выявления и идентификации типа опухоли. Данная технология позволяет повысить точность диагностики патологий кожи, учитывая физиологические особенности пациента, а также композитные и морфологические особенности поверхности кожного покрова.

Целью работы является изучение возможностей нейронной сети для классификации гиперспектральных изображений кожи.

## 2. МАТЕРИАЛЫ И МЕТОДЫ

В работе использованы 2550 изображений: 1275 – злокачественной меланомы (ММ) и 1250 – пигментного невуса (PN) (см. Таблицу I). Гиперспектральные изображения регистрировались *in vivo* с помощью акустооптической гиперспектральной камеры. Ее особенностью является двойная последовательная фильтрация. Она обеспечивает практически полную компенсацию спектральных и пространственных искажений изображения в одиночной ячейке, вызываемых дифракцией Брэгга, обычно приводящих к изменению спектров в отдельных точках [5].

Таблица I. СОСТАВ НАБОРА ДАННЫХ

№	Диагноз	Количество образцов	Количество изображений
1	Злокачественная меланома	25	1275
2	Пигментный невус	25	1275

Регистрация гиперспектральных изображений производилась в Самарском областном клиническом онкологическом диспансере. Получены информационные согласия каждого испытуемого. Проведение исследования было одобрено этическим комитетом Самарского государственного медицинского университета.

Результатом регистрации одного образца с помощью описанной установки является гиперкуб, состоящий из 151 оптического изображения на длинах волн от 430 нм до 730 нм с шагом 2 нм. Перед дальнейшим анализом гиперкубы были уменьшены до 51 изображения в диапазоне от 530 нм до 630 нм.

Для классификации изображений использовалась сверточная нейронная сеть архитектуры VGG [6]. В отличие от AlexNet, фокусирующейся на меньших размерах окон и шагах первого сверточного уровня, VGG обращается к глубине изображения [7]. Информация о слоях нейронной сети представлена на Рис. 1. На вход нейросети подается двумерное RGB изображение, приведенное к размеру 224x224 пикселей. Обучающая и тестовая выборки сформированы из изображений, извлеченных из зарегистрированных гиперкубов в указанном диапазоне от 530 нм до 630 нм (см. Таблицу I), в соотношении 90% и 10%, соответственно.

Layer (type)	Output Shape
conv2d_40 (Conv2D)	(None, 224, 224, 32)
max_pooling2d_40 (MaxPooling)	(None, 112, 112, 32)
conv2d_41 (Conv2D)	(None, 112, 112, 64)
max_pooling2d_41 (MaxPooling)	(None, 56, 56, 64)
conv2d_42 (Conv2D)	(None, 56, 56, 128)
max_pooling2d_42 (MaxPooling)	(None, 28, 28, 128)
conv2d_43 (Conv2D)	(None, 28, 28, 256)
max_pooling2d_43 (MaxPooling)	(None, 14, 14, 256)
conv2d_44 (Conv2D)	(None, 14, 14, 256)
max_pooling2d_44 (MaxPooling)	(None, 7, 7, 256)
dropout_8 (Dropout)	(None, 7, 7, 256)
flatten_8 (Flatten)	(None, 12544)
dense_16 (Dense)	(None, 256)
dense_17 (Dense)	(None, 2)

Рис. 1. Архитектура используемой сверточной нейронной сети

В архитектуре нейронной сети также предусмотрен триггер в виде обратной связи, прерывающий обучение, если точность не увеличивается в течение трех эпох обучения.

### 3. РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Обучение и тестирование нейронной сети проводилось на компьютере, оснащённом процессором Intel(R) Core (TM) i7-10700KF 3,80 ГГц, видеокартой NVIDIA GeForce RTX 3080 и 32 ГБ оперативной памяти.

Метрики обучения представлены на Рис. 2.

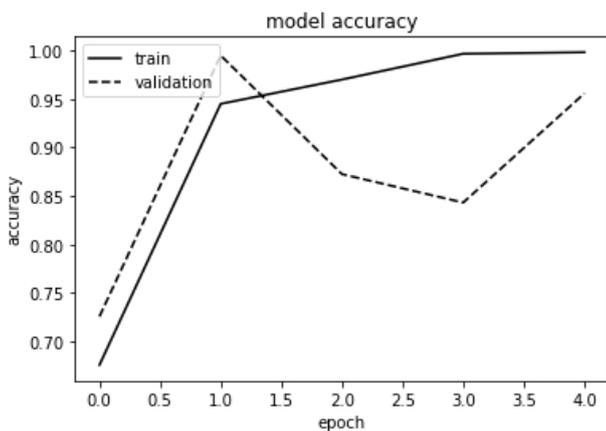


Рис. 2. Точность модели классификации при прореживании 10% признаков: сплошная линия – обучающая выборка, пунктирная линия – тестовая выборка

В работе использовались различные вариации функции удаления нейронов последнего слоя, которое заключается в присваивании нуля случайно выбираемым признакам на этапе обучения. Мы использовали удаление 10%, 15%, 20%, 25%, 30%, 40%, 50% признаков. Увеличение процента удаления приводило к

уменьшению точности модели. При удалении половины весов точность нейросетевого классификатора снизилась до 76%. Наибольшую точность, равную 95%, нейросеть представила при удалении 10% признаков (см Рис. 2). Учитывая небольшой размер обучающей и тестовой выборок, достигнутые значения точности могут как увеличиваться, так и ухудшаться при их увеличении. Однако, полученные результаты демонстрируют возможность применения нейронных сетей для анализа гиперспектральных изображений с целью обнаружения злокачественной меланомы.

### 4. ЗАКЛЮЧЕНИЕ

В данной работе была проведена двухклассовая классификация гиперспектральных изображений 50 образцов патологий кожи в видимой области с помощью нейронной сети архитектуры VGG. Точность классификации злокачественной меланомы и пигментного невуса составила 95%. Использование алгоритма классификации гиперспектральных изображений на основании нейронных сетей позволило повысить точность разделения патологий кожи по сравнению с другими методами классификации [8, 9]. Также развиваемые подходы могут быть использованы для анализа мультимодальных оптических данных.[10]

Дальнейшие исследования планируется посвятить оптимизации архитектуры нейронной сети, увеличению обучающей выборки и модернизации аппаратных средств регистрации гиперспектральных изображений.

### ЛИТЕРАТУРА

- [1] Cancer [Electronic resource]. — Access mode: <https://www.who.int/news-room/fact-sheets/detail/cancer> (01.11.2022).
- [2] Ferlay, J. Cancer statistics for the year 2020: An overview / J. Ferlay et al. // International journal of cancer. – 2021. – Vol. 149(4). – P. 778-789.
- [3] Винокуров, В. О. Нейросетевой классификатор гиперспектральных снимков кожных патологий / В. О. Винокуров и др. // Компьютерная оптика. – 2021. – Т. 45, №. 6. – С. 879-886.
- [4] Karim, S. Hyperspectral Imaging: A Review and Trends towards Medical Imaging / S. Karim et al. // Current Medical Imaging. – 2022.
- [5] Machikhin, A. Aberration analysis of AOTF-based spectral imaging systems / A. Machikhin, V. Batshev, V. Pozhar // JOS A. – 2017. – Vol. 34(7). – P. 1109-1113.
- [6] Simonyan, K. Very deep convolutional networks for large-scale image recognition / Simonyan K., Zisserman A. // arXiv preprint arXiv:1409.1556. – 2014.
- [7] Neural Network Architectures [Electronic resource]. — Access mode: <https://towardsdatascience.com/neural-network-architectures-156e5bad51ba> (01.11.2022).
- [8] Шерендак, В. П. Гиперспектральный in vivo анализ хромофоров нормальной кожи и визуализация онкологических патологий / В. П. Шерендак и др. // Компьютерная оптика. – 2019. – Т. 43, №. 4. – С. 661-670.
- [9] Bratchenko, I. A. In vivo diagnosis of skin cancer with a portable Raman spectroscopic device / I. A. Bratchenko et al. // Experimental Dermatology. – 2021. – Vol. 30(5). – P. 652-663.
- [10] Borisova, E. Multispectral autofluorescence detection of skin neoplasia using steady-state techniques / E. Borisova, A. Gisbrecht, T. Genova-Hristova, P. Troyanova, E. Pavlova, N. Penkov, I. Bratchenko, V. Zakharov, I. Lihachova, I. Kuzmina, J. Spigulis // Proc. SPIE 11047, 20th International Conference and School on Quantum Electronics: Laser Physics and Applications. – 2019. – 1104704.