Тип статьи: научная УДК 004.932.2

DOI: 10.35887/2305-2538-2023-6-102-110

СОВЕРШЕНСТВОВАНИЕ АЛГОРИТМА МАШИННОГО ЗРЕНИЯ В БИОТЕХНИЧЕСКИХ СИСТЕМАХ С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ

Дарья Сергеевна Пожидаева ¹, Максим Юрьевич Левин ², Станислав Александрович Нагорнов ³, Ирина Анатольевна Коваленко ⁴, Любовь Александровна Лунева ⁵

1,2,4</sup> Липецкий государственный технический университет, г. Липецк, Россия

¹ pozhidaeva28@mail.ru, ² lmu@list.ru

³ ВНИИТиН, г. Тамбов, Россия

³ snagornov@yandex.ru

⁵ МГТУ им. Н.Э. Баумана, г. Москва, Россия

⁵ luneva@bmstu.ru

Автор, ответственный за переписку: Дарья Сергеевна Пожидаева, pozhidaeva28@mail.ru Corresponding author: Darya Pozhidaeva, pozhidaeva28@mail.ru

Реферат. В работе приведён обзор аппаратного устройства систем машинного зрения, рассмотрены основные принципы обработки изображений биотехнических систем и соответствующий математический аппарат на примере использования технологии машинного зрения в иифровой дерматоскопии. Извлеченная системой машинного зрения цифровая информация передается в специальное программное обеспечение для обработки изображения методами машинного обучения, среди которых в работе отмечены такие как: нейронные сети, регрессия, классификация, детектирование объектов. Приведена классификация нейронных сетей, которые применяются для машинного зрения и дана их краткая характеристика по практическому применению. Рассмотренные методы систем машинного зрения биотехнологической практике с применением сверточных нейронных сетей открывают возможности для повышения качества визуальной диагностики. Для анализа эфективности применения CNN в работе проводилось сравнение с ранее известными методами классификации цифровых объектов. С применением пакета прикладных программ Statistica, проведенный сверточной нейронной сетью анализ цифрового объекта выявил различные цветовые области. Точность классификации областей цифрового объекта составила 94,7 %, что говорит о высокой точности распознавания цифрового объекта с применением CNN и на 1,5% точнее статистических методов классификации.

Ключевые слова: машинное зрение, компьютерное зрение, обработка изображений, автоматизация, дерматоскопия.

IMPROVING THE MACHINE VISION ALGORITHM IN BIOTECHNICAL SYSTEMS USING NEURAL NETWORKS

Daria Pozhidaeva ¹, Maxim Levin ², Stanislav Nagornov ³, Irina Kovalenko ⁴, Lyubov Luneva ⁵
ALL-Russian research Institute for the use of machinery and petroleum products in agriculture,

1,2,4 Lipetsk State Technical University, Lipetsk, Russia

1 pozhidaeva28@mail.ru, ² lmu@list.ru

3 VNIITiN, Tambov, Russia

3 snagornov@yandex.ru

5 Bauman Moscow State Technical University, Moscow, Russia

5 luneva@bmstu.ru

Abstract. A review of the hardware design of machine vision systems is given in the work; the basic principles of image processing of biotechnical systems and the corresponding mathematical apparatus are considered using the example of the use of machine vision technology in digital dermatoscopy. The digital information extracted by the computer vision system is transferred to special software for image processing using machine learning methods, among which the work highlights the following: neural networks, regression, classification, and object detection. A classification of neural networks that are used for computer vision is given and a brief description of their practical application is given. The considered methods of computer vision systems in biotechnological practice using convolutional neural networks open up opportunities for improving the quality of visual diagnostics. A comparison with previously known methods for classifying digital objects was carried out in the work to analyze the effectiveness of using CNN. Analysis of the digital object by a convolutional neural network using the Statistica software package revealed different color regions. The accuracy of classification of areas of a digital object was 94.7%, which indicates a high accuracy of digital object recognition using CNN and is 1.5% more accurate than statistical classification methods.

Keywords: machine vision, computer vision, image processing, automation, dermatoscopy.

Для цитирования: Пожидаева Д.С., Левин М.Ю., Нагорнов С.А., Коваленко И.А., Лунева Л.А. Совершенствование алгоритма машинного зрения в биотехнических системах с применением нейронных сетей // Наука в Центральной России. 2023. Т. 66, № 6. С. 102-110. https://doi.org/10.35887/2305- 2538-2023-6-102-110.

For citation: Pozhidaeva D., Levin M., Nagornov S., Kovalenko I., Luneva L. Improving the machine vision algorithm in biotechnical systems using neural networks. *Nauka v central'noj Rossii* = Science in the Central Russia: 2023; 66(6): 102-110. (In Russ.) https://doi.org/10.35887/2305-2538-2023-6-102-110.

Введение. В последние десятилетия в нашей стране активно развивается отрасль научных знаний в биотехнических системах и технологиях. Предлагаются новые научные и технические решения для улучшения качества сельскохозяйственной продукции, животноводства, автотранспорта, жизни человека.

В настоящее время под термином «биотехнические системы» (БТС) подразумеваются системы, состоящие из биологических и технических элементов, связанных между собой для выполнения различного рода задач [1] в сельском хозяйстве, транспорте, охране труда и промышленной безопасности, медицине и других отраслях. БТС способны решить следующие задачи: инструментальная диагностика, реабилитация, контроль состояния окружающей среды, лечение заболеваний, обеспечение биологической и химической защиты и так далее. Повысить точность работы и расширить функциональные возможности БТС можно с помощью интеграции новых технологий, таких как искусственный интеллект и машинное зрение с целью распознавания контента или содержимого цифрового изображения.

Согласно определению, машинное зрение — это автоматизированная технология получения, обработки и анализа изображений объектов, использующаяся для решения прикладных задач [2]. С помощью машинного зрения программное обеспечение способно провести классификацию исследуемого цифрового объекта, выделить конечные наборы фиксированных признаков.

Перспективными областями применения машинного зрения являются те отрасли, в которых необходимо принимать решения, подкрепленные выверенными математическими расчетами. Например, в сельском хозяйстве — это определение участков с заболеваниями культур, с недостатком полива, удобрений; а медицине и ветеринарии — это дерматоскопия, неизвазивный метод визуальной диагностики кожи посредством распознавания специфических признаков заболеваний с последующей объективной оценкой различных параметров (геометрических, структурных, цветовых и т. д.). Именно этот метод применяется при диагностике меланомы — онкологического заболевания кожи, на долю которого приходится 80% смертельных исходов появления кожных новообразований. Поскольку за последние 50 лет распространённость меланомы значительно возросла [3—4], её своевременная диагностика с помощью современных

технологий является актуальной задачей. В работе усовершенствован метод машинного зрения на примере определения меланомы с применением нейронных сетей глубокого обучения.

Материалы и методы. В работе использовались методы машинного зрения, для получения и обработки информации, а также пакет прикладных программ Statistica Automated Neural Networks для создания и обучения сверточной нейронной сети. В качестве математического аппарата для повышения качества изображения был применен частотный Фурье-преобразователь. Система машинного зрения включает несколько основных компонентов: камера, специализированная система освещения объекта, система передачи результатов (физические входы/выходы, протоколы передачи данных), программное обеспечение для обработки изображений [5].

Камеры машинного зрения должны обеспечивать получение чётких изображений, а также при необходимости — точную передачу цветов объекта съёмки. Поэтому одним из требований, предъявляемым к камерам, является большая площадь светочувствительных элементов (пикселей).

В формировании цифрового изображения участвует твердотельная матрица, состоящая из фотодетекторов. Такими элементами могут быть приборы с зарядовой связью (ПЗС, или ССD), а также металл-оксид-полупроводниковые устройства (КМОП, или СМОS).

От количества пикселей в матрице зависит чёткость и информативность изображения (рисунок 1).



16-пиксельная (4х4 матрица)



400-пиксельная (20х20 матрица)



81-пиксельная (9х9 матрица)



2025-пиксельная (45х45 матрица)



11881-пиксельная (109х109 матрица)

Рисунок 1 – Матрицы, используемые в камерах машинного зрения

Камеры, используемые в диагностике, должны иметь разрешение до 20 мегапикселей, а также осуществлять возможность производить предобработку полученных данных. Для этого камеры машинного зрения обеспечиваются программно-вычислительным модулем. Данная технология позволяет разгрузить процессор компьютера, взяв на себя операции по кодировке и коррекции изображения [6].

В цифровых камерах, которые используются в дерматоскопах, на светочувствительные детекторы производится наслоение комплекса графических цифровых фильтров, который называется матрицей (шаблоном) Байера (рисунок 2). В каждом структурном элементе матрицы содержится два зеленых, один красный и один синий пиксель. Такая схема распределения цветов является наиболее распространенной.

G	R	G	R	G	R
В	G	В	G	В	G
G	R	G	R	G	R
В	G	В	G	В	G
G	R	G	R	G	R
В	G	В	G	В	G

Рисунок 2 – Шаблон Байера

Зафиксированные отдельными цветными пикселями значения интенсивности используются для вычисления цветовых значений. Происходит экстраполяция значений интенсивности на данные цветовой модели RGB (R-red, G-green, B-blue; каждый цвет кодируется 8 битами). Этот процесс известен как дебайеризация, он осуществляется непосредственно во встроенном вычислительном модуле современных камер машинного зрения.

Извлеченная системой машинного зрения информация передается в компьютер с целью дальнейшей обработки изображения с помощью программных средств [5] и методов машинного обучения, среди которых можно выделить такие как: нейронные сети, регрессия, классификация, детектирование объектов. Приведем классификацию нейронных сетей для машинного зрения в таблице 1

Таблица 1. Нейронные сети для машинного обучения

Код сети	Наименование нейронной сети	Основные особенности	
CNN	Сверточные нейронные сети	С помощью свертки и пуллинга	
		производится извлечение	
		признаков из цифрового объекта	
		для последующей классификации	
		или сегментации	
DCGAN	Глубокие сверточные генеративные	На основе обучающего примера	
	модели	генерирует новые цифровые	
		объекты	
RNN	Рекуррентные нейронные сети	Производят анализ текстов или	
		временных рядов, учитывая	
		предыдущие состояния	

Применение глубокого обучение в компьютерном зрении в совокупности с различными классами нейронных сетей позволяют создавать и расширять возможности сложных биотехнических систем.

Результат и их обсуждение. Проведем совершенствование алгоритма машинного зрения в биотехнических системах с применением нейронных сетей на примере оценки изображения пигментного пятна на коже, полученного при помощи камеры дерматоскопа в работе [8].

При первоначальной обработке цифрового снимка создается гистограмма. Для монохромного изображения гистограмма представляет собой таблица, где каждый элемент — число, отражающее количество пикселей с конкретным уровнем яркости. Всего таких уровней 256. Аналогичным образом формируется гистограмма цветного изображения, в которой отражается число пикселей каждого из цветов модели RGB (рисунок 3).

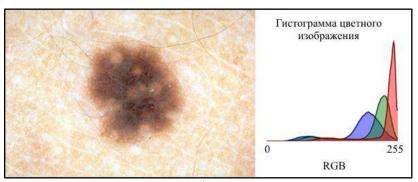


Рисунок 3 – Цветное изображение и его гистограмма

На данном этапе можно автоматически выделить наличие определённых цветов, которые учитываются при дерматоскопии: белый, красный, бежевый, коричневый, сине-серый, черный. Качественная оценка наличия каждого из данных цветов конвертируется в количественную оценку в баллах: каждому обнаруженному цвету соответствует один балл. Чем больше баллов, тем выше общий дерматоскопический индекс, позволяющий оценить злокачественность образования.

Далее для выделения объекта интереса (в данном случае – пигментного пятна) применяется бинаризация (рисунок 4). Бинаризацией называют процесс преобразования данных, сигналов или изображений в двоичную форму, то есть форму, которая имеет только два возможных значения или состояния: 0 и 1. В данном случае такому преобразованию подвергается яркость пикселей [6].

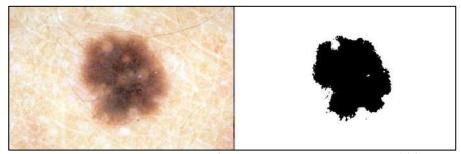


Рисунок 4 – Бинаризация изображения по яркости с порогом 146

Пороговое значение бинаризации определяет такой уровень яркости, выше которого все значения будут приравнены к максимальному уровню (белый цвет); соответственно, пиксели с уровнем яркости ниже порога приобретут минимальную яркость (чёрный цвет).

В цветных изображениях аналогичная бинаризация может проводиться по компоненту тона, что позволит увеличить точность распознавания пигментного образования на коже. Сформированное таким образом бинарное изображение подвергается дальнейшему анализу, включающему оценку геометрических параметров пятна. Для этого процесса используется определённый математический аппарат [7].

Площадь области А:

$$S = \sum_{y=Y \min}^{Y \max} \sum_{x=X \min}^{X \max} g(x, y),$$

где g(x,y) — множество пикселей, принадлежащих области A.

Вычисление центра тяжести графической области производится путем формирования начальных координат Y_C и X_C , которые рассчитывают как среднее значение координат в графическом пространстве A и обозначают (x, y):

$$Y_C = \frac{1}{S} \sum_{(x,y) \in A} y; \qquad X_C = \frac{1}{S} \sum_{(x,y) \in A} x.$$

Периметр при количестве граничных точек равном N:

$$P = \sum_{i=1}^{N} r_i \; ; \quad r_i = \sqrt{\left(x_{i+1} - x_i\right)^2 + \left(y_{i+1} - y_i\right)^2} \; .$$

Расчетным значением коэффициента формы является отношение квадрата периметра к площади и записывается выражением:

$$K = \frac{P^2}{S}.$$

Расчетным значением округлости являются выражения:

$$C = \frac{m_A}{\sigma_A}; \quad m_A = \frac{1}{N} \sum_{i=1}^{N} r_{ic}; \quad \sigma_A = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N} (r_{ic} - m_A)^2};$$

где та— среднее расстояние от центра тяжести до граничных пикселей;

 σ_A – среднеквадратическое отклонение этих расстояний.

Данные параметры позволяют дать количественную оценку критериям асимметрии, формы пигментного пятна, провести сегментирование для оценки границ кожного образования. Общий дерматоскопический индекс (ОДИ), по которому проводится объективная оценка злокачественности меланомы, определяется по формуле:

ОДИ =
$$1,3A + 0,1\Gamma + 0,5 \coprod + 0,5 \coprod$$
,

где A – асимметрия пигментного пятна, Γ – чёткость границ, Π – цвета, Π – дифференциация структур.

При $ODU \le 4,75$ новообразование считается доброкачественным, значения выше этого являются признаком злокачественности меланомы.

По данным проведённых исследований, при анализе снимков меланом по этому алгоритму с помощью машинного зрения чувствительность (процент обнаруженных заболеваний) составляет 93,75%, специфичность (процент обнаруженных здоровых людей) 79,9% (p<0,01) [8], что свидетельствует о высоком уровне точности данного метода и больших перспективах применения машинного зрения для автоматической диагностики заболеваний кожи.

Данный алгоритм можно усовершенствовать с применением CNN, которые являются биологическим аналогом многослойной персептронной нейронной сети, с отличием что сеть имеет один общий вес. Запишем алгоритм обучения такой сети. Учитывая входное изображение I и фильтр (ядро) K размером $M \times N$, операция свертки определяется выражением:

$$(I * K)_{i,j} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} I(i+m,j+n)K(-m,-n)$$

Легко видеть, что свертка в данном случае является взаимной корреляцией с перевернутым ядром K, где K(-m,-n) == K(m,n). CNN будет состоять из сверточных слоев с входным изображение I и фильтрами K и смещением b.

Фильтр К в нашем случае является частотным методом улучшения качества цифровых объектов. В основе данного метода положено Фурье-преобразование функции двух переменных. Запишем выражение для прямого Фурье-преобразование дискретное функции, обозначенной как f(x, y), где переменные x и y являются пространственными, примененной к цифровому объекту с размерами M×N:

$$F(u,v) = \frac{1}{MN} \sum_{r=0}^{M-1} \sum_{v=0}^{N-1} f(x,y) e^{-i2\pi \left(\frac{ux}{M} + \frac{vy}{N}\right)},$$

где u = 0,1,2... M - 1; v = 0,1,2... N - 1, которые также называют переменными преобразования или частотными переменными.

Теперь запишем выражение для обратного Фурье-преобразование, примененной к этому же цифровому объекту:

$$f(x, y) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} F(u, y) e^{i2\pi \left(\frac{ux}{M} + \frac{vy}{N}\right)}.$$

Частотная область цифрового объекта является пространством, в котором происходит изменение значений методом Φ урье-преобразования переменных (u, v).

В случае с изображением на рисунке 3 мы получаем сверточную нейронную сеть с высотой изображения H, шириной W и тремя каналами цветов C=3 (RGB):

$$(I*K)_{i,j} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \sum_{c=1}^{C} K_{m,n,c} \cdot I_{i+m,j+n,c} + b$$
 Для обучения такой сети применяется алгоритм обратного распространения ошибки (E).

$$\frac{\partial E}{\partial x_{l,j}^{l}} = rot_{180^{\circ}} \left\{ \sum_{m=0}^{k_{1}-1} \sum_{n=0}^{k_{2}-1} \delta_{l+m,j+n}^{l+1} \cdot w_{m,n}^{l+1} \right\} f(x_{l,j}^{l})$$

где δ – предыдущий слой нейронной сети

С учетом гипербалического тангенса в качестве функции активации f = 1,7159 th(0,66x) получим[9]:

$$\frac{\partial E}{\partial x_{i,f}^{l}} = rot_{180^{\circ}} \left\{ \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \delta_{i+m,f+n}^{l+1} \cdot w_{m,n}^{l+1} \right\} 1,7159th(0,66x_{i,f}^{l})$$

С применением пакета прикладных программ Statistica, проведенный сверточной нейронной сетью анализ рисунка 3 выявил различные цветовые области. Точность классификации цифрового объекта составила 94,7 %, что говорит о высокой точности распознования цифрового объекта с применением CNN.

Выводы. В настоящее время сделан большой шаг в научном познании машинного зрения для цифровых объектов. Однако, несмотря на полученные положительные результаты работы машинного зрения, существующие автоматизированные системы пока не могут составить конкуренцию человеку. Вместе с тем проблема цифрового зрения является краеугольной при внедрении интеллектуальных систем в практику. Поэтому в области компьютерного распознавания цифровых объектов существует ряд общих до сих пор нерешенных проблем, для решения которых прикладываются усилия ученых и разработчиков всего мира.

Одна из центральных - это то, что проблемы данного направления необходимо решать в условиях ограниченного ресурса времени. Рассмотренные в настоящей работе принципы обработки изображений в биотехнологической практике использования систем соответствующий математический аппарат на примере использования технологии машинного зрения в цифровой дерматоскопии с применением сверточных нейронных сетей открывают возможности для повышения качества визуальной диагностики. Анализ эффективности применения CNN в сравнении с методом, представленным в работе [8], показал хорошие результаты. Использование машинного зрения в цифровой дерматоскопии выявило ряд преимуществ, включая увеличение скорости и точности диагностики, возможность анализа больших объемов данных и автоматизацию рутинных процедур. С применением пакета прикладных программ, проведенный сверточной нейронной сетью анализ рисунка из работы [8] выявил различные цветовые области. Точность классификации цифрового объекта составила 94,7 %, что говорит о высокой точности распознавания цифрового объекта с применением CNN по сравнению с точностью статистических методов классификации.

Список источников

- 1. Акулов С.А., Федотов А.А. Основы теории биотехнических систем. М.: ФИЗМАТЛИТ. 259 с. ISBN 978-5-9221-1552-0.
- 2. Ситников В. В., Люминарский В. В., Коробейников А. В. Обзор методов распознавания объектов, используемых в системах машинного зрения. // Вестник ИжГТУ имени М. Т. Калашникова. 2018. Т. 21, № 4, 222 229 с.
- 3. Римская Е.Н., Аполлонова И.А. Разработка требований для автоматизированного комплекса экспресс-диагностики пигментных новообразований кожи // Современные научные исследования и инновации. 2015. № 6.Ч. 5
- 4. Эркенова Ф.Д., Пузин С.Н. Статистика меланомы в России и странах Европы // Медикосоциальная экспертиза и реабилитация. 2020; 23(1): 44–52.
- 5. Основы машинного зрения / Френк Лэмб; перевод с английского В. Рентюка // Control Engineering Россия. 2019, №1 (79), 59–62 с.
- 6. Берингер П., Деттмер Д. Камеры машинного зрения в медицине. Анализ возможностей ПЗС-/КМОП-сенсоров с акцентом на обеспечении точности цветовоспроизведения: технический документ Basler AG.
- 7. Фисенко В.Т., Фисенко Т.Ю. Компьютерная обработка и распознавание изображений: учеб. пособие. СПб: СПбГУ ИТМО, 2008. 192 с.
- 8. Козлов С. В., Неретин Е.Ю., Куколкина В.В. Перспективы применения «машинного зрения» в цифровой дерматоскопии при подозрении на меланому кожи. Саратовский научно-медицинский журнал 2014; №10 (2): 281–285 с.
- 9. Левин М.Ю. Формализация алгоритма проектирования архитектуры нейронных сетей на практике [Текст] / Левин М.Ю., Нагорнов С.А. // Наука в центральной России. 2016. № 1 (19). С. 81-97.

References

- 1. Akulov S.A., Fedotov A.A. Fundamentals of the theory of biotechnical systems. M.: FIZMATLIT. 259 p. ISBN 978-5-9221-1552-0.
- 2. Sitnikov V. V., Luminarsky V. V., Korobeynikov A.V. Review of object recognition methods used in machine vision systems. // Bulletin of IzhSTU named after M. T. Kalashnikov. 2018. Vol. 21, No. 4, 222-229 p.
- 3. Rimskaya E.N., Apollonova I.A. Development of requirements for an automated complex of express diagnostics of pigmented skin neoplasms // Modern scientific research and innovations. 2015. No. 6.Ch. 5
- 4. Erkenova F.D., Puzin S.N. Statistics of melanoma in Russia and European countries // Medicosocial expertise and rehabilitation. 2020; 23(1): 44-52.
- 5. Fundamentals of machine vision / Frank Lamb; translated from English by V. Rentyuk // Control Engineering Russia. 2019, No. 1 (79), 59-62 p.
- 6. Behringer P., Dettmer D. Machine vision cameras in medicine. Analysis of CCD/CMOS Sensor Capabilities with a Focus on Color Accuracy: Basler AG White Paper.
- 7. Fisenko V.T., Fisenko T.Yu. Computer processing and image recognition: textbook. allowance. St. Petersburg: St. Petersburg State University ITMO, 2008. 192 p.

- 8. Kozlov S.V., Neretin E.Yu., Kukolkina V.V. Prospects for the use of "machine vision" in digital dermatoscopy for suspected skin melanoma. Saratov Scientific and Medical Journal 2014; No. 10 (2): 281–285 p.
- 9. Levin M.Yu. Formalization of the algorithm for designing the architecture of neural networks in practice [Text] / Levin M.Yu., Nagornov S.A. // Science in central Russia. 2016. No. 1 (19). pp. 81-97.

Информация об авторах

Д. С. Пожидаева – студент; М.Ю. Левин – доктор технических наук, профессор; С.А. Нагорнов – доктор технических наук, профессор, И.А. Коваленко – кандидат технических наук, доцент; Л.А. Лунева – кандидат технических наук, доцент.

Information about the authors

D. Pozhidaeva – student; M. Levin – Doctor of Technical Sciences, Professor; S. Nagornov – Doctor of Technical Sciences, Professor, I. Kovalenko – candidate of technical sciences, associate professor; L. Luneva – Candidate of Technical Sciences, Associate Professor.

Вклад авторов все авторы сделали эквивалентный вклад в подготовку публикации.

Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: all authors have made an equivalent contribution to the preparation of the publication.

The authors declare no conflict of interest.

Поступила в редакцию (Received): 17.11.2023 Принята к публикации (Accepted): 20.12.2023