



Использование генетических алгоритмов и нейронных сетей в анализе деформаций стопы

С.И. Киреев, ORCID: 0000-0002-3318-5633 <kireevsiorto@yandex.ru>
И.А. Батраева, ORCID: 0000-0002-6539-8473 <batraevaia@info.sgu.ru>
Д.С. Пантелеев ORCID: 0000-0003-4271-6915 <pantelev00@gmail.com>
М.В. Забоев <zaboevmv@mail.ru>

*Саратовский национальный исследовательский государственный
университет имени Н.Г. Чернышевского,
Россия, 410012, г. Саратов, ул. Астраханская, д. 83.*

Аннотация Работа посвящена актуальной проблеме диагностики деформаций стопы, характеризующихся высокой частотой встречаемости среди всех возрастных групп. Среди объективных количественных методов диагностики плоскостопия широкое распространение в клинической практике получила плантография, основанная на оценке отпечатков подошвенной поверхности стопы. Целью исследования является оценка и анализ эффективности методов автоматической оценки отпечатков стопы с использованием «компьютерного зрения». В исследовании рассматриваются методы автоматического распознавания и разметки фотоплантограмм стопы с использованием генетических алгоритмов и нейронных сетей для построения контрольных точек стопы на примере вычисления индексов продольного и поперечного сводов стопы. Было проведено сравнение результатов расчета индексов плоскостопия, фотоплантограмм с использованием ручной и автоматической разметки. Было установлено, что точность автоматических методов анализа фотоплантограмм с использованием генетических алгоритмов и нейронных сетей составляет 92 – 97% по отношению к ручной разметке. При этом затраты времени на ручную разметку превысили в 2 – 2,5 раза продолжительность автоматического анализа изображений. Полученные результаты подтвердили возможность оптимизировать диагностический процесс при проведении массовых (скрининговых) обследований состояния сводов стопы.

Ключевые слова: стопа; фотоплантограмма; нейронные сети; генетические алгоритмы; контрольные точки стопы; машинное обучение; Python; openCV; плоскостопие; индекс Штритера.

Для цитирования: Киреев С.И., Батраева И.А., Пантелеев Д.С., Забоев М.В. Использование генетических алгоритмов и нейронных сетей в анализе деформаций стопы. Труды ИСП РАН, том 36, вып. 3, 2024 г., стр. 241–258. DOI: 10.15514/ISPRAS–2024–36(3)–17.

Use of Genetic Algorithms and Neural Networks in the Analysis of Foot Deformities

S.I. Kireev, ORCID: 0000-0002-3318-5633 <kireevsiorto@yandex.ru>
I.A. Batraeva, ORCID: 0000-0002-6539-8473 <batraevaia@info.sgu.ru>
D.S. Pantelev ORCID: 0000-0003-4271-6915 <pantelev00@gmail.com>
M.V. Zaboiev <zaboievmv@mail.ru>

*Saratov National Research State University named after N.G. Chernyshevsky,
Russia, 410012, Saratov, st. Astrakhanskaya, 83*

Abstract. The work is devoted to the current problem of diagnosing foot deformities, which are characterized by a high incidence among all age groups. Among the objective quantitative methods for diagnosing flatfoot, plantography, based on the assessment of prints of the plantar surface of the foot, has become widespread in clinical practice. The purpose of the study was to evaluate and analyze the effectiveness of methods for automatic assessment of footprints using “computer vision”. The study examines methods for automatic recognition and marking of photoplantograms of the foot using genetic algorithms and neural networks to construct control points of the foot using the example of calculating the indices of the longitudinal and transverse arches of the foot. A comparison was made of the results of calculating flatfoot indices and photoplantograms using manual and automatic markings. It was found that the accuracy of automatic methods for analyzing photoplantograms using genetic algorithms and neural networks is 92–97% in relation to manual marking. At the same time, the time spent on manual marking exceeded the duration of automatic image analysis by 2 - 2.5 times. The results obtained confirmed the possibility of optimizing the diagnostic process when conducting mass (screening) examinations of the condition of the arches of the feet.

Keywords: foot; photoplantogram; neural networks; genetic algorithms; foot control points; machine learning; Python; openCV; Strieter index.

For citation: Kireev S.I., Batraeva I.A., Pantelev D.S., Zaboiev M.V. Use of genetic algorithms and neural networks in the analysis of foot deformities. *Trudy ISP RAN/Proc. ISP RAS*, vol. 36, issue 3, 2024. pp. 241-258 (in Russian). DOI: 10.15514/ISPRAS-2024-36(3)-17.

1. Введение

Стопа представляет собой сложную анатомо-функциональную структуру опорно-двигательного аппарата, непосредственно взаимодействующую с плоскостью опоры при стоянии и ходьбе. Изучение анатомического и функционального состояния стопы имеет большое научное и практическое значение в решении фундаментальных и прикладных задач современной травматологии и ортопедии. Одной из медицинских специальностей была определена подиатрия, предметом изучения которой служит стопа.

В научной и клинической практике используются различные методы оценки структурного и функционального состояния стопы. Наиболее популярным методом признана плантография (плантоскопия), использующая в качестве критерия оценки отпечатки подошвенной поверхности стопы. Этот метод позволяет выявить и оценить степень плоскостопия, отражающую выраженность патологической деформации свода стопы. Изначально отпечаток подошвенной поверхности стопы пациента получали на бумаге. В настоящее время в диагностической практике используются фотографии, выполненные через стекло, на котором стоит пациент. Полученные данные позволяют использовать плантоскопию (плантографию) для обследования пациентов с деформациями стопы и для проведения массовых скрининговых исследований здоровых лиц.

Исследования с помощью плантоскопов имеют при всей своей простоте и наглядности существенный недостаток, связанный с тем, что оценка состояния стопы производится визуально, во многом зависит от опыта специалиста, проводящего осмотр, а результаты осмотра не имеют каких-либо количественных показателей и сравнение результатов по одному и тому же пациенту в разные периоды времени осуществляется также только визуально.

Количественная оценка состояния сводов стопы проводится в рамках плантографического исследования, предполагающего разметку фотоснимков подошвенной поверхности стопы с последующим измерением линейных и угловых параметров и вычислением индексов. Все следующие на текущий момент методы требуют значительного количества времени, затрачиваемого специалистом для расстановки контрольных точек на полученном изображении. Поэтому разработка методов автоматического анализа изображений подошвенной поверхности стопы позволит существенно оптимизировать диагностический процесс, особенно при обследовании большого количества людей. Такой подход был реализован ранее в ряде исследований [1-4]. Однако, в большинстве из них применялись методы анализа отпечатка стопы, полученного методом бароподометрии [1-3]. Обоснованность такого подхода вызывает сомнение, так как получаемое изображение, является трансформацией параметров давления от множества тензодатчиков. То есть цифровая информация переводится в аналоговую для последующего автоматического анализа. Более обоснованным в данном случае следует признать подход, основанный на автоматическом анализе первичной цифровой информации. Так же индекс плоскостопия авторы этих исследований рассчитывают по площади участков стопы, что в рутинной клинической практике технически сложно осуществить из-за криволинейности границ участков и необходимости использовать для этого интегральное исчисление, поэтому такой подход представляется мало перспективным для последующего применения на практике в медицинских учреждениях. Кроме этого, бароподометрические комплексы не получили широкого распространения в клинической практике из-за высокой стоимости и сложности эксплуатации. Наиболее приближенным к реальной клинической практике следует признать автоматизированный анализ фотоснимков подошвенной поверхности стопы, полученных фотокамерой при использовании плантоскопа [4]. Недостатком этого исследования следует признать то, что вычисляемые количественные показатели, не включают в себя наиболее распространенный в скрининговых клинических и научных исследованиях индекс Штритера. Если говорить о используемых в текущий момент в клинической медицине программно-аппаратных средствах диагностики, то большая часть существующего на сегодняшний день программного обеспечения (MultiReha, ORTMANN PRO Diagnostics) поставляется в комплекте с плантографами и являются полностью коммерческими продуктами зарубежного производства. Из отечественных производителей надо отметить фирму ООО «Неврокор», разрабатывающую оборудование для стабилотрии и подографии Биокинект и Балфит, однако их программное обеспечение имеет свою специфику и также поставляется в комплекте с оборудованием.

Поэтому вопрос о разработке платформенно- и аппаратно-независимого программного обеспечения, способного работать просто с предоставляемыми изображениями, в том числе не самого хорошего качества является актуальным

2. Методы автоматизации разметки данных для моделирования

При работе с большими данными можно выделить две основные проблемы:

- автоматизация сбора данных, которая, в принципе, для каждой прикладной задачи решается своими способами, в зависимости от типа задачи,
- проблема разметки имеющихся данных, которая во многих случаях до сих пор осуществляется вручную. Это сильно замедляет подготовку данных для дальнейшего моделирования, особенно при обработке изображений, в которых могут присутствовать посторонние артефакты, дефекты съемки или предъявляются особые требования к изучаемым объектам. Современные решения в большей степени нацелены не на автоматизацию процесса, а на ускорение ручной разметки [5-6]. Существуют также, решения, которые используют нейронную сеть, обученную на ограниченных данных, для разметки остальной части неразмеченных данных. Так в работе [7] авторы решают проблему

распознавания объектов на снимках в реальном времени. Для этого они используют дополнительную нейронную сеть, которая выделяет объекты на изображениях для того, чтобы затем обучать другую нейросеть для распознавания объектов с помощью этих размеченных изображений. причем, в качестве нейронной сети для разметки ими использовалась сверточная нейросеть класса YOLO, а для распознавания использовалась рекуррентная нейросеть с долгосрочной краткосрочной памятью (LSTM).

Для медицинских исследований есть еще одна существенная проблема – количество данных, которые можно получить для анализа. В основном [8] можно рассчитывать на несколько сотен, может быть, тысяч изображений или результатов анализов. Этого недостаточно для обучения с нуля специализированной нейронной сети. Поэтому авторами статьи предлагается использовать составную методику анализа:

- open source библиотеки компьютерного зрения для выделения фрагментов изображений,
- сверточная нейронная сеть (в данном случае, сеть класса Unet),
- генетические алгоритмы, решающие задачу оптимизации для конкретных случаев.

Также использование генетических алгоритмов [9] существенно снижает временные и мощностные затраты на обучение сети – вместо выделенного сервера хватает обычного ноутбука.

Основными инструментами при разработке методов анализа при реализации на языке Python стали: OpenCV – фреймворк для работы с растровыми изображениями и видео, PyGAD – фреймворк для работы с генетическими алгоритмами, Numpy – библиотека, предоставляющая мощные инструменты для работы с большими многомерными массивами и выполнения вычислений на них, rembg – библиотека для удаления фона с изображений.

Датасет для исследования был составлен из нескольких наборов данных:

25 снимков подошвенной части пар стоп, то есть 50 снимков отдельных стоп, были предоставлены коллегами с факультета фундаментальной медицины и медицинских технологий СГУ в количестве, в уже обозначенном виде и для них были рассчитаны экспертные оценки характеристик стоп. Все снимки были хорошего качества, без бликов и лишних отражений в кадре

4 снимка стоп были сделаны на плантографе в ортопедическом салоне и на личный смартфон одного из авторов статьи, все снимки хорошего качества и были использованы в тестировании

19 снимков подошвенной части пар стоп, то есть 38 снимков были сделаны в процессе экспериментов с добровольцами студентами факультета компьютерных наук и информационных технологий СГУ, обезличены. Для них так же были рассчитаны экспертные оценки характеристик стоп. В данном случае снимки были разного качества, так как выполнялись не профессионалами и в очень маленькой аудитории. Снимки были разделены на три группы – 14 снимков хорошего качества, 15 – среднего, 9 – плохого качества и тестирование разработанных моделей было проведено на этом наборе данных, с учетом разделения на группы. Такое разделение представляется важным, так как можно сразу получить методические рекомендации по выполнению снимков в будущем. Распределение по группам было сделано вручную, оценивались четкость изображения, количество бликов и дополнительных отражений в кадре.

Так как одним из показателей качества любой методики (модели) является величина отклонения на тестовых данных от экспертных значений, то необходимо выбрать методику расчета точности результатов вычислений. В данном случае, для нас существенно отклонение рассчитанных характеристик для каждой стопы от ее экспертных значений, также интересны среднее и максимальное отклонение по тестовой выборке в целом, поэтому было решено использовать стандартную относительную погрешность, так как для каждой из стоп

существует только один экспертный расчет характеристик, что соответствует реальной ситуации - врач будет сравнивать программный расчет со своим личным ручным расчетом. Стандартная относительная погрешность рассчитывается по следующей формуле:

$$\frac{|X_{\text{Хизм}} - X_{\text{Эксп}}|}{X_{\text{Эксп}}} 100\%$$

где $X_{\text{Хизм}}$ – полученное по методике значение, $X_{\text{Эксп}}$ – значение, рассчитанное экспертом, для удобства записи было решено числовое значение погрешности рассматривать в процентах.

2.1 Алгоритмы расчета характеристик плантограммы вручную

2.1.1. Коэффициент распластанности переднего отдела стопы k_2

Данный метод согласно [10] определяется следующим образом, как показано на рис. 1:

1. Строится линия в самом широком месте верхней части стопы (АБ);
2. С внутренней и наружной сторон стопы проводятся линии до касания с пяткой и строится соединяющая точки касания линия (А'Б') (серые линии на рис. 1.)
3. Отрезок EF строится как линия параллельная линии (Е'F'), соединяющей середины отрезков АБ и А'Б' длиной от наивысшей точки пальцев, до нижней части пятки
4. Коэффициент распластанности $k_2 = AB/EF$.

Если полученное соотношение находится в диапазоне 0.3 – 0.35, то стопа считается нормальной. Если же значение превышает 0.35, то стопа имеет поперечное плоскостопие.




Рис. 1. Схема расчета коэффициента распластанности переднего отдела стопы
Fig 1. Scheme for calculating the coefficient of spread of the forefoot

2.1.2. Индекс Шриттера

Наглядным методом определения плоскостопия является метод Шриттера [11], представленный на рис. 2:

1. К наиболее выступающим точкам внутренней части отпечатка стопы проводится касательная линия (АБ) и находится середина отрезка АБ.
2. Из середины отрезка АБ возводится перпендикуляр (ВД) до пересечения с наружным краем отпечатка.
3. Отмечаются точки Г и Д – пересечения перпендикуляра с внутренней и наружной частями отпечатка стопы соответственно.
4. Индекс, используемый для характеристики формы стопы, рассчитывается по формуле: $I = \Gamma Д * 100 / ВД$.

Применяется следующая градация плоскостопия:

- 00,0–36 – высокосводчатая (полая) стопа
- 36,1–43 – повышенный свод
- 43,1–50 – нормальная стопа
- 50,1–60 – уплощенная стопа
- 60,1–70 – плоскостопие

Данные стандартные медицинские методики расчета характеристик стопы основаны на том, что врач-ортопед может визуально выделить контуры стопы на плантограмме, определить необходимые контрольные точки и произвести расчет с использованием линейки и ручки (для получения точных значений) и просто «на глаз», если не требуется высокая точность вычислений. В следующих разделах статьи данные методики расчета применяются к распознанным в автоматизированном режиме разработанными авторами статьи алгоритмами контурам стопы и вычисленным контрольным точкам. Такой подход позволяет врачу легко проверить правильность вычислений и разметки плантограммы стопы, так как разметка будет иметь привычный вид для специалиста.




Рис. 2. Схема расчета индекса Штриетера
Fig 2. Scheme for calculating the Strieter index

2.2 Алгоритм анализа плантограммы с использованием генетического алгоритма

Рассмотрим методику анализа состояния стопы на примере, приведенном на рис. 3, для случая вычисления степени плоскостопия. Для данной методики были сформулированы следующие необходимые функциональные возможности:

- Анализ отпечатков стопы
- Расчет степени плоскостопия
- Построение контрольных линий (срезов) на плантограмме
- Визуализация результатов анализа в виде маски изображения



Рис. 3. Исходный фотоснимок подошвенной поверхности стопы
Fig 3. Original foot image

2.2.1 Подготовка данных

Подготовка данных для исследований включает в себя следующие шаги:

- 1) Выделение контура стопы с помощью функции `draw_contour()`, входными параметрами функции являются ширина, высота изображения в пикселях, число цветовых каналов. Данная функция удаляет фон вокруг стопы с помощью библиотеки `rembg`, преобразовывает изображение в оттенки серого как показано на рис. 4., что позволяеткратно ускорить обработку изображения нейросетью при меньшем потреблении памяти, а также исключить влияние цветовых отклонений, возникающих из-за неоптимальных условий съемки;




Рис. 4. Исходный снимок стопы в оттенках серого
Fig 4. Original grayscale shot of the foot

- 2) Из изображения в оттенках серого функцией определения максимального порога контрастности получаем рис. 5;




Рис. 5. Изображение с максимальным порогом контрастности
Fig. 5. Image with maximum contrast threshold

- 3) Полученное изображение обрабатывается нейросетью для получения набора контуров в виде двумерного массива. После чего происходит вычисление координат и фильтрация контуров по заданным параметрам, а именно: минимальный размер контура в пикселях (`size`), минимальное число сторон замкнутого контура (`sides`) и приближение периметра замкнутых контуров. На последний параметр влияет коэффициент периметра (`arcLength`). После чего, все соседние контуры соединяются в более крупные контуры, чтобы образовать непрерывные линии на снимке с помощью библиотеки `NumPy`, а именно с помощью функции `np.vstack(contours)`, в результате мы получаем список непрерывных контуров, отсортированный по размеру контуров. Далее, эти же контуры сортируются по оси `Oy` изображения в отдельный массив для определения верхней и нижней границ стопы, и в результате преобразований получаем рис. 6.



Рис. 6. Контуры: *a* – неотфильтрованные, *b* – максимальный четкий контур
Fig. 6. Contours: *a* – unfiltered, *b* – maximum clear contour

Основной проблемой шага 3) является определение четких контуров стопы и удаление лишних линий. Результат работы функции зависит от следующих параметров: *size* – минимальный размер создаваемых контуров в пикселях, *sides* – минимальное количество сторон создаваемых замкнутых контуров, *arcLength* – коэффициент расчета периметра при анализе замкнутых контуров.

Эти параметры должны быть одинаковы для всех изображений и именно подбор их оптимальных значений осуществляется с помощью генетического алгоритма [12] для максимальной точности работы функции.

2.2.2 Генетический алгоритм для подбора параметров алгоритма оконтуривания плантограммы

Для подбора параметров алгоритма оконтуривания плантограммы стопы генетическим алгоритмом (ГА) был использован размеченный вручную датасет из фотоснимков подошвенной поверхности стоп 25 обследованных добровольцев (50 стоп), пример снимка приведен на рис.7.



Рис. 7. Пример датасета
Fig.7. Sample dataset

Для унификации алгоритма и увеличения размера датасета правые стопы были выделены в отдельные снимки и отзеркалены относительно вертикальной оси как показано на рис.8-а.



a – зеркальное отображение подошвенной поверхности правой стопы b – левая стопа
a – mirror image of the plantar surface of the right foot, b – left foot

Рис. 8. Стопы, подготовленные для ГА
Fig. 8. Feet prepared for GA

Основными шагами генетического алгоритма в данном случае являются:

1. Создается словарь данных, где для каждого входного изображения заданы эталонные значения (рассчитанные вручную), к которым должен стремиться ГА в своей эволюции.
2. Задается фитнес-функция, которая рассчитывает точность определения характеристик плоскостопия в соответствии с п. 2.1.1-2.1.2. на текущем шаге эволюции по отношению к эталонным значениям.
3. Для каждого изображения из словаря данных при создании экземпляра класса ГА происходит заданное количество случайных инициализаций первого поколения. Происходит эволюция заданной глубины (не дальше определенного числа поколений). Значение глубины также было задано при инициализации.
4. Выбирается наилучшее значение фитнес-функции среди всех поколений всех инициализаций для каждого изображения, и запоминаются значения параметров, при которых получено это фитнес значение, а для каждого изображения дополнительно записывается фактический результат расчета степени плоскостопия с сохраненными параметрами.
5. Эволюция была запущена на 100 случайных инициализаций параметров, по 80 поколений в каждой инициализации, тем самым пройдя 8000 поколений. Остальные параметры были оставлены по умолчанию.
6. В ходе генетической эволюции алгоритма были подобраны следующие значения входных параметров для анализа: `size = 26`, `sides = 4`, `arcLength = 0.016046139380579895`.

Валидационным набором данных для генетического алгоритма являлась ручная разметка от экспертов, сделанная для каждого снимка из набора для обучения: для каждого снимка были подсчитаны все учитываемые метрики. Непосредственной валидацией является фитнес-функция, которая для каждого изображения в каждой эпохе эволюции считала метрики автоматически и сравнивает насколько они близки к экспертным значениям.

2.2.3 Алгоритм расчета контрольных линий и точек плантограммы

Необходимые координаты точек и линий для построения маски контрольных линий анализа плантограммы (стопы) рассчитываются следующим образом:

Входные данные: список упорядоченных по оси Y контуров, список непрерывных контуров, высота, ширина изображения.

1. По списку отсортированных контуров определить верхнюю и нижнюю границы стопы и построить продольный срез стопы.
2. Относительно середины линии продольного среза ищутся ближайшая левая и правая точки из списка непрерывных контуров, по этим точкам строится линия поперечного среза.
3. Находится точка пересечения срезов. Рассчитываются длины срезов и соотношения образованных точками пересечения отрезков в соответствии с п. 2.1.1-2.1.2. (рис. 9, рис. 10)

На рисунке 9 приведен пример расчета индекса распластанности k_2 для стопы из тестового множества. В данном случае была взята стопа из набора снимков оцененных как снимки хорошего качества, так как это в наибольшей степени соответствует условиям клинической плантографии. Были получены следующие результаты: для коэффициента распластанности стопы k_2 : программный коэффициент $k_2 = 0.487$, экспертный расчет коэффициента $k_2 = 0.456$, соответственно относительная погрешность составляет $|0.456 - 0.487| * 100\% / 0.487 = 6.37\%$.

После тестирования методики на тестовом множестве была получена представленная в табл. 1 оценка точности работы.


На рис. 10 приведен пример расчета индекса Шриттера для стопы из тестового множества. В данном случае была взята стопа из набора снимков оцененных как снимки хорошего качества, так как это в наибольшей степени соответствует условиям клинической плантографии. Для индекса Шриттера результат, полученный при помощи разработанной нами программы автоматического анализа фотоплантограммы составляет 47.036, а ручной расчет – 47.82, и ошибка составила $|47.82 - 47.86| * 100\% / 47.036 = 1.67\%$.




Рис. 9. Расчет коэффициента k_2 с помощью генетического алгоритма (a) и ручной разметки (b)
 Fig. 9. Calculating the coefficient k_2 using a genetic algorithm (a) and manual marking (b)

Табл. 1. Результаты тестирования методики для индекса распластанности k_2
 Table 1. Results of testing the methodology for the k_2 flatness index

Качество снимков	Количество снимков	Среднее отклонение от экспертного расчета (%)	Худшее отклонение от экспертного расчета (%)
Хорошее	14	2.50	13.20
Среднее	15	5.15	21.47
Плохое	9	9.14	53.35



a) индекс Штритера = 47.036
a) Strieter index = 47.036



b) индекс Штритера = 47.82
b) Strieter index = 47.82

Рис. 10. Расчет индекса Штритера с помощью генетического алгоритма (a) и ручной разметки (b).
Fig. 10. Calculating the Strieter index using a genetic algorithm (a) and manual marking (b).

После тестирования методики на тестовом множестве была получена представленная в табл. 2 оценка точности работы.

Табл. 2. Результаты тестирования методики для индекса Штритера
Table 2. Results of testing the methodology for the Strieter index

Качество снимков	Количество снимков	Среднее отклонение от экспертного расчета (%)	Худшее отклонение от экспертного расчета (%)
Хорошее	14	7.74	25.04
Среднее	15	20.60	45.40
Плохое	9	86.82	143.71

Также был проведен эксперимент по разметке снимков, полученных на камеру смартфона без использования каких-либо дополнительных технических средств, в эксперименте был использован смартфон Google Pixel 6, с камерой 50 Мп, 1/1,31", 1,2 мкм, f/1,9, 25 мм, Dual Pixel PDAF, Laser AF, OIS. Объектами съемки были стопы нескольких добровольцев из числа авторов статьи и их знакомых в возрасте от 22 до 54 лет. Для коэффициента распластанности k2 алгоритм дает хороший результат и в разметке контрольных точек, и в расчете показателей (рис. 11. a, b, c).



a) $k_2 = 0.413$



b) $k_2 = 0.439$



c) $k_2 = 0.428$

Рис. 11. Результаты расчета коэффициента k2 с помощью генетического алгоритма (a), ручной разметки с фотографии (b), ручной разметки снимка стопы с плантоскопа (c)

Fig.11. Results of calculating coefficient k2 using a genetic algorithm (a), manual marking from a photograph (b), manual marking of a photograph of a foot from a plantoscope (c)

Индекс Штритера, который очень сильно зависит от того, как стопа прижата к стеклу, в данном случае не рассчитывался. Пока такой способ исследования назвать значимым и достаточно точным невозможно из-за малого набора данных и неотработанности механизма съемки, но как тема для дальнейшего исследования как методики упрощенного получения информации, представляет интерес.

2.3 Алгоритм анализа плантограммы с использованием нейронных сетей

Другим подходом к анализу изображений является использование нейронных сетей, в частности, такой вариант исследования использовался ранее для диагностики варикоза [13], затяжных пневмоний [14], диагностики внутренних кровотечений [15]. Практически везде исследователь сталкивается с проблемой малого количества данных, но для первых двух примеров нейронные сети строились на основе числовых характеристик анализов, а в нашем случае целью исследования как раз и является получение числовых характеристик стопы, но по небольшому количеству изображений. Единственным способом увеличить количество изображений в этих случаях является аугментация – увеличение выборки данных для обучения через модификацию существующих данных (увеличение контраста, яркости; различные повороты изображения, вариативное масштабирование; добавление шумов, бликов, вырезание частей). В нашем случае, аугментацию приходится делать специфичным образом, так как при стандартной аугментации снимка он перестанет быть снимком стопы – а для исследования надо сохранить ее форму.

Поэтому было принято решение использовать частичную аугментацию изображений, направленную в первую очередь не на увеличение общего количества снимков стопы, а на увеличение количества изображений для выделения контуров стопы. Разработанный алгоритм на основе выделения на изображениях случайных точек как центров новых изображений позволил увеличить количество снимков из исходных 50 до 900, что уже вполне приемлемо для обработки нейронной сетью.

Для ускорения обучения и с учетом ограничений оперативной памяти, памяти видеокарты и мощности GPU было принято решение проводить обучение нейронной сети на одноканальных изображениях (в оттенках серого), поэтому была выбрана сеть U-net как самая нетребовательная к ресурсам из сетей разработанных для обработки медицинских изображений в условиях нехватки данных).

2.3.1 Архитектура сети

Архитектура нейронной сети U-net является сверточной, то есть имеет слои разной размерности, в данном случае упорядоченные от сужения к расширению. Так как входные изображения имеют размер 256x256 пикселей и 1 канал, то в качестве параметров входного тензора в функцию сети мы будем использовать их. Для написания модели была использована библиотека TensorFlow.

Блок слоев сужения размерности – Encoder представлен 4 сверточными слоями с количеством фильтров 64, 128, 256, 512 соответственно с размером матрицы 3x3. Они представлены матрицами весов, которые применяются к локальным областям входных данных и позволяют выделить важные признаки. После свертки с фильтром происходит активация, результатом которой является выходная карта признаков. В данном случае функцией активации является ReLU.

Так как карта признаков после операции свертки может измениться, необходимо использовать padding с параметром same. Он добавляет недостающие пиксели нулевого значения вокруг входных данных, чтобы размер выхода был таким же, как размер входа. Это позволяет сохранить пространственную информацию в процессе свертки и упрощает последующие операции объединения и декодирования. После каждого сверточного слоя необходимо сделать субдискретизацию – max pooling, с размером окна (2, 2), которая уменьшает размерность входных данных.

После сужения размерности идет средний блок, который используется для сохранения и агрегации информации с высоким уровнем абстракции. Он выполняет следующие задачи – извлечения более абстрактных признаков из-за большего размера фильтра, который равен

1024 и улучшение представления признаков, путем удаления ненужных шумов и усиления значимых признаков.

Благодаря pooling и свертке в Encoder, модель теряет некоторую контекстную информацию о положении объектов на изображении. Средний блок помогает сохранить эту информацию и предоставить ее декодеру для более точного восстановления объектов.

Последним блоком является блок расширения размерности – Decoder, который является обратным Encoder, то есть каждый слой свертки имеет количество фильтров 512, 256, 128, 64, а перед операцией свертки, идет объединение входных тензоров, получая на вход результат среднего блока и Decoder.


Для получения результата мы используем выходной сверточный слой с 1 фильтром и полудром 1x1, который использует сигмоидную функцию активации для генерации карты сегментации.

2.3.2 Обучение сети


Для обучения сети необходимо разбить данные на тестовые и тренировочные наборы. Для этого используется функция `train_test_split` с параметром разбиения 0.3, то есть 70% данных идет в тренировочный набор, а 30% в тестовый. Модель будет компилироваться с оптимизатором `adam`, функцией потерь `binary_crossentropy` и метрикой `accuracy`, которая будет определять оценку обучения модели. Метрика `accuracy` была выбрана для определения точности работы нейронной сети, так как необходимо сравнить результат, полученный с помощью нейронной сети с исходной маской данного изображения, а данная метрика как раз сравнивает результат с исходным, и в результате получаем характеристику того, на сколько близко измеренное значение к исходному.

Обучение модели проходило на 25 эпохах, с размером пакета 16 – столько образцов будет обрабатываться на каждой итерации обучения модели. Также для определения оценки модели на каждой эпохе во время обучения была использована функция `validation_data`. Обучение дало результат в 72% распознавания контуров стопы.

Для визуального определения результатов обучения была взята плантограмма стопы и обработана моделью (см. рис.12).



a



b

Рис. 12. Исходное изображение подошвенной поверхности стопы (a) и обработанное моделью (b)
Fig.12. Original foot (a) and processed model (b)

Можно видеть, что модель убрала свет со снимка и выделила стопу, но из-за того, что обучение проходило на аугментированных данных, на полученном изображении остаются лишние шумы и объекты. Но даже сейчас есть возможность отделить стопу от остального изображения, а также можно заметить часть стопы, которая прижата к стеклу, и часть, которая находится чуть выше него, что и требуется для дальнейшей обработки.

2.3.3 Обработка полученных результатов с помощью алгоритмов компьютерного зрения

Для удаления оставшихся шумов и определения той части стопы, которая плотно лежит на плантоскопе, был использован алгоритм обработки изображений для формата HSV, позволяющий выделить ту часть стопы, которая находится в воздухе, и окрасить ее в красный цвет (см. рис. 13).



Рис. 13. Маскированная стопа
Fig.13. Masked foot

Далее на основе разработанного алгоритма определяются координаты высшей (рис. 14-а) и нижней точек стопы (рис. 14-б), а также ее срединная линия (рис. 14-с).




Рис. 14. Контрольные точки стопы: а- высшая точка, б- низшая точка, с- срединная линия стопы
Fig. 14. Foot reference point: a- highest point, b- lowest point, c- midline of the foot


После всех вычислений в программе получаем программную разметку стопы на рис. 15-а, которая сравнима по результату с ручной разметкой на рис. 15-б. В данном случае, из-за особенностей алгоритма рассчитывались не абсолютные длины прилегающей и не прилегающих частей стопы, а их процентное соотношение, поэтому итоговое значение индекса Штритера определяется как величина процент прилегания стопы к плантоскопу.

В программной разметке соотношение прилегающей и не прилегающей частей стопы равно 68% и 32% соответственно, а в ручной – 66.39% и 33.61% соответственно. В результате итоговая ошибка в точности определения плоскостопия составляет $|68 - 66.39| * 100\% / 68 = 2.425\%$.

После тестирования методики на тестовом множестве была получена представленная в табл. 3 оценка точности работы:



a) Индекс Штритера 68
a) Strieter index = 68



b) индекс Штритера 66
b) Strieter index = 66

Рис. 15. Результаты расчета индекса Штритера с помощью нейронной сети (a) и при ручной разметке (b)

Fig.15. Results of calculating the Strieter index using neural (a) and manual marking (b)

Табл. 3. Результаты тестирования методики для индекса Штритера
Table 3. Results of testing the methodology for the Strieter index

Качество снимков	Количество снимков	Среднее отклонение от экспертного расчета (%)	Худшее отклонение от экспертного расчета (%)
Хорошее	14	7.339	69.88
Среднее	15	21.715	100
Плохое	9	23.553	100

Надо отметить, что модель, построенная на нейронной сети, оказалась в среднем более точной на снимках среднего и плохого качества, но, при этом если ошибки распознавания возникали, то они были более серьезными. Это свидетельствует о том, что для нейронных сетей количество данных в датасете должно быть больше и не все проблемы ограниченности датасета можно решить его аугментацией.

Заключение

Актуальность разработки и внедрения цифровых медицинских технологий в настоящее время признается в рамках междисциплинарного консенсуса специалистов. Наибольшее распространение такие технологии получили в анализе медицинских изображений. Одной из актуальных в клинической практике методик количественной оценки изображений является плантография, используемая в диагностике плоскостопия. Значимой проблемой использования этого метода служит трудоемкость. Часть этой проблемы решена за счет технологий «медицинского калькулятора». Однако, сохраняется необходимость существенных временных затрат на проведение ручной разметки изображений. Разработанные авторами методики точного определения контура стопы дают возможность автоматизировать разметку стопы по индексу Штритера и коэффициенту распластанности стопы k2. Это может помочь в снижении нагрузки на врача и повышении эффективности его работы, так как проще проверить рассчитанные точки и контрольные линии на их правильность, чем выполнять разметку вручную. Соответственно, это позволит упростить и ускорить диагностику заболеваний стопы врачом, так как единственным требованием методик является качественный снимок стопы, который можно сделать даже без использования дорогостоящего оборудования в виде бароподометрических комплексов.

Для дальнейшего исследования можно выделить следующие основные две задачи:

- уточнение обеих методик распознавания деформаций стопы на основе большего объема данных для обучения,

- добавление в проект расчетов для большего количества характеристик деформаций стопы (как, например, вальгусное отклонение первого пальца стопы).

Список литературы / References

- [1]. Babovi'c, S.S.; Vujovi'c, M.; Stilino'vi'c, N.P.; Jefi'c, O.; Novakovi'c, A.D. Labeling of Baropodometric Analysis Data Using Computer Vision Techniques in Classification of Foot Deformities. *Medicina* 2023, 59, 840. <https://doi.org/10.3390/medicina59050840>
- [2]. Chae J, Kang YJ, Noh Y. A Deep-Learning Approach for Foot-Type Classification Using Heterogeneous Pressure Data. *Sensors (Basel)*. 2020 Aug 11;20(16):4481. doi: 10.3390/s20164481. PMID: 32796568; PMCID: PMC7472491.
- [3]. Oliveira FP, Sousa A, Santos R, Tavares JM. Towards an efficient and robust foot classification from pedobarographic images. *Comput Methods Biomech Biomed Engin.* 2012;15(11):1181-8. doi: 10.1080/10255842.2011.581239. Epub 2011 Jun 8. PMID: 21660782.
- [4]. Maestre-Rendon JR, Rivera-Roman TA, Sierra-Hernandez JM, Cruz-Aceves I, Contreras-Medina LM, Duarte-Galvan C, Fernandez-Jaramillo AA. Low Computational-Cost Footprint Deformities Diagnosis Sensor through Angles, Dimensions Analysis and Image Processing Techniques. *Sensors (Basel)*. 2017 Nov 22;17(11):2700. doi: 10.3390/s17112700. PMID: 29165397; PMCID: PMC5713009.
- [5]. Гилязов Р. А., Турдаков Д. Ю. Активное обучение и краудсорсинг: обзор методов оптимизации разметки данных. *Труды ИСП РАН*, том 30, вып. 2, 2018 г., стр. 215–250. DOI: 10.15514/ISPRAS-2018-30(2)-11. / Gilyazev R.A., Turdakov D.Y. Active learning and crowdsourcing: a survey of annotation optimization methods. *Trudy ISP RAN/Proc. ISP RAS*, 2018, vol. 30, issue 2, pp. 215-250. (in Russian). DOI:10.15514/ISPRAS-2018-30(2)-11.
- [6]. Береснев А. П., Зоев И. В., Марков Н. Г. Исследование свёрточных нейронных сетей класса yolo для мобильных систем детектирования объектов на изображениях. 28-я Международная конференция по компьютерной графике и машинному зрению. *Труды конференции*. 2018, стр. 196-199. / Beresnev A. P., Zoev I. V., Markov N. G. Study of convolutional neural networks of the yolo class for mobile systems for detecting objects in images. 28th International Conference on Computer Graphics and Computer Vision. *Proceedings of the conference*. 2018, pp. 196-199. (in Russian). Доступно по ссылке: <https://www.graphicon.ru/html/2018/papers/proceedings.pdf>. 14.04.2024.
- [7]. Polaka I., Sudars K., Namatevs I. Automatic data labeling by neural networks for the counting of objects in videos. *Procedia Computer Science*, 2019, issue 149, pp. 151–158. DOI: 10.1016/j.procs.2019.01.118. Доступно по ссылке: https://www.researchgate.net/publication/331694901_Automatic_data_labeling_by_neural_networks_for_the_counting_of_objects_in_videos, 14.04.2024.
- [8]. Батраева И.А., Беликов А.В., Ионкина И.А., Забоев М.В., Миронов С.В., Пантелеев Д.С., Шапкин Ю.Г. Проблемы подготовки данных для анализа медицинских снимков. *Методы компьютерной диагностики в биологии и медицине - 2023. Сборник статей Всероссийской школы-семинара*. Саратов, 2023. стр. 192-194. / Batraeva I.A., Belikov A.V., Ionkina I.A., Zaboiev M.V., Mironov S.V., Pantelev D.S., Shapkin Yu.G. Problems of preparing data for analyzing medical images. *Methods of computer diagnostics in biology and medicine - 2023. Collection of articles of the All-Russian school-seminar*. Saratov, 2023. pp. 192-194. (in Russian). Доступно по ссылке: <https://www.elibrary.ru/item.asp?id=55822502/>.
- [9]. Пантелеев Д.С., Киреев С.И., Фалькович А.С., Батраева И.А., Забоев М.В., Чабукиани П.М. Программа для анализа и оценки плантографических критериев состояния (деформации) стопы "Подовизир". Свидетельство о регистрации программы для ЭВМ RU 2023682484, 25.10.2023. / Pantelev D.S., Kireev S.I., Falkovich A.S., Batraeva I.A., Zaboiev M.V., Chabukiani P.M. A program for analyzing and assessing plantographic criteria for the condition (deformation) of the foot "Podovisir". Certificate of registration of the computer program RU 2023682484, 10/25/2023. (in Russian). Доступно по ссылке: <https://www.elibrary.ru/item.asp?id=56001622/>.
- [10]. Смирнова Л. М., Аржаникова Е. Е., Карапетян С. В., Гаевская О. Э. Методика использования комплексов серии «Скан» при диагностике состояния стопы и назначении ортопедических стелек. СПб: ООО «ЦИАЦАН», 2015, 75 с. / Methodology for using the Scan series complexes in diagnosing foot conditions and prescribing orthopedic insoles: method. manual / Smirnova L. M., Arzhannikova E. E., Karapetyan S. V., Gaevskaya O. E. St. Petersburg: LLC "CIATSAN", 2015, 75 p. (in Russian)
- [11]. Akambase Jonas, Kokoreva Tatyana, Gurova Olga, Akambase Joseph. The effect of body positions on foot types: Considering body weight. *Translational Research in Anatomy*, 2019, vol. 16, pp. 1048-1053.

DOI:10.1016/j.tria.2019.100048. (in Russian). Доступно по ссылке:
<https://www.sciencedirect.com/science/article/pii/S2214854X19300470/>.

- [12]. Вирсански Эял. Генетические алгоритмы на Python. М.: ДМК-Пресс, 2020, стр. 286. / Virsanski Eyal. Genetic algorithms in Python. M.: DMK-Press, 2020, p. 286. (in Russian).
- [13]. Веденяпин Д.А., Лосев А.Г. Применение искусственных нейронных сетей в диагностике венозных заболеваний. Вестник новых медицинских технологий, том XIX, вып 2, 2012, стр. 241. / Vedenyapin D.A., Losev A.G. Application of artificial neural networks in the diagnosis of venous diseases. Bulletin of new medical technologies, volume XIX, issue 2, 2012, p. 241. (in Russian). Доступно по ссылке: <https://cyberleninka.ru/article/n/primeneniye-iskusstvennyh-neyronnyh-setey-v-diagnostike-venozyh-zabolevaniy>
- [14]. Провоторов В.М., Шалагина И.В., Демьяшкин В.А. Использование нейросетевых методов для решения вопросов дифференциальной диагностики при затяжных пневмониях. Пульмонология, 2003, вып.4, стр. 36-40 / Provotorov V.M., Shalagina I.V., Demyashkin V.A. The use of neural network methods to solve issues of differential diagnosis in prolonged pneumonia. Pulmonology, 2003, issue 4, pp. 36-40. (in Russian). Доступно по ссылке: <https://journal.pulmonology.ru/pulm/article/view/2639>
- [15]. Ионкина И.А., Беликов А.В., Шапкин Ю.Г., Пантелеев Д.С., Батраева И.А., Миронов С.В., Тышкевич С.В. Применение ИТ-технологий в анализе эндоизображений при диагностике рецидивов желудочно-кишечных кровотечений. Материалы Международной конференции молодых ученых «Фундаментальная и прикладная медицина». Саратов, 2023, стр. 109-111. (in Russian). / Ionkina I.A., Belikov A.V., Shapkin Yu.G., Panteleev D.S., Batraeva I.A., Mironov S.V., Tyshkevich S.V. Application of IT technologies in the analysis of endoimages in the diagnosis of recurrent gastrointestinal bleeding. Proceedings of the International Conference of Young Scientists "Fundamental and Applied Medicine". Saratov, 2023, pp. 109-111. (in Russian). Доступно по ссылке: <https://elibrary.ru/item.asp?id=60363677>

Информация об авторах / Information about authors

Сергей Иванович КИРЕЕВ – доктор медицинских наук, доцент. Ведущий научный сотрудник лаборатории цифровых медицинских технологий факультета фундаментальной медицины и медицинских технологий СГУ. Сфера научных интересов: методики лечения деформаций стопы, патологии суставов, патологии позвоночника, ограничения подвижности суставов при последствиях травм и заболеваниях нервной системы.

Sergey Ivanovich KIREEV – Dr. Sci. (Medicine), Associate Professor. Area of scientific interests: methods of treating foot deformities, joint pathologies, spinal pathologies, limitation of joint mobility due to the consequences of injuries and diseases of the nervous system.

Инна Александровна БАТРАЕВА – кандидат физико-математических наук, доцент, заведующая кафедрой технологий программирования факультета компьютерных наук и информационных технологий СГУ. Сфера научных и практических интересов: теория компиляторов, информационные системы и анализ данных в прикладной лингвистике, компьютерное зрение и анализ данных в медицине.

Inna Aleksandrovna BATRAEVA – Cand. Sci. (Phys.-Math.), Associate Professor, Head of the Department of Programming Technologies, Faculty of Computer Science and Information Technologies, SSU. Areas of scientific and practical interests: compiler theory, information systems and data analysis in applied linguistics, computer vision and data analysis in medicine.

Дмитрий Сергеевич ПАНТЕЛЕЕВ – студент магистратуры по направлению математическое обеспечение и администрирование информационных сетей факультета компьютерных наук и информационных технологий СГУ. Сфера научных и практических интересов: системы управления базами данных, графовые модели и алгоритмы анализа графов в сфере финансов, компьютерное зрение и анализ данных в медицине.

Dmitry Sergeevich PANTELEEV – Master student in software and administration of information networks, Faculty of Computer Science and Information Technology, SSU. Areas of scientific and

practical interests: database management systems, graph models and graph analysis algorithms in finance, computer vision and data analysis in medicine.

Максим Владиславович ЗАБОЕВ – бакалавр по направлению фундаментальная информатика и информационные технологии факультета компьютерных наук и информационных технологий СГУ. Сфера научных и практических интересов: системы управления базами данных, графовые модели и алгоритмы анализа графов в сфере финансов, компьютерное зрение и анализ данных в медицине.

Maxim Vladislavovitch ZABOEV – Bachelor in fundamental computer science and information technology, Faculty of Computer Science and Information Technology, SSU. Areas of scientific and practical interests: database management systems, graph models and graph analysis algorithms in finance, computer vision and data analysis in medicine.