

УДК 612.766:004.8.032.26:616.8-009.18-07

DOI: [10.26102/2310-6018/2025.50.3.004](https://doi.org/10.26102/2310-6018/2025.50.3.004)

Автоматическая детекция событий походки с использованием рекуррентных нейронных сетей

Т.А. Клишковская¹✉, А.Ю. Аксенов², И.В. Богданов², Е.А. Некрасова²,
С.В. Щербаков²

¹Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» имени В.И. Ульянова (Ленина), Санкт-Петербург, Российская Федерация

²Санкт-Петербургский государственный университет промышленных технологий и дизайна, Санкт-Петербург, Российская Федерация

Резюме. Клинический анализ походки является ключевым инструментом диагностики и планирования реабилитационных мероприятий у пациентов с двигательными нарушениями, однако точная и автоматическая детекция событий походки остается сложной задачей в условиях ограниченных ресурсов. Золотым стандартом автоматического определения событий походки является применение силовых платформ, но их применение ограничено при патологических паттернах ходьбы и использовании пациентами вспомогательных технических средств реабилитации. В данной работе представлен подход к автоматической детекции событий походки у детей с патологией походки на основе рекуррентных нейронных сетей. Представленная методология позволяет эффективно обнаруживать ключевые события походки (касание пяткой и отрыв пальцев). В исследовании использованы кинематические данные пациентов с нарушениями походки, полученные с помощью оптической системы захвата движений в различных условиях: при ходьбе босиком, в ортопедической обуви, с использованием ортезов и других технических средств реабилитации. Для обнаружения событий походки были обучены 4 модели (для каждой ноги и события). Модели продемонстрировали высокую чувствительность при малых временных задержках между предсказанным и реальным событием. Предложенный метод может быть использован в условиях клинической практики для автоматизации разметки данных и ускорения обработки данных анализа походки.

Ключевые слова: события походки, нейронные сети, рекуррентные нейронные сети, захват движений, биомеханика, детский церебральный паралич, кинематика стопы, машинное обучение.

Для цитирования: Клишковская Т.А., Аксенов А.Ю., Богданов И.В., Некрасова Е.А., Щербаков С.В. Автоматическая детекция событий походки с использованием рекуррентных нейронных сетей. *Моделирование, оптимизация и информационные технологии*. 2025;13(3). URL: <https://moitvvt.ru/ru/journal/pdf?id=1942> DOI: 10.26102/2310-6018/2025.50.3.004

Automatic detection of gait events using recurrent neural networks

Т.А. Klishkovskaia¹✉, A.Yu. Aksenov², I.V. Bogdanov², E.A. Nekrasova²,
S.V. Shcherbakov²

¹Saint Petersburg Electrotechnical University "LETI", Saint Petersburg,
the Russian Federation

²Saint Petersburg State University of Industrial Technologies and Design, Saint Petersburg,
the Russian Federation.

Abstract. Clinical gait analysis is a key tool for diagnosis and rehabilitation planning in patients with motor disorders; however, accurate and automatic detection of gait events remains a challenging task in

resource-limited settings. Force plates are considered the gold standard for automatic gait event detection, but their application is limited in cases of pathological gait patterns and when patients use assistive rehabilitation devices. This paper presents an approach to automatic detection of gait events in children with pathological gait using recurrent neural networks. The presented methodology effectively identifies key gait events (heel strike and toe off). The study used kinematic data from patients with gait disorders, collected using an optical motion capture system under various conditions: barefoot walking, in orthopedic footwear, with orthoses, and other technical rehabilitation aids. Four models were trained to detect gait events (one for each leg and event type). The models demonstrated high sensitivity with small time delays between predicted and actual events. The proposed method can be used in clinical practice to automate data annotation and reduce processing time for gait analysis results.

Keywords: gait events, neural networks, recurrent neural networks, motion capture, biomechanics, cerebral palsy, foot kinematics, machine learning.

For citation: Klishkovskaia T.A., Aksenov A.Yu, Bogdanov I.V., Nekrasova E.A., Shcherbakov S.V. Automatic detection of gait events using recurrent neural networks. *Modeling, Optimization and Information Technology*. 2025;13(3). (In Russ.). URL: <https://moitvivi.ru/journal/pdf?id=1942> DOI: 10.26102/2310-6018/2025.50.3.004

Введение

Клинический анализ походки на сегодняшний день является одним из самых информативных методов исследования локомоторных нарушений, возникающих при неврологических и ортопедических заболеваниях [1]. Этот метод помогает клиницистам ставить и уточнять диагнозы, планировать хирургические операции и комплексы реабилитационных мер, а также производить подбор ортопедической обуви и технических средств передвижения, включая индивидуальные ортезы. В частности, у пациентов с детским церебральным параличом (ДЦП) инструментальный анализ походки способствует выбору тактики хирургического и реабилитационного вмешательства [2], а при нейродегенеративных заболеваниях, таких как болезнь Паркинсона и болезнь Альцгеймера, применяется для ранней диагностики, оценки степени двигательной дисфункции и мониторинга эффективности терапии [3, 4].

Анализ походки позволяет получать количественные показатели кинематики (координаты тела в пространстве и угловые изменения суставов), кинетики (силы реакции опоры, центры давления, моменты сил в суставах, работу и мощность) и пространственно-временных параметров ходьбы (длина и ширина шага, скорость ходьбы, длительность шага, длительность фаз опоры и переноса ноги и др.). Важным этапом обработки данных является выделение событий походки – моментов контакта стопы с поверхностью (при нормальной походке это касание пяткой – heel strike – HS) и отрыва пальцев (toe off – TO), которые используются для выделения фаз походки (фаза опоры и фаза переноса ноги) и полных циклов шага (от одного касания стопой поверхности до следующего касания той же ногой). Такое разбиение кинематических и кинетических данных на отдельные циклы позволяет проводить их нормализацию по времени, усреднение, расчет параметров и дальнейшую интерпретацию результатов.

Золотым стандартом автоматической детекции событий походки является использование силовых платформ, регистрирующих силы реакции опоры и определяющих события по их превышению порогового значения [5]. Однако для точной разметки всех событий необходимо большое количество платформ (что значительно увеличивает стоимость оборудования), а также соблюдение важного условия: каждая нога пациента касается только одной платформы. Что довольно сложно соблюсти у пациентов с патологической ходьбой, в особенности, у детей: небольшая длина шага, волочение стопы или использование вспомогательных технических средств (костыли, ходунки и др.). В таких случаях события походки расставляются вручную оператором,

что увеличивает временные затраты на обработку и анализ данных, а точность детекции зависит от опыта специалиста.

По этой причине активно разрабатываются иные методы автоматической детекции [6, 7]. Алгоритмы на основе кинематических данных, полученных с видеосистем захвата движений, демонстрируют хорошие результаты для нормотипичной походки [8, 9]; однако их точность снижается при патологиях. В исследовании Бруэнинга и Риджи, сравнивающем 9 таких алгоритмов, показано, что выбор алгоритма определения событий походки во многом зависит от характера движения стопы во время фазы переноса; причем для одного и того же пациента оптимальными для определения момента контакта пятки и отрывы пальцев могут быть абсолютно разные алгоритмы [10]. Несмотря на это, алгоритмы на основе кинематики продолжают дорабатывать и улучшать для возможности использования у пациентов с патологической походкой [11].

С другой стороны, развивались методы на основе использования инерциальных измерительных устройств (IMU – inertial measurement units) [12, 13]. Однако данные об эффективности расходятся: одни исследования показывают довольно хорошие результаты [14, 15], другие же говорят о большей вариабельности и меньшей точности по сравнению с теми же кинематическими методами, в особенности, при патологической походке [16]. Но вместе с тем, все авторы сходятся во мнении, что точность детекции событий во многом зависит от места и правильности расположения датчиков, характера двигательных нарушений пациента и влияния внешних факторов (некоторые датчики могут быть чувствительны к наличию металлических объектов). К тому же чаще всего биомеханические лаборатории оснащены оптическими системами захвата движений, так как они являются более точными по сравнению с инерциальными системами, и позволяют регистрировать дополнительные показатели кинетики (моменты и мощности суставов).

Последние 10 лет большое внимание стало уделяться применению нейронных сетей для решения данной задачи [17, 18]. Причем с IMU сенсорами используют и сверточные нейронные сети (CNN – Convolutional Neural Network) [19, 20], и рекуррентные нейронные сети (RNN – Recurrent Neural Networks) [21], а также гибридные модели, совмещающие в себе обе эти архитектуры [22]. В частности, высокую эффективность показывают рекуррентные нейронные сети с архитектурой типа LSTM (Long Short-Term Memory), предназначенной для обработки временных рядов [23]. Применение LSTM-сетей позволяет достигать высокой точности детекции событий походки даже при использовании всего 1–2 датчиков, как это продемонстрировали Ли [24] и Саршар [25].

Кроме этого, предлагались даже модели нейросетей, обученных на электромиографических сигналах [26]. Они достигли средней ошибки 16 ± 18 мс для контакта пятки и 21 ± 18 мс для отрыва пальцев.

Также активно разрабатываются LSTM-архитектуры нейросетей, обучаемых на кинематических данных, что особенно актуально для клинической практики, когда применение силовых платформ ограничено, а ручная расстановка трудоемка и затратна по времени. Так, Ким и соавторы разработали модели, точность определения которых достигла 89,7 % для контакта стопы и 71,6 % для отрыва пальцев; при этом в качестве критерия совпадения использовалось узкое временное окно ± 16 мс относительно истинного события, что соответствует $\pm 2,4$ кадрам при частоте 150 Гц и $\pm 4,8$ кадрам при частоте 300 Гц, попадание в которое засчитывалось за правильный ответ [27]. В своем исследовании они использовали трехмерные координаты и скорости комбинаций 4-х маркеров, расположенных на стопе.

Иной подход к формированию базы данных для обучения был предложен Киджински и соавторами [28]. Они использовали большее количество входных параметров: координаты маркеров на стопе, голени, бедре и тазу, а также углы суставов, рассчитанные с использованием биомеханической модели Plug-in-Gait. При этом они смогли достичь средней ошибки 10 мс для контакта стопы и 13 мс для отрыва пальцев у детей с патологией походки, что значительно превзошло по точности классические кинематические методы, с которыми проводилось сравнение.

Однако, Лемперур и соавторы [29] показали, что приемлемую точность можно достичь, используя меньшее количество признаков. Они использовали трехмерные позиции трех маркеров на каждой ноге (пятка, пальцы и латеральная сторона лодыжки) и их скорости, получив среднюю ошибку 5,5 мс для касания пяткой и 10,7 мс для отрыва пальцев.

Обобщая данные о применении LSTM-моделей, обученных на кинематике, можно отметить разнообразие стратегий обучения: Ким [27] и Киджински [28] обучали отдельные модели для каждого события (контакт и отрыв для каждой ноги), тогда как Лемперур [29] обучал одну модель, решающую задачу мультиклассовой классификации (пять возможных событий: нет события, левый/правый контакт, левый/правый отрыв). Так же не все авторы раскрывают архитектуру своих нейромоделей: у Кима она не описана, у Киджински указана только величина временного отрезка входной последовательности – 128 кадров; тогда как Лемперур дает полное описание: максимальная длина записи (1536 кадров) была принята за длину обучающей входной последовательности, использовалось 3 LSTM-слоя по 800 нейронов в каждом. Общим для всех рассмотренных исследований является использование обширных баз данных для обучения (более 200 человек в каждом исследовании), что может быть затруднительно для небольших лабораторий, особенно в условиях клинической практики. С другой стороны, любое обучение нейромоделей требует предварительной подготовки данных: контроль качества записей и ручную верификацию всех событий, что при большом объеме может быть ресурсозатратно.

Представленное в данной работе исследование направлено на демонстрацию принципиальной работоспособности (proof-of-concept) подхода к автоматической детекции событий походки у детей с патологией. В отличие от вышеописанных работ, основной акцент сделан на возможность обучения нейросети при ограниченном объеме данных и минимальном наборе биомеханических признаков — координатах и скоростях всего трёх маркеров стопы.

Материалы и методы

Данные. Сбор данных проводился на базе лаборатории биомеханики Санкт-Петербургского государственного университета промышленных технологий и дизайна. Регистрация осуществлялась при помощи оптической системы захвата движений Qualisys, оснащенной девятью инфракрасными камерами Miquis M5 с частотой 100 Гц. При сборе данных использовалась маркерная IOR-модель [30].

В исследовании были использованы записи ходьбы 47 детей с диагнозом ДЦП в возрасте от 3 до 19 лет (средний возраст $8,9 \pm 3,7$ года), из них 18 мальчиков и 29 девочек. Всего было собрано 666 записей походки. Регистрация данных проводилась с комфортной для испытуемых скоростью. Были получены записи ходьбы в различных условиях: босиком, в ортопедической обуви, с использованием ортезов и костылей.

Все события походки были расставлены вручную оператором, имеющим 15-летний опыт работы в биомеханической лаборатории. Таким образом было получено:

- 1755 левых касаний пяткой (LHS – left heel strike);

- 1168 левых отрывов пальцев (LTO – left toe off);
- 1685 правых касаний пяткой (RHS – right heel strike);
- 1114 правых отрывов носка (RTO – right toe off).

Различие в количестве HS и TO объясняется особенностями дальнейшего анализа биомеханики и расчета пространственно-временных параметров походки, при котором учитываются только те события отрыва пальцев, которые попадают в полный цикл шага (от одного касания пятки до другого той же ноги).

Формирование признаков и базы данных. Для обучения нейронной сети использовались признаки, рассчитанные на основе трех точек: пятки (FCC), латеральной стороны лодыжки (FAL) и усредненного положения трех маркеров переднего отдела стопы (FM1, FM2 и FM5). Анатомическое расположение маркеров представлено на Рисунке 1. Для каждой из этих точек рассчитывались трехмерные координаты и скорости, полученные методом конечных разностей между соседними кадрами. В ряде случаев отсутствовал один из передних маркеров (чаще FM2); в таких случаях использовалось среднее значение доступных координат.




Рисунок 1 – Анатомическое расположение используемых маркеров стопы: FCC – пятка, FAL – латеральная сторона лодыжки, FM1, FM2, FM5 – маркеры переднего отдела стопы

Figure 1 – Anatomical placement of the markers used for feature extraction: FCC – heel, FAL – lateral malleolus, and FM1, FM2, FM5 – forefoot region

Таким образом, в каждый момент времени формировался 18-мерный вектор признаков, рассчитываемый для каждой ноги.

Далее данные были разделены на обучающую (78 %), валидационную (8 %) и тестовую (15 %) выборки таким образом, чтобы данные одного и того же испытуемого попадали только в одну из выборок для избегания переобучения или утечек данных.

Дополнительно была проведена оценка длительности записей. Как видно из гистограммы (Рисунок 2), основная часть записей укладывается в диапазон от 200 до 450 кадров. Основываясь на этом, было принято решение использовать фиксированную длину входной обучающей последовательности, равную 300 кадрам. Записи менее 300 дополнялись нулями (zero-padding), а более длительные фрагменты разбивались на отрезки по 300 кадров с 50 % перекрытием.




Рисунок 2 – Распределение длительностей записей походки
Figure 2 – Distribution of gait recording durations

Кроме того, выбор 300 кадров (3 секунды) был обусловлен стремлением сохранить цикличность походки во фрагменте, так как один такой отрезок включает от 1 до 2 полных циклов шага, что должно помочь уловить нейросети типовой паттерн движений во время обучения.

Разметка событий. Метки событий формировались в виде бинарных последовательностей, где «0» – отсутствие события, «1» – наличие события походки (LHS, RHS, LTO или RTO). Для повышения сходимости обучения и увеличения устойчивости модели к шуму бинарные метки были сглажены до куполообразной формы путем свертки с гауссовым ядром ($\sigma = 3$) (Рисунок 3). Сглаживание позволяло модели лучше учитывать окрестность события и было связано с выбором регрессионной постановки задачи (см. далее).




Рисунок 3 – Пример бинарной и сглаженной меток событий походки
Figure 3 – Example of binary and smoothed gait event labels

Архитектура нейросети. Для решения задачи детекции событий походки была спроектирована рекуррентная нейронная сеть на основе двунаправленных слоев LSTM (Bidirectional Long Short-Term Memory, BiLSTM).

С учетом ограниченного объема данных и высокой вариабельности походки у пациентов с ДЦП было принято решение обучать отдельные модели для каждого типа события (LHS, RHS, LTO или RTO).

Также была выбрана регрессионная формулировка задачи вместо жесткой классификации, что позволило предсказывать вероятность наличия события в каждом кадре с использованием сглаженных меток и сигмоидальной активации на выходе.

Непосредственно архитектура модели включала следующие компоненты:

- Входной слой на 18 признаков (3 маркера по 3 координаты и 3 скорости);
- BiLSTM-слой (128 нейронов);
- Dropout-слой с вероятностью исключения нейронов 0,3 (для предотвращения переобучения);
- BiLSTM-слой (64 нейрона);
- Dropout-слой с коэффициентом 0,3;
- Полносвязный слой (fully connected) на 32 нейрона с функцией активации ReLU;
- Выходной полносвязный слой на 1 нейрон с сигмоидальной функцией активации.

Функция потерь. Для компенсации несбалансированности классов, связанной с редкостью событий походки относительно общего числа кадров, при обучении использовалась модифицированная функция потерь – взвешенная бинарная кросс-энтропия (Weighted Binary Cross Entropy). Положительные классы (события походки) получали увеличенный вес ($PosWeight = 20$). Формула вычисления потерь имела вид:

$$L = -\frac{1}{N} \sum_{i=1}^N w_i (T_i \ln(Y_i + \varepsilon) + (1 - T_i) \ln(1 - Y_i + \varepsilon)), \quad (1)$$

где T_i – истинные метки, Y_i – предсказанные значения, ε – малое число для численной стабильности, w_i – веса, вычисляемые по формуле:

$$w_i = T_i \cdot PosWeight + (1 - T_i). \quad (2)$$

Это позволило сделать модель более чувствительной к редким событиям, сохраняя целостность временных данных.

Параметры обучения модели. Обучение моделей проводилось в среде MATLAB R2024a с использованием оптимизатора Adam. Максимальное количество эпох составляло 20, а размер мини-батча – 20. Валидация выполнялась каждые 10 итераций. Перемешивание данных происходило после каждой эпохи.

Оценка качества работы модели. Для оценки качества работы модели ее выход (предсказанные вероятностные характеристики) преобразовывался в бинарные с использованием порога, равного 0,5. Обнаружение событий осуществлялось через поиск локальных максимумов, высотой не менее 0,45, и минимальным расстоянием между ними 50 кадров (Рисунок 4).




Рисунок 4 – Пример обнаружения событий по предсказанной вероятности
Figure 4 – Example of gait event detection using predicted probabilities

Предсказанный пик считался корректным, если он находился в интервале ± 10 кадров от истинного события.

Основной метрикой качества в данном исследовании выступала чувствительность (или полнота – Recall), поскольку целью являлось максимальное обнаружение всех событий, размеченных оператором.

Дополнительно рассчитывались следующие показатели для оценки задержек между предсказанными и истинными событиями: средняя величина ошибки, средняя абсолютная величина ошибки, медианная ошибка, медианная абсолютная ошибка, стандартное отклонение и 95 % доверительный интервал среднего значения ошибки.

Результаты

Как упоминалось ранее, для оценки работы сети использовалось 15 % от общего числа записей, в событиях походки это составило: 298 – LHS, 227 – LTO, 283 – RHS, 225 – RTO.

Архитектура каждой модели и параметры (включая количество слоев, число нейронов и порог детекции события) подбирались эмпирически и приведены в разделе «Методы».

Для каждого события походки обучалась отдельная нейросеть. Чувствительность моделей составила от 99,3 % до 100 % (Таблица 1). Следует отметить, что все размеченные события были обнаружены, однако в отдельных случаях наблюдались отклонения предсказанных значений за пределы установленного допуска ± 10 кадров; при его увеличении до ± 15 полнота всех моделей достигала 100 %.

С учетом частоты дискретизации 100 Гц, 1 кадр соответствует 10 мс. Таким образом, все средние значения задержек не превышают одного кадра. Несмотря на то, что для некоторых моделей доверительный интервал не включает ноль, величина смещения остается незначительной, что позволяет говорить об отсутствии клинически значимого систематического сдвига в сторону раннего или запаздывающего предсказания событий. Также средние абсолютные значения для большинства моделей не превышают 2 кадров (20 мс), за исключением модели RTO, где оно составило 2,3 кадра (23,1 мс).

Таблица 1 – Статистические показатели задержек между предсказанными и реальными событиями

Table 1 – Statistical characteristics of delays between predicted and actual gait events

Метрика	LHS	LTO	RHS	RTO
Полнота	100 %	99,6 %	99,3 %	100 %
Средняя задержка, мс	–0,8	1,6	–3,5	1,0
Медианная задержка, мс	0	0	0	0
Средняя абсолютная, мс	11,6	14,7	12,9	23,1
Медиальная абсолютная задержка, мс	10	10	10	20
Стандартное отклонение, мс	16,5	20,3	18,5	29,7
95 % Доверительный интервал, мс	[–2,6 1,1]	[–1,0 4,3]	[–5,6 –1,3]	[0,04 7,7]

На Рисунке 5 представлены гистограммы задержек предсказаний для каждой модели.




Рисунок 5 – Распределение временных задержек между предсказанными и истинными событиями (LHS, LTO, RHS и RTO)

Figure 5 – Distribution of time delays between predicted and true gait events (LHS, LTO, RHS, RTO)

Медианная задержка для всех моделей составила 0 мс, а медианная абсолютная задержка – 20 мс для RTO и 10 для остальных. Это говорит о том, что в половине случаев ошибка предсказания составляет не более 1–2 кадров.

Стоит отметить, что стандартное отклонение задержек было ниже для моделей, определяющих касание пяткой HS – до двух кадров, в то время как для моделей отрыва пальцев TO оно составило 2–3 кадра.

Обсуждение

Целью данного исследования была демонстрация возможности обучения и применения нейросетевого подхода к автоматической детекции событий походки при ограниченном объеме обучающей выборки.

В рамках работы были протестированы различные архитектуры, включая однослойные, двуслойные и трехслойные LSTM- и BiLSTM-сети. Наилучшие результаты были достигнуты при использовании двух BiLSTM-слоев, за которым следовал полносвязный слой. Уменьшение числа нейронов в слоях приводило к снижению чувствительности, в то время как увеличение значительно не улучшало точность предсказаний, но приводило к переобучению. Также к переобучению приводило повышение количества эпох сверх 20.

В отличие от предложенного в данной работе подхода, Лемперур и соавторы [29] использовали мультиклассовую постановку задачи, обучая одну модель, одновременно классифицирующую 5 событий (отсутствие события, LHS, RHS, LTO, RTO). Такой подход требует существенно большего объема данных для обеспечения устойчивости модели. В настоящем исследовании при попытке применения аналогичной постановки

задачи наблюдалось явное недообучение модели, вероятно связанное с ограниченным размером обучающей выборки. Увеличение количества нейронов в слоях не позволяло компенсировать дефицит данных и не приводило к улучшению качества классификации.

Также была предпринята попытка обучения моделей по объединенным данным правой и левой ноги (две модели HS и TO): в этом случае данные левой стороны симметрично отображали относительно сагиттальной плоскости – за ось симметрии была взята середина таза. Несмотря на двухкратное увеличение объема обучающей выборки, такие модели показали нестабильные результаты: наблюдались ложные срабатывания и значительные задержки определения событий. В связи с этим было принято решение обучать отдельные модели для каждого события и каждой ноги, что обеспечило более высокую точность и стабильность предсказаний, а также лучше учитывало возможную асимметрию походки, характерную для пациентов с ДЦП.

Стоит отметить, что длина временной последовательности для обучения была выбрана равной 300 кадрам (3 секунды) с перекрытием 50 %. Такая длина фрагмента позволяла включать от одного до двух полных циклов шага, что должно было способствовать лучшему захвату цикличности походки моделью. Следует отметить, что в других работах длина обучающей последовательности существенно отличалась: Лемперур и соавторы [29] использовали максимальную длину среди всех записей, равную 1536 кадрам, а Киджински и соавторы выбрали 128 кадров [28]. Дополнительно эта процедура позволила увеличить объем обучающей выборки за счет большей вариативности расположения событий внутри фрагментов. Разбиение записей на отрезки по 300 отсчетов осуществлялось уже после разделения данных на обучающую и валидационную выборки, что исключило риск утечки данных. Итоговые результаты, полученные на тестовой выборке, демонстрируют то, что использование такого подхода не привело к переобучению.

В работе Киджински и соавторов [28] для обучения модели использовались не только маркеры, но и углы суставов нижних конечностей, полученных путем биомеханического моделирования. Такой подход потенциально способствует повышению точности моделей, но подобные вычисления требуют специализированного программного обеспечения, что ограничивает его использование в некоторых лабораториях. Настоящее же исследование подтвердило возможность использования меньшего количества признаков – это согласуется с выводами предыдущих исследований [27, 29], однако высокие результаты были получены в условиях существенно меньшего объема данных.

Тестирование всех обученных моделей дало высокие показатели чувствительности – более 99 % (Таблица 1), что сопоставимо или даже превышает результаты других исследований [28, 29]. Из всех рассмотренных работ только Ким и соавторы [27] указывали допустимый интервал отклонения от истинного события, попадание в который считалось корректным предсказанием. При этом их подход базировался на событиях, расставленных по данным силовых платформ, а все записи выполнялись у пациентов, идущих босиком. В настоящем исследовании использовались записи как босиком, так и в обуви, ортезах и с использованием других вспомогательных средств поддержки. Тем не менее средняя и абсолютная средняя задержки были менее 1 кадра (10 мс) и в пределах 2–3 (20–30 мс) кадров, соответственно, что можно считать незначительными, особенно с учетом возможной неточности ручной разметки оператора.

Дополнительно стоит отметить, что вариабельность ошибок при определении HS меньше, чем при отрыве стопы (ТО), что подтверждается меньшим стандартным отклонением задержек (Таблица 1) и более узким распределением ошибок (Рисунок 5); аналогичные результаты описывали и другие исследователи [27, 29]. Это связано с

характером самого события касания поверхности пяткой как более четким биомеханическим событием, в отличие от менее выраженного и более вариативного момента отрыва пальцев, особенно у пациентов с патологией походки. А также может иметь место факт субъективной разметки оператором: точный момент отрыва труднее определить даже визуально при просмотре записи.

Заключение

В рамках данного исследования была продемонстрирована возможность использования рекуррентных нейронных сетей на основе BiLSTM-слоев для детекции событий походки, обученных на ограниченном объеме записей пациентов с патологией походки. Были обучены отдельные модели для каждого типа события (LHS, LTO, RHS и RTO). Предложенный метод разбиения данных на отдельные перекрывающиеся фрагменты длиной 300 кадров (3 секунды) позволил увеличить количество данных для обучения, не вызывая переобучения модели.

Несмотря на ограниченный объем исходных данных и высокую вариабельность походки, все модели показали высокую чувствительность. Полученные результаты сопоставимы с более сложными моделями из литературы, что подтверждает работоспособность предложенного подхода и его применимость в условиях ограниченных ресурсов. Метод может быть полезен для автоматизации клинического анализа походки и сокращения времени на разметку данных в биомеханических лабораториях.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Wren T.A.L., Gorton III G.E., Öunpuu S., Tucker C.A. Efficacy of Clinical Gait Analysis: A Systematic Review. *Gait & Posture*. 2011;34(2):149–153. <https://doi.org/10.1016/j.gaitpost.2011.03.027>
2. States R.A., Krzak J.J., Salem Ya., Godwin E.M., Bodkin A.W., McMulkin M.L. Instrumented Gait Analysis for Management of Gait Disorders in Children with Cerebral Palsy: A Scoping Review. *Gait & Posture*. 2021;90:1–8. <https://doi.org/10.1016/j.gaitpost.2021.07.009>
3. Del Din S., Elshehabi M., Galna B., et al. Gait Analysis with Wearables Predicts Conversion to Parkinson Disease. *Annals of Neurology*. 2019;86(3):357–367. <https://doi.org/10.1002/ana.25548>
4. Cicirelli G., Impedovo D., Dentamaro V., Marani R., Pirlo G., D’Orazio T.R. Human Gait Analysis in Neurodegenerative Diseases: A Review. *IEEE Journal of Biomedical and Health Informatics*. 2022;26(1):229–242. <https://doi.org/10.1109/JBHI.2021.3092875>
5. Veilleux L.-N., Raison M., Rauch F., Robert M., Ballaz L. Agreement of Spatio-Temporal Gait Parameters Between a Vertical Ground Reaction Force Decomposition Algorithm and a Motion Capture System. *Gait & Posture*. 2016;43:257–264. <https://doi.org/10.1016/j.gaitpost.2015.10.007>
6. Zeni Jr J.A., Richards J.G., Higginson J.S. Two Simple Methods for Determining Gait Events During Treadmill and Overground Walking Using Kinematic Data. *Gait & Posture*. 2008;27(4):710–714. <https://doi.org/10.1016/j.gaitpost.2007.07.007>
7. Ghousayni S., Stevens Ch., Durham S., Ewins D. Assessment and Validation of a Simple Automated Method for the Detection of Gait Events and Intervals. *Gait & Posture*. 2004;20(3):266–272. <https://doi.org/10.1016/j.gaitpost.2003.10.001>

8. Hreljac A., Marshall R.N. Algorithms to Determine Event Timing During Normal Walking Using Kinematic Data. *Journal of Biomechanics*. 2000;33(6):783–786. [https://doi.org/10.1016/S0021-9290\(00\)00014-2](https://doi.org/10.1016/S0021-9290(00)00014-2)
9. De Asha A.R., Robinson M.A., Barton G.J. A Marker Based Kinematic Method of Identifying Initial Contact During Gait Suitable for Use in Real-Time Visual Feedback Applications. *Gait & Posture*. 2012;36(3):650–652. <https://doi.org/10.1016/j.gaitpost.2012.04.016>
10. Bruening D.A., Ridge S.T. Automated Event Detection Algorithms in Pathological Gait. *Gait & Posture*. 2014;39(1):472–477. <https://doi.org/10.1016/j.gaitpost.2013.08.023>
11. Gómez-Pérez C., Martori J.C., Diví A.P., Casanovas J.M., Samsó J.V., Font-Llagunes J.M. Gait Event Detection Using Kinematic Data in Children with Bilateral Spastic Cerebral Palsy. *Clinical Biomechanics*. 2021;90. <https://doi.org/10.1016/j.clinbiomech.2021.105492>
12. Prasanth H., Caban M., Keller U., et al. Wearable Sensor-Based Real-Time Gait Detection: A Systematic Review. *Sensors*. 2021;21(8). <https://doi.org/10.3390/s21082727>
13. Niswander W., Kontson K. Evaluating the Impact of IMU Sensor Location and Walking Task on Accuracy of Gait Event Detection Algorithms. *Sensors*. 2021;21(12). <https://doi.org/10.3390/s21123989>
14. Voisard C., de l'Escalopier N., Ricard D., Oudre L. Automatic Gait Events Detection with Inertial Measurement Units: Healthy Subjects and Moderate to Severe Impaired Patients. *Journal of NeuroEngineering and Rehabilitation*. 2024;21. <https://doi.org/10.1186/s12984-024-01405-x>
15. Romijnders R., Warmerdam E., Hansen C., Welzel J., Schmidt G., Maetzler W. Validation of IMU-Based Gait Event Detection During Curved Walking and Turning in Older Adults and Parkinson's Disease Patients. *Journal of NeuroEngineering and Rehabilitation*. 2021;18. <https://doi.org/10.1186/s12984-021-00828-0>
16. Zampier V.C., Simonsen M.B., Barbieri F.A., Oliveira A.S. On the Accuracy of Methods Identifying Gait Events Using Optical Motion Capture and a Single Inertial Measurement Unit on the Sacrum. [Preprint]. bioRxiv. URL: <https://doi.org/10.1101/2025.03.09.642234> [Accessed 28th March 2025].
17. Narayan V., Awasthi Sh., Fatima N., Faiz M., Srivastava S. Deep Learning Approaches for Human Gait Recognition: A Review. In: *2023 International Conference on Artificial Intelligence and Smart Communication (AISC)*, 27–29 January 2023, Greater Noida, India. IEEE; 2023. P. 763–768. <https://doi.org/10.1109/AISC56616.2023.10085665>
18. Dehzangi O., Taherisadr M., ChagalVala R. IMU-Based Gait Recognition Using Convolutional Neural Networks and Multi-Sensor Fusion. *Sensors*. 2017;17(12). <https://doi.org/10.3390/s17122735>
19. Su B., Smith Ch., Gutierrez Farewik E. Gait Phase Recognition Using Deep Convolutional Neural Network with Inertial Measurement Units. *Biosensors*. 2020;10(9). <https://doi.org/10.3390/bios10090109>
20. Romijnders R., Warmerdam E., Hansen C., Schmidt G., Maetzler W. A Deep Learning Approach for Gait Event Detection from a Single Shank-Worn IMU: Validation in Healthy and Neurological Cohorts. *Sensors*. 2022;22(10). <https://doi.org/10.3390/s22103859>
21. Wang F.-Ch., Li Yo.-Ch., Kuo T.-Yu., Chen S.-F., Lin Ch.-H. Real-Time Detection of Gait Events by Recurrent Neural Networks. *IEEE Access*. 2021;9:134849–134857. <https://doi.org/10.1109/ACCESS.2021.3116047>

22. Kreuzer D., Munz M. Deep Convolutional and LSTM Networks on Multi-Channel Time Series Data for Gait Phase Recognition. *Sensors*. 2021;21(3). <https://doi.org/10.3390/s21030789>
23. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
24. Lee J., Hong W., Hur P. Continuous Gait Phase Estimation Using LSTM for Robotic Transfemoral Prosthesis Across Walking Speeds. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2021;29:1470–1477. <https://doi.org/10.1109/tnsre.2021.3098689>
25. Sarshar M., Polturi S., Schega L. Gait Phase Estimation by Using LSTM in IMU-Based Gait Analysis-Proof of Concept. *Sensors*. 2021;21(17). <https://doi.org/10.3390/s21175749>
26. Nazmi N., Rahman M.A.A., Yamamoto Sh.-I., Ahmad S.A. Walking Gait Event Detection Based on Electromyography Signals Using Artificial Neural Network. *Biomedical Signal Processing and Control*. 2019;47:334–343. <https://doi.org/10.1016/j.bspc.2018.08.030>
27. Kim Yo.K., Visscher R.M.S., Viehweger E., Singh N.B., Taylor W.R., Vogl F. A Deep-Learning Approach for Automatically Detecting Gait-Events Based on Foot-Marker Kinematics in Children with Cerebral Palsy – Which Markers Work Best for Which Gait Patterns? *PLoS ONE*. 2022;17(10). <https://doi.org/10.1371/journal.pone.0275878>
28. Kidziński Ł., Delp S., Schwartz M. Automatic Real-Time Gait Event Detection in Children Using Deep Neural Networks. *PLoS ONE*. 2019;14(1). <https://doi.org/10.1371/journal.pone.0211466>
29. Lempereur M., Rousseau F., Rémy-Néris O. A New Deep Learning-Based Method for the Detection of Gait Events in Children with Gait Disorders: Proof-Of-Concept and Concurrent Validity. *Journal of Biomechanics*. 2020;98. <https://doi.org/10.1016/j.jbiomech.2019.109490>
30. Leardini A., Sawacha Z., Paolini G., Ingrosso S., Nativo R., Benedetti M.G. A New Anatomically Based Protocol for Gait Analysis in Children. *Gait & Posture*. 2007;26(4):560–571. <https://doi.org/10.1016/j.gaitpost.2006.12.018>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Клишкова Татьяна Алексеевна, аспирант кафедры «Биотехнических систем», Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» имени В. И. Ульянова (Ленина), Санкт-Петербург, Российская Федерация.
e-mail: tatianaklishkov@mail.ru

Tatiana A. Klishkovskaia, Postgraduate at the Department of Biotechnical Systems, Saint Petersburg Electrotechnical University "LETI", Saint Petersburg, the Russian Federation.

Аксенов Андрей Юрьевич, PhD, руководитель лаборатории научной биомеханики движения, Санкт-Петербургский государственный университет промышленных технологий и дизайна, Санкт-Петербург, Российская Федерация.
e-mail: a.aksenov@hotmail.com

Andrey Yu. Aksenov, PhD, Head of the Scientific Biomechanics of Movement Laboratory, Saint Petersburg State University of Industrial Technologies and Design, Saint Petersburg, the Russian Federation.

Богданов Илья Владимирович, магистрант кафедры конструирования и технологии изделий из кожи им. проф. А.С. Шварца, Санкт-Петербургский государственный университет промышленных

Ilya V. Bogdanov, Master's Degree student at the Department of design and technology of leather products in the name of prof. A. S. Schwartz, Saint Petersburg State University of Industrial

технологий и дизайна, Санкт-Петербург, Российская Федерация.

e-mail: ibo@mail.ru

Technologies and Design, Saint Petersburg, the Russian Federation.

Некрасова Екатерина Александровна, магистрант кафедры конструирования и технологии изделий из кожи им. проф. А.С. Шварца, Санкт-Петербургский государственный университет промышленных технологий и дизайна, Санкт-Петербург, Российская Федерация.

e-mail: necrasova.ekaterina@yandex.ru

Ekaterina A. Nekrasova, Master's Degree student at the Department of design and technology of leather products in the name of prof. A. S. Schwartz, Saint Petersburg State University of Industrial Technologies and Design, Saint Petersburg, the Russian Federation.

Щербakov Сергей Валерьевич, кандидат технических наук, исполняющий обязанности заведующего кафедрой конструирования и технологии изделий из кожи им. проф. А.С. Шварца, Санкт-Петербургский государственный университет промышленных технологий и дизайна, Санкт-Петербург, Российская Федерация.

e-mail: shcherbakov@sutd.ru

Sergey V. Shcherbakov, Candidate of Engineering Sciences, Acting Head of the Department of Design and Technology of Leather Products named after Prof. A.S. Schwartz, Saint Petersburg State University of Industrial Technologies and Design, Saint Petersburg, the Russian Federation.

Статья поступила в редакцию 04.05.2025; одобрена после рецензирования 06.06.2025; принята к публикации 26.06.2025.

The article was submitted 04.05.2025; approved after reviewing 06.06.2025; accepted for publication 26.06.2025.