

УДК 004.885

Б. А. Ассанович¹, Е. В. Косарева², Н. Н. Бич³¹Гродненский государственный университет имени Янки Купалы²Университет кардинала Стефана Вышинского, Польша³Гродненский государственный медицинский университет

МЕТОДИКА СОЗДАНИЯ ДЕТЕКТОРА ПАДЕНИЯ ПОЖИЛЫХ ЛЮДЕЙ НА ОСНОВЕ МАШИННОГО ЗРЕНИЯ И ПРЕОБРАЗОВАНИЯ ПРИЗНАКОВ ДВИЖЕНИЯ ОБЪЕКТА

Предлагается новая методика создания детектора падений на основе машинного зрения, которая использует инструмент tsfresh для генерации признаков с учетом параметров движения ограничивающей области объекта рамки и выполняет классификацию в режиме скользящего окна. Демонстрируется эффективность сгенерированных tsfresh признаков по сравнению с первичными признаками. Определяется наилучшая модель обнаружения падений человека с использованием библиотеки «auto-sklearn» и обобщенного набора данных из датасетов «UR Fall Detection и CAUCAFall». Модель, основанная на классификаторе методом gradient boosting, реализует точность детектирования 96% на основе образованных tsfresh вторичных признаков. Разделимость классов с использованием анализа главных компонент показала, что для вторичных признаков 99% дисперсии приходится на первые 4 главных компонента, в то время как для первичных признаков первые 10 главных компонент содержат только 80% дисперсии данных. Рассмотрена практическая применимость предлагаемого подхода в системах мониторинга человека в реальном времени. Время обработки для генерации вторичных признаков и прогнозирования составляет не более 3 с на последовательность, что подтверждает практическую применимость предлагаемого подхода в системах мониторинга падений в реальном времени.

Ключевые слова: машинное зрение, скользящее окно, падение человека, модель классификации, tsfresh, auto-sklearn.

Для цитирования: Ассанович Б. А., Косарева Е. В., Бич Н. Н. Методика создания детектора пожилых людей на основе компьютерного зрения и преобразования признаков движения объекта // Труды БГТУ. Сер. 3, Физико-математические науки и информатика. 2026. № 1 (302). С. 76–86.

DOI: 10.52065/2520-6141-2026-302-7.

B. A. Assanovich¹, E. V. Kosareva², N. N. Bich³¹Yanka Kupala State University of Grodno²University of Cardinal Stefan Wyszyński, Poland³Grodno State Medical University

METHOD FOR CREATING A FALL DETECTOR FOR ELDERLY PEOPLE BASED ON MACHINE VISION AND TRANSFORMATION OF OBJECT MOTION FEATURES

A new method for creating a computer vision-based fall detector is proposed. It uses the tsfresh tool to generate features based on the motion parameters of the object's bounding box and performs classification in a sliding window mode. The effectiveness of the generated tsfresh features is demonstrated compared to primary parameters. The best model for human fall detection is determined using the auto-sklearn library and a generalized dataset from the UR Fall Detection and CAUCAFall datasets. The model, based on a gradient boosting classifier, achieves 96% detection accuracy based on secondary features generated by tsfresh. Class separability using principal component analysis showed that for secondary features, 99% of the variance is accounted for by the first 4 principal components, while for primary features, the 10 first principal components contain only 80% of the data variance. The practical applicability of the proposed approach to real-time human monitoring systems is discussed. The processing time for generating secondary features and prediction is no more than 3 seconds per sequence, which confirms the practical applicability of the proposed approach in real-time fall monitoring systems.

Keywords: machine learning, sliding window, human fall detection, classification model, tsfresh, auto-sklearn.

For citation: Assanovich B. A., Kosareva E. V., Bich N. N. Method for creating a fall detector for elderly people based on machine vision and transformation of object motion features. *Proceedings of BSTU, issue 3, Physics and Mathematics. Informatics*, 2026, no. 1 (302), pp. 76–86 (In Russian).

DOI: 10.52065/2520-6141-2026-302-7.

Введение. Мониторинг активности пожилых людей привлекает значительное внимание в последние годы. Одной из серьезных проблем для людей старше 70 лет является потеря равновесия и падение, что особенно опасно для одиноко проживающих, поскольку они могут не получить своевременную помощь. Эта проблема вызвала всплеск исследований, посвященных дистанционному обнаружению падений, позволяющему быстро и качественно помочь пожилым людям. Падения действительно представляют собой серьезную проблему общественного здравоохранения, особенно среди пожилого населения. По данным Всемирной организации здравоохранения, падения являются второй по значимости причиной смерти от травм во всем мире среди людей в возрасте 65 лет и старше [1]. Системы обнаружения падений могут использоваться как инвазивные, созданные на носимых сенсорных устройствах, так и неинвазивные методы, базирующиеся на компьютерном зрении (КЗ) или так называемых технологиях, основанных на зрительном восприятии. Очевидно, что во многих практических ситуациях дистанционное управление КЗ предпочтительнее. Кроме того, система обнаружения падений на основе зрительного восприятия может обеспечить обратную связь и обучение людей для улучшения их равновесия и снижения риска падений. Эта технология обладает огромным потенциалом для революционного изменения контроля падений и улучшения жизни уязвимых людей.

Комплексный обзор многих опубликованных работ по этой тематике был проведен в работе Гутьерреса и других [2], где были описаны основные характеристики более чем 80 аналогичных систем, включая их классификацию и производительность. В его обзоре было проанализировано почти 500 работ, большинство из которых основаны на машинном обучении и использовании нейронных сетей. Недавно Алам и другие [3] представили исследование методов обнаружения падений на основе глубокого обучения, в котором они оценивают производительность систем обнаружения падений, их показатели производительности и соответствующие наборы данных. Анализ этих публикаций показал, что многие современные системы характеризуются вероятностью обнаружения падений более 90%. В целом, детекторы падений включают три основных этапа:

- 1) предварительная обработка видеосигнала, включая преобразование изображения и его сегментацию;
- 2) извлечение признаков (дескрипторов) путем выделения локальных или глобальных характеристик изображения;
- 3) фактическое обнаружение падений на основе полученных признаков и алгоритмов классификации [3].

В настоящее время применение новых компьютерных технологий позволило улучшить алгоритмы обработки данных о ключевых точках человека, что подтверждается реализацией ряда моделей YOLO, включающих специально обученные структуры для обнаружения падений [4]. Однако данные модели довольно сложны и ресурсоемки.

Для сокращения времени процесса обнаружения падений эффективен алгоритм скользящего окна, широко используемый в машинном обучении в сочетании с инженерией признаков. В работах [5, 6] показано его применение не только для определения состояния человека с помощью носимых датчиков, но и для диагностики аномального состояния объектов, например элементов машин. Однако по-прежнему эта техника недостаточно представлена исследователями в области визуального мониторинга, например, активности пожилых людей. В публикации [7] рассматривается применение визуального мониторинга для обнаружения

падений. Однако, несмотря на хорошие результаты, необходимо было расширить исследования и провести их верификацию на большем по объему датасете.

Кроме того, появилась возможность использования нового инструмента машинного обучения AutoML (Automated Machine Learning), применимого для обнаружения падений. Каусар и другие провели анализ данных с носимых датчиков [8] и заявили, что можно детектировать падения у пожилых людей с точностью около 99%. Однако результирующая точность их метода составляла все же 95–97% [3]. В связи с этим принято решение проверить использование технологии AutoML для обнаружения падения на основе машинного зрения и предложить методологию построения детектора на ее базе с использованием библиотеки tsfresh (Time Series Feature extraction based on scalable hypothesis tests).

Новизна проведенного исследования характеризуется рядом составляющих. Во-первых, был предложен алгоритм скользящего окна для увеличения объема как обучающих, так и тестовых данных и ускорения обнаружения падений в течение нескольких секунд. Во-вторых, был подготовлен набор данных CAUCAFall для обучения и тестирования предложенного алгоритма, на основе которого обобщен датасет, объединяющий также последовательно из набора данных UR Fall. И в-третьих, был применен подход для автоматического выбора наиболее эффективного алгоритма классификации с его оптимальными гиперпараметрами с использованием библиотеки auto-sklearn для обнаружения падений на основе видеоданных.

Основная часть. Теоретические сведения о физике падения описывают положение центра масс (ЦМ) тела человека, что очень важно для поддержания его равновесия как в положении стоя, так и в движении. Изменение положения человека при падении – это динамический процесс, определяемый переходом из устойчивого в неустойчивое состояние. Однако момент падения неопределен: тело человека может быть неустойчивым из-за воздействия внешних сил, или равновесие может быть нарушено по вине самого человека. Падение происходит непрерывно и изменчиво во времени: после падения поза тела динамически меняется, и каждая часть тела может изменить положение по-своему. Модель тела человека может быть представлена скелетной структурой, состоящей из соединенных линий, проходящих через ключевые точки (КТ). Исследования показали, что динамическая устойчивость человека при ходьбе определяется крестцовым маркером (точкой, расположенной у основания позвоночника), который с достаточно высокой точностью может быть заменен ЦМ. Согласно представлению о человеческом теле, состоящем из отдельных элементов, расположенных вокруг ЦМ, каноническая форма объекта определяется внешними силами, действующими на него. Однако на практике учет всех внешних сил практически невозможен, и в этом случае применяется расчет косвенных параметров, таких как скорость и ускорение ЦМ. В то же время, на основе технологии КЗ, местоположение человека может быть определено с предположением, что его тело находится внутри ограничивающей рамки (ОР). Чтобы упростить разработку практической модели контроля падений, в данном исследовании выполняется анализ падения человека, геометрический центр которого совпадает с центром масс, что характерно для простых и симметричных фигур [9] и называется их центроидом. Вычисление скорости центроида и отношения сторон ограничивающей рамки (ОР) и определяет основные подходы к обнаружению падений, описанные ниже.

Методы описываемого исследования опираются на использование известных наборов данных и их «очистки». Датасет для обнаружения падений UR [10], широко известный как UR Fall, массово используется в машинном обучении и представляет особую ценность для тех, кто занимается распознаванием человеческой активности, особенно в здравоохранении и уходе за пожилыми людьми. Этот набор данных содержит 70 последовательностей (30 падений и 40 других активностей activity of daily life (ADL)). Падения фиксируются с помощью двух камер Microsoft Kinect вместе с соответствующими данными акселерометра, в то время как события ADL регистрируются с помощью только одного устройства (камера 0) и акселерометра.

Набор данных включает файлы с признаками, извлеченными из карт глубины, сохраненные в формате CSV. Каждая строка представляет собой выборку данных, соответствующую одному изображению глубины, и включает: название последовательности (например, «fall-01», «adl-01»), номер кадра, метку («-1» означает, что человек не лежит, «1» означает, что человек лежит на земле, «0» указывает на временную позу во время падения) и ряд других параметров. Наиболее значимым параметром является отношение высоты к ширине OP , который называется как $HeightWidthRatio$ или $Aspect Ratio (AR)$ и используется для анализа. Дополнительную информацию о наборе данных можно найти в работах Кволека и Кепски [10], а также в работе Идего и других [11]. Характеристики, извлеченные из видео, имеют решающее значение для различения падений и иных активностей. CAUCAFall [12] – это база данных, предназначенная для распознавания падений человека в неконтролируемых домашних условиях, с различными условиями, такими как окклюзии, изменения освещения, различие в одежде, изменение фона, различные углы падения и расстояние от камеры. Она включает метки сегментации для каждого изображения, что облегчает реализацию методов распознавания падений человека с использованием детекторов YOLO. Набор данных включает моделирование пяти различных типов падений и пяти других движений. Падения обозначены как «падение», а эти движения — как «без падения». Данные структурированы в 10 основных каталогах, каждый соответствует отдельной теме. В каждом каталоге находится 10 папок, относящихся к различным действиям, выполняемым участниками. Каждая папка содержит видео соответствующего действия в формате .avi, изображения действий в формате .png и метки сегментации кадра в формате .txt. Для набора данных UR Fall были объединены записи в один фрейм данных, к которому добавлена переменная-индикатор «Падение», принимающая значения true/false для записей с падениями и без них соответственно. Каждый кадр в наборе данных помечен как -1; 0; 1, это определяет, что человек «не лежит», «лежит» и «падает/лежит» соответственно. Также проведена «очистка» данных. Во-первых, для видео ADL были обрезаны последовательности, где метка 0 появлялась после метки 1, что указывает на то, что человек встал после лежания, поскольку система должна немедленно выдавать сигнал о падении, не дожидаясь окончания записи. Во-вторых, последовательности с пропущенными кадрами также были найдены, как только была применена нумерация кадров для расчета скорости OP . В проведенных экспериментах параметр «FrameSpeed» и являлся вторым значимым параметром и рассчитывался за одну миллисекунду по следующей формуле:

$$\text{FrameSpeed} = \frac{fps}{1000df} \sqrt{dx^2 + dy^2}, \quad (1)$$

где dx , dy определяют соответствующее изменение координат центра OP ; df – приращение номера видеокadra при нумерации (в видео могут быть пропущены кадры); fps – частота кадров, для датасета UR Fall составляет 30 кадров в секунду.

Для набора данных CAUCAFall информация из файлов всех папок была объединена в один набор данных, и переменной «fall» было присвоено значение true для видеозаписей с падениями. Затем координаты OP каждого кадра были преобразованы из формата YOLO в абсолютные значения. Два признака $HeightWidthRatio$ и $FrameSpeed$ были рассчитаны для $fps = 23$ в этом наборе данных. Для видеозаписей набора данных CAUCAFall для последовательностей, соответствующих процессу падения (папки набора данных «fall»), было выбрано начало скользящего окна, начиная с 5-го кадра, поскольку визуальный анализ и расчет стандартного отклонения параметра $FrameSpeed$ в серии предварительных экспериментов показал 3-кратное превышение над его стационарным значением в первых 4 кадрах с начала записи. Это объяснимо наличием разброса параметров из-за артефактов при регистрации. Затем была выполнена процедура преобразования скользящего окна, аналогично той, которая использовалась для набора данных UR Fall. В нашей работе проведены эксперименты

по обучению вышеуказанной модели с использованием первичных признаков видео (HightWidthRatio и FrameSpeed) и вторичных признаков, сгенерированных библиотекой tsfresh [13], которая используется для систематического проектирования признаков из временных рядов. Далее, для подготовки данных к настройке параметров детектора падения (рис.1) необходимо было преобразовать все записи в выходные последовательности определенной длины.

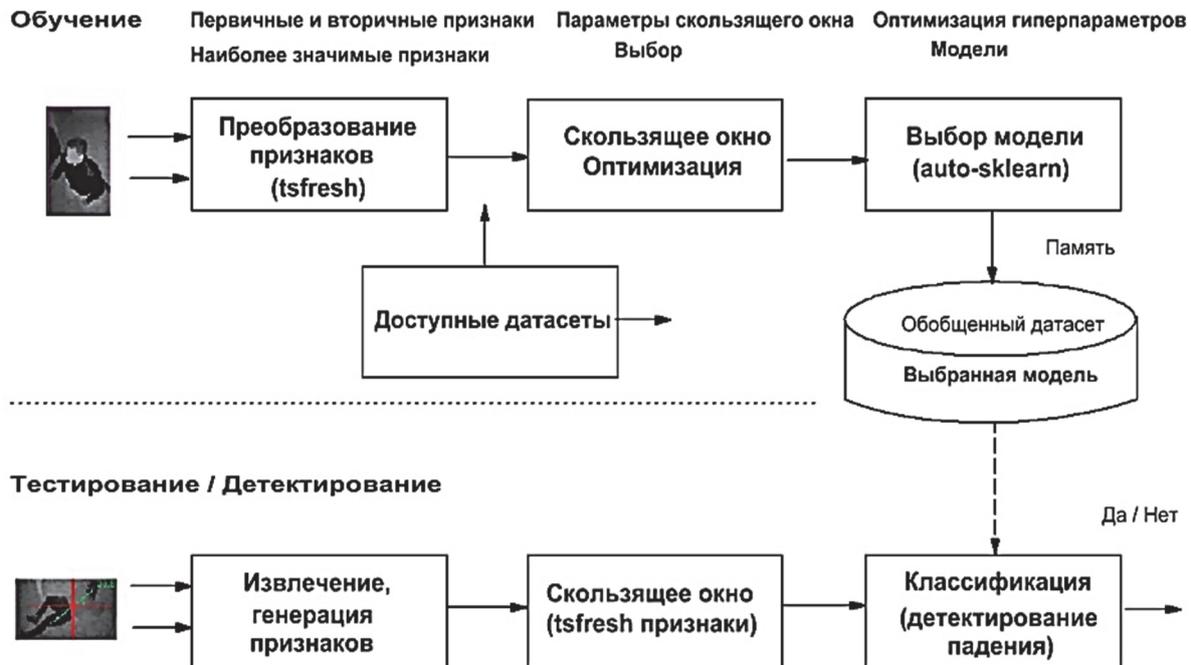


Рис. 1. Обработка данных в детекторе падения

Для этого использовался алгоритм скользящего окна с заданными параметрами:

Window – ширина скользящего окна (равная длине последовательности);

Stride – шаг преобразования кадров;

Fall_Frames – количество кадров с падениями (элементов в выходной последовательности, помеченных как 0).

Работа метода для Window=5, Stride=2, Fall_Frames=2 показана на рис. 2. В этом примере разработанный алгоритм преобразования возвращает только те последовательности длиной 5, в которых хотя бы 2 элемента имеют метку 0 (падение).

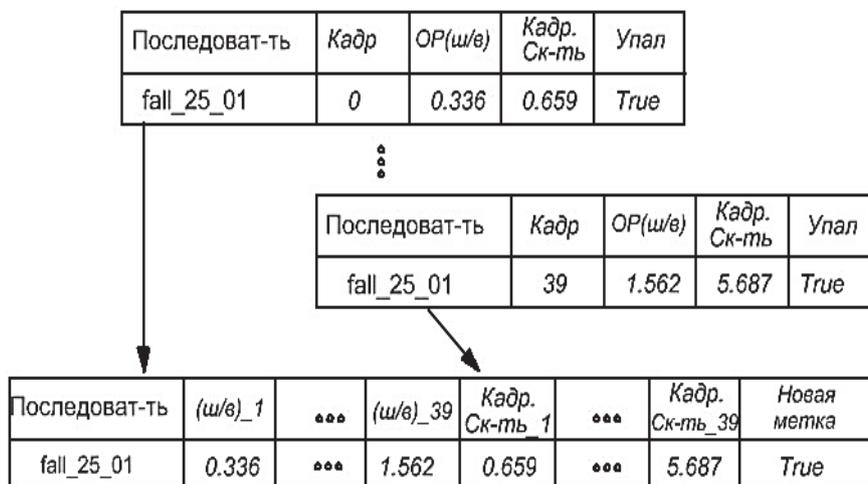


Рис. 2 Склейка данных из видеокадров

Опишем конфигурацию параметров скользящего окна. Для выбора значений параметров Window, Stride, Fall_Frames была обучена модель случайного леса с использованием перекрестной проверки. Значения параметров выбирались из следующих диапазонов: Window = (30, 40, 50), Stride = (3, 5, 7, 10), Fall_Frames = (10, 15, 20). Использовался метод полного перебора для поиска оптимальной совокупности параметров. Для каждой комбинации применялось скользящее окно к данным, базирующееся на значениях параметров Window, Stride и Fall_Frames на основе генерации нескольких последовательностей. Поскольку количество последовательностей «без падения» было значительно больше количества последовательностей «с падением» (в некоторых комбинациях параметров отношение случайных чисел к падению достигало 4 к 1), применялось выравнивание данных. Затем для каждой полученной последовательности добавлялась к вектор-строке признаков метка класса «Новая метка», которая соответствовала событию – «падение» в этой последовательности кадров.

Таким образом, был получен набор данных, в котором каждая последовательность представлена вектором длины $2 \cdot \text{Window} + 1$ (рис. 2). Затем данные были разделены на обучающий и тестовый наборы в соотношении 4 : 1.

Для оценки эффективности каждой комбинации параметров Window, Stride и Fall_Frames был обучен классификатор Random Forest и использован поиск по сетке для определения наилучшего количества оценщиков (деревьев) с 5-кратной перекрестной проверкой. Лучшая комбинация была выбрана на основе эффективности обученной модели RandomForest на тестовых данных. Лучшие параметры представлены в табл. 1 (худшая эффективность выделена курсивом, а лучшая — жирным шрифтом). Для обобщенного набора данных с первичными признаками выбраны параметры, гарантирующие, чтобы количество выходных последовательностей для наборов данных UR Fall и CAUCAFall не было слишком малым и чтобы точность детектирования падения оставалась высокой. Поэтому для обобщенного набора данных были установлены значения Window = 40, Stride = 3, Fall_Frames = 20.

Таблица 1. Лучшие параметры для первичных признаков

Размер окна	Шаг	Кол-во кадров	Точность %	Кол-во послед-тей
40	3	20	95	100
40	3	15	94	124
30	7	20	97	30
50	3	20	92	<i>104</i>
50	3	15	93	120
40	3	20	81	272
40	3	15	72	<i>119</i>
30	7	20	80	304
50	3	20	83	272
50	3	15	82	304

Далее была выполнена процедура выбора наилучших параметров Window, Stride, Fall_Frames для вторичных признаков, извлеченных из последовательностей, сгенерированных скользящим окном, с помощью библиотеки tsfresh. В этом случае вектор вторичных признаков был сгенерирован автоматически для каждой последовательности. Для генерации вторичных признаков были оставлены только параметры HeightWidthRatio и FrameSpeed, поскольку предыдущие исследования [7, 14] показали, что эти признаки оказывают наибольшее влияние на точность классификации. Наилучшие параметры представлены в табл. 2.

Для набора данных CAUCAFall с Window ≥ 40 и любыми значениями Stride, Fall_Frames удалось обучить модель с получением 100%-ной точности детектирования на тестовом наборе. Для обобщенного набора данных с вторичными признаками приняли оптимальные значения: Window = 40, Stride = 3, Fall_Frames = 20.

Таблица 2. Лучшие параметры для вторичных признаков

Размер окна	Шаг	Кол-во кадров	Точность %	Кол-во послед-тей
40	3	20	96	77
40	3	20	95	100
30	3	15	94	120
50	3	10	91	138
50	3	10	93	143
40	3	20	85	272
40	3	15	100	272
30	7	20	90	304
50	3	20	100	284
50	3	15	100	275

Анализ первичных и вторичных признаков. Корреляционный анализ показал, что первичные и вторичные признаки слабо коррелируют с классом данных («падение»/«не падение»): максимальное значение корреляции для вторичных признаков составляет 0,55, а для первичных признаков – 0,5. В то же время, как и ожидалось, для первичных признаков значения HeightWidthRatio и FrameSpeed в более поздних кадрах последовательности сильнее коррелируют с меткой класса. Кроме того, чтобы проверить гипотезу о том, что вторичные признаки лучше первичных для разделения классов, проведен их анализ на основе главных компонент (PCA). В наборе данных с вторичными признаками 99% дисперсии приходилось на первые четыре главных компонента, тогда как для первичных признаков первые десять главных компонентов составляют только 80% дисперсии. Это указывает на то, что вторичные признаки лучше объясняют поведение целевой переменной, чем первичные признаки.

Обучение и выбор лучшей модели с помощью auto-sklearn. Для достижения данной цели создавались 2 отдельных набора данных с первичными и вторичными признаками, как описано выше. После применения построения набора данных и балансировки классов было получено 2 набора данных размером 1856 последовательностей каждый, где 498 последовательностей были из датасета UR Fall, а 1358 – из датасета CAUCAFall. Набор данных с первичными признаками содержит 80 признаков, сгенерированных самим скользящим окном, а набор данных с вторичными признаками содержит 585 признаков, сгенерированных с помощью инструмента tsfresh от каждой исходной последовательности. Наборы данных были разделены на обучающую и тестовую выборки в соотношении 80% к 20%. Для выбора лучшей модели из ансамбля использовалась библиотека auto-sklearn, которая предоставляет готовые контролируемые машинные методы обучения [15], с автоматизацией полного цикла построения моделей.

В результате применения инструментов Auto-sklearn были найдены оптимальные алгоритмы как для первичных, так и для вторичных наборов данных и оптимизированы их гиперпараметры.

Оптимальной моделью, обученной на основном наборе данных признаков, является VotingClassifier, использующий алгоритм gradient boosting sklearn, а именно HistGradient BoostingClassifier, со следующими гиперпараметрами:

```
early_stopping=False,
l2_regularization=0.0015999096167997723,
learning_rate=0.024544266632179432,
max_iter=512, max_leaf_nodes=28,
min_samples_leaf=5,
random_state=1, validation_fraction=None, warm_start=True.
```

Модель реализует точность детектирования 80% на тестовом наборе. Для набора данных вторичных признаков та же архитектура модели была признана наилучшей, но со скорректированными гиперпараметрами:

```
early_stopping=True,  
l2_regularization=2.22710531072698e-08,  
learning_rate=0.02095996930896952,  
max_iter=512, max_leaf_nodes=20,  
min_samples_leaf=1,  
random_state=1,  
validation_fraction=None, warm_start=True.  
Модель достигла точности тестирования 96%.
```

Обсуждение результатов. В данной работе изучена эффективность первичных и вторичных признаков при обнаружении падений с применением метода скользящего окна для увеличения размера и вариативности обучающих данных. Наборы данных были созданы путем сегментации последовательностей из датасетов UR Fall и CAUCAFall, что привело к получению двух наборов признаков: первичных с 80 признаками, сгенерированными непосредственно скользящим окном, и вторичных из 585 признаков, сгенерированных с помощью инструмента tsfresh.

В работе представлена реализация автоматического извлечения признаков с помощью библиотек tsfresh и scikit-learn, которые затем используются для решения задач классификации, регрессии или кластеризации с помощью классических моделей машинного обучения, таких как Gradient Boosting или Random Forest.

После предварительной обработки и балансировки данных был применен подход AutoML с помощью библиотеки auto-sklearn для выбора оптимальных моделей для обоих наборов данных. Этот подход оказался эффективным: наилучшая модель для первичного набора признаков достигла 80% точности детектирования падений с использованием HistGradientBoostingClassifier. Для вторичных признаков та же настройка модели с скорректированными гиперпараметрами повысила точность до 96%, что демонстрирует преимущества извлечения вторичных признаков.

Заключение. В данной работе показано, что предложенная методика создания детектора, использующего скользящее окно для преобразования данных, является эффективной. Полученные результаты доказывают, что применение инструмента tsfresh, генерирующего новые вторичные признаки только из двух первичных, связанных с параметрами ОР, позволяет построить ансамбль хороших моделей машинного обучения. Дальнейшее использование инструмента auto-sklearn дает возможность выбрать наилучшую модель из классификаторов gradient boosting на основе гистограмм и достичь точности детектирования 0,96, что несколько лучше по сравнению с использованием аналогичной модели для датчиков в работе Нишиямы и др. [16], в которой средняя точность составила 0,936.

В представленном исследовании эффективность инструментов tsfresh и auto-sklearn подтверждается с использованием данных из двух датасетов: UR Fall Dataset и CAUCAFall Dataset, а также их комбинации. Проведенные эксперименты показывают, что вторичные признаки описывают поведение целевой переменной лучше, чем первичные, а также что время обработки для генерации вторичных признаков занимает не более 3 с на последовательность, что подчеркивает практическую применимость этого подхода в системах мониторинга падений в реальном времени.

Выбор между моделями детектирования падений определяется условиями эксплуатации и допустимыми временными затратами. Модель на основе первичных признаков (точность 80%) целесообразно применять в системах, где критически важна мгновенная скорость реакции (миллисекунды) — например, на носимых устройствах или микрокомпьютерах с ограниченными ресурсами, обрабатывающих потоковый видеосигнал без задержек. В свою очередь, высокоточная модель на вторичных признаках (96%) требует дополнительных затрат (до 3 с на генерацию признаков), однако эта задержка является приемлемой в сценариях, в которых приоритетом является достоверность детектирования: в медицинских

учреждениях или при постобработке данных на серверной инфраструктуре, где цена пропуска события существенно превышает требования к мгновенному оповещению. Кроме того, данное исследование подтверждает потенциал комбинирования метода скользящего окна с автоматизированными методами извлечения признаков, что позволяет унифицировать пайплайн обработки для обоих типов признаков и масштабировать систему мониторинга падений без потери качества детектирования.

Дальнейшим исследованием может быть интеграция детектора падений с трекингом объектов на основе алгоритма SORT (Simple Online and Realtime Tracking) и фильтра Калмана, что принципиально расширяет возможности и повышает надежность и масштабируемость системы [17]. Кроме того, использование IoU-метрики (Intersection over Union) позволяет системе одновременно отслеживать состояние множества людей в кадре, предотвращая смешивание их траекторий [18].

Список литературы

1. World Health Organization. Falls. website. URL: <https://www.who.int/news-room/fact-sheets/detail/falls> (дата обращения: 05.09.2025).
2. Gutiérrez J., Rodríguez V., Martín S. Comprehensive review of vision-based fall detection systems // *Sensors*. 2021. No. 21 (3). 947 p.
3. Vision-based human fall detection systems using deep learning: A review / E. Alam [et al.] // *Computers in Biology and Medicine*. 2022. Vol. 7. 146 p.
4. Yolo-fall: A novel convolutional neural network model for fall detection in open spaces / D. Zhao [et al.] // *IEEE Access*. 2024. Vol. 12. P. 26137–26149.
5. Yhdego H., Paolini C., Audette M. Toward real-time, robust wearable sensor fall detection using deep learning methods: A feasibility study. *Applied // Sciences*. 2023. Vol. 13 (8). 4988 p. <https://doi.org/10.3390/app13084988>.
6. Enhancing gearbox fault diagnosis through advanced feature engineering and data segmentation techniques / K. Shukla [et al.] // *Machines*. 2024. Vol. 12 (4). 261 p.
7. Kosarava K., Assanovich B. A simple indoor fall control system for the elderly based on the analysis of object bounding box parameters // *Proceedings of the International Conference on Pattern Recognition and Information Processing, Minsk, 21–24 September 2021*. Minsk, 2021. P. 92–96.
8. Automated machine learning based elderly fall detection classification / F. Kausar [et al.] // *Procedia Computer Science*. 2022. Vol. 203 (9). P. 16–23.
9. Gahramanova A. Locating centers of mass with image processing // *Undergraduate Journal of Mathematical Modeling: One+ Two*. 2019. Vol. 10 (1). P. 14–25.
10. Kwolek B., Kepski M. Human fall detection on embedded platform using depth maps and wireless accelerometer // *Computer Methods and Programs in Biomedicine*. 2014. Vol. 17 (3). P. 489–501.
11. Yhdego H., Paolini C., Audette M. Toward real-time, robust wearable sensor fall detection using deep learning methods: A feasibility study // *Applied Sciences*. 2023. Vol. 13 (8). 4988 p.
12. Dataset CAUCAFall / J. Eraso [et al.] // *Mendeley Data*. 2022. Vol. 4. 489 p.
13. Overview on extracted features. URL: https://tsfresh.readthedocs.io/en/latest/text/list_of_features.html (дата обращения: 05.09.2025).
14. Assanovich B., Kosarava K. Vision-Based Fall Detector for Elderly Based on Sliding Window Approach and Feature Engineering // *Journal of Data Science and Intelligent Systems*. 2025. Vol. 3 (1). P. 27–34.
15. Auto-sklearn 2.0: Hands-free AutoML via meta learning / M. Feurer [et al.] // *Journal of Machine Learning Research*. 2022. Vol. 23 (261). P. 1–61.
16. Accurate fall risk classification in elderly using one gaitcycle data and machine learning / D. Nishiyama [et al.] // *Clinical Biomechanics*. 2024. Vol. 115. 62 p.

17. Simple online and realtime tracking / A. Bewley [et al.] // IEEE International Conference on Image Processing (ICIP). Phoenix, AZ, USA, 2016. P. 3464–3468.

18. Wojke N., Bewley A. and Paulus D. Simple online and realtime tracking with a deep association metric. 2017 IEEE International Conference on Image Processing (ICIP). Beijing, China, 2017. P. 3645–3649.

References

1. World Health Organization. Falls. website. Available at: <https://www.who.int/news-room/fact-sheets/detail/falls> (accessed 05.09.2025).

2. Gutiérrez J., Rodríguez V., Martín S. Comprehensive review of vision-based fall detection systems. *Sensors*, 2021, no. 21 (3). 947 p.

3. Alam E., Sufian A., Dutta P., & Leo M. Vision-based human fall detection systems using deep learning: A review. *Computers in Biology and Medicine*, 2022, vol. 7. 146 p.

4. Zhao D., Song T., Gao J., Li D., & Niu Y. Yolo-fall: A novel convolutional neural network model for fall detection in open spaces. *IEEE Access*, 2024, vol. 12, pp. 26137–26149.

5. Yhdego H., Paolini C., Audette M. Toward real-time, robust wearable sensor fall detection using deep learning methods: A feasibility study. *Applied Sciences*, 2023, vol. 13 (8), pp. 4988 p. <https://doi.org/10.3390/app13084988>.

6. Shukla K., Holderbaum W., Theodoridis T., & Wei G. Enhancing gearbox fault diagnosis through advanced feature engineering and data segmentation techniques. *Machines*, 2024, vol. 12 (4). 261 p.

7. Kosarava K., Assanovich B. A simple indoor fall control system for the elderly based on the analysis of object bounding box parameters. *Proceedings of the International Conference on Pattern Recognition and Information Processing*, Minsk, 2021, pp. 92–96.

8. Kausar F., Awadalla M., Mesbah M., & AlBadi T. Automated machine learning based elderly fall detection classification. *Procedia Computer Science*, 2022, vol. 203 (9), pp. 16–23.

9. Gahramanova A. Locating centers of mass with image processing. *Undergraduate Journal of Mathematical Modeling: One+ Two*, 2019, vol. 10 (1), pp. 14–25.

10. Kwolek B., Kepski M. Human fall detection on embedded platform using depth maps and wireless accelerometer. *Computer Methods and Programs in Biomedicine*, 2014, vol. 17 (3), pp. 489–501.

11. Yhdego H., Paolini C., Audette M. Toward real-time, robust wearable sensor fall detection using deep learning methods: A feasibility study. *Applied Sciences*, 2023, vol. 13 (8). 4988 p.

12. Eraso J. C., Munoz E., Munoz, M., Pinto J. Dataset CAUCAFall. *Mendeley Data*, 2022, vol. 4. 489 p.

13. Overview on extracted features. Available at: https://tsfresh.readthedocs.io/en/latest/text/list_of_features.html (accessed 05.09.2025).

14. Assanovich B., Kosarava K. Vision-Based Fall Detector for Elderly Based on Sliding Window Approach and Feature Engineering. *Journal of Data Science and Intelligent Systems*, 2025, vol. 3 (1), pp. 27–34.

15. Feurer M., Eggenberger K., Falkner S., Lindauer M., Hutter F. Auto-sklearn 2.0: Hands-free AutoML via meta learning. *Journal of Machine Learning Research*, 2022, vol. 23 (261), pp. 1–61.

16. Nishiyama D., Arita S., Fukui D., Yamanaka M., & Yamada H. Accurate fall risk classification in elderly using one gaitcycle data and machine learning. *Clinical Biomechanics*, 2024, vol. 115. 62 p.

17. Bewley A., Ge Z., Ott L., Ramos F., and Uppcroft B. Simple online and realtime tracking. *IEEE International Conference on Image Processing (ICIP)*, Phoenix, Sep. 25–28 2016. Phoenix, Arizona, USA, 2016, pp. 3464–3468.

18. Wojke N., Bewley A., Paulus D. Simple online and realtime tracking with a deep association metric. *IEEE International Conference on Image Processing (ICIP)*. Beijing, China, 2017, pp. 3645–3649.

Информация об авторах

Ассанович Борис Алиевич – кандидат технических наук, доцент кафедры информационных систем и технологий. Гродненский государственный университет имени Янки Купалы (ул. Поповича, 50, 230024, г. Гродно, Республика Беларусь). E-mail: bas@grsu.by. SPIN-код: 1837-9308. Scopus ID: 23003590900. ORCID: 0000-0003-0418-9595. ResearcherID: U-4926-2018.

Косарева Екатерина Владимировна – кандидат физико-математических наук, доцент Института информатики факультета математики и естественных наук. Университет кардинала Стефана Вышинского, Варшава (ул. Девайтис, 5 01-815, Варшава). E-mail: k.kosarava@uksw.edu.pl. SPIN-код: 8822-9228. Scopus ID: 57226374685. ORCID: 0000-0001-7326-5307. ResearcherID: LZG-4251-2025.

Бич Наталья Николаевна – кандидат физико-математических наук, доцент кафедры медицинской и биологической физики. Гродненский государственный медицинский университет (ул. М. Горького, 80, 230009, г. Гродно, Республика Беларусь). E-mail: nadaliya@mail.ru. SPIN-код: 5435-9008.

Information about the authors

Boris Assanovich – PhD (Engineering), Assistant Professor, the Department of Information Systems and Technologies. Yanka Kupala State University of Grodno (50 Popovicha str., 230024, Grodno, Republic of Belarus). E-mail: bas@grsu.by. SPIN code: 1837-9308. Scopus ID: 23003590900. ORCID: 0000-0003-0418-9595. ResearcherID: U-4926-2018.

Ekaterina Kosareva – PhD (Physics and Mathematics), Assistant Professor. Institute of Computer Science at the Faculty of Mathematics and Natural Sciences. University of Cardinal Stefan Wyszyński of Warsaw (Devaitis str., 5 01-815, Warsaw). E-mail: k.kosarava@uksw.edu.pl. SPIN code: 8822-9228. Scopus ID: 57226374685. ORCID: 0000-0001-7326-5307. ResearcherID: LZG-4251-2025.

Natalia Bich – Ph.D (Physics and Mathematics), Assistant Professor, the Department of Medical and Biological Physics. Grodno State Medical University (80 M. Gorky str., 230009, Grodno, Republic of Belarus). E-mail: nadaliya@mail.ru. SPIN code: 5435-9008.

Поступила после доработки 15.12.2025