

УДК 004.8

DOI: 10.18413/2518-1092-2026-11-2-0-7

**Басов О.О.¹
Колесникова А.И.²****ПОДХОДЫ К ВЫЯВЛЕНИЮ АНОМАЛЬНОГО ПОВЕДЕНИЯ
ЛЮДЕЙ НА ОСНОВЕ ИЗОБРАЖЕНИЙ
С КАМЕР ВИДЕОНАБЛЮДЕНИЯ**

¹) Общество с ограниченной ответственностью «СПИЧАП»,
ул Седова, 11к.2, литера А, помещ. 7Н-35, часть помещ. 1, г. Санкт-Петербург, 192019, Россия

²) Акционерное общество «АСТ», пер. Капранова, 3, стр. 2, г. Москва, 123242, Россия

e-mail: nastya.wheel@gmail.com

Аннотация

В статье представлен обзор подходов к автоматическому выявлению аномального поведения человека по видеозаписям с камер наблюдения. Актуальность работы обусловлена многообразием несистематизированных подходов к решению задачи детекции аномального поведения, а также наличием нерешённых проблем, сохраняющихся в данной области. Рассматриваются методы, ориентированные на детекцию отклоняющегося поведения людей. Проведена систематизация существующих исследований, выделены основные направления развития области и актуальные проблемы, а также проанализированы преимущества и ограничения рассматриваемых подходов. Отдельное внимание уделено наборам данных, применяемым для решения задачи детекции аномалий поведения человека: обозревается их направленность, количество данных, разметка. В результате исследования установлено, что в области автоматического определения аномалий преобладает тенденция к использованию semi-supervised обучения, тогда как supervised обучение остаётся актуальным для узких областей, где возможно чётко определить случаи аномального поведения.

Ключевые слова: видеонаблюдение; детекция аномального поведения; компьютерное зрение; semi-supervised обучение; наборы данных; систематизация подходов

Для цитирования: Басов О.О., Колесникова А.И. Подходы к выявлению аномального поведения людей на основе изображений с камер видеонаблюдения // Научный результат. Информационные технологии. – Т.11, №2, 2026. – С. 77-90. DOI: 10.18413/2518-1092-2026-11-2-0-7

**Basov O.O.¹
Kolesnikova A.I.²****APPROACHES TO DETECTING ANOMALOUS HUMAN
BEHAVIOR BASED ON IMAGES FROM CCTV CAMERAS**

¹) Limited Liability Company «SPEECHUP»,
11 Sedova St., Building 2, Litera A, Premises 7N-35, Part of Premises 1, Saint Petersburg, 192019, Russia

²) Joint Stock Company «AST»,
3 Kapranova trans., Building 2, Moscow, 123242, Russia

e-mail: nastya.wheel@gmail.com

Abstract

This paper presents a review of approaches to the automatic detection of anomalous human behavior from surveillance video recordings. The relevance of the study is обусловлена the diversity of existing yet insufficiently systematized approaches to anomaly detection, as well as the presence of unresolved problems that remain in this field. The review focuses on methods aimed at detecting deviant human behavior. Existing studies are systematized, the main directions of the field's development and its current challenges are identified, and the advantages and limitations of the considered approaches are analyzed. Special attention is given to the datasets used for human behavior anomaly detection, including their application focus, data volume, and annotation characteristics. The study shows that semi-supervised learning currently dominates in the VAD

field, whereas supervised learning remains relevant for narrow domains in which anomalous behavior can be clearly defined.

Keywords: video surveillance; anomaly detection; computer vision; semi-supervised learning; datasets; systematization of approaches

For citation: Basov O.O., Kolesnikova A.I. Approaches to Detecting Anomalous Human Behavior Based on Images from CCTV Cameras // Research result. Information technologies. – Т.11, №2, 2026. – P. 77-90. DOI: 10.18413/2518-1092-2026-11-2-0-7

ВЕДЕНИЕ

Крайне важным для обеспечения общественной безопасности, в частности, для своевременного реагирования и возможного предотвращения противоправного поведения или несчастных случаев, является определение подозрительной активности в видеопотоках систем видеонаблюдения. Однако повсеместное внедрение и совершенствование таких систем делает невозможным ручной мониторинг наблюдаемых событий и сцен. Автоматизировать процесс контроля за видеопотоками позволяют технологии компьютерного зрения.

Подозрительная активность – достаточно широкое понятие, которое позволяет рассматривать автоматическое определение аномалий (video anomaly detection, VAD) в следующих основных направлениях: 1) аномалии поведения людей, 2) аномалии дорожного движения, 3) аномалии окружающей среды и 4) аномалии инфраструктуры. Настоящее исследование ставит целью рассмотрение методов, позволяющих детектировать подозрительную активность человека, и не обзвевает оставшиеся три направления.

Аномалия – это событие, значительно отклоняющееся от нормального поведения человека. Это отклонение может быть разным в зависимости от контекста и требует рассмотрения разных видов аномального поведения. Для удобства анализа на основе множества классификаций была составлена наиболее полная для VAD классификация видов поведения (Рис.1). Она не раскрывает внутренние виды отклоняющегося поведения, к которым (в зависимости от классификаций) относятся психопатологические типы и ряд аддиктивных типов, которые не могут быть определены визуально.

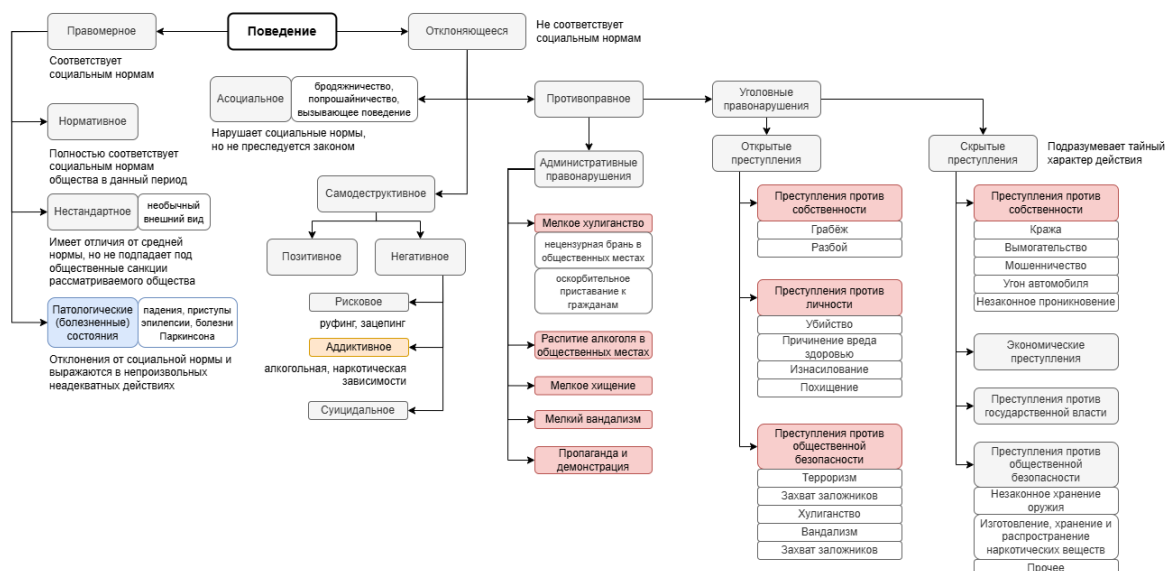


Рис. 1. Классификация отклоняющегося поведения
Fig. 1. Classification of deviant behavior

В психолого-педагогической литературе отклоняющееся поведение человека принято называть девиантным [2]. Оно трактуется как система поступков или отдельные поступки человека, в зависимости от его возраста, носящие характер отклонения от принятых в обществе норм. Это

определение включает в себя класс нестандартного поведения, которое является правомерным и не рассматривается в области VAD. С точки зрения социологического подхода девиантное поведение является поведение, которое отклоняется от институционализованных ожиданий. Это определение можно расширить до поступков, действий человека или группы лиц, не соответствующих официально установленным (правовым) или фактически сложившимся (обычай, традиции, мораль) в данном обществе нормам и ожиданиям [3]. Такой подход позволяет относить к девиантному поведению и положительное и одобряемое обществом отклоняющееся поведение, такое как героизм, трудоголизм, альтруизм и прочее. Аномальное поведение также может определяться социологами как различные формы негативного поведения лиц, сфера нравственных пороков, отступление от принципов, норм морали и права. Вместе с тем правовой подход окончательно сужает этот круг типов до противоправного поведения, определяя аномальное поведение как поведение, нарушающее существующие в данном обществе общепринятые (в том числе правовые) нормы и являющееся общественно опасным или социально вредным [1].

Анализ толкований позволяет выделить цветом на схеме (Рис.1) актуальные для области VAD виды аномального поведения. Они включают в себя аддиктивное поведение (пребывание в сильном алкогольном и наркотическом опьянении), административные правонарушения, которые могут быть зафиксированы камерами видеонаблюдения, открытые уголовные преступления и ряд скрытых уголовных преступлений, к которым относятся кражи. Помимо названных проявлений отклоняющегося поведения, цветом на схеме обозначена детекция патологических, или болезненных, состояний, которые включают в себя падения, эпилептические приступы и прочие внешние проявления потери человеком контроля над своим состоянием. Такой тип поведения некорректно относить к отклоняющемуся по причине отсутствия принятия решения со стороны человека о его начале; патологическое состояние начинается непроизвольно. Детекция патологических состояний полезно в медицинской сфере и также изучается областью автоматического определения аномального поведения.

Широкий спектр детектируемых видов поведения сопряжён с внушительным рядом проблем. Рассмотрим их подробнее.

А. Открытый характер аномалий

П1. Зависимость от контекста. Аномальность поведения сильно зависит от контекста, что требует определения понимания перечня аномальных и нормальных действий на момент постановки задачи. Даже если задача чётко сформулирована и перечень аномальных действий известен, невозможно показать модели все возможные аномалии на этапе обучения, поскольку аномалией является любое отклонение от нормы, включая события, которых никогда не было раньше.

П2. Изменение нормы. Обученная модель не сможет адаптироваться к сдвигу нормы, который возможен как с корректировкой постановки задачи (введение новых правил в области эксплуатации или их аннулирование), так и с косвенным изменением паттернов поведения людей. Это требует дообучения модели.

Б. Проблемы данных

П3. Данные для обучения. Аномалии по определению являются редким событием, поэтому неизбежно возникают трудности со сбором достаточного для обучения негативных примеров. Дополнительной проблемой является сложность разметки таких данных ввиду своей трудозатратности и неоднозначности определения аномалии.

В. Использование пространственно-временных характеристик

П4. Вариативность окружающей среды. Если модель работает на уровне пикселей, это делает её чувствительной к изменениям освещения и фона. Может возникать и обратный эффект, когда информация в кадре избыточна, что может мешать модели улавливать паттерны при обучении. При этом некоторые задачи нуждаются в детальной визуальной информации и не позволяют ограничиться pose-based методами.

П5. Временные паттерны. Аномалии представляют собой нерегулярные вариативные по продолжительности движения. Определение сложной подозрительной активности достигается через анализ длинной последовательности, что затрудняет реакцию на кратковременные резкие аномалии.

П6. Аномалии на уровне группы. Некоторые аномалии включают в себя взаимодействие нескольких человек или толпы, для их обнаружения требуется моделирование коллективного поведения. Последнее также приводит к проблеме установления инициатора аномалии, а не вынесения решения для всего кадра. Также существует проблема сложной динамики, окклюзий и аномалий толпы, когда действия людей по отдельности не являются аномальными.

Г. Проблемы оценки

П7. Оценка качества. Ввиду специфики данных (аномалия – редкое событие) классов для оценки качества модели ограниченное количество, как и примеров в них. Оценка может быть неточной ещё и потому, что может провалиться в детекции при появлении нового типа аномалий при высоком качестве на тестовых данных. Определение качества также затруднено отсутствием метрики, в достаточной мере учитывающей специфику VAD.

Д. Проблемы эксплуатации

П8. Устойчивость и обобщаемость. В зависимости от обучающих данных модели могут быть чувствительны как к визуальному шуму, так и к изменению положению камеры, масштабу и частоте следования видеок кадров. Последние критерии актуальны и для pose-based методов, которые не используют пиксели.

П9. Калибровка. При использовании модели необходимо выбрать чувствительность модели, пожертвовав либо точностью, либо полнотой, когда оба из критериев могут быть крайне важны при эксплуатации: FN (false negative, или ложно отрицательные) случаи обесценивают работу системы, а FP (false positive, или ложно положительные) снижают внимание к срабатываниям при ручном контроле.

П10. Катастрофическое забывание. Проблема П10 обращает внимание на важность дообучения модели со временем, что поднимает проблему компромисса между сохранением существующих знаний и и приобретением новых без взаимного ущерба, так как при дообучении на новых данных могут быть потеряны старые знания.

П11. Использование в режиме реального времени. Архитектура модели должна быть достаточно лёгкой, чтобы обрабатывать необходимый объём данных без задержки. Pose-based методы в свою очередь требуют дополнительного использования вспомогательных моделей для обнаружения людей, их отслеживания и поиска ключевых точек, что также создаёт трудности при эксплуатации.

Активное развитие области автоматического определения аномального поведения требует систематизации полученных результатов и созданных датасетов, анализа опробованных подходов и выделения дальнейших направлений совершенствования VAD.

Работа состоит из 4 частей. Часть 1 посвящена краткому обзору истории развития VAD для отслеживания тенденций развития области и освещения основных методов. Часть 2 представляет обзор подходов к детектированию определённых выше типов аномального поведения. В части 3 описаны актуальные датасеты и их содержание. Часть 4 подводит итоги работы и представляет дальнейшие направления исследования.

I. ИСТОРИЧЕСКАЯ СПРАВКА

Развитие методов VAD в современном виде начинается с работ начала 2010-х годов и несколько разных траекторий исследования. В работе Anomaly Detection in Crowded Scenes (2010) [27] нормальность сцены моделировалась через совместное описание внешнего вида и динамики локальных участков видео, тогда как в Sparse Reconstruction Cost for Abnormal Event Detection (2011) [13] аномалия определялась по тому, насколько хорошо наблюдение разлагается по словарю

нормальных паттернов. Параллельно с развитием методов формировались и первые наборы данных, многие из которых актуальны и на текущий момент: датасеты UCSD Ped1/Ped2 [24], CUNK Avenue [26] и позднее ShanghaiTech Campus [25] постепенно усложняли постановку задачи, переходя от обнаружения нетипичных объектов в сцене к более разнообразным и реалистичным сценариям аномального поведения.

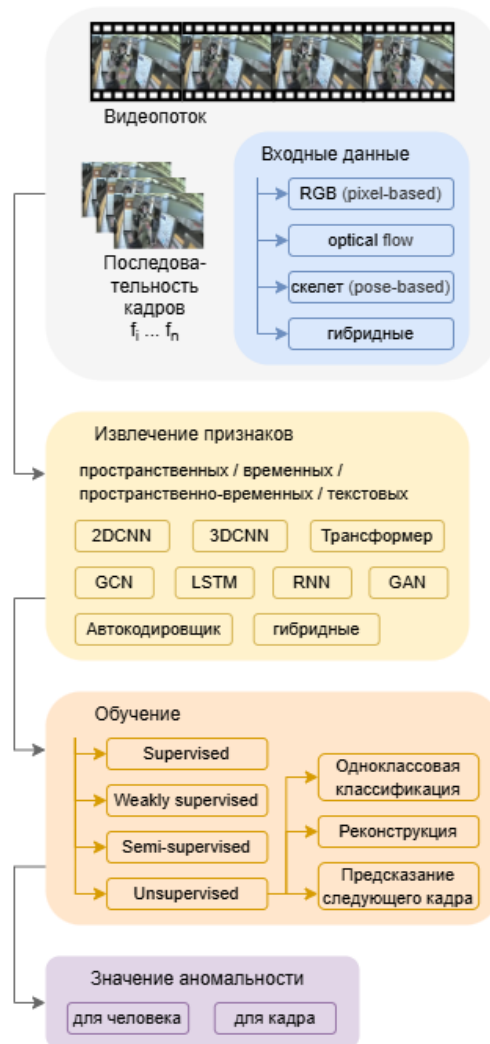


Рис. 2. Обобщённая схема методов VAD
Fig. 2. Generalized diagram of VAD methods

Следующий этап был связан с переходом к глубоким моделям и дальнейшим расширением самих подходов. В работе Learning Temporal Regularity in Video Sequences (2016) [20] был предложен автоэнкодерный reconstruction-based подход, выявляющий аномалию по ошибке реконструкции нормальной динамики, а в Future Frame Prediction for Anomaly Detection (2018) [25] эта логика была развита в prediction-based направлении, где отклонение фиксируется уже через ошибку предсказания будущего кадра. В том же 2018 году работа Real-World Anomaly Detection in Surveillance Videos [40] с датасетом UCF-Crime существенно расширила обучающую постановку, введя weakly supervised подход на основе video-level меток и multiple instance learning. В дальнейшем область стала смещаться от анализа сцены целиком к более семантически насыщенным object-centric стратегиям, в которых рассматриваются отдельные объекты, прежде всего люди, и их поведение.

К началу 2020-х годов область автоматического определения аномального поведения представляла собой совокупность различных направлений – от статистических до

реконструирующих, предсказательных, weakly supervised и объектно-ориентированных моделей. Общий пайплайн обработки видео в VAD методов отражён на Рисунке 2. Он систематизирует основные компоненты задачи – типы входных данных, используемые архитектуры и виды обучения.

II. ОБЗОР МЕТОДОВ

1. Общая направленность

Для устранения проблемы сбора и разметки данных (проблема П3) в области VAD остаётся популярным решение задачи через *semi-supervised*, или полуконтролируемое, обучение. При таком подходе в обучающей выборке присутствуют только наблюдения положительного класса, и модель изучает распределение нормального поведения. На этапе инференса наблюдения, которые плохо объясняются этим распределением, классифицируются моделью как аномалия.

В качестве примера была рассмотрена и исследована модель COSKAD [19]. Её авторы ставят целью выявление любого поведения, отклоняющегося от нормы, поэтому модель обучается на нормальных *скелетных представлениях*. Фиксированные последовательности человеческого движения кодируются в виде пространственно-временных скелетных графов [39] и проецируются в латентное пространство. В статье предложено три варианта пространства: 1) евклидово, 2) сферическое и 3) гиперболическое. Функция обучения модели выглядит следующим образом:

$$\min_{\mathcal{W}} \frac{1}{N} \sum_{i=1}^N d(\Phi(x_i, \mathcal{W}), c) + \alpha f(\mathcal{W}),$$

где x_i - i -ая последовательность движений фиксированной длины, c – центр, вокруг которого модель старается собрать нормальные образцы, $\Phi(x_i, \mathcal{W})$ - отображение этого образца в латентное пространство, полученное с помощью COSKAD, $d(\cdot, \cdot)$ – расстояние в выбранном латентном пространстве, $f(\mathcal{W})$ – регуляризатор весов. Таким образом модель учится проецировать полученные эмбединги в латентное пространство и обучается “сжимать” нормальные образцы в узкую область вокруг центра.

Для экспериментального подтверждения эффективности архитектуры модель была обучена в конфигурации евклидового латентного пространства, которая показала наилучшие результаты в оригинальной статье. Результаты подтвердили эффективность модели COSKAD на реальных данных, их выборочная демонстрация приведена на Рисунке 3.



Рис. 3. Инференс COSKAD на реальных данных: а) драка, б) драка, в) танец
Fig. 3. COSKAD inference on real data: a) fight, b) fight, c) dance

Несмотря на свою эффективность, COSKAD и другие схожие модели [28] сталкиваются с рядом ограничений. Так, модель классифицирует ряд нормальных для общества действий как аномальное событие (см. Рисунок 3, в). Это отсылает к проблеме контекстности аномальности поведения (проблема П1), которую *semi-supervised* модели не могут решить в полной мере ввиду

отсутствия возможности показать при обучении аномальные примеры. Полуконтролируемый подход обучения не позволяет включить положительно-ложные срабатывания в обучающую выборку, если их недостаточно или если они похожи на требуемые к детекции типы девиантного поведения. Отдельным ограничением является фиксированная при обучении длина последовательности (проблема П5).

Благодаря графовой нейронной сети внутри сама COSKAD работает с достаточной производительностью, но, как и все *skeleton-based* подходы, требует использования детектора, трекера и модели поиска ключевых точек (проблема П11). Это делает её напрямую зависимой от качества работы предшествующих моделей и замедляет скорость обработки видеопотока.

Эти методы могут детектировать отдельные типы поведения, представленные на Рисунке 1. Так, в наборе данных UBnormal [4], который среди прочих использовали авторы COSKAD, представлены примеры патологических состояний. Однако ввиду своей направленности общие методы не всегда показывают свою эффективность на специфических аномалиях и не всегда могут быть использованы из-за невозможности сильно урезать круг аномальных событий.

2. Отклоняющееся поведение

В рассматриваемом классе задач распространёнными остаются *пиксельные* методы, так как позволяют учитывать мелкие детали сцены и внешний вид объектов. Так, методы [22; 30] предлагают использовать *pixel-based* подход для определения кражи. На их фоне выделяются работы [29] и [12], которые предлагают детектировать не сам момент кражи, а подозрительное поведение человека. Используя *supervised* обучение, такие подходы неизбежно сталкиваются с проблемами ограниченности данных для обучения, проблемой дисбаланса классов и чувствительностью к шуму (проблемы П3-П4, П8). В противовес им для детекции краж предлагаются и знакомые нам *posed-based*, или *skeleton-based*, методы [36] и [38]. Имея преимущество с точки зрения анонимизированности используемых данных, эти методы сталкиваются с проблемой зависимости от качества работы предшествующих моделей (проблема П11).

Предлагаются решения и для других категорий противоправного поведения. Так, для обнаружения **вооружённого ограбления** предлагаются методы, завязанные на детекции оружия. Если [7] предлагает обособленную детекцию, то [38] учитывает ключевые точки человека, а [18] после определения оружия обрабатывает изображение с помощью свёрточной нейронной сети, что повышает надёжность и применимость методов. Существуют методы определения **вандализма** [33], **физического насилия** с использованием информации кадра [14] и поз [31], **сексуальных домогательств** [21] и **применения насилия к женщинам** [6].

3. Патологические состояния

Область VAD предлагает решения для определения болезненных состояний, когда человеку необходима сторонняя помощь. Ранние подходы в выявлении **падений** человека использовали *пиксельные методы* [43], но с развитием методов перешли к использованию *скелетных представлений* [34] и *смешанных подходов* [9]. Вместе с попыткой уменьшить вычислительную нагрузку в исследовании [32] также пробуют работать напрямую с RGB-кадром более совершенными методами. Помимо определения падений существуют решения для определения эпилептических припадков [10; 44; 35], болезни Паркинсона [41; 23].

В отличие от сферы общественной безопасности, где преобладают варианты *semi-supervised* обучения, для сферы детекции болезненных состояний значительно чаще используется *supervised* подход. Это ставит решение в большую зависимость от узкоспециализированных датасетов (проблема П3). Тем не менее, в подобных задачах круг аномалий и нормы практически не меняется (проблемы П1 и П2 отсутствуют), и архитектура, жертвуя своей универсальностью, позволяют гарантировать большую надёжность детекции.

III. ОБЗОР ДАТАСЕТОВ

Все рассмотренные ранее методы VAD в значительной степени опираются на общедоступные датасеты, которые используются для обучения, тестирования и оценки предлагаемых моделей. Для удобства их использования помимо текстового описания оформлена сводная таблица (Табл. 1) с характеристиками датасетов, годом публикации, указанием заявленной разметки.

A. UCSD Ped1 u Ped2. Набор данных собран стационарной камерой на территории кампуса. Нормальный паттерн в нём задаётся движением только пешеходов, тогда как аномалии связаны либо с появлением непешеходных объектов, либо с нетипичными траекториями движения людей. Датасет разделён на две сцены: Ped1 содержит клипы размером 158x238 пикселей, в этих сценах люди движутся в направлении к камере и от камеры, Ped2 имеет более высокое разрешение 240x360 пикселей, где большинство пешеходов движется параллельно камере.

B. CUHK Avenue представляет собой датасет из 15 видеопоследовательностей с человеческой активностью. Он ориентирован на выявление нетипичного поведения в обычной уличной среде, где аномалии представлены такими событиями, как бег, бесцельное пребывание в зоне наблюдения и бросание предметов.

B. ShanghaiTech Campus охватывает 13 различных сцен. В отличие от более ранних небольших наборов данных, он ориентирован на более сложные сценарии, поскольку включает большое число обучающих и тестовых видеопоследовательностей, а также несколько типов аномальных событий.

Г. UCF-Crime u HR-Crime. В отличие от ранних VAD-датасетов, он построен на реальных, а не постановочных сценах и охватывает широкий спектр опасных и криминальных инцидентов в разнообразных условиях наблюдения. Набор данных включает 13 типов аномалий: Abuse, Arrest, Arson, Assault, Accident, Burglary, Explosion, Fighting, Robbery, Shooting, Stealing, Shoplifting и Vandalism. HR-Crime – это подмножество UCF-Crime, специально отфильтрованное так, чтобы в аномалии ключевую роль играло поведение человека; из него исключались события, не связанные с человеком, сцены без чёткого обзора людей, большие толпы и слишком длинные видео.

Д. UBI-Fights u XD-Violence. Оба набора данных позволяют решать задачу детектирования насилия. UBI-Fights – узкий датасет, направленный на автоматическое определение драк. XD-Violence заметно шире: он ориентирован на детекцию насилия в общем смысле и включает шесть типов событий – Abuse, Car Accident, Explosion, Fighting, Riot и Shooting.

Е. VFP290K – специализированный датасет для визуального обнаружения лежащего или упавшего человека. В отличие от общих VAD-датасетов, здесь целевое событие заранее фиксировано: модель должна различать упавшего и неупавшего человека на уровне детекции объектов.

Ж. UBnormal представляет собой 29 виртуальных сцен, сгенерированных на основе реальных фоновых изображений и анимированных 3D-персонажей и объектов. В отличие от классических VAD-датасетов, он включает аномальные события в обучающую выборку, но при этом сохраняет отдельные наборы типов аномалий в обучении и тесте.

З. CamNuvem. Этот набор данных предназначен для выявления ограблений. Он включает 972 видео, из которых 486 содержат сцены ограблений, собранные из открытых источников, а ещё 486 нормальных видео заимствованы из UCF-Crime для формирования сбалансированного набора. Датасет отражает вариативность реальных условий наблюдения – различия в точках обзора, композиции сцены и признаках ограбления.

И. NWPU Campus включает 28 классов аномальных событий в 43 сценах с участием пешеходов и транспорта. В отличие от более ранних наборов данных, он охватывает широкий спектр нормальных и аномальных событий, включая контекстные аномалии, где интерпретация события зависит от условий.

К. CHAD. Это набор данных ограничен одной сценой, запись которой ведётся с четырёх разных камер видеонаблюдения. CHAD включает в себя 22 класса аномального поведения, в том числе драки, воровство, обмороки/падения, погоню, выбрасывание мусора, бег. В отличие от

многих ранних VAD-датасетов, он ориентирован на анализ поведения человека и помимо покадровых меток содержит подробные аннотации людей – ограничивающие рамки, идентификаторы и ключевые точки позы.

Л. PoseLift. Это специализированный датасет для детекции магазинных краж, состоящий из 43 видео с кражами и 112 – с обычным шопингом. Его особенность заключается в нераспространении исходных пиксельных видео, из-за чего набор данных предоставляет из себя последовательности поз, ограничивающие рамки и идентификаторы людей, собранным по реальным записям розничного магазина.

IV. ВЫВОДЫ

Представленная работа систематизирует используемые в области автоматического детектирования аномального поведения человека подходы и данные. Комплексный обзор позволяет говорить о преобладании semi-supervised методов в области общественной безопасности и supervised обучения в сфере специфических аномалий, свойственных, например, медицине. Эта тенденция отражается и в адаптированности многих наборов данных под semi-supervised обучение путём формирования обучающей выборки из нормальных наблюдений.

Дальнейшие исследования предполагается направить на применение исследованных методов для решения конкретных практических задач выявления аномального поведения людей, в частности, автоматической детекции административных правонарушений на изображениях с камер городского видеонаблюдения.

Таблица

Сводная таблица датасетов VAD

Table

Summary table of VAD datasets

Название	Направленность	Год	Длительность	Разметка	Источник
UCSD Ped1	Общая	2010	5 минут	покадровые бинарные метки; пиксельные маски для части тестовых данных	[24]
UCSD Ped2	Общая		5 минут		
CUNY Avenue	Общая	2013	30 минут	покадровые бинарные метки и bounding box	[26]
ShanghaiTech Campus	Общая	2018	3,5 часа	покадровые бинарные метки; пиксельные маски для тестовых данных	[25]
UCF-Crime	Общая	2018	128 часов	бинарные метки на уровне видео для обучающих данных; временные аннотации тестовых данных	[40]
HR-Crime	Общая	2021			[8]
UBI-Fights	Драки	2020	80 часов	покадровые бинарные метки	[17]
XD-Violence	Насилие	2020	217 часов	бинарные метки и класс на уровне видео; временные аннотации для тестовых данных	[42]
VFP290K	Падение людей	2021	294713 кадров	bounding box, бинарные метки для них	[5]
UBnormal	Общая	2022	132 минуты	пиксельные маски (для всех данных)	[4]
CamNuvem	Ограбления	2022	57 часов	бинарные метки на уровне видео; покадровые метки для тестовых данных	[16]

NWPU Campus	Общая	2023	16 часов	бинарные метки на уровне видео; временные аннотации для тестовых данных	[11]
CHAD	Общая	2023	10,5 часов	покадровые метки, bounding box, ключевые точки позы	[15]
PoseLift	Кражи	2025	63 минуты	покадровые метки, bounding box, ключевые точки позы	[37]

Список литературы

1. Девиантное поведение // Энциклопедия права, 2015 г. URL: https://encyclopediya_prava.academic.ru/1486/%D0%94%D0%B5%D0%B2%D0%B8%D0%B0%D0%BD%D1%82%D0%BD%D0%BE%D0%B5_%D0%BF%D0%BE%D0%B2%D0%B5%D0%B4%D0%B5%D0%BD%D0%B8%D0%B5 (дата обращения: 29.03.2026).
2. Мардахаев Л.В. Социальная педагогика: учебник. М.: Гардарики, 2005. 269 с.
3. Отклоняющееся поведение // Большая российская энциклопедия, 2022 г. URL: <https://bigenc.ru/c/otkloniaiushcheesia-povedenie-b3ad70> (дата обращения: 29.03.2026).
4. UBnormal: New Benchmark for Supervised Open-Set Video Anomaly Detection / Acsintoae A., Florescu A., Georgescu M.-I., Mare T., Sumedrea P., Ionescu R. T., Khan F. S., Shah M. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 20143–20153.
5. VFP290K: A Large-Scale Benchmark Dataset for Vision-based Fallen Person Detection / An J., Kim J., Lee H., Kim J., Kang J., Shin S., Kim M., Hong D., Woo S.S. // NeurIPS 2021 Datasets and Benchmarks Track. 2021.
6. SUSAN: A Deep Learning-Based Architecture for Violence Detection Against Women in Surveillance Videos / Andrade J.P.F., Si T., Cavalcanti A.P., Nascimento A.C.A., Miranda P.B.C. // Expert Systems with Applications. 2025. Vol. 280. Art. 127337. DOI: 10.1016/j.eswa.2025.127337.
7. Weapon Detection in Real-Time CCTV Videos Using Deep Learning / Bhatti M.T., Khan M.G., Aslam M., Fiaz M.J. // IEEE Access. 2021. DOI: 10.1109/ACCESS.2021.3059170.
8. HR-Crime: Human-Related Anomaly Detection in Surveillance Videos / Boekhoudt K., Matei A., Aghaei M., Talavera E. // Computer Analysis of Images and Patterns. CAIP 2021. Lecture Notes in Computer Science. 2021. P. 164–174. DOI: 10.1007/978-3-030-89131-2_15.
9. Khraief C., Benzarti F., Amiri H. Elderly Fall Detection Based on Multi-Stream Deep Convolutional Networks // Multimedia Tools and Applications. 2020. Vol. 79. P. 19537–19560. DOI: 10.1007/s11042-020-08812-x.
10. Convolutional Neural Network-Based Fast Seizure Detection from Video Electroencephalograms / Chou C.-H., Shen T.-W., Tung H., Hsieh P.F., Kuo C.-E., Chen T.-M., Yang C.-W. // Biomedical Signal Processing and Control. 2023. Vol. 80. Art. 104380. DOI: 10.1016/j.bspc.2022.104380.
11. A New Comprehensive Benchmark for Semi-Supervised Video Anomaly Detection and Anticipation / Cao C., Lu Y., Wang P., Zhang Y. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2023. P. 20392–20401. DOI: 10.1109/CVPR52729.2023.01953.
12. Chinthulla A. Deep Learning-Based Detection of Shoplifting Behavior: Using 3DCNN and LRCN: Masters thesis. Dublin: National College of Ireland, 2025.
13. Cong Y., Yuan J., Liu J. Sparse Reconstruction Cost for Abnormal Event Detection // 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2011. P. 3449–3456. DOI: 10.1109/CVPR.2011.5995434.
14. Combining a Mobile Deep Neural Network and a Recurrent Layer for Violence Detection in Videos / Contardo P., Tomassini S., Falcionelli N., Dragoni A.F., Sernani P. // Proceedings of the RTA-CSIT 2023: 5th International Conference on Recent Trends and Applications in Computer Science and Information Technology. 2023. P. 35-43.
15. CHAD: Charlotte Anomaly Dataset / Danesh Pazho A., Alinezhad Noghre G., Rahimi Ardabili B., Neff C., Tabkhi H. // Image Analysis. SCIA 2023. Lecture Notes in Computer Science. 2023. P. 50–66. DOI: 10.1007/978-3-031-31435-3_4.
16. de Paula D.D., Salvadeo D.H.P., de Araujo D.M.N. CamNuvem: A Robbery Dataset for Video Anomaly Detection // Sensors. 2022. Vol. 22. No. 24. Art. 10016. DOI: 10.3390/s222410016.
17. Degardin B., Proença H. Iterative Weak/Self-Supervised Classification Framework for Abnormal Events Detection // Pattern Recognition Letters. 2021. Vol. 145. P. 50–57. DOI: 10.1016/j.patrec.2021.01.031.

18. Fernandez-Testa S., Salcedo E. Distributed Intelligent Video Surveillance for Early Armed Robbery Detection Based on Deep Learning // 2024 37th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). 2024. DOI: 10.1109/SIBGRAPI62404.2024.10716299.
19. Contracting Skeletal Kinematics for Human-Related Video Anomaly Detection / Flaborea A., D'Amely di Melendugno G.M., D'Arrigo S., Sterpa M.A., Sampieri A., Galasso F. // Pattern Recognition. 2024. Vol. 156. Art. 110817. DOI: 10.1016/j.patcog.2024.110817.
20. Hasan M., Choi J., Neumann J., Roy-Chowdhury A.K., Davis L.S. Learning Temporal Regularity in Video Sequences // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 733-742
21. A Deep Spatio-Temporal Network for Vision-Based Sexual Harassment Detection / Islam M.S., Hasan M.M., Abdullah S., Akbar J.U.M., Arafat N., Murad S. // Proceedings of the 2021 Emerging Technology in Computing, Communication and Electronics (ETCCE). 2021. P. 1–6.
22. Kirichenko L., Radivilova T., Sydorenko B., Yakovlev S. Detection of Shoplifting on Video Using a Hybrid Network // Computation. 2022. Vol. 10. No. 11. Art. 199. DOI: 10.3390/computation10110199.
23. Video-Based Detection of Freezing of Gait in Daily Clinical Practice in Patients With Parkinsonism / Kondo Y., Bando K., Suzuki I., Miyazaki Y., Nishida D., Hara T., Kadone H., Suzuki K. // IEEE Transactions on Neural Systems and Rehabilitation Engineering. 2024. Vol. 32. P. 2250–2260. DOI: 10.1109/TNSRE.2024.3413055.
24. Li W., Mahadevan V., Vasconcelos N. Anomaly Detection and Localization in Crowded Scenes // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2014. Vol. 36. No. 1. P. 18–32. DOI: 10.1109/TPAMI.2013.111.
25. Liu W., Luo W., Lian D., Gao S. Future Frame Prediction for Anomaly Detection – A New Baseline // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2018. P. 6536–6545. DOI: 10.1109/CVPR.2018.00684.
26. Lu C., Shi J., Jia J. Abnormal Event Detection at 150 FPS in MATLAB // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2013. P. 2720–2727. DOI: 10.1109/ICCV.2013.338.
27. Mahadevan V., Li W., Bhalodia V., Vasconcelos N. Anomaly Detection in Crowded Scenes // 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR). 2010. P. 1975–1981.
28. Graph Embedded Pose Clustering for Anomaly Detection / Markovitz A., Sharir G., Friedman I., Zelnik-Manor L., Avidan S. // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020. DOI: 10.1109/CVPR42600.2020.01055.
29. Criminal Intention Detection at Early Stages of Shoplifting Cases by Using 3D Convolutional Neural Networks / Martínez-Mascorro G.A., Abreu-Pederzini J.R., Ortiz-Bayliss J.C., Garcia-Collantes A., Terashima-Marín H. // Computation. 2021. Vol. 9. No. 2. Art. 24. DOI: 10.3390/computation9020024.
30. Shoplifting Detection Using Hybrid Neural Network CNN-BiLSMT and Development of Benchmark Dataset / Muneer I., Saddique M., Habib Z., Mohamed H.G. // Applied Sciences. 2023. Vol. 13. No. 14. Art. 8341. DOI: 10.3390/app13148341.
31. Detecting School Violence Using Artificial Intelligence to Interpret Surveillance Video Sequences / Narynov S., Zhumanov Z., Gumar A., Khassanova M., Omarov B. // Advances in Computational Collective Intelligence. ICCCI 2021. 2021. P. 401–412. DOI: 10.1007/978-3-030-88113-9_32.
32. Núñez-Marcos A., Arganda-Carreras I. Transformer-Based Fall Detection in Videos // Engineering Applications of Artificial Intelligence. 2024. Vol. 132. Art. 107937. DOI: 10.1016/j.engappai.2024.107937.
33. Nyajowi T., Oyie N.O., Ahuna M. CNN Real-Time Detection of Vandalism Using a Hybrid-LSTM Deep Learning Neural Networks // 2021 IEEE AFRICON. 2021. P. 1–6. DOI: 10.1109/AFRICON51333.2021.9570902.
34. Keskes O., Noumeir R. Vision-Based Fall Detection Using ST-GCN // IEEE Access. 2021. Vol. 9. P. 28224–28236. DOI: 10.1109/ACCESS.2021.3058219.
35. Automated Analysis and Detection of Epileptic Seizures in Video Recordings Using Artificial Intelligence / Rai P., Knight A., Hiillos M., Kertész C., Morales E., Terney D., Larsen S. A., Østerkjerhuus T., Peltola J., Beniczky S. // Frontiers in Neuroinformatics. 2024. Vol. 18. Art. 1324981. DOI: 10.3389/fninf.2024.1324981.
36. Shopformer: Transformer-Based Framework for Detecting Shoplifting via Human Pose / Rashvand N., Alinezhad Noghre G., Danesh Pazho A., Rahimi Ardabili B., Tabkhi H. // 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). 2025. P. 5752–5761. DOI: 10.1109/CVPRW67362.2025.00574.
37. Exploring Pose-Based Anomaly Detection for Retail Security: A Real-World Shoplifting Dataset and Benchmark / Rashvand N., Alinezhad Noghre G., Danesh Pazho A., Yao S., Tabkhi H. // Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW). 2025.

38. Salido J., Lomas V., Ruiz-Santaquiteria J., Deniz O. Automatic Handgun Detection with Deep Learning in Video Surveillance Images // Applied Sciences. 2021. Vol. 11. No. 13. Art. 6085. DOI: 10.3390/app11136085.
39. Sofianos T., Sampieri A., Franco L., Galasso F. Space-Time-Separable Graph Convolutional Network for Pose Forecasting // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). 2021. P. 11189–11198. DOI: 10.1109/ICCV48922.2021.01102.
40. Sultani W., Chen C., Shah M. Real-World Anomaly Detection in Surveillance Videos // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2018. P. 6479- 6488.
41. Connie T., Aderinola T. B., Ong T. S., Goh M. K. O., Erfianto B., Purnama B. Pose-Based Gait Analysis for Diagnosis of Parkinson’s Disease // Algorithms. 2022. Vol. 15. No. 12. Art. 474. DOI: 10.3390/a15120474.
42. Not Only Look, but Also Listen: Learning Multimodal Violence Detection under Weak Supervision / Wu P., Liu J., Shi Y., Sun Y., Shao F., Wu Z., Yang Z. // Computer Vision – ECCV 2020. 2020. DOI: 10.1007/978-3-030-58577-8_20.
43. Cai X., Li S., Liu X., Han G. Vision-Based Fall Detection With Multi-Task Hourglass Convolutional Auto-Encoder // IEEE Access. 2020. Vol. 8. P. 44493–44502. DOI: 10.1109/ACCESS.2020.2978249.
44. Towards Surveillance Video-and-Language Understanding: New Dataset, Baselines, and Challenges / Yuan T., Zhang X., Liu K., Liu B., Chen C., Jin J., Jiao Z. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2024. P. 22052-22061. DOI: 10.1109/CVPR52733.2024.02082.

References

1. Deviant Behavior. Entsiklopediya prava, 2015. URL: https://encyclopediya_prava.academic.ru/1486/%D0%94%D0%B5%D0%B2%D0%B8%D0%B0%D0%BD%D1%82%D0%BD%D0%BE%D0%B5_%D0%BF%D0%BE%D0%B2%D0%B5%D0%B4%D0%B5%D0%BD%D0%B8%D0%B5 (accessed: 29.03.2026).
2. Mardakhaev L.V. Social Pedagogy. Moscow: Gardariki, 2005. 269 p.
3. Deviant Behavior. Bol’shaya rossiyskaya entsiklopediya, 2022. URL: <https://bigenc.ru/c/otkloniaiushcheesia-povedenie-b3ad70> (accessed: 29.03.2026).
4. UBnormal: New Benchmark for Supervised Open-Set Video Anomaly Detection / Acintoae A., Florescu A., Georgescu M.-I., Mare T., Sumedrea P., Ionescu R. T., Khan F. S., Shah M. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2022. P. 20143–20153.
5. VFP290K: A Large-Scale Benchmark Dataset for Vision-based Fallen Person Detection / An J., Kim J., Lee H., Kim J., Kang J., Shin S., Kim M., Hong D., Woo S.S. // NeurIPS 2021 Datasets and Benchmarks Track. 2021.
6. SUSAN: A Deep Learning-Based Architecture for Violence Detection Against Women in Surveillance Videos / Andrade J.P.F., Si T., Cavalcanti A.P., Nascimento A.C.A., Miranda P.B.C. // Expert Systems with Applications. 2025. Vol. 280. Art. 127337. DOI: 10.1016/j.eswa.2025.127337.
7. Weapon Detection in Real-Time CCTV Videos Using Deep Learning / Bhatti M.T., Khan M.G., Aslam M., Fiaz M.J. // IEEE Access. 2021. DOI: 10.1109/ACCESS.2021.3059170.
8. HR-Crime: Human-Related Anomaly Detection in Surveillance Videos / Boekhoudt K., Matei A., Aghaei M., Talavera E. // Computer Analysis of Images and Patterns. CAIP 2021. Lecture Notes in Computer Science. 2021. P. 164–174. DOI: 10.1007/978-3-030-89131-2_15.
9. Khraief C., Benzarti F., Amiri H. Elderly Fall Detection Based on Multi-Stream Deep Convolutional Networks // Multimedia Tools and Applications. 2020. Vol. 79. P. 19537–19560. DOI: 10.1007/s11042-020-08812-x.
10. Convolutional Neural Network-Based Fast Seizure Detection from Video Electroencephalograms / Chou C.-H., Shen T.-W., Tung H., Hsieh P.F., Kuo C.-E., Chen T.-M., Yang C.-W. // Biomedical Signal Processing and Control. 2023. Vol. 80. Art. 104380. DOI: 10.1016/j.bspc.2022.104380.
11. A New Comprehensive Benchmark for Semi-Supervised Video Anomaly Detection and Anticipation / Cao C., Lu Y., Wang P., Zhang Y. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2023. P. 20392- 20401. DOI: 10.1109/CVPR52729.2023.01953.
12. Chinthulla A. Deep Learning-Based Detection of Shoplifting Behavior: Using 3DCNN and LRCN: Masters thesis. Dublin: National College of Ireland, 2025.
13. Cong Y., Yuan J., Liu J. Sparse Reconstruction Cost for Abnormal Event Detection // 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2011. P. 3449–3456. DOI: 10.1109/CVPR.2011.5995434.
14. Combining a Mobile Deep Neural Network and a Recurrent Layer for Violence Detection in Videos / Contardo P., Tomassini S., Falcionelli N., Dragoni A.F., Sernani P. // Proceedings of the RTA-CSIT 2023: 5th

International Conference on Recent Trends and Applications in Computer Science and Information Technology. 2023. P. 35-43.

15. CHAD: Charlotte Anomaly Dataset / Danesh Pazho A., Alinezhad Noghre G., Rahimi Ardabili B., Neff C., Tabkhi H. // Image Analysis. SCIA 2023. Lecture Notes in Computer Science. 2023. P. 50–66. DOI: 10.1007/978-3-031-31435-3_4.

16. de Paula D.D., Salvadeo D.H.P., de Araujo D.M.N. CamNuvem: A Robbery Dataset for Video Anomaly Detection // Sensors. 2022. Vol. 22. No. 24. Art. 10016. DOI: 10.3390/s222410016.

17. Degardin B., Proença H. Iterative Weak/Self-Supervised Classification Framework for Abnormal Events Detection // Pattern Recognition Letters. 2021. Vol. 145. P. 50–57. DOI: 10.1016/j.patrec.2021.01.031.

18. Fernandez-Testa S., Salcedo E. Distributed Intelligent Video Surveillance for Early Armed Robbery Detection Based on Deep Learning // 2024 37th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). 2024. DOI: 10.1109/SIBGRAPI62404.2024.10716299.

19. Contracting Skeletal Kinematics for Human-Related Video Anomaly Detection / Flaborea A., D'Amely di Melendugno G.M., D'Arrigo S., Sterpa M.A., Sampieri A., Galasso F. // Pattern Recognition. 2024. Vol. 156. Art. 110817. DOI: 10.1016/j.patcog.2024.110817.

20. Hasan M., Choi J., Neumann J., Roy-Chowdhury A.K., Davis L.S. Learning Temporal Regularity in Video Sequences // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. P. 733-742

21. A Deep Spatio-Temporal Network for Vision-Based Sexual Harassment Detection / Islam M.S., Hasan M.M., Abdullah S., Akbar J.U.M., Arafat N., Murad S. // Proceedings of the 2021 Emerging Technology in Computing, Communication and Electronics (ETCCE). 2021. P. 1–6.

22. Kirichenko L., Radivilova T., Sydorenko B., Yakovlev S. Detection of Shoplifting on Video Using a Hybrid Network // Computation. 2022. Vol. 10. No. 11. Art. 199. DOI: 10.3390/computation10110199.

23. Video-Based Detection of Freezing of Gait in Daily Clinical Practice in Patients With Parkinsonism / Kondo Y., Bando K., Suzuki I., Miyazaki Y., Nishida D., Hara T., Kadone H., Suzuki K. // IEEE Transactions on Neural Systems and Rehabilitation Engineering. 2024. Vol. 32. P. 2250–2260. DOI: 10.1109/TNSRE.2024.3413055.

24. Li W., Mahadevan V., Vasconcelos N. Anomaly Detection and Localization in Crowded Scenes // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2014. Vol. 36. No. 1. P. 18–32. DOI: 10.1109/TPAMI.2013.111.

25. Liu W., Luo W., Lian D., Gao S. Future Frame Prediction for Anomaly Detection – A New Baseline // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2018. P. 6536–6545. DOI: 10.1109/CVPR.2018.00684.

26. Lu C., Shi J., Jia J. Abnormal Event Detection at 150 FPS in MATLAB // Proceedings of the IEEE International Conference on Computer Vision (ICCV). 2013. P. 2720–2727. DOI: 10.1109/ICCV.2013.338.

27. Mahadevan V., Li W., Bhalodia V., Vasconcelos N. Anomaly Detection in Crowded Scenes // 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR). 2010. P. 1975–1981.

28. Graph Embedded Pose Clustering for Anomaly Detection / Markovitz A., Sharir G., Friedman I., Zelnik-Manor L., Avidan S. // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020. DOI: 10.1109/CVPR42600.2020.01055.

29. Criminal Intention Detection at Early Stages of Shoplifting Cases by Using 3D Convolutional Neural Networks / Martínez-Mascorro G.A., Abreu-Pederzini J.R., Ortiz-Bayliss J.C., Garcia-Collantes A., Terashima-Marín H. // Computation. 2021. Vol. 9. No. 2. Art. 24. DOI: 10.3390/computation9020024.

30. Shoplifting Detection Using Hybrid Neural Network CNN-BiLSMT and Development of Benchmark Dataset / Muneer I., Saddique M., Habib Z., Mohamed H.G. // Applied Sciences. 2023. Vol. 13. No. 14. Art. 8341. DOI: 10.3390/app13148341.

31. Detecting School Violence Using Artificial Intelligence to Interpret Surveillance Video Sequences / Narynov S., Zhumanov Z., Gumar A., Khassanova M., Omarov B. // Advances in Computational Collective Intelligence. ICCCI 2021. 2021. P. 401–412. DOI: 10.1007/978-3-030-88113-9_32.

32. Núñez-Marcos A., Arganda-Carreras I. Transformer-Based Fall Detection in Videos // Engineering Applications of Artificial Intelligence. 2024. Vol. 132. Art. 107937. DOI: 10.1016/j.engappai.2024.107937.

33. Nyajowi T., Oyie N.O., Ahuna M. CNN Real-Time Detection of Vandalism Using a Hybrid-LSTM Deep Learning Neural Networks // 2021 IEEE AFRICON. 2021. P. 1–6. DOI: 10.1109/AFRICON51333.2021.9570902.

34. Keskes O., Noumeir R. Vision-Based Fall Detection Using ST-GCN // IEEE Access. 2021. Vol. 9. P. 28224–28236. DOI: 10.1109/ACCESS.2021.3058219.

35. Automated Analysis and Detection of Epileptic Seizures in Video Recordings Using Artificial Intelligence / Rai P., Knight A., Hiillos M., Kertész C., Morales E., Terney D., Larsen S. A., Østerkjerhuus T.,

Peltola J., Beniczky S. // *Frontiers in Neuroinformatics*. 2024. Vol. 18. Art. 1324981. DOI: 10.3389/fninf.2024.1324981.

36. Shopformer: Transformer-Based Framework for Detecting Shoplifting via Human Pose / Rashvand N., Alinezhad Noghre G., Danesh Pazho A., Rahimi Ardabili B., Tabkhi H. // *2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. 2025. P. 5752–5761. DOI: 10.1109/CVPRW67362.2025.00574.

37. Exploring Pose-Based Anomaly Detection for Retail Security: A Real-World Shoplifting Dataset and Benchmark / Rashvand N., Alinezhad Noghre G., Danesh Pazho A., Yao S., Tabkhi H. // *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW)*. 2025.

38. Salido J., Lomas V., Ruiz-Santaquiteria J., Deniz O. Automatic Handgun Detection with Deep Learning in Video Surveillance Images // *Applied Sciences*. 2021. Vol. 11. No. 13. Art. 6085. DOI: 10.3390/app11136085.

39. Sofianos T., Sampieri A., Franco L., Galasso F. Space-Time-Separable Graph Convolutional Network for Pose Forecasting // *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*. 2021. P. 11189–11198. DOI: 10.1109/ICCV48922.2021.01102.

40. Sultani W., Chen C., Shah M. Real-World Anomaly Detection in Surveillance Videos // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2018. P. 6479–6488.

41. Connie T., Aderinola T. B., Ong T. S., Goh M. K. O., Erfianto B., Purnama B. Pose-Based Gait Analysis for Diagnosis of Parkinson’s Disease // *Algorithms*. 2022. Vol. 15. No. 12. Art. 474. DOI: 10.3390/a15120474.

42. Not Only Look, but Also Listen: Learning Multimodal Violence Detection under Weak Supervision / Wu P., Liu J., Shi Y., Sun Y., Shao F., Wu Z., Yang Z. // *Computer Vision – ECCV 2020*. 2020. DOI: 10.1007/978-3-030-58577-8_20.

43. Cai X., Li S., Liu X., Han G. Vision-Based Fall Detection With Multi-Task Hourglass Convolutional Auto-Encoder // *IEEE Access*. 2020. Vol. 8. P. 44493–44502. DOI: 10.1109/ACCESS.2020.2978249.

44. Towards Surveillance Video-and-Language Understanding: New Dataset, Baselines, and Challenges / Yuan T., Zhang X., Liu K., Liu B., Chen C., Jin J., Jiao Z. // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2024. P. 22052–22061. DOI: 10.1109/CVPR52733.2024.02082.

Басов Олег Олегович, доктор технических наук, доцент, исполнительный директор, Общество с ограниченной ответственностью «СПИЧАП», г. Санкт-Петербург, Россия

Колесникова Анастасия Ильинична, аналитик данных, Акционерное общество «АСТ», г. Москва, 123242, Россия

Basov Oleg Olegovich, Doctor of Technical Sciences, Associate Professor, Executive Director, Limited Liability Company «SPEECHUP», Saint Petersburg, Russia

Kolesnikova Anastasia Ilyinichna, Data Analyst, Joint Stock Company «AST», Moscow, Russia