

Федеральное государственное автономное образовательное учреждение высшего образования «Национальный исследовательский университет «Высшая школа экономики»

На правах рукописи

Рыжиков Артём

Глубокие порождающие модели для поиска аномалий

Резюме

диссертации на соискание ученой степени
кандидата компьютерных наук

Научный руководитель:
PhD
Деркач Денис Александрович

Москва – 2024

ТЕМА ДИССЕРТАЦИИ

Машинное обучение (ML) имеет широкий спектр применений и остается важной областью научных и компьютерных исследований. В большинстве этих областей ML дает стабильные и многообещающие результаты. В частности, алгоритмы контролируемого обучения (SL), которые включают задачи классификации, являются одной из наиболее хорошо изученных областей ML.

Однако в некоторых реалистичных сценариях эти алгоритмы остаются неоптимальными. Высокая несбалансированность наборов данных и отсутствие выборок данных из некоторых классов или доменов могут быть одной из причин такого неоптимального поведения. В первом случае такие редкие образцы классов называются аномалии, а соответствующая задача называется обнаружение аномалий. Во втором случае задача называется доменная адаптация.

Обнаружение аномалий используется во многих реальных сценариях и областях, таких как идентификация частиц [1], обнаружение точек разладки [2], контроль химических процессов [3], обнаружение мошенничества с кредитными картами [4], прогнозирование сложных системных сбоях [5], анализ видеорядов [6], обнаружение новизны в данных временных рядов [7], сертификация качества данных [8], обнаружение климатических изменений [9], поиск редких специфических случаев заболеваний в медицине [10], контроль качества продукции [11], мониторинг воздушных судов [12], вибромониторинг механических систем [13], обработка сейсмических сигналов [14], анализ движений человека и состояния его здоровья [15], обнаружение кибератак [16], сегментация аудиосигнала [17] и многие другие [18].

Эта область по-прежнему остается недостаточно изученной, поскольку многие современные алгоритмы обнаружения аномалий не в полной мере используют возможности методов глубинного обучения (DL). В частности, использование глубоких генеративных моделей для обнаружения аномалий еще недостаточно изучено.

Основной целью данной работы является изучение возможности использования генеративных моделей для обнаружения аномалий и доменной адаптации, чтобы раскрыть потенциал DL и SL в этих задачах. В этом исследовании рассматриваются различные методологии, включая комплексные методы обнаружения аномалий на основе DL и методов доменной адаптации, различные модели глубокой генерации для создания суррогатных аномалий для обогащения наборов данных, а также их применение и усовершенствования в реальных сценариях обнаружения аномалий, такие как повышение скорости предсказания аномалий. Представленные методологии позволяют использовать графические, табличные и временные данные, демонстрируя существенные улучшения по сравнению с ведущими современными подходами.

ТЕОРЕТИЧЕСКАЯ И ПРАКТИЧЕСКАЯ ЗНАЧИМОСТЬ

В диссертации представлены значительные теоретические и практические достижения в области обнаружения аномалий и определения точек изменения (CPD) с использованием алгоритмов генеративного глубокого обучения (DL).

Теоретическая значимость заключается во внедрении новых алгоритмов обнаружения аномалий. Метод классификации по $(1 + \epsilon)$ -классу представляет собой новое семейство алгоритмов, которые эффективно решают проблемы, относящиеся к одно- или двух-классовым методам. Этот метод может включать любое количество известных аномальных примеров, не требуя репрезентативной выборки аномальных данных, что является значительным достижением по сравнению с традиционными подходами. Еще одним важным достижением является метод NFAD, который использует нормализующие потоки. Этот метод значительно превосходит предыдущие алгоритмы, включая метод $(1 + \epsilon)$ -class, в различных сценариях. Он не зависит от модели и может быть интегрирован с любыми алгоритмами обучения с учителем. Кроме того, применение скрытых нейронных стохастических дифференциальных уравнений (SDE) для обнаружения аномалий временных рядов является новаторской разработкой в этой области. Этот метод значительно превосходит существующие

алгоритмы CPD, обеспечивая надежное и масштабируемое решение для обнаружения точек изменения в данных многомерных временных рядов. В диссертации также приводятся подробные описания представленных алгоритмов, включая теоремы и доказательства, обеспечивающие их функциональность. Эта строгая теоретическая основа гарантирует надежность предлагаемых методов.

С практической точки зрения, диссертация включает всесторонние оценки различных наборов данных, демонстрирующие, что предлагаемые алгоритмы неизменно превосходят существующие базовые показатели. Эти эмпирические данные подтверждают практическую применимость методов. В диссертацию включены программные реализации предложенных алгоритмов, а также сценарии для воспроизведения экспериментов. Такая прозрачность и воспроизводимость имеют решающее значение для практического применения и дальнейших исследований. Реализации опубликованы и доступны, что облегчает их использование и адаптацию в других проектах. В исследовании также рассматривается доменная адаптация с инверсией градиента для приложений физики высоких энергий и методы вариационного разрежения для ускорения работы нейронных сетей. Эти исследования демонстрируют применимость предложенных генеративных подходов в реальных сценариях, в частности, в области идентификации частиц на БАК.

В диссертации намечено несколько многообещающих направлений для будущих исследований, включая повышение надежности моделей и возможностей обобщения, разработку методов для улучшения интерпретируемости и объяснимости глубоких генерирующих моделей для обнаружения аномалий, изучение методов динамического обнаружения аномалий, которые могут адаптироваться к меняющимся распределениям данных и моделям аномалий с течением времени, подтверждение эффективности глубоких генерирующих моделей в реальных приложениях в различных областях, и изучение подходов "человек в курсе событий" с целью использования человеческого опыта для дополнения и проверки предсказаний моделей.

В заключение, диссертация вносит существенный вклад в области обнаружения аномалий и точек разладки, представляя новые подходы, основанные на генеративном

глубоком обучении, которые являются теоретически обоснованными и практически эффективными. Исследование обеспечивает прочную основу для дальнейших исследований и инноваций, прокладывая путь для передовых приложений в различных областях. Ожидается, что предложенные алгоритмы и их реализация окажут значительное влияние как на академические исследования, так и на практическое применение.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ

Первая работа "(1 + ε)-Классификация классов: метод обнаружения аномалий для сильно несбалансированных или неполных наборов данных" [19], представленная в этой части, представляет собой новый подход к обнаружению аномалий, основанный на использовании МСМС (Markov Chain Monte Carlo, [20]) семплирования для генерации суррогатных аномалий. В этой работе представлено новое семейство алгоритмов обнаружения аномалий. Оно может быть эффективно применено к задачам, находящимся на промежуточном уровне между одноклассовыми и двухклассовыми сценариями. Решения, полученные с помощью этих методов, сочетают в себе преимущества одно- и двухклассового подходов. В отличие от традиционных одноклассовых подходов, предлагаемые методы обнаружения аномалий могут эффективно учитывать любое количество известных примеров аномалий и, в отличие от традиционной двухклассовой классификации, не требуют репрезентативной выборки аномальных данных. Эксперименты показывают лучшую или сопоставимую производительность по сравнению с обычными двухклассовыми и одноклассовыми алгоритмами. Этот подход особенно полезен для задач обнаружения аномалий, в которых аномальные данные не являются репрезентативными или могут изменяться с течением времени. Алгоритм значительно превосходит существующие подходы и представляет собой концептуально новый подход к проблеме обнаружения аномалий, благодаря чему представленный метод $1 + \epsilon$ хорошо работает с любой долей аномалий в обучающей выборке данных.

Вторая работа называется "NFAD: исправление обнаружения аномалий с помощью нормализующих потоков" [21] продолжает предыдущую работу. В этом исследовании представлена новая схема обучения для обнаружения аномалий, не зависящая от модели. Теоретические и практические результаты демонстрируют ее эффективность при решении задачи обнаружения аномалий. По аналогии с предыдущим подходом, этот метод объединяет преимущества как одно-, так и двухклассовых алгоритмов. В отличие от одноклассовых методов, этот новый подход позволяет классификатору эффективно использовать любые доступные примеры аномалий, не прибегая к большому набору данных об аномалиях, как того требуют традиционные двухклассовые подходы. Представленный алгоритм превосходит существующие методы обнаружения аномалий в большинстве практических сценариев. Внедренный подход быстр, надежен и может быть адаптирован как на этапах обучения, так и на этапах предсказания. Его комплексная стратегия обучения расширяет возможности для текущих исследований в области обнаружения аномалий и позволяет применять любые классификаторы к любым типам данных. Кроме того, результаты обработки данных изображений могут быть улучшены за счет внедрения новых методов нормализующих потоков. Соответствующий алгоритм называется NFAD и значительно превосходит все ранее существовавшие алгоритмы обнаружения аномалий, включая $1 + \varepsilon$. Кроме того, представленный метод не зависит от модели и может быть использован с любыми алгоритмами обучения с учителем, включая классические.

В третьей работе "Скрытые нейронные стохастические дифференциальные уравнения для определения точек разладки" [22] представлен первый алгоритм обнаружения аномалий глубокого обучения (точек разладки) для данных временных рядов, основанный на нейронных стохастических дифференциальных уравнениях. Цель работы - разработать эффективное обобщение традиционных подходов к оценке отношения правдоподобия, основанных на стохастических дифференциальных уравнениях. С этой целью представлено первое исследование латентных нейронных стохастических дифференциальных уравнений в задаче обнаружения точек разладки (Change Point Detection, CPD). В результате этой работы был разработан новый алгоритм CPD, сочетающий в себе современные подходы к глубокому обучению

и традиционные методы CPD. Это первая модификация метода стохастических дифференциальных уравнений для определения точки изменения, основанная на глубинном обучении. Как теоретические, так и экспериментальные данные демонстрируют, что предлагаемый подход эффективно находит все основные типы точек разладки в данных многомерных временных рядов, включая изменения тренда, среднего и волатильности. В большинстве сценариев модель демонстрирует высокую надежность и качество, которые значительно выше, чем у других современных алгоритмов CPD, используемых в этой работе. Учитывая все вышесказанное, предложенный алгоритм представляет большой интерес с теоретической точки зрения и с точки зрения эффективности для решения задачи определения точек разладки, которая возникает во многих сценариях анализа временных рядов. Представленный алгоритм также значительно превосходит существующие алгоритмы обнаружения точек разладки и обладает большим исследовательским потенциалом в качестве первого приложения neural SDE и одного из первых эффективных приложений глубокого обучения для решения проблемы обнаружения точек разладки.

Следующая статья называется "Доменная адаптация с инверсией градиента для калибровки MC/реальных данных" [23] и включает в себя исследование методики доменной адаптации [24] для задачи обнаружения аномалий PID. Результаты этой работы показывают, что метод доменной адаптации может быть эффективно применен к реальной задаче обнаружения аномалий, а именно к идентификации частиц (PID) в физике высоких энергий. Полученные результаты обладают большим потенциалом, доказывая, что подход доменной адаптации может быть эффективно применен к задаче, предохраняя классификатор нейронной сети от переобучения в обучающей области.

Пятая статья "Вариационное разреживание нейросетей для ускорения идентификации частиц" [25] представляет собой исследование методов разреживания нейронных сетей и ускорения в применении к задаче PID. Результаты показывают, что метод разреживания с вариационным дропаутом обеспечивает наилучшие результаты для данной задачи. В задаче PID изученный метод дает впечатляющее ускорение в 16

раз без потери качества, что представляет большой интерес для исследований и применения во многих других сценариях использования.

Наконец, в статье, озаглавленной "Робастные нейронные модели идентификации частиц" [26], представлена методика, использующая общую специфическую декомпозицию [27]. В этой работе изучается недавний алгоритм низкоранговой декомпозиции (CAD), основанный на общих характеристиках, в применении к задаче обнаружения реальных аномалий (PID). Алгоритм способен выделять общие признаки даже для распадов, которые отсутствуют в исходных данных и доменах. Полученный алгоритм демонстрирует более высокую стабильность по сравнению с ранее представленными алгоритмами, тем самым демонстрируя существенное повышение качества решения для конкретного случая и демонстрируя значительный интерес ко многим другим приложениям машинного обучения. Этот метод учитывает различные области в пространстве обучающих данных, разделяя общие и уникальные элементы исходного набора признаков. Это эффективно снижает падение производительности алгоритмов обнаружения аномалий в практических сценариях наподобие PID.

ПУБЛИКАЦИИ И АПРОБАЦИЯ РАБОТЫ

Автор диссертации является основным автором большинства и соавтором остальных предложенных алгоритмов обнаружения аномалий [19], [21], [22] и связанных с ними прикладных исследований [23], [25], [26].

Эти алгоритмы основаны на глубоких генеративных моделях и обеспечивают научную новизну в данной области. Автор диссертации выполнил методологическую разработку вышеупомянутых алгоритмов обнаружения аномалий и связанных с ними экспериментов, их техническую реализацию и анализ полученных результатов. В результате три новых алгоритма обнаружения аномалий были опубликованы в авторитетных журналах Q1 и Q2. В двух из них (Q1 и Q2) диссертант является

основным автором. В третьей статье (Q1) диссертант является вторым автором и имеет такое же влияние, как и первый автор (Максим Борисьяк, НИУ ВШЭ).

Кроме того, были опубликованы три исследования в журналах Q4, посвященные приложениям для обнаружения аномалий. В двух из них диссертант является основным автором. В третьей статье диссертант является вторым соавтором.

Публикации повышенного уровня¹

- [19] M. Borisyak, A. Ryzhikov, A. Ustyuzhanin, D. Derkach, F. Ratnikov and O. Mineeva, '(1 + epsilon)-class classification: An anomaly detection method for highly imbalanced or incomplete data sets,' 2020. [Online]. Available: <https://jmlr.csail.mit.edu/papers/volume21/19-514/19-514.pdf>.
- [21] A. Ryzhikov, M. Borisyak, A. Ustyuzhanin and D. Derkach, Nfad: Fixing anomaly detection using normalizing flows, 2021. DOI: [10.7717/peerj-cs.757](https://doi.org/10.7717/peerj-cs.757). [Online]. Available: <https://peerj.com/articles/cs-757/>.
- [22] A. Ryzhikov, M. Hushchyn and D. Derkach, Latent stochastic differential equations for change point detection, 2023. DOI: [10.1109/ACCESS.2023.3318318](https://doi.org/10.1109/ACCESS.2023.3318318). [Online]. Available: <https://ieeexplore.ieee.org/document/10261192>.

Публикации стандартного уровня²

- [23] A. Ryzhikov and A. Ustyuzhanin, 'Domain adaptation with gradient reversal for mc/real data calibration,' in Journal of Physics: Conference Series, IOP Publishing, vol. 1085, 2018, p. 042018.

¹Публикациями повышенного уровня являются статьи в изданиях, входящих системы цитирования Web of Science (квартили Q1, Q2) или Scopus (квартили Q1, Q2), а также в рецензируемых трудах конференций, входящих в рейтинг CORE (ранги A и A*).

²Публикациями стандартного уровня являются статьи в изданиях, входящих в список рекомендованных журналов НИУ ВШЭ или в системы цитирования Web of Science (квартили Q3, Q4) или Scopus (квартили Q3, Q4), а также в рецензируемых трудах конференций, входящих в рейтинг CORE (ранг B).

-
- [25] A. Ryzhikov, D. Derkach, M. Hushchyn, L. Collaboration et al., ‘Variational dropout sparsification for particle identification speed-up,’ in Journal of Physics: Conference Series, IOP Publishing, vol. 1525, 2020, p. 012 099.
- [26] A. Ryzhikov, A. Temirkhanov, D. Derkach et al., ‘Robust neural particle identification models,’ in Journal of Physics: Conference Series, IOP Publishing, vol. 2438, 2023, p. 012 119.

СОДЕРЖАНИЕ РАБОТЫ

Первая и основная часть работы включает в себя три новых алгоритма обнаружения аномалий DL [19], [21], [22]. Разработанные методы позволяют использовать методы обнаружения аномалий в виде таблиц, изображений и временных рядов как в режиме обучения с учителем, так и на частично или полностью несбалансированных данных, когда в обучающем наборе данных задано произвольное количество аномалий. Алгоритмы основаны на глубоких генеративных моделях и позволяют использовать любую архитектуру нейронной сети. По сравнению с обычными алгоритмами обнаружения аномалий, представленные методы разработаны таким образом, чтобы одинаково хорошо работать с различной долей аномалий в обучающем наборе данных. Кроме того, они не имеют ограничений на архитектуру нейронной сети, лежащей в основе.

Вторая часть работы включает в себя три прикладных исследования для реального эксперимента по обнаружению аномалий (PID [1]). Эта часть включает в себя два исследования по доменной адаптации [23], [26], примененные к эксперименту PID, и одно исследование существующих подходов к ускорению нейронных сетей для решения задачи обнаружения аномалий PID.

ВЫВОДЫ

Эта диссертация содержит полный набор научных исследований по обнаружению аномалий, а также прикладные исследования существующих методов в области обнаружения аномалий и смежных областях.

Новый набор алгоритмов обнаружения аномалий DL, представленных в этой диссертации, эффективно решает трудноразрешимые задачи как с помощью одно-, так и двухклассовых методов. Эти решения для обнаружения аномалий являются первыми, которые сочетают в себе лучшие черты одно- и двухклассовых подходов с мощностью глубоких генеративных моделей. Это формирует новое, сильное и многообещающее направление в исследованиях по обнаружению аномалий.

Результаты, полученные с помощью этих алгоритмов, значительно превосходят существующие подходы к обнаружению аномалий в большинстве сценариев. Это первое хорошо зарекомендовавшее себя и эффективное применение глубоких генерирующих моделей для решения реальных задач обнаружения аномалий с широким потенциалом дальнейшего применения.

В диссертации представлены несколько инновационных разработок в области обнаружения аномалий, которые кратко излагаются следующим образом:

- разработан и опубликован в популярном журнале Q1 совершенно новый генеративный подход к проблеме обнаружения аномалий (автор диссертации является вторым соавтором). Это первый подход к обнаружению аномалий, который хорошо работает как в одноклассовых, так и в двухклассовых и промежуточных сценариях. Алгоритм называется " $1 + \epsilon$ " и основан на MCMC семплировании суррогатных аномалий вокруг границ классификационной нейронной сети. Алгоритм продемонстрировал выдающуюся производительность во всех вышеупомянутых сценариях.
- другой глубокий генерирующий подход, основанный на нормализующих потоках, называется NFAD и также опубликован в журнале Q2 (автор

диссертации является основным соавтором). Это первый подход, который использует нормализующие потоки в задаче обнаружения аномалий и превосходит все ранее существовавшие алгоритмы, включая " $1 + \varepsilon$ ", в большинстве экспериментов.

- первый подход к обнаружению аномалий временных рядов (точек разладки), основанный на нейронных (скрытых) стохастических дифференциальных уравнениях, опубликован в ведущем журнале Q1 (автор диссертации является основным соавтором). Этот метод значительно превосходит все существующие алгоритмы обнаружения точек разладки практически во всех изученных тестовых корпусах, метриках и бенчмарках.
- Два метода обучения адаптации к предметной области и один метод разрежения впервые изучены в применении к реальной задаче обнаружения аномалий. Каждое из трех исследований опубликовано в просидингах конференций (Q4).

Bibliography

- [1] C. Lippmann, ‘Particle identification,’ Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment, vol. 666, pp. 148–172, 2012, Advanced Instrumentation, ISSN: 0168-9002. DOI: <https://doi.org/10.1016/j.nima.2011.03.009>. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0168900211005419>.
- [2] S. Aminikhanghahi and D. J. Cook, ‘A survey of methods for time series change point detection,’ Knowledge and information systems, vol. 51, no. 2, pp. 339–367, 2017.
- [3] B. Huang, ‘Detection of abrupt changes of total least squares models and application in fault detection,’ IEEE Transactions on Control Systems Technology, vol. 9, no. 2, pp. 357–367, 2001. DOI: [10.1109/87.911387](https://doi.org/10.1109/87.911387).
- [4] E. Aleskerov, B. Freisleben and B. Rao, ‘Cardwatch: A neural network based database mining system for credit card fraud detection,’ pp. 220–226, Apr. 1997.
- [5] J. Xu and H. Li, ‘The Failure Prediction of Cluster Systems Based on System Logs,’ Wang M. (eds) Knowledge Science, Engineering and Management. KSEM 2013. Lecture Notes in Computer Science, vol 8041., 2013.
- [6] Z. Gao, G. Lu, C. lv and P. Yan, ‘Key-frame selection for automatic summarization of surveillance videos: A method of multiple change-point detection,’ Machine Vision and Applications, vol. 29, Oct. 2018. DOI: [10.1007/s00138-018-0954-7](https://doi.org/10.1007/s00138-018-0954-7).
- [7] M. Schmidt and M. Simic, ‘Normalizing flows for novelty detection in industrial time series data,’ 2019. eprint: [arXiv:1906.06904](https://arxiv.org/abs/1906.06904).
- [8] M. Borisyak, F. Ratnikov, D. Derkach and A. Ustyuzhanin, ‘Towards automation of data quality system for cern cms experiment,’ Journal of Physics: Conference Series, vol. 898, no. 9, p. 092041, 2017.

-
- [9] J. Reeves, J. Chen, X. L. Wang, R. Lund and Q. Q. Lu, ‘A review and comparison of changepoint detection techniques for climate data,’ *Journal of Applied Meteorology and Climatology*, vol. 46, no. 6, pp. 900–915, 2007. DOI: [10.1175/JAM2493.1](https://doi.org/10.1175/JAM2493.1). eprint: <https://doi.org/10.1175/JAM2493.1>. [Online]. Available: <https://doi.org/10.1175/JAM2493.1>.
- [10] C. Spence, L. Parra and P. Sajda, ‘Detection, synthesis and compression in mammographic image analysis with a hierarchical image probability model,’ pp. 3–10, 2001. DOI: [10.1109/MMBIA.2001.991693](https://doi.org/10.1109/MMBIA.2001.991693).
- [11] A. F. Bissell, ‘Cusum techniques for quality control,’ *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, vol. 18, no. 1, pp. 1–30, 1969, ISSN: 00359254, 14679876. [Online]. Available: <http://www.jstor.org/stable/2346436>.
- [12] D. Henry, S. Simani and R. J. Patton, ‘Fault detection and diagnosis for aeronautic and aerospace missions,’ in *Fault Tolerant Flight Control: A Benchmark Challenge*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, pp. 91–128, ISBN: 978-3-642-11690-2. DOI: [10.1007/978-3-642-11690-2_3](https://doi.org/10.1007/978-3-642-11690-2_3). [Online]. Available: https://doi.org/10.1007/978-3-642-11690-2_3.
- [13] G. A. Susto, A. Schirru, S. Pampuri, S. McLoone and A. Beghi, ‘Machine learning for predictive maintenance: A multiple classifier approach,’ *IEEE Transactions on Industrial Informatics*, vol. 11, no. 3, pp. 812–820, 2015.
- [14] M. Basseville and I. V. Nikiforov, ‘Detection of abrupt changes: Theory and application,’ *Technometrics*, vol. 36, p. 550, 1993.
- [15] A. Briassouli, T. Vagia and I. Kompatsiaris, ‘Human motion analysis via statistical motion processing and sequential change detection,’ *EURASIP Journal on Image and Video Processing*, vol. 2009, Jan. 2009. DOI: [10.1155/2009/652050](https://doi.org/10.1155/2009/652050).
- [16] A. G. Tartakovsky, B. Rozovskii, R. B. Blazek and H. Kim, ‘Detection of intrusions in information systems by sequential change-point methods,’ *Statistical Methodology*, vol. 3, pp. 252–293, 2006.
- [17] Z. Shuyang, T. Heittola and T. Virtanen, ‘Active learning for sound event detection,’ *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, vol. 28, pp. 2895–2905, 2020.

-
- [18] A. Tartakovsky, I. Nikiforov and M. Basseville, *Sequential Analysis: Hypothesis Testing and Changepoint Detection*. Aug. 2014, ISBN: 9781439838204. DOI: [10.1201/b17279](https://doi.org/10.1201/b17279).
- [19] M. Borisyak, A. Ryzhikov, A. Ustyuzhanin, D. Derkach, F. Ratnikov and O. Mineeva, ‘(1 + epsilon)-class classification: An anomaly detection method for highly imbalanced or incomplete data sets,’ 2020. [Online]. Available: <https://jmlr.csail.mit.edu/papers/volume21/19-514/19-514.pdf>.
- [20] F. Septier and G. W. Peters, ‘Langevin and hamiltonian based sequential mcmc for efficient bayesian filtering in high-dimensional spaces,’ 2015. DOI: [10.1109/JSTSP.2015.2497211](https://doi.org/10.1109/JSTSP.2015.2497211). eprint: [arXiv:1504.05715](https://arxiv.org/abs/1504.05715).
- [21] A. Ryzhikov, M. Borisyak, A. Ustyuzhanin and D. Derkach, Nfad: Fixing anomaly detection using normalizing flows, 2021. DOI: [10.7717/peerj-cs.757](https://doi.org/10.7717/peerj-cs.757). [Online]. Available: <https://peerj.com/articles/cs-757/>.
- [22] A. Ryzhikov, M. Hushchyn and D. Derkach, Latent stochastic differential equations for change point detection, 2023. DOI: [10.1109/ACCESS.2023.3318318](https://doi.org/10.1109/ACCESS.2023.3318318). [Online]. Available: <https://ieeexplore.ieee.org/document/10261192>.
- [23] A. Ryzhikov and A. Ustyuzhanin, ‘Domain adaptation with gradient reversal for mc/real data calibration,’ in *Journal of Physics: Conference Series*, IOP Publishing, vol. 1085, 2018, p. 042 018.
- [24] Y. Ganin and V. Lempitsky, ‘Unsupervised domain adaptation by backpropagation,’ in *International conference on machine learning*, PMLR, 2015, pp. 1180–1189.
- [25] A. Ryzhikov, D. Derkach, M. Hushchyn, L. Collaboration et al., ‘Variational dropout sparsification for particle identification speed-up,’ in *Journal of Physics: Conference Series*, IOP Publishing, vol. 1525, 2020, p. 012 099.
- [26] A. Ryzhikov, A. Temirkhanov, D. Derkach et al., ‘Robust neural particle identification models,’ in *Journal of Physics: Conference Series*, IOP Publishing, vol. 2438, 2023, p. 012 119.
- [27] V. Piratla, P. Netrapalli and S. Sarawagi, Efficient domain generalization via common-specific low-rank decomposition, 2020. arXiv: [2003.12815 \[cs.LG\]](https://arxiv.org/abs/2003.12815).