

# АЛГОРИТМЫ МАШИННОГО ОБУЧЕНИЯ В УСКОРИТЕЛЬНОЙ ТЕХНИКЕ

*Волков М.И.<sup>1</sup>, Каргина П.С.<sup>2</sup>, Шкитов Д.А.<sup>3</sup>*

<sup>1</sup>*Томский политехнический университет, ИШФВП, А3-05, miv5@tpu.ru*

<sup>2</sup>*Томский политехнический университет, ИЯТШ, ОБМ21, psk22@tpu.ru*

<sup>3</sup>*Томский политехнический университет, ИШФВП, к.ф.–м.н., shkitovda@tpu.ru*

## **Аннотация**

В данной работе рассмотрены примеры применения алгоритмов машинного обучения к задачам диагностики пучков заряженных частиц, оптимизации работы ускорителя и обнаружения аномалий.

**Ключевые слова:** виртуальная диагностика пучка, обнаружение аномалий, полносвязные нейронные сети, Isolation Forest, Bagged Decision Trees.

## **Введение**

Машинное обучение нашло широкое применение в обработке данных и анализе результатов экспериментов в физике высоких энергий [1-3]. Алгоритмы машинного обучения обучаются на больших объёмах данных и работают эффективнее, чем традиционные методы анализа данных. В физике высоких энергий алгоритмы используются для распознавания частиц, определения траекторий их движения, классификации событий и во многих других задачах. В зависимости от способа обучения различают: обучение с учителем, обучение без учителя и обучение с подкреплением. К числу задач, которые способны решить алгоритмы машинного обучения, можно отнести задачи регрессии, кластеризации, сегментации, шумоподавления, генерации искусственных данных и т. д.

В настоящее время планируется строительство новых электронных ускорителей в России, (не говоря о строящейся в настоящее время установке СКИФ). Например, обновление источника синхротронного излучения КИСИ в Москве, строительство источника синхротронного излучения СИЛА в Подмоскowie и РИФ во Владивостоке, источника комптоновского излучения в Сарове. В связи с этим возникает необходимость использования методов и средств диагностики параметров пучков заряженных частиц, которые ранее в России практически не были востребованы.

Одной из существенных проблем по использованию машинного обучения в ускорительной технике является проблема набора качественных данных. В ускорителе частиц достаточно много параметров, которые способны повлиять на выходной пучок. Выбор, настройка и измерение необходимых параметров является достаточно сложной задачей. Помимо этого, для обучения алгоритма и дальнейшего прогнозирования параметров ускорителя требуется большое количество данных (в случае использования обучения с учителем). В связи с этим для успешного применения алгоритмов машинного обучения в ускорительной технике требуется накопить и проанализировать определённый опыт по применению этих алгоритмов в этой сфере.

Целью данной работы является проведение обзора основных способов применения алгоритмов машинного обучения в ускорительной технике. В данной работе рассмотрены примеры применения алгоритмов машинного обучения к задачам диагностики пучков ускорителей, оптимизации работы ускорителя и обнаружения аномалий.

## **Основная часть**

На данный момент настройка многих ускорителей и получение пучка с заданными параметрами до сих пор происходит вручную. В связи с этим необходимы инструменты по автоматической настройке пучка. Ускорители частиц всегда производят большие объёмы данных со сложными взаимосвязями, а машинное обучение полезно для поиска сложных правил, скрытых в таких данных [4, 5]. Поэтому машинное обучение должно хорошо подходить для ускорителей частиц, и благодаря применению этого инструмента уже достигнуто множество положительных результатов. Зная параметры работы ускорителя в определённый момент времени, мы можем получать параметры исследуемого пучка без остановки ускорителя в реальном времени. При правильной реализации это позволяет облегчить управление ускорителем, автоматизировать и оптимизировать весь процесс его настройки.

Это так же позволяет проводить, так называемую, виртуальную диагностику пучка заряженных частиц, поскольку параметры работы ускорителя связаны с пучком и его характеристиками. Виртуальная диагностика может помочь в случае, если прямое измерение может иметь разрушительные последствия для работы или в местах, где невозможно разместить физические приборы [4].

В работе [5] алгоритмы машинного обучения используют в качестве средства для виртуальной диагностики и настройки положения пучка в источнике рентгеновского излучения на основе томсоновского рассеяния, расположенного в университете Цинхуа, который представляет из себя экспериментальную платформу для получения и применения электронных пучков высокой интенсивности. Цель работы [5] состояла в том, чтобы спрогнозировать положение пучка до и после экспериментальной камеры с помощью регрессионной модели, основанной на данных. В работе авторами использованы модели для классификации и регрессии. Модель классификации использовалась для оценки того, будет ли пучок потерян при определенном наборе параметров, и для получения действительного комбинированного диапазона параметров. В качестве модели для классификации использовалась модель Bagged Tree Classification. Эта модель базировалась на более простом алгоритме дерева решений и представляет его сильную модификацию. В качестве признаков одного события для классификации использовались 20 изменяемых параметров ускорителя, которые наиболее сильно влияют на характеристики выходного пучка. Сами данные получены при случайных изменениях этих признаков (диапазоны изменения этих параметров заданы), поскольку варьирование признаков между собой привело бы к огромным временным затратам только на сбор данных. Точность модели для классификации составила 95 %, площадь под ROC-кривой (метрика AUC) составила 0.98. Обученная модель позволяла предсказать, приведет ли данная комбинация настроек к потере пучка, что может значительно ускорить процесс сбора данных и может использоваться в качестве процессе управления ускорителем.

Модель для регрессии использовалась для прогнозирования положения пучка. В качестве алгоритма машинного обучения выбрана полносвязная нейронная сеть [5]. В качестве входных данных использовались 20 независимых параметров (которые использовались при классификации) и данные с первых двух мониторов положения пучка. В качестве выходных данных использовались измерения с 3-го и 4-го мониторов положения пучка. Архитектура нейронной сети состояла из 3 скрытых слоев с 256 нейронами (в качестве функции активации выбрана tanh). Данные были случайно разделены на три выборки: обучающие (70 %), валидационные (15 %) и тестовые (15 %). Скорость обучения изначально установлена на уровне 0.001, а затем снижалась с определенной скоростью. Размер батча равен 1000. Для модели регрессии в качестве метрики использован корень из среднеквадратичной ошибки (RMSE). Вид модели представлен на рис. 1 [5].

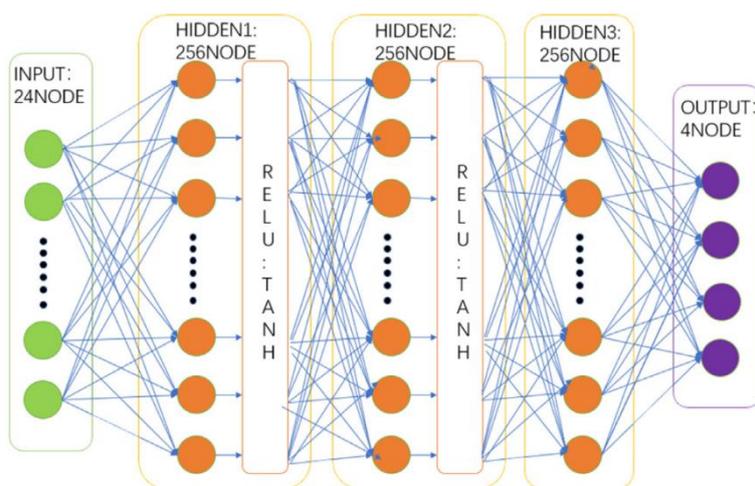


Рис. 1. Архитектура нейронной сети для регрессии

Точность регрессии по метрике RMSE составила 0.1313 мм на обучающей выборке, 0.1286 мм на валидационной выборке и 0.1263 мм на тестовой выборке. Результаты, полученные на проверочном

наборе, близки к результатам, достигнутым на обучающем наборе, что указывает на отсутствие переобучения.

Другим примерами реализации виртуальной диагностики являются исследования по диагностике продольного фазового пространства на основе алгоритмов машинного обучения на установке FACET-II и источнике когерентного света Linac (LCLS) [6]. В качестве инструмента машинного обучения использовалась полносвязная нейронная сеть прямого распространения с тремя скрытыми слоями (количества нейронов в скрытых слоях: 200, 100, 50). В качестве функции активации использована *relu*. Для оценки модели использовалась метрика *score* [6]. Среднее значение данной метрики составило  $0.68 \pm 0.16$ . В качестве данных для обучения выступало огромное количество данных по моделированию, которые представляли изменение в распределении продольного фазового пространства от различных параметров ускорителя. Помимо этого, использованы данные из существующих измерений LCLS. Полученная модель продемонстрировала хорошее согласие между прогнозом и смоделированными и измеренными изображениями продольного фазового пространства.

Еще одним примером является исследование корреляций между размером пучка и изображениями из многоцелевой системы визуализации, направленное на повышение точности мониторов положения пучка (BPM) с использованием нейронных сетей на Шанхайской установке синхротронного излучения (SSRF) [4].

Свёрточные нейронные сети (CNN) применялись в FAST на изображениях во время проведения операций с пучком [4]. Комбинация CNN и нейронных сетей прямого распространения дала многообещающие результаты для прогнозирования параметров пучка на смоделированных наборах данных. В качестве входных данных модели использовались результаты моделирования и некоторые другие параметры. На выходе модель позволила предсказывать параметры выходного пучка.

Используя измеряемые параметры ускорителя, можно автоматизировать работу ускорителя и оптимизировать параметры выходного пучка. Примером реализации такой оптимизации является применение методов интеллектуального управления для максимизации средней энергии импульса в лазерах на свободных электронах. Разработанные методы позволили настроить до 105 компонентов одновременно, основываясь только на измерениях средней зашумленной энергии сгустка [4].

При работе ускорителя необходимо следить за исправностью работы его оборудования. Выход оборудования из строя можно обнаружить по его показаниям. Обнаруживая аномальные показания приборов, которые не соответствуют ожидаемым паттернам, можно выявить неисправное оборудование. Аномалии могут обнаруживаться через задачу классификации (обучение с учителем), кластеризации (обучение без учителя) и др.

Примером работы алгоритма с обучением без учителя по обнаружению аномалий является обнаружение неисправных мониторов пучка на Большом адронном коллайдере (БАК) [4, 7, 8]. Проблема заключалась в том, что обнаружение неисправных мониторов пучка не являлось тривиальной задачей, поскольку не все причины появления аномалий BPM были известны. Из-за этого до применения машинного обучения определением неисправных мониторов пучка занимались люди, что требовало значительное количество времени. В качестве алгоритма по выявлению неисправных мониторов авторами был выбран Isolation Forest (IF) [4], который представлял алгоритм на основе дерева решений. В качестве данных для обучения использовались данные для моделирования, в которых заранее известны исправные и неисправные мониторы пучка. Поскольку сведения о фактических дефектных BPM недоступны, оценку алгоритмов очистки выполняли на результатах моделирования, в котором фактические дефектные BPM были известны и могли использоваться в качестве маркированных данных для оценки производительности алгоритма. К минусам алгоритма IF можно отнести то, что некоторые мониторы были ошибочно классифицированы как неисправные (что не сильно важно для БАК, но может оказаться критично для небольших ускорителей с малым количеством BPM).

## **Заключение**

В ходе проведённого обзора установлено, что алгоритмы машинного обучения применяются в ускорительной технике в качестве инструментов для диагностики пучка, обнаружения неисправного оборудования (например, мониторов положения пучка), оптимизации параметров выходного пучка и частичной автоматизации работы ускорителя.

Наличие виртуальной диагностики пучка позволяет осуществлять ряд определенных операций с пучком без прекращения работы ускорителя (в отличие от разрушающих методов). Оптимизация

работы ускорителя с использованием алгоритмов машинного обучения уменьшит время настройки ускорителя и позволит сократить время его запуска. Обнаружение аномалий в крупном ускорительном комплексе облегчает управление ускорителем.

Наиболее часто встречающимися в литературе алгоритмами по машинному обучению являются различные модификации алгоритма дерева решений (Boosted Decision Trees, Bagged Decision Trees, Isolation Forest Tree и др.) и нейронные сети (CNN, GAN, RNN и т.д.) [3-5]. Среди нейронных сетей наиболее часто применяются полносвязные нейросети с несколькими скрытыми слоями.

Основным ограничением применения алгоритмов машинного обучения в ускорительной физике являются необходимость объёма данных, которые важны для работы алгоритма (в случае использования алгоритмов обучения с учителем). Помимо большого количества данных необходимо наличие приборов, позволяющих измерять независимые (но коррелирующие друг с другом) параметры ускорителя, изменение которых влияет на характеристики пучка. В отличие от других областей применения машинного обучения, в ускорительной технике такие наборы данных возможно собрать не только экспериментальным путём, но и с использованием моделирования. Если результаты экспериментальных данных согласуются в достаточной степени с результатами моделирования, то результаты моделирования можно использовать для обучения алгоритма машинного обучения. Это сильно облегчает сбор обучающих наборов данных, но появляется зависимость точности предсказания алгоритма от точности моделирования. Однако, такое высокоточное моделирование, как правило, доступно лишь на больших ускорительных комплексах. В связи с этим применение алгоритмов машинного обучения для многих ускорителей требует проведения модернизации оборудования и автоматизации сбора данных.

Следует отметить, что потенциально возможно применение алгоритмов машинного обучения для управления, оптимизации работы микротрона ТПУ, а также для диагностики параметров электронного пучка. Для этого необходимо автоматизировать процесс сбора данных с детекторов и собрать обучающий набор необходимых размеров.

#### Список использованных источников

1. Aaij R., Abdelmotteleb A.S.W., Abellan Beteta C. Observation of the decay  $B_s^0 \rightarrow D^{*+} D^{*-}$  // Phys. Rev. Lett. – 2016. – Vol. 117. – № 261801.
2. Aaij R., Abellán Beteta C., Ackernley T. Measurement of CP violation in the decay  $B^+ \rightarrow K^+ \pi^0$ , Observation of the decay // Phys. Rev. Lett. – 2021. – Vol. 126. – № 091802.
3. Albertsson K., Gleyzer S., Hoecker A. Toolkit for Multivariate Data Analysis with ROOT : users guide. – Текст: электронный // Journal of High Energy Physic. – 2023. – URL: <https://root.cern.ch/download/doc/tmva/TMVAUsersGuide.pdf> (дата обращения: 22.03.2024).
4. Fol E., Coello de Portugal J.C., Franchetti G. Application of Machine Learning to Beam Diagnostic // in Proc. 39th Free Electron Laser Conf. (FEL'19). – 2019. – P. 311–317.
5. ShaoHong G., WenHui H., Chuang Ye S. Multivariable virtual diagnostics and tuning of beam positioning using machine learning // Nuclear Inst. and Methods in Physics Research, A. – 2023. – Vol. 1052. – № 168245.
6. Emma C., Edelen A., Hogan M.J. Machine learning-based longitudinal phase space prediction of particle accelerators // Phys. Rev. Accel. Beams. – 2018. – Vol.21. – № 112802.
7. Fol E., Tomás R., Coello de Portugal J. Detection of faulty Beam Position Monitors // ICFA Beam Dynamics Mini-Workshop: Machine Learning Applications for Particle Accelerators. – 2018. – № 51.
8. Fol. E., Coello de Portugal J.M., Tomás R. Unsupervised Machine Learning for Detection of Faulty Beam Position Monitors // Proc. IPAC. – 2019. – Vol. 19 – P. 2668–2671.