

МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ В ЯДЕРНЫХ ТЕХНОЛОГИЯХ

УДК 53.083.98

НЕЙРОННЫЕ СЕТИ ДЛЯ ОБРАБОТКИ ЯДЕРНЫХ ЭМУЛЬСИЙ

© 2024 г. В. Т. Васильев^а, Н. С. Коновалова^а, Н. М. Окатьева^а, Н. Г. Полухина^а, Ж. Т. Садыков^а,
Е. Н. Старкова^а, Н. И. Старков^а, М. М. Чернявский^а, Т. В. Щедрина^а, *

^аФизический институт им. П.Н. Лебедева РАН, Москва, 119991 Россия

*E-mail: tvshchedrina@gmail.com

Поступила в редакцию 04.06.2023 г.

После доработки 23.06.2023 г.

Принята к публикации 28.07.2023 г.

Благодаря развитию оптической прецизионной и вычислительной техники, растёт количество экспериментов, базирующихся на визуальных методах обработки данных трековых детекторов. Применение нейронных сетей для выделения кластеров в изображениях, полученных с помощью сканирующих станций нового поколения, позволит не только ускорить обработку изображений в ядерных эмульсиях, но и сделать процесс реконструкции трека на порядок более эффективным.

Ключевые слова: нейронная сеть, фотографическая ядерная эмульсия, выделение кластеров в изображениях

DOI: 10.56304/S2079562923010293

ВВЕДЕНИЕ

Развитие современной экспериментальной физики требует создания новых высокотехнологичных измерительных систем и решения связанных с ними нестандартных наукоёмких задач. В данной работе представлен алгоритм распознавания изображений в ядерных эмульсиях с использованием нейронных сетей, позволяющий обеспечить скорость и качество обработки экспериментальных данных на принципиально новом уровне.

Прогресс прецизионной и вычислительной техники, в том числе создание оптических столов с высокой точностью перемещения, привел к заметному увеличению количества экспериментов, основанных на визуальных методах обработки данных с использованием эмульсионных трековых детекторов. Эти эксперименты относятся как к фундаментальным (ядерная физика, физика высоких энергий и элементарных частиц), так и к прикладным исследованиям, находящим применение в таких областях, как геологоразведка, мониторинг состояний крупных промышленных и природных объектов, анализ сейсмических процессов и др.

Фотографические ядерные эмульсии с прецизионной точностью, превосходящей точность электронных приборов, фиксируют треки проходящих через них высокоэнергичных заряженных частиц, которые изучаются под оптическим микроскопом при увеличении от нескольких сотен до тысяч крат. Эта кропотливая обработка в настоящее время автоматизирована и осуществляется с помощью измерительных сканирующих систем [1, 2].

Большой объем данных ядерно-эмульсионных экспериментов требует увеличения скорости сканирования, первичной обработки и анализа, что предполагает повышение количества этапов обработки в режиме реального времени. В данной работе предложен метод оптимизации одного из этапов обработки ядерно-эмульсионных данных, необходимых в большинстве физических экспериментов с использованием данной методики.

АРХИТЕКТУРА СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ U-Net

U-Net – это архитектура сверточной нейронной сети, которая была разработана в 2015 г. О. Роннебергером, Ф. Фишером и Т. Броксом для сегментации клеток на микроскопических снимках [3]. Она хорошо зарекомендовала себя и широко используется при решении задач сегментации изображений. Данная архитектура содержит две части: сужающуюся (свертка) и расширяющуюся (пулинг), которые образуют U-образную структуру (рис. 1).

Первым этапом работы нейронной сети является ее обучение, когда на вход сети подается известное изображение, а выходные значения сравниваются с истинными метками классов. По результатам сравнения параметры нейронной сети корректируются, и ее ответы подстраиваются под истинные, пока разница не станет минимальной.

В сверточной сети, использованной в данной работе, исходное и контрольное изображения обрабатываются параллельно, каждое в своей сети. Поступающие на вход в сужающейся части струк-




Рис. 1. Архитектура сверточной нейронной сети U-Net.

туры (левая сторона рис. 1) изображения претерпевают целый ряд преобразований, и на этапе свертки будут представлены не в пикселях, а в виде матриц с числами. В начале в каждом пикселе изображения производится свертка с числовыми матрицами (ядрами) размерностью 3×3 или 5×5 , последовательность пикселей которых отражает определенный признак (линию, угол, пятно и т.п.). На полученные сверточные изображения накладывается маска (матрица размером 2×2) и перемещается по нему. Внутри каждого из положений матрицы определяется число, обычно максимальное из чисел в матрице. Набор полученных чисел образует карту признаков. В результате этой процедуры размеры карт признаков становятся в два раза меньше сверточных изображений, а изучаемый признак усиливается. Процедура получения свертки и карты признаков многократно повторяется, и размерность карт поэтапно уменьшается.

При достижении определенного уровня сжатия изображения в результате указанных процедур, производится сравнение карт признаков исходного и контрольного изображений и определяются поправочные коэффициенты, меняющие значение числовых величин, участвующих в работе сети. Следующим этапом является обратный процесс — развертывание полученных карт признаков исходного и контрольного изображений (правая сторона рис. 1) — который производится с таким же количеством шагов, что и при свертке. После этого изображения сравниваются попиксельно. При сравнении изображений используется лосс-функция (“loss” от англ. “потери”), вычисляющая количество ошибок, совершенных при обучении сети.

Обработка осуществляется эпохами, каждая из которых включает весь набор изображений. После каждой эпохи обучения изображение на выходе сравнивается с поданной маской, соответствующей сегментируемому изображению, и вычисляется коэффициент, характеризующий долю площади правильно отмеченных кластеров (коэффициент Жаккара, Jaccard similarity coefficient). Коэффициент Жаккара определяется как отношение площади пересечения (логическая операция “И”) к площади объединения (логическая операция “ИЛИ”), и чем ближе его значение к единице, тем точнее нейросеть выделяет кластеры, относящиеся к “сигналу”. Эпоха увеличивается каждый раз, когда сеть проходит весь обучающий набор. В первом приближении, чем больше эпоха, тем лучше “натренирована” сеть и, соответственно, точнее результат. Однако, после определенного числа эпох результат работы сети перестает улучшаться и даже может ухудшиться (так называемое “переобучение” — одна из проблем глубоких нейронных сетей). Для этого случая был реализован алгоритм, выбирающий наилучший результат из имеющихся эпох.

Обучающая выборка для решения данной задачи включала 1261 пару изображений (1280×1024 пикселей каждое), что соответствует стандартному размеру, не приводящему к переобучению нейронной сети.

СТРУКТУРА ПРОГРАММНОГО КОДА

Обучающий набор фотографических изображений фрагментов облученной эмульсии для нейросети был получен на измерительном комплексе




Рис. 2. Элементы программного кода для обработки изображений с помощью нейросети: (а) разделение кода на модули, (б) часть кода, отвечающая за реализацию нейросети.

ПАВИКОМ (Полностью АВтоматизированный Измерительный КОМПлекс) в Физическом институте имени П.Н. Лебедева Российской академии наук. Измерительный комплекс предназначен для высокотехнологичной обработки экспериментальных данных в области ядерной физики, физики космических лучей, физики высоких энергий и элементарных частиц, получаемых с помощью твердотельных трековых детекторов [4, 5].

На рис. 2а приведена общая структура программы для обработки изображений с помощью нейросети, а на рис. 2б более подробно представлена часть кода, отвечающая за ее реализацию на архитектуре U-Net.

Программный код для нейросети разбит на несколько модулей, каждый из которых выполняет свою конкретную задачу (табл. 1).

ТЕСТИРОВАНИЕ И ПРИМЕНЕНИЕ ПРОГРАММНОГО КОДА ДЛЯ НЕЙРОННОЙ СЕТИ

На рис. 3 показан пример, отображающий результат тестирования сверточной нейронной сети на основе обучающего набора изображений. На рис. 3б, показаны кластеры, выделенные с помо-

щью графического процессора сканирующей станции ПАВИКОМ, а рис. 3в демонстрирует результаты выделения кластеров нейронной сетью из обучающего набора изображений (совпадение с исходным изображением $\sim 95\%$; коэффициент Жаккара = 0.954317).

На рис. 4 показан результат работы нейросети по восстановлению кластеров, полученных после обучения сети, т.е. исходное изображение взято не из обучающего набора. Совпадение с исходным изображением получено на уровне $\sim 93\%$, коэффициент Жаккара = 0.933682.

Увеличение числа изображений обучающего набора приведет к увеличению точности работы нейронной сети по восстановлению изображений кластеров, однако это потребует больших ресурсов оперативной памяти и дискового пространства.

В табл. 2 приведены сравнительные характеристики доступных на сегодняшний день альтернативных способов обработки изображений.

Как видно из табл. 2, нейросети обладают бесспорным преимуществом по скорости обработки изображений, в пять и более раз превосходя альтернативные методы. Данный аспект является ключевым, учитывая большой объем массивов данных

Таблица 1. Структура программного кода для обработки изображений с помощью нейросети

	Название модуля	Функции модуля
Модуль 1	Импорт всех библиотек	Подключение библиотек Python для извлечения данных из облачного хранилища, их обработки, вывода на экран, внесения в обучающий набор, а также библиотек, необходимых для создания и обучения нейронной сети.
Модуль 2	Выделение файлов из хранилища и их преобразование	Извлечение, обработка и конвертация в необходимый формат исходных изображений.
Модуль 3	Image Data Generator	Создание генератора, который на основе известных изображений формирует похожие.
Модуль 4	Создание нейросети и ее обучение	Построение сверточной нейросети и ее обучение в течение нескольких эпох (с сохранением наилучшего результата).
Модуль 5	Результаты обучения	Вывод на экран нескольких примеров изображений из обучающего набора и сгенерированного нейросетью изображения (с указанием коэффициента Жаккара).
Модуль 6	Сохранение модели	Загрузка в один файл (с расширением *.h5) больших объемов числовых, графических и текстовых данных.
Модуль 7	Загрузка натренированной модели	Выгрузка на сервер Google Colab файла *.h5, т.е. модели нейросети, что позволяет не обучать сеть заново и сократить время работы.
Модуль 8	Проверка сети на новом наборе после ее обучения	На входе подаются изображения файлов вне обучающего набора, нейронная сеть обрабатывает изображения и генерирует выходной файл в виде изображения с восстановленными кластерами.

эмульсионных экспериментов и временные затраты на их обработку и анализ.

ИТОГИ И ПЕРСПЕКТИВЫ

Впервые для обработки экспериментов в области физики высоких энергий и элементарных частиц с использованием фотографической ядерной эмульсии применена методика распознавания изображений с помощью нейросети. Создана и обучена сверточная нейронная сеть на архитектуре U-Net с обучающим набором изображений, полученных в эмульсии с помощью сканирующей станции ПАВИКОМ. Скорость обработки изобра-

жения с помощью нейросети после ее обучения в пять раз превышает скорость обработки на графическом процессоре ПАВИКОМ. Точность восстановления изображения достигает 93%.

Полученные результаты указывают на перспективность дальнейших исследований в данном направлении. На следующих этапах работы планируется имплементация обработки изображений и выделения кластеров с помощью нейронной сети в программный комплекс ПАВИКОМ, а также создание и обучение сверточной нейронной сети на архитектуре 3D U-Net с использованием набора изображений, воспроизводящих трехмерный объект.




Рис. 3. Обработка изображения из обучающего набора для нейронной сети: (а) исходное изображение 1280 × 1024 пикселей, полученное на измерительном комплексе ПАВИКОМ; (б) кластеры, восстановленные с помощью графического процессора; (в) кластеры, восстановленные с использованием нейросети.




Рис. 4. Изображение вне обучающего набора: (а) исходное изображение 1280×1024 пикселя, полученное на измерительном комплексе ПАВИКОМ; (б) кластеры, восстановленные с помощью графического процессора; (в) кластеры, восстановленные с использованием нейросети.

Таблица 2. Характеристики различных методов обработки изображений

Метод обработки изображений	Наличие высокоскоростного интернета	Большой объем оперативной памяти компьютера	Время обработки одного изображения размером 1280×1024 пикселей
С помощью нейронных сетей	Не требуется	Требуется	8–9 мс
На графическом процессоре	Требуется	Требуется	40 мс
С помощью авторских алгоритмов ПАВИКОМ	Не требуется	Не требуется	До 100 мс

БЛАГОДАРНОСТИ

Работа поддержана Российским научным фондом по программе “Проведение фундаментальных научных исследований и поисковых научных исследований отдельными научными группами” (проект № 23-12-00054).

СПИСОК ЛИТЕРАТУРЫ/REFERENCES

1. Alexandrov A. et al. // J. Instrum. 2016. V. 11 (6). P. P06002. <https://doi.org/10.1088/1748-0221/11/06/P06002>
2. Alexandrov A. et al. // Sci. Rep. 2019. V. 9 (1). P. 2870. <https://doi.org/10.1038/s41598-019-39415-8>
3. Ronneberger O. et al. // Proc. Intl. Conf. on Medical Image Computing and Computer-Assisted Intervention. 2015. P. 234. <https://doi.org/10.48550/arXiv.1505.04597>
4. Aleksandrov A.B. et al. // Bull. Lebedev Phys. Inst. 2012. V. 39 (9). P. 269. <https://doi.org/10.3103/S1068335612090059>
5. Alexandrov A. et al. // Measurement. 2022. V. 187. P. 110244. <https://doi.org/10.1016/j.measurement.2021.110244>

Neural Networks for Nuclear Emulsion Processing

V. T. Vasilev¹, N. S. Konovalova¹, N. M. Okateva¹, N. G. Polukhina¹, Zh. T. Sadykov¹, E. N. Starkova¹, N. I. Starkov¹, M. M. Chernyavskiy¹, and T. V. Shchedrina¹, *

¹Lebedev Physical Institute, Russian Academy of Sciences, Moscow, 119991 Russia

*e-mail: tvshchedrina@gmail.com

Received June 4, 2023; revised June 23, 2023; accepted July 28, 2023

Abstract—Due to the development of precision optical and computational techniques, the number of experiments based on visual methods of processing track detector data increases. Application of neural networks for cluster extraction in images obtained with new generation scanning stations will not only speed up processing of images in nuclear emulsions, but also make the track reconstruction process an order of magnitude more efficient.

Keywords: neural network, photographic nuclear emulsion, cluster extraction in images