

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ ОБРАЗОВАТЕЛЬНОЕ
УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЯДЕРНЫЙ УНИВЕРСИТЕТ «МИФИ»
(НИЯУ МИФИ)

УДК 539.12

ПРЕДДИПЛОМНАЯ ПРАКТИКА

НА ТЕМУ

**ПРИМЕНЕНИЕ СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ
РЕКОНСТРУКЦИИ ПОЛОЖЕНИЯ СОБЫТИЯ В
ЭКСПЕРИМЕНТЕ DEAP-3600**

Научный руководитель

к.ф.-м.н.

А. В. Гробов

Студент

А. И. Ильясов

Москва 2021

СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	3
1 Эксперимент DEAP-3600.....	5
2 Машинное обучение.....	8
2.1 Полносвязная нейронная сеть.....	8
2.2 Нейронная сеть с короткими связями.....	9
2.3 Свёрточная нейронная сеть.....	9
3 Существующие на данный момент алгоритмы.....	11
4 Процесс исследования.....	13
РЕЗУЛЬТАТЫ.....	19
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ.....	20

ВВЕДЕНИЕ

Наблюдения за этапами развития Вселенной показали, что Вселенная состоит на $\Omega_\Lambda = 68.5\%$ из темной энергии и на $\Omega_\Lambda = 31.5\%$ из нерелятивистского вещества, из которых $\Omega_\Lambda = 26.5\%$ — темная материя и $\Omega_\Lambda = 5.0\%$ — барионное вещество [1]. Отметим, что темная материя, по всей видимости, состоит из массивных частиц, которые отсутствуют в Стандартной модели физики частиц. Эти частицы — нерелятивистские, почти не взаимодействуют между собой (иначе это привело бы к формированию в основном шарообразных гало, а это противоречит наблюдениям) и не взаимодействуют с фотонами [1].

Сделав предположение о том, что частицы темной материи X находились в термодинамическом равновесии с обычным веществом в ранней Вселенной, можно принять, что эти частицы вышли из равновесия в какой-то момент времени и с тех пор распространяются свободно. Сравнивая температуру закалки $T_{\text{freeze-out}}$ с массой темной материи, разделяют три модели [1]:

- холодная темная материя: $T_f < M_X$, основной кандидат — слабовзаимодействующие массивные частицы - *WIMP*;
- горячая темная материя: $T_f > M_X$, $M_X < 1$ эВ, основной кандидат — нейтрино;
- теплая темная материя: $T_f > M_X$, $M_X > 1$ эВ, основной кандидат — стерильное нейтрино.

Наиболее приемлемым вариантом считается холодная темная материя (cold dark matter), а соответствующая ей пространственно-плоская модель Вселенной — Λ CDM модель [1].

За последние 20 лет создано большое число экспериментов по прямому и косвенному обнаружению темной материи. Косвенный метод основан на попытках измерить вторичные продукты взаимодействия темной

материи. Метод прямого обнаружения предполагает непосредственную регистрацию частиц темной материи в детекторе, обеспечивая низкоэнергетические (<100 кэВ) ядра отдачи. Прогнозируемые скорости столкновений крайне малы и требуют ультранизких фоновых детекторов с большими (1–100 т) мишенями, расположенными глубоко под землей, чтобы исключить мюонный фон.

Жидкие благородные газы обладают множеством свойств, которые делают их подходящими для обнаружения темной материи. Их относительно легко извлечь из атмосферы и очистить, что позволяет создавать большие однородные мишени. В настоящее время жидкий аргон (LAr) и жидкий ксенон (LXe) являются основным выбором для экспериментов с темной материей. Энергия отдачи может быть передана в детектор за счет рассеяния частиц на ядрах (NR) или атомных электронах (ER), и различие между NR и ER имеет важное значение. Это выделение энергии может вызвать возбуждение или ионизацию атомов жидких благородных газов. По параметрам события можно определить тип частицы.

Однако с каждого детектора поступает большое число как сигнальных, так и шумовых и фоновых событий. Очень важно понимать происхождение каждого из них, а для этого не менее важно правильно определять пространственное положение первичного взаимодействия. В данной работе описывается метод реконструкции положения события внутри детектора DEAP-3600 с помощью различных конфигураций нейронной сети.

1 Эксперимент DEAP-3600

DEAP-3600 — это однофазный детектор по поиску темной материи, в котором в качестве мишени используется жидкий аргон (LAr) [2]. Он изображен на рисунке 1 и имеет следующие характеристики и особенности [3]:

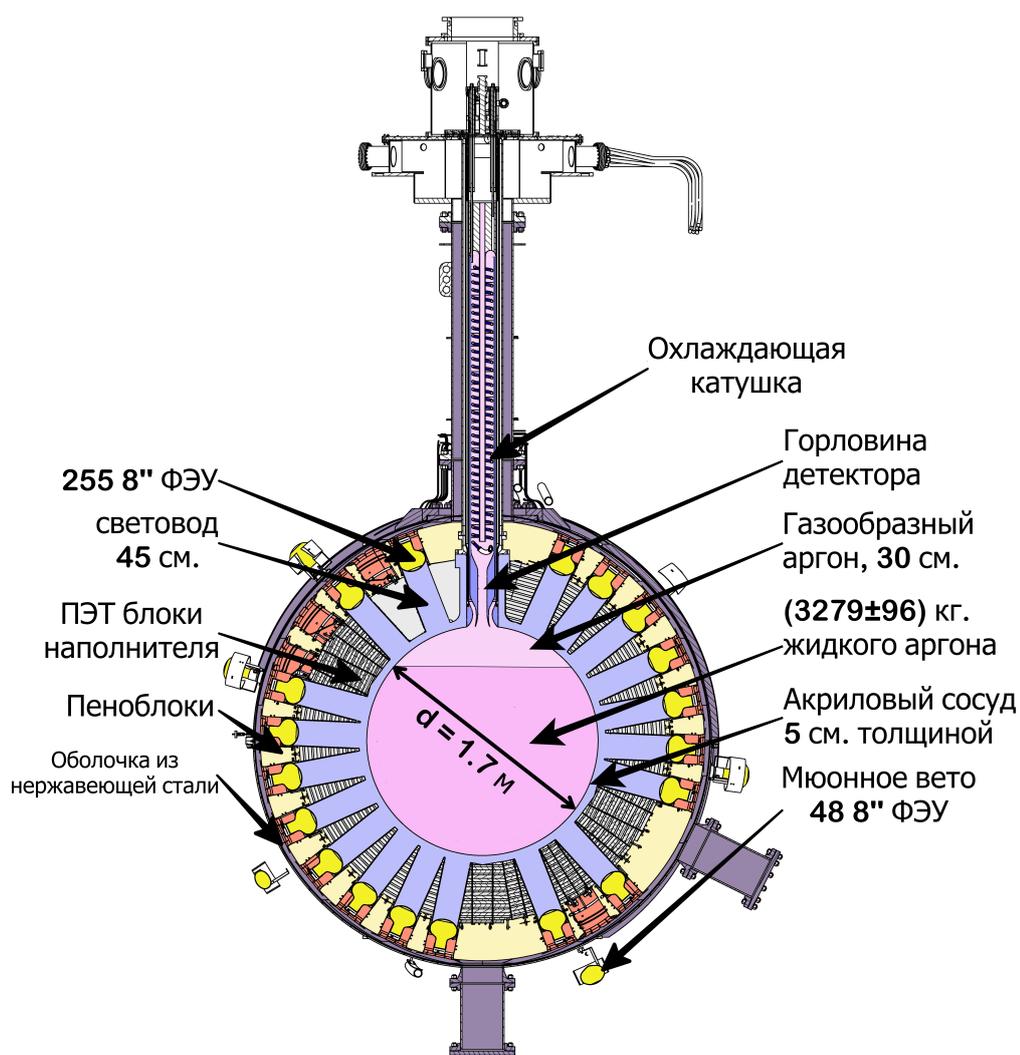


Рисунок 1 – Внутреннее строение детектора DEAP-3600

- а) расположен в лаборатории SNOLAB (Онтарио, Канада) ≈ 2 км под землей;
- б) предел на спин независимое сечение рассеяния частиц темной материи на аргоновой мишени – $3.9 \times 10^{-45} \text{ см}^2$ ($1.5 \times 10^{-44} \text{ см}^2$) для

массы WIMP $100 \text{ ГэВ}/c^2$ ($1 \text{ ТэВ}/c^2$) на уровне достоверности 90% [3];

- в) мишенью является (3279 ± 96) кг. жидкого аргона (LAr). Также имеется 30 см. прослойка газообразного аргона (GAr) вверху детектора;
- г) аргон содержится в отражающем ультрафиолет (тетрафенилбутадиен, TPB) акриловом сосуде (acrylic vessel, AV) толщиной 5 см. с внутренним диаметром 1.7 м.;
- д) события внутри детектора регистрируются 255 8-дюймовыми фотоэлектронными умножителями (ФЭУ) Hamamatsu R5912 HQE с низкой радиоактивностью (рисунок 1);
- е) вверху имеется горловины, который используется для поддержания рабочего объема детектора, охлаждения аргона и использования калибровочных источников;
- ж) основание горловины обернуто в оптические волокна, и в сочетании с 4 дополнительными ФЭУ образуют шейное вето;
- з) нейтронная защита:
 - 1) 45 см. световоды между ФЭУ и акриловым сосудом;
 - 2) пространство между световодами заполнено полиэтиленовыми блоками.
- и) черенковское мюонное вето:
 - 1) детектор заключен в оболочку из нержавеющей стали и погружен в 300 т. чистой воды;
 - 2) на наружной части оболочки из нержавеющей стали расположены 48 ФЭУ.

DEAP-3600 — это один из немногих в мире детекторов по прямому обнаружению темной материи, использующих жидкий благородный газ в

качестве мишени. Благодаря сцинтилляции жидкого аргона детектор обладает мощным свойством разделения по форме импульса, позволяющим эффективно идентифицировать ядерные отдачи взаимодействия частиц темной материи от фоновых отдач электронов [2].

В настоящий момент времени для реконструкции положения события в детекторе используется два метода [3] на основе распределения фотоэлектронов и на основе временного распределения фотоэлектронов. Оба алгоритма эффективны. В данной работе описывается несколько методов на основе нейронных сетей для улучшения имеющего результата.

2 Машинное обучение

В работе используется три принципиально разных алгоритма машинного обучения.

2.1 Полносвязная нейронная сеть

Нейронная сеть — это алгоритм машинного обучения, в котором существует входной слой, в котором количество нейронов эквивалентно количеству параметров события, выходной слой, в котором количество нейронов соответствует количеству определяемых переменных, и любого количества “скрытых” слоев, в котором может быть любое количество нейронов. Полносвязная нейронная сеть — это нейронная сеть, в котором каждый нейрон слоя связан со всеми нейронами следующего слоя. Эти связи являются весовыми значениями и настраиваются в течение обучения. Пример полносвязной нейронной сети представлен на рисунке 2.

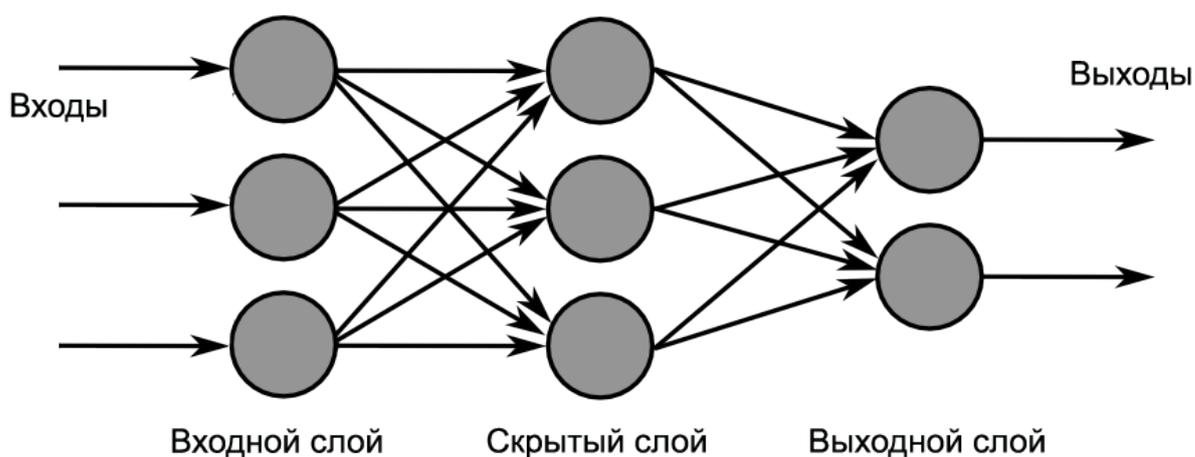


Рисунок 2 – Пример полносвязной нейронной сети

Основным слоем в такой структуре является полносвязный (*Dense*) слой. В качестве аргументов он имеет значение количества нейронов в данном слое и функцию активации. Этой функции передается вектор размерности предыдущего скрытого или входного слоя, по результатам вычислений выдается значение, которое передается на следующий слой. В данной работе использовались две функции активации: “reLU” и “linear”, которые

выражаются следующим образом:

$$f_{reLU}(x) = \begin{cases} 0, & x < 0, \\ x, & x > 0 \end{cases}, \quad f_{linear}(x) = x \quad (1)$$

2.2 Нейронная сеть с короткими связями

Нейронная сеть с короткими (*shortcut*) связями [4; 5] — это нейронная сеть, в которой выходной вектор с какого-либо слоя передается на более чем один последующий слой. Преимуществом такой сети перед полносвязными является тот факт, что в процессе обучения модель на последних слоях не теряет информацию, которая могла быть получена на более ранних слоях. Недостатками такого алгоритма является необходимость соответствия длин векторов начального и конечного слоя *shortcut* соединения, а также более высокое время работы сети. Пример такой сети представлен на рисунке 3.

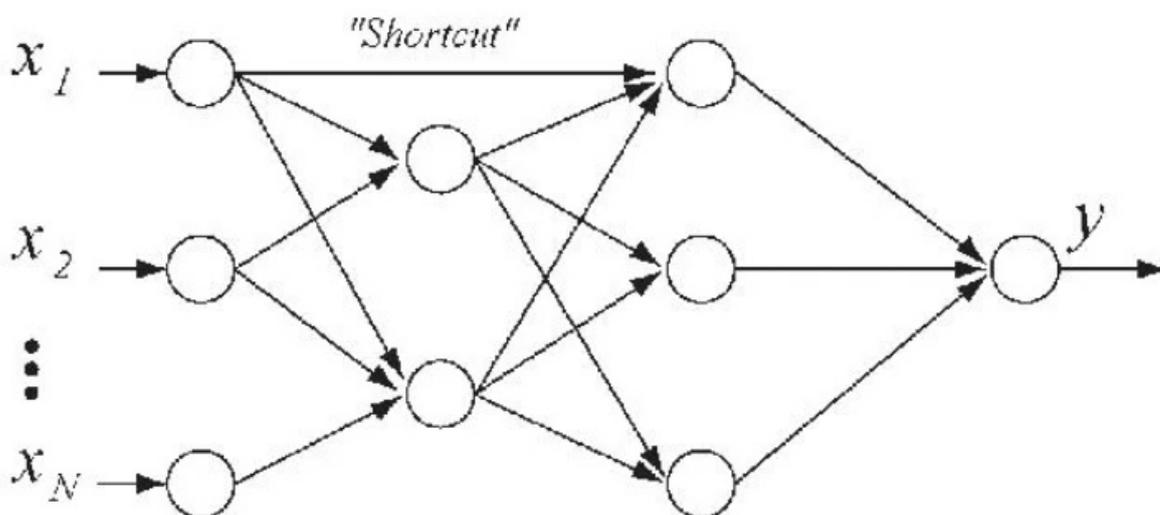


Рисунок 3 – Пример нейронной сети с короткими связями

2.3 Свёрточная нейронная сеть

Свёрточная нейронная сеть [6; 7] — это алгоритм глубокого обучения, который используется для нахождения шаблонов во входных данных. Эти сети основаны на слоях свёртки — они математически сворачивают входную матрицу в матричное представление с определенным набором

ядер. Каждое ядро призвано подчеркнуть определенные особенности входной матрицы. После последовательности этих слоев результат выравнивается и распространяется на полносвязную нейронную сеть. Пример работы свёрточного слоя представлен на рисунке 4.

Основными слоями в данной модели служили: *Conv1D* — выполняли свертку входного слоя с разными ядрами для обнаружения основных характеристик входных данных, *flatten* — для преобразования матрицы в вектор для дальнейшего использования его в полносвязной нейронной сети и *Dense* — для окончательного определения координаты.

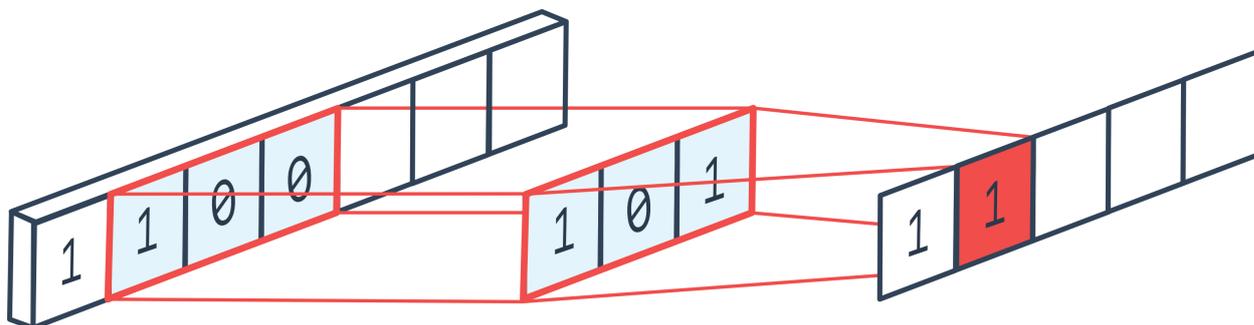


Рисунок 4 – Пример работы ядра свёрточной нейронной сети

3 Существующие на данный момент алгоритмы

В эксперименте DEAP-3600 на данный момент используется два алгоритма реконструкции положения [3]:

- а) метод, основанный на распределении фотоэлектронов [3]. Он основан на вычислении вероятности $\ln \mathcal{L}(\vec{x})$ того, что событие произошло в некоторой позиции x :

$$\ln \mathcal{L}(\vec{x}) = \sum_{i=1}^{N_{\text{PMTs}}} \ln \text{Poisson}(q_i, \lambda_i), \quad \lambda_i = \lambda_i \left(|\vec{x}|, \frac{\vec{x} \cdot \vec{r}_i}{|\vec{x}| |\vec{r}_i|}, q_{\text{total}} \right), \quad (2)$$

где $\text{Poisson}(q_i, \lambda_i)$ — Пуассоновская вероятность обнаружить q_i фотоэлектронов в ФЭУ i в позиции \vec{r}_i в течение всего окна событий 10 мкс. Ожидаемое количество фотоэлектронов в ФЭУ i определяется как λ_i , которое является функцией радиуса тестового положения $|\vec{x}|$, угла между тестовым положением и ФЭУ i и общего количества фотоэлектронов q_{total} .

- б) метод, основанный на временной невязке [3]. Данный метод использует информацию о заряде и времени ранних импульсов в событии для вычисления положения. Временные остатки определяются как время, в которое был обнаружен РЕ, сверх того, что предполагает время пролета. Перед обработкой данных внутри жидкого аргона определяется сетка тестовых позиций \vec{x}_j относительно местоположения ФЭУ, и вычисляются временные остатки $\mathcal{L}^{\text{t res}} = (\Delta t, \vec{x}_j, \text{PMT}_i)$. Вероятность для заданного времени события t_0 и тестового положения \vec{x}_0 вычисляется следующим образом:

$$\ln \mathcal{L}(t_0, \vec{x}_0) = \sum_{i=1}^{N_{\text{PE}}} \ln \mathcal{L}^{\text{t res}}(t_i - t_0; \vec{x}_0, \text{PMT}_i), \quad (3)$$

где t_i — время, в которое фотоэлектрон i было обнаружен в ФЭУ $_i$.

После выделения чувствительного объема до 630 мм на основе первого алгоритма данные и моделирование согласуются с точностью до 13%.

Оба алгоритма согласуются для событий ^{39}Ar в данных и для моделирования отдачи ^{40}Ar , возвращая z-координаты, которые согласуются с точностью до 35 мм для 50% событий. Свет от событий, которые происходят в горловине распространяется на нижнюю часть детектора, заставляя алгоритм на основе фотоэлектронов восстанавливать его с низкой координатой Z, в то время как алгоритм на основе временных остатках систематически восстанавливает эти события ближе к верху детектора. В результате второй алгоритм восстанавливает эти события в среднем на 290 мм выше, чем первый.

4 Процесс исследования

Ход работы был следующим:

- а) с помощью данных, полученных в результате Монте-Карло моделирования детектора DEAR-3600 получены root-файлы, которые содержат в себе информацию о величине и времени прихода импульса в каждый фотоэлектронный умножитель;
- б) с помощью root-файлов была создана база данных, которая содержит 765 столбцов и 600 тысяч строк. Каждый столбец — параметр события, каждая строка — отдельное событие. Распределение смоделированных координат $X - Y - Z$ событий представлено на рисунке 5;

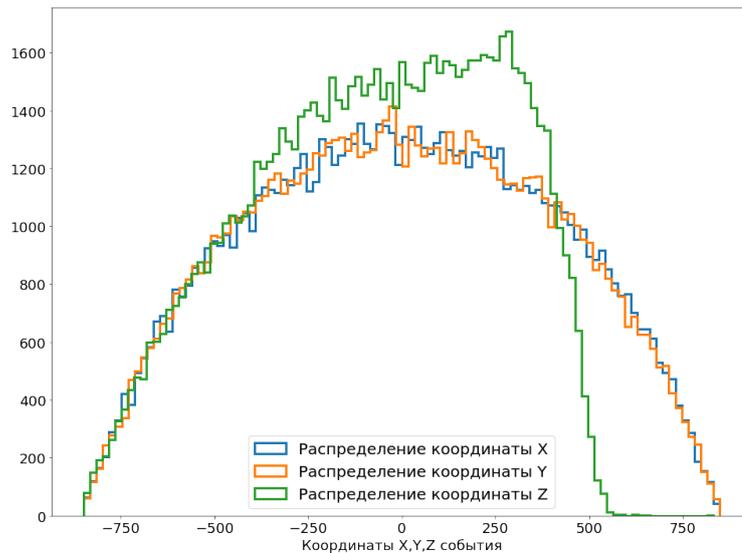


Рисунок 5 – Распределение координат X, Y, Z Монте-Карло моделирования. Необычное распределение координаты Z объясняется прослойкой газообразного аргона вверху детектора

- в) параметры событий следующие:
 - 1) 255 значений импульсов в каждом фотоэлектронном умножителе;
 - 2) по 255 значений времени начала и окончания импульса в каждом ФЭУ, отнормированное на временное окно;

г) было рассмотрено несколько конфигураций слоёв нейронной сети, а также несколько областей детектора с применяемым физическим ограничением на радиус рабочего объема детектора. Количество событий N в каждой из областей указаны в таблице 1.

Таблица 1 – Количество событий N , оставшееся после применения ограничения на радиус рабочего объема детектора R

	$R < 430$	$R < 630$	$R < 720$	$R < 850$
$N, 10^3$	107	300	426	677
	$200 < R < 430$	$430 < R < 630$	$630 < R < 720$	$720 < R < 850$
$N, 10^3$	96	193	126	251

В работе использовались следующие структуры нейронных сетей:

а) Обычная полносвязная сеть с входным слоем и 4 скрытыми слоями. Структура этой сети и ее параметры указаны на рисунке 6. На рисунке 7 представлены графики ошибок по координатам X, Y, Z и по R ;

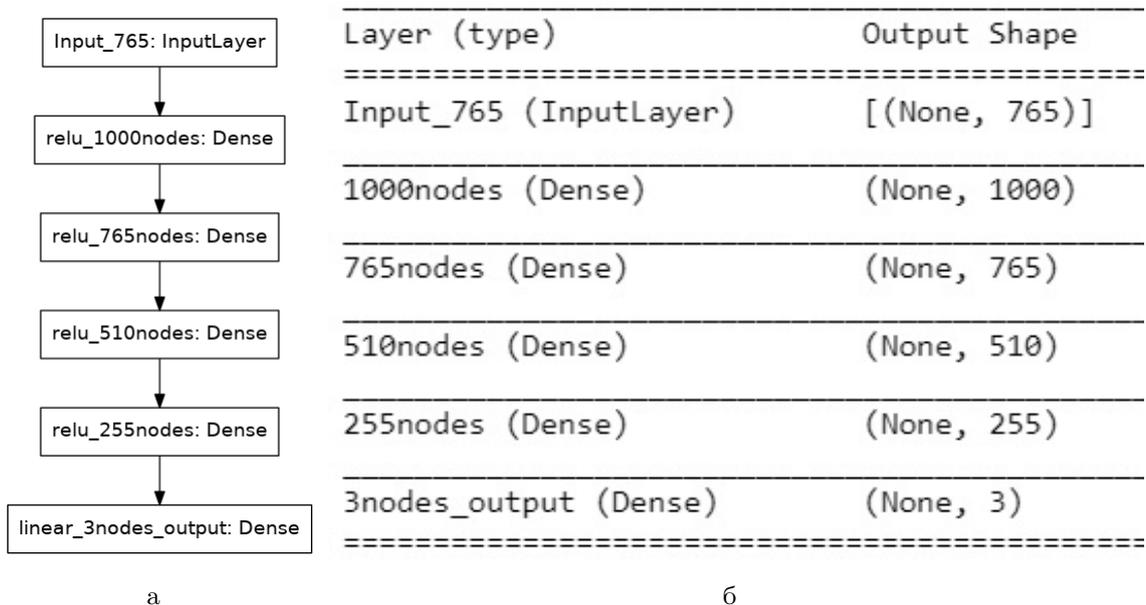


Рисунок 6 – Полносвязная нейронная сеть: **а** — схема слоёв, **б** — структура данных внутри сети

б) *Shortcut* структура нейронной сети. Это модель, в которой некоторые слои могут пропускаться и выходной вектор после очередного

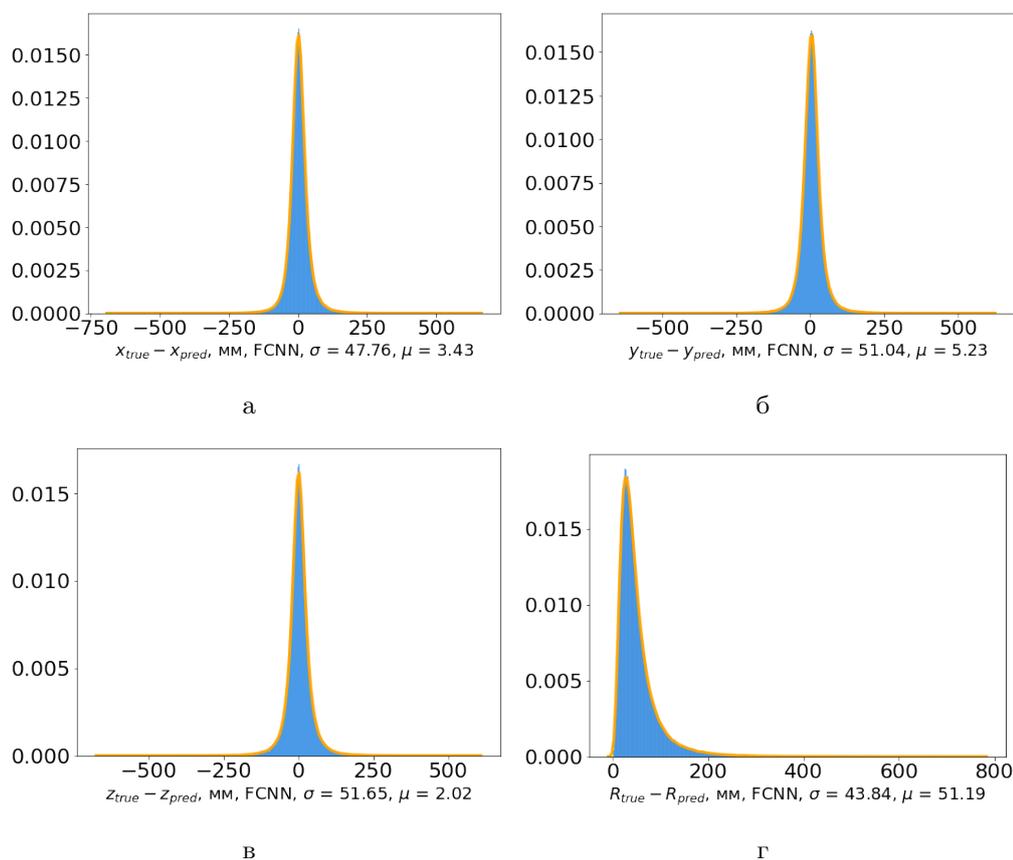
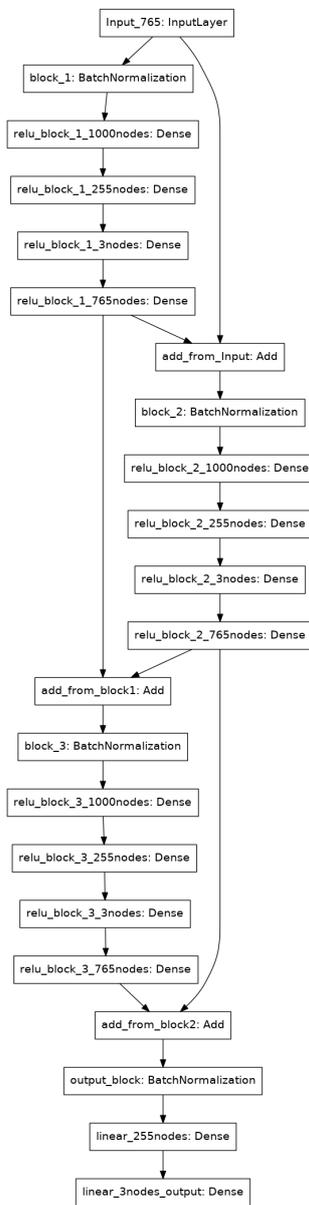


Рисунок 7 – Ошибка полносвязной нейронной сети в определении координаты X (а), Y (б), Z (в) и R (г) при $R < 850$

слоя подается на несколько последующих слоёв одновременно. В данной работе использовалась блочная структура сети и на входной слой нового блока подавался также входной вектор предыдущего блока. Структура такой сети и ее конфигурация указаны на рисунке 8. На рисунке 9 представлены графики ошибок по координатам X , Y , Z и по R ;

- в) Структура сети со свёрточными слоями. В такой сети в свёрточных слоях $Conv1D$ ядро заданной размерности проходит с заданным шагом через весь вектор и находит определенные шаблоны во входном векторе. Создается многомерная матрица с результатом такого поиска, которая затем с помощью сглаживающего слоя $flatten$ преобразуется в вектор единичной размерности и этот вектор проходит через полносвязную $Dense$ нейронную сеть. Пример такой сети указан на рисунке 10. На рисунке 11 представлены графики ошибок по координатам X , Y , Z и по R .



а

Layer (type)	Output Shape
Input_765 (InputLayer)	[(None, 765)]
block_1 (BatchNormalization)	(None, 765)
block_1_1000nodes (Dense)	(None, 1000)
block_1_255nodes (Dense)	(None, 255)
block_1_3nodes (Dense)	(None, 3)
block_1_765nodes (Dense)	(None, 765)
add_from_input (Add)	(None, 765)
block_2 (BatchNormalization)	(None, 765)
block_2_1000nodes (Dense)	(None, 1000)
block_2_255nodes (Dense)	(None, 255)
block_2_3nodes (Dense)	(None, 3)
block_2_765nodes (Dense)	(None, 765)
add_from_block1 (Add)	(None, 765)
block_3 (BatchNormalization)	(None, 765)
block_3_1000nodes (Dense)	(None, 1000)
block_3_255nodes (Dense)	(None, 255)
block_3_3nodes (Dense)	(None, 3)
block_3_765nodes (Dense)	(None, 765)
add_from_block2 (Add)	(None, 765)
output_block (BatchNormalization)	(None, 765)
255nodes (Dense)	(None, 255)
3nodes_output (Dense)	(None, 3)

б

Рисунок 8 – *Shortcut* нейронная сеть: а — схема слоёв, б — структура данных внутри сети

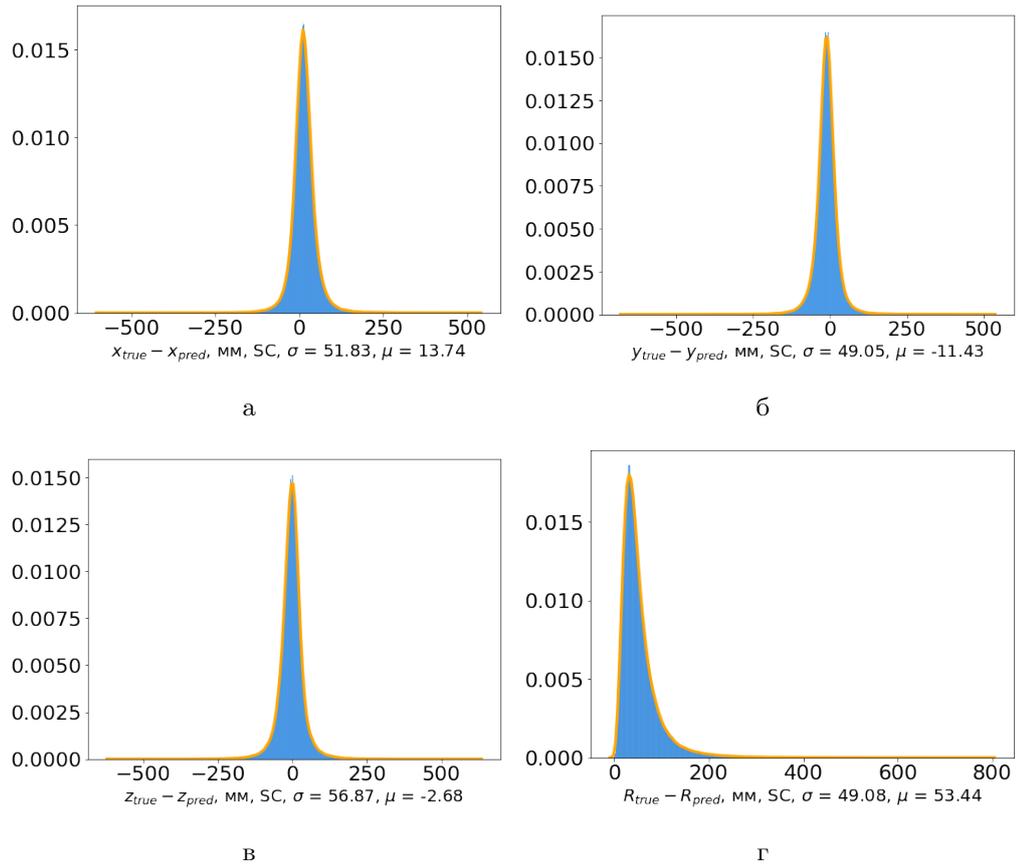


Рисунок 9 – Ошибка *shortcut* нейронной сети в определении координаты X (а), Y (б), Z (в) и R (г) при $R < 850$

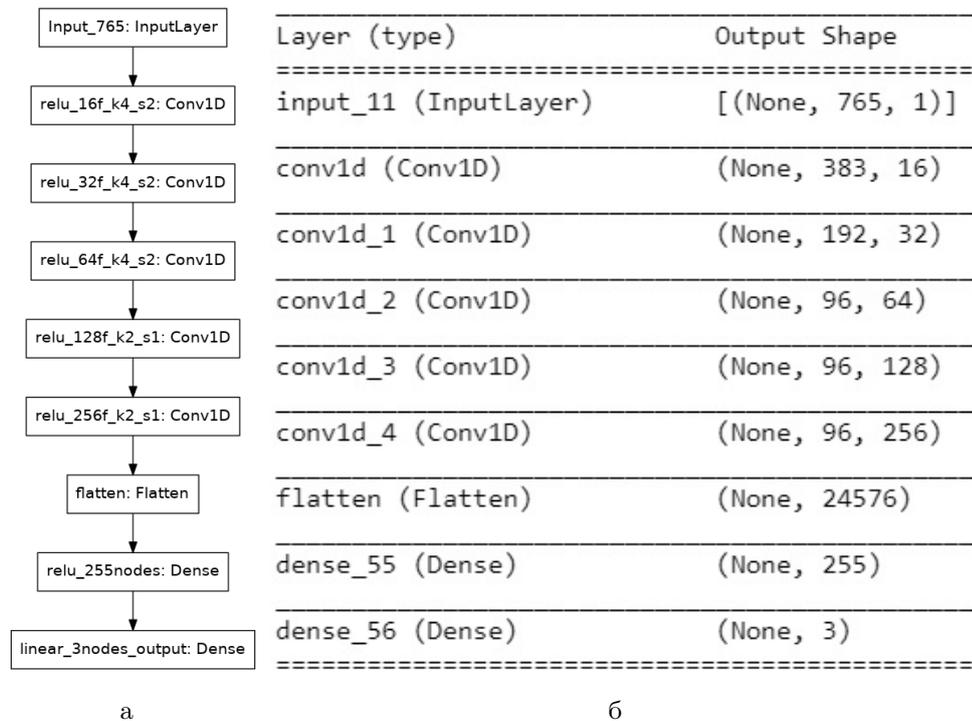


Рисунок 10 – Нейронная сеть со свёрточными слоями: а — схема слоёв, б — структура данных внутри сети

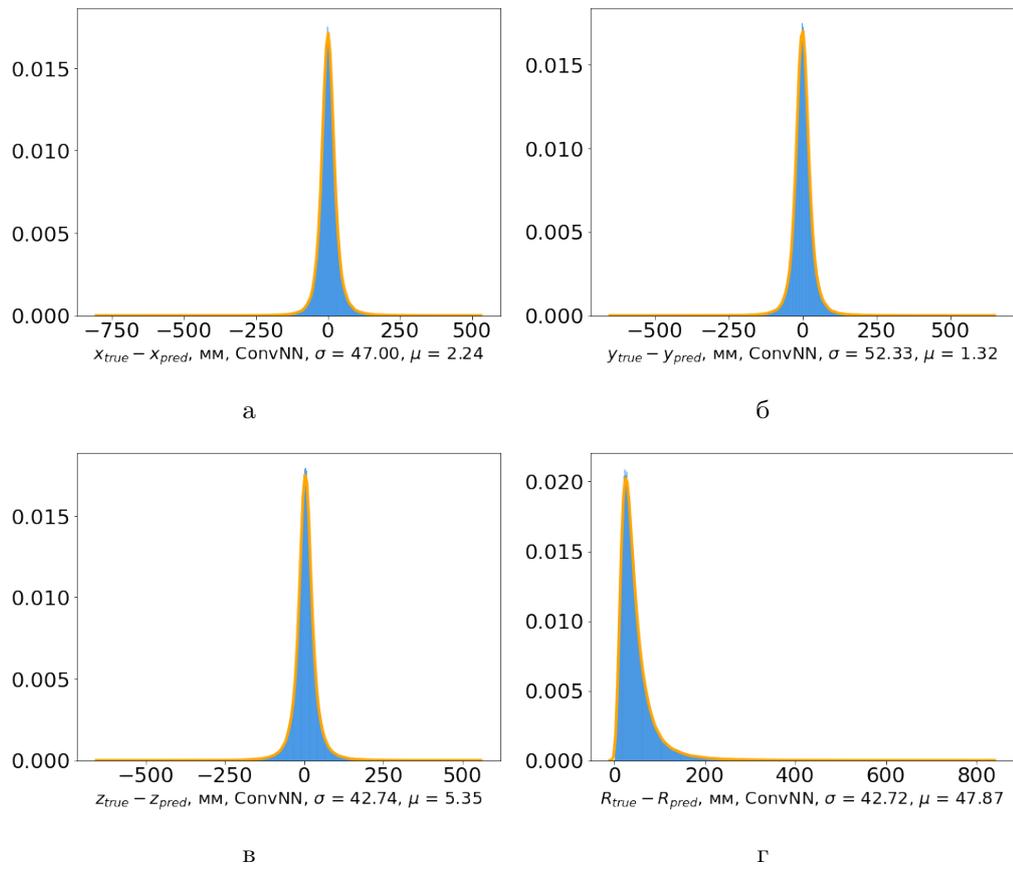


Рисунок 11 – Ошибка нейронной сети со свёрточными слоями в определении координаты X (а), Y (б), Z (в) и R (г) при $R < 850$

РЕЗУЛЬТАТЫ

Для каждой сети построены среднеквадратичные ошибки на тренировочном и тестовом наборе (рисунок 12), построены гистограммы ошибок (рисунки 7, 9, 11), посчитаны окончательные погрешности в определении координат $X-Y-Z$ событий для каждой модели. Результаты всех моделей для различных физических ограничений представлены в таблице 2.

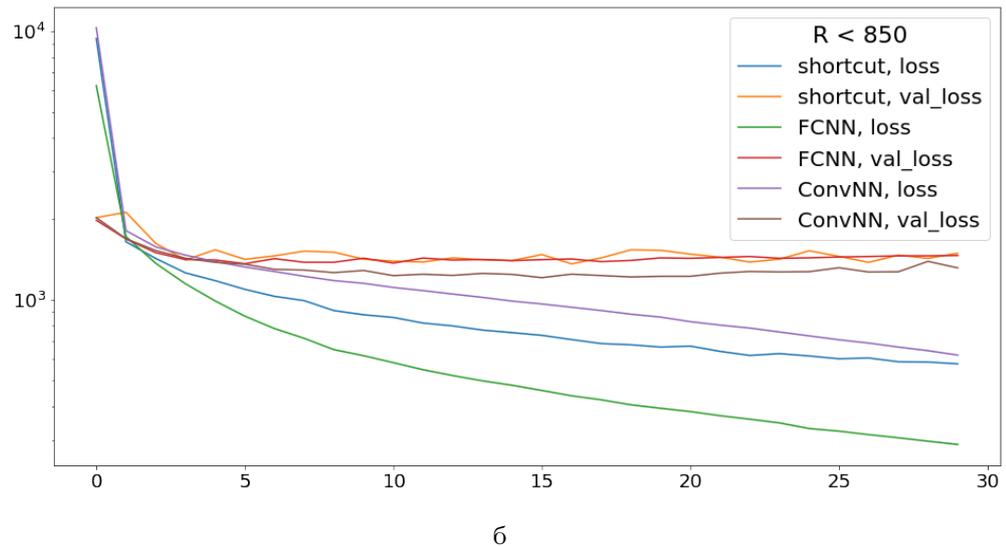
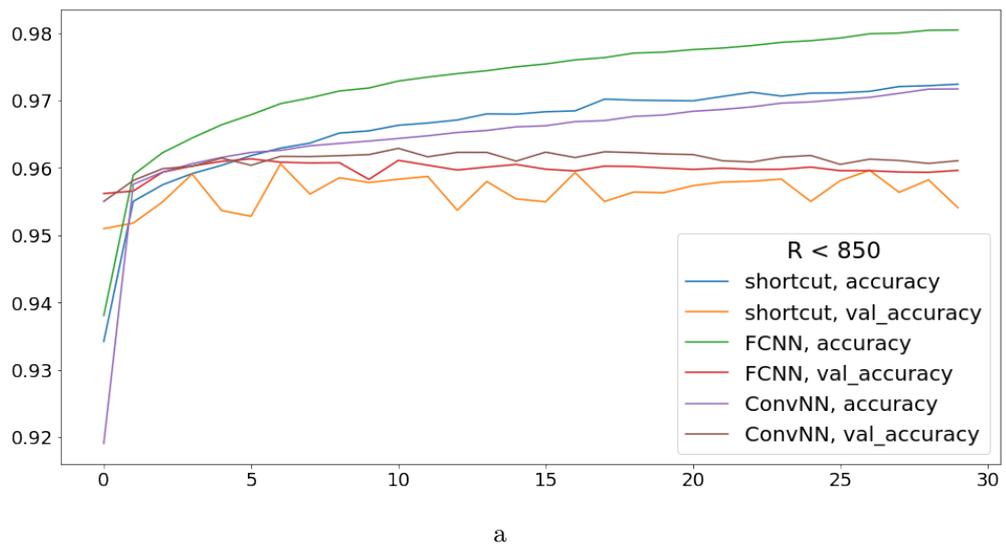


Рисунок 12 – Точность **a** и среднеквадратичная ошибка **б** на тренировочном и тестовом наборе для всех трех типов сетей при $R < 850$

Окончательные выводы следующие:

Таблица 2 – Погрешности для координат X , Y , Z для каждой рассматриваемой области параметра R . $\text{FWHM} = 2.355 \sigma$

	Точность	X_{FWHM} , мм	Y_{FWHM} , мм	Z_{FWHM} , мм
$R < 850$	0.959 ± 0.003	47 ± 4	49 ± 3	51 ± 7
$R < 720$	0.944 ± 0.001	64 ± 3	64 ± 7	66 ± 2
$R < 630$	0.933 ± 0.002	75 ± 3	76 ± 6	78 ± 2
$R < 430$	0.899 ± 0.007	91 ± 7	92 ± 8	105 ± 15
$720 < R < 850$	0.983 ± 0.003	41 ± 9	42 ± 8	42 ± 9
$630 < R < 720$	0.966 ± 0.005	55 ± 5	55 ± 8	42 ± 5
$430 < R < 630$	0.952 ± 0.002	79 ± 10	77 ± 8	58 ± 2
$200 < R < 430$	0.913 ± 0.004	90 ± 5	88 ± 3	98 ± 7

- а) хуже всего реконструируются события в центральной области детектора ($R < 430$) в связи с тем, что значения импульсов, пришедших в каждый ФЭУ практически не отличается от события к событию;
- б) лучше всего алгоритм работает на внешнем слое детектора ($720 < R < 850$) выдавая ошибку около 40 мм. и во всём объеме детектора ($R < 850$) со средней ошибкой около 50 мм.;
- в) для более точной работы модели в центре детектора необходимо увеличивать статистику или конструировать новые переменные.

Дальнейшие планы работы:

- а) Увеличить статистику событий Монте-Карло моделирования или использовать более новую версию Монте-Карло;
- б) сконструировать новые переменные. На данный момент уже в работе две новые переменные, связанные с ранним сигналом в ФЭУ (за первые 40 нс) и поздним сигналом (за последние 100 нс);
- в) опробовать новые методики построения сетей. На данный момент в разработке *stacking* модель, в которой предсказание от нескольких натренированных алгоритмов подается на вход новой, еще не тренированной модели. Так можно настроить реконструкцию положения события для различных частей детектора.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Горбунов Д. С., Рубаков В. А. Введение в теорию ранней Вселенной. Теория горячего Большого взрыва. — Российская акад. наук, Ин-т ядерных исслед., 2007.
2. *Amaudruz P.-A.* [et al.]. Design and construction of the DEAP-3600 dark matter detector // *Astroparticle Physics*. — 2019. — Vol. 108. — P. 1–23.
3. *Collaboration D.* Search for dark matter with a 231-day exposure of liquid argon using DEAP-3600 at SNOLAB // *Physical Review D*. — 2019. — Vol. 100, no. 2. — P. 022004.
4. *Li Y.* [et al.]. A concatenating framework of shortcut convolutional neural networks // arXiv preprint:1710.00974. — 2017.
5. *Geirhos R.* [et al.]. Shortcut learning in deep neural networks // *Nature Machine Intelligence*. — 2020. — Vol. 2, no. 11. — P. 665–673.
6. *Matsugu M.* [et al.]. Subject independent facial expression recognition with robust face detection using a convolutional neural network // *Neural Networks*. — 2003. — Vol. 16, no. 5/6. — P. 555–559.
7. *LeCun Y.* [et al.]. Backpropagation applied to handwritten zip code recognition // *Neural computation*. — 1989. — Vol. 1, no. 4. — P. 541–551.