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

ИНСТИТУТ ЯДЕРНОЙ ФИЗИКИ И ТЕХНОЛОГИЙ КАФЕДРА №40 «ФИЗИКА ЭЛЕМЕНТАРНЫХ ЧАСТИЦ»

На правах рукописи

ЗАРЕЦКИЙ НИКИТА ДМИТРИЕВИЧ

МОДЕЛИРОВАНИЕ СИГНАЛОВ ПОЛУПРОВОДНИКОВЫХ ГЕРМАНИЕВЫХ ДЕТЕКТОРОВ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ЭКСПЕРИМЕНТА LEGEND

Направление подготовки 14.04.02 «Ядерная физика и технологии» Диссертация на соискание степени магистра

Научный руководитель, д.ф.-м.н., проф.

_____ М. Д. Скорохватов

Научный консультант

_____ А. Е. Черногоров

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА МАГИСТРА

МОДЕЛИРОВАНИЕ СИГНАЛОВ ПОЛУПРОВОДНИКОВЫХ ГЕРМАНИЕВЫХ ДЕТЕКТОРОВ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ЭКСПЕРИМЕНТА LEGEND

Студент	Н. Д. Зарецкий		
Научный руководитель,			
д.фм.н., проф.	М. Д. Скорохватов		
Научный консультант	А. Е. Черногоров		
Рецензент,			
к.фм.н., с.н.с.	К. Н. Гусев		
Секретарь ГЭК,			
к.фм.н.	А. А. Кириллов		
Зав. каф. №40,			
д.фм.н., проф.	М. Д. Скорохватов		
Рук. учеб. прог.,			
д.фм.н., проф.	М. Д. Скорохватов		

СОДЕРЖАНИЕ

Bı	зедеі	ние	5
1	Физ	зика нейтрино	7
	1.1	Возможные расширения Стандартной Модели	7
		1.1.1 Массовые члены нейтрино	8
		1.1.2 Безнейтринный двойной бета распад $(0\nu\beta\beta)$	10
	1.2	Детектирование $0\nu\beta\beta$ с помощью германиевых детекторов	12
2	Экс	сперименты GERDA и LEGEND	13
	2.1	GERDA	14
	2.2	LEGEND	14
	2.3	Германиевые детекторы	16
		2.3.1 Взаимодействие частиц с веществом	16
		2.3.2 HPGe детекторы	18
3 Разделение сигналов по форме импульса в эксперимент			
GERDA и LEGEND			22
	3.1	Разделение сигналов по форме импульса для детекторов типа	
		Broad Energy Germanium и Inverted Coaxial Point-Contact	22
	3.2	Разделение сигналов по форме импульса для полукоаксиаль-	
		ных детекторов	24
4	Kaj	ибровка детекторов LEGEND	26
5	Прі	инцип работы нейронной сети	27
	5.1	Сверточные нейронные сети	27
	5.2	Метод главных компонент	28

6	Ген	еративно-состязательная сеть	30		
	6.1	Алгоритм «Minimax»	31		
	6.2	Алгоритм «Wasserstein»	32		
	6.3	Автокодировщик	33		
7	Дис	ффузионная модель	35		
8	8 Моделирование сигналов для детекторов типа Inverted Coaxial				
	Poi	nt-Contact эксперимента LEGEND	37		
	8.1	Генеративно-состязательная сеть без использования автокоди-			
		ровщика	39		
		8.1.1 Алгоритм «Minimax»	39		
		8.1.2 Алгоритм «Wasserstein-gp»	41		
	8.2	Генеративно-состязательная сеть с использованием автокоди-			
		ровщика	42		
		8.2.1 Алгоритм «Minimax» с применением автокодировщика .	43		
		8.2.2 Алгоритм «Wasserstein-gp» с применением автокодиров-			
		щика	44		
	8.3	Алгоритм «Minimax» с применением метода главных компонент	46		
	8.4	Диффузионная модель	49		
	8.5	Обучение нейронных сетей на данных, полученных на герма-			
		ниевых детекторах другой конфигурации	50		
	8.6	Оценка эффективности модели	53		
За	клю	чение	56		
C	писо	к использованных источников	57		

ВВЕДЕНИЕ

Гипотеза о существовании нейтрино была выдвинута В.Паули в начале XX века в качестве объяснения нарушения закона сохранения энергии в β -распаде. В дальнейшем его существование было обосновано как теоретически, так и экспериментально. С открытием нейтринных осцилляций стало очевидно, что нейтрино обладают массой, однако природа ее образования остается неизвестной. Безнейтринный двойной бета распад ($0\nu\beta\beta$) — гипотетический процесс, в котором при одновременном распаде двух нейтронов в ядре не испускаются антинейтрино — может стать ключом к пониманию ключевых свойств нейтрино. Так, обнаружение этого процесса укажет на то, что нейтрино является частицей Майораны, то есть неотличимой от своей античастицы.

Таким образом, поиск безнейтринного двойного бета распада является одной из важнейших тем современной физики частиц. Помимо указания на майорановскую природу нейтрино, такой процесс может происходить только с нарушением закона сохранения лептонного числа, поэтому его обнаружение однозначно продемонстрирует существование более полной физической теории, чем Стандартная Модель. Поиск $0\nu\beta\beta$ ведется на многих экспериментах в течение более 30 лет, однако свидетельства его существования пока не были обнаружены. Вне зависимости от эксперимента, поиск основан на веществах, изотопы которых способны испытывать двухнейтринный двойной бета распад $2\nu\beta\beta$ — тоже редкий ($T_{1/2}^{2\nu} \sim 10^{21}$ лет), но наблюдаемый в природе процесс. По последним данным [1], полученным на завершившем работу эксперименте GERDA, $T_{1/2}^{0\nu} > 10^{26}$ лет. В настоящий момент начал набор данных эксперимент LEGEND, ведущий поиск $0\nu\beta\beta$ на германиевых детекторах, обогащенных способным испытывать 2
uetaetaизотопе $^{76}{
m Ge}$. Так как безнейтринный и двухнейтринный распады являются крайне редкими процессами, эксперимент LEGEND использует различные техники по подавлению фона, одной из которых является разделение сигнальных и фоновых событий по форме

импульса (PSD - Pulse Shape Discrimination).

Целью настоящей работы является разработка алгоритма машинного обучения на основе нейронных сетей для моделирования сигнала для ICPC (Inverted Coaxial Point-Contact) детекторов эксперимента LEGEND. Мотивацией являлось предположение, что моделирование событий с помощью нейронных сетей может стать дополнением или альтернативой Монте-Карло моделированию, а также что синтезированные сетью события (в случае успешного моделирования) могут быть использованы для уточнения и проверки критериев отбора, используемых в эксперименте для отбора событий по форме импульса. Также успешная модель машинного обучения может быть обобщена на другие эксперименты. В рамках данной цели ставились следующие задачи:

- Подбор архитектуры и алгоритма генеративно-состязательной нейронной сети и обучение ее на калибровочных данных, полученных на детекторах типа ICPC.
- Обучение диффузионной модели на калибровочных данных, полученных на детекторах типа ICPC.
- Выбор наилучшей модели и обобщение ее работы на данных, полученных для другого типа германиевых детекторов в Объединенном институте ядерных исследований, как дополнительный критерий приемлемой работы нейронной сети и возможности обобщения задачи моделирования за рамками эксперимента LEGEND.

1 ФИЗИКА НЕЙТРИНО

1.1 ВОЗМОЖНЫЕ РАСШИРЕНИЯ СТАНДАРТНОЙ МОДЕЛИ

Материя состоит из фермионов (т.е. частиц со спином $s = \frac{1}{2}$), а с помощью калибровочных бозонов со спином s = 1 в Стандартной Модели (СМ) осуществляется их взаимодействие. Фермионы, не участвующие в сильном взаимодействии, называются лептонами (с лептонным числом L = 1); а фермионы, которые участвуют в сильном взаимодействии, называются адронами (в состав которых входят кварки). Частицы в СМ показаны на рисунке 1.1. В СМ предусмотрено, что нейтрино не имеют массы и являются лептонами, поэтому участвуют только в слабом взаимодействии. Типичным слабым процессом является β -распад: $n \to p + e^- + \bar{\nu}_e$. Было также экспериментально выяснено, что антинейтрино являются правополяризованными (то есть их спин сонаправлен с направлением движения), а нейтрино являются левополяризованными (то есть их спин направлен против направления движения) [2]. Концепция спиральности не является Лоренц-инвариантной, так как для любой массивной частицы можно найти такую систему отсчета, в которой импульс будет направлен в противоположную сторону, то есть спиральность будет иметь другой знак. Таким образом, любая массивная частица будет суперпозицией левого и правого состояний.

Лагранжиан нейтрино, соответствующий СМ, может быть записан следующим образом [3]:

$$\mathcal{L}_{\nu}^{SM} = \sum_{\alpha=\mu,e,\tau} \left[\bar{\nu}_{\alpha L} i \partial \!\!\!\!/ \nu_{\alpha L} + \frac{g}{\sqrt{2}} \left(W_{\mu}^{+} \bar{\nu}_{\alpha L} \gamma^{\mu} l_{\alpha L} + h.c \right) + \frac{g}{2\cos\theta_{w}} Z_{\mu} \bar{\nu}_{\alpha L} \gamma^{\mu} \nu_{\alpha L} \right].$$
(1.1)

Первое слагаемое является кинетическим членом, далее идут слагаемые, описывающие взаимодействие. Если у нейтрино есть масса, на что указывает

generation	Ι	II	III		
quarks					
	up	charm	top		
mass [MeV]	2.3	1275	173.21×10^3		
charge [e]	$\frac{2}{3}$	$\frac{2}{3}$	$\frac{2}{3}$		
	down	strange	bottom		
mass [MeV]	4.8	95	4180		
charge [e]	$-\frac{1}{3}$	$-\frac{1}{3}$	$-\frac{1}{3}$		
leptons					
	e	μ	au		
mass [MeV]	0.511	105.7	1776.82		
charge	1	1	1		
	ν_e	ν_{μ}	ν_{τ}		
mass					
charge	0	0	0		
gauge bosons					
	\mathbf{Z}^{0}	\mathbf{W}^{\pm}	γ	gluons	
mass [MeV]	91.19×10^3	80.39×10^3			
charge	0	± 1	0	0	
Higg bosons					
	Higgs				
mass [MeV]	125.09×10^3				
charge	0				

Рисунок 1.1 – Частицы СМ

открытие нейтринных осцилляций, то в лагранжиан должен быть добавлен массовый член.

1.1.1 МАССОВЫЕ ЧЛЕНЫ НЕЙТРИНО

Для расширения CM, с помощью которого можно было бы учесть наличие массы у нейтрино, в лагранжиан для нейтрино следует добавить массовую компоненту, которая по определению содержит волновую функцию правого нейтрино:

$$\mathcal{L}_m = m_D \bar{\psi} \psi = m_D (\bar{\psi}_L \psi_R + \bar{\psi}_R \psi_L). \tag{1.2}$$

Правополяризованного нейтрино не существует в CM, поэтому есть два варианта решения этой проблемы:

• Вариант Дирака заключается в том, чтобы добавить в СМ правое нейтрино, которое не участвует в калибровочных взаимодействиях. То-

гда массовая компонента будет записана так:

$$\mathcal{L}_m = m_D \bar{\nu} \nu = m_D (\bar{\nu}_L \nu_R + \bar{\nu}_R \nu_L). \tag{1.3}$$

Массы нейтрино тогда появляются за счет механизма Хиггса, как в Стандартной Модели. Этот механизм не объясняет малую величину массы нейтрино.

• Вариант Майораны заключается в предположении, что $\nu_R = (\nu_L)^C$, то есть нейтрино является своей собственной античастицей (такие частицы называются майорановскими частицами). Другими словами, различие между нейтрино и антинейтрино определяется только спиральностью, то есть превращение одного в другое можно осуществить переворотом спина. Тогда массовая компонента будет записана так:

$$\mathcal{L}_m = \frac{1}{2} m_L (\bar{\nu_L^c} \nu_L + \bar{\nu_L} \nu_L^c) + \frac{1}{2} m_R (\bar{\nu_R^c} \nu_R + \bar{\nu_R} \nu_R^c).$$
(1.4)

Этот механизм работает для истинно нейтральных частиц. Компонента $\bar{\nu}_L^c \nu_L$ запрещена в СМ. В этом случае также не сохраняется лептонное число [3].

Обычно рассматривают механизм **seesaw** образования массы нейтрино. В этом механизме используются оба массовых члена и вводится майорановское правое нейтрино, являющееся истинно нейтральной частицей, не испытывающей калибровочных взаимодействий. Для одного аромата массовый член теперь запишется в следующем виде:

$$\mathcal{L}_{m} = m_{D}(\bar{\nu}_{L}\nu_{R} + \bar{\nu}_{R}\nu_{L}) + \frac{1}{2}m_{L}(\bar{\nu}_{L}^{c}\nu_{L} + \bar{\nu}_{L}\nu_{L}^{c}) + \frac{1}{2}m_{R}(\bar{\nu}_{R}^{c}\nu_{R} + \bar{\nu}_{R}\nu_{R}^{c}).$$
(1.5)

Новый базис, описыващий майорановские состояния, выглядит следующим образом (причем $N_L = (N_R)^c$):

$$\begin{cases} N_L = \frac{\nu_L + \nu_L^c}{\sqrt{2}} \\ N_R = \frac{\nu_R + \nu_R^c}{\sqrt{2}}. \end{cases}$$
(1.6)

Тогда уравнение (1.5) можно записать в следующем виде:

$$\mathcal{L}_m = \begin{pmatrix} \bar{N}_L & \bar{N}_R \end{pmatrix} \cdot \begin{pmatrix} m_L & m_D \\ m_D & m_R \end{pmatrix} \cdot \begin{pmatrix} N_L \\ N_R \end{pmatrix}.$$
(1.7)

После диагонализации массовой матрицы (1.7) будет выглядеть следующим образом:

$$\mathcal{L}_m = \begin{pmatrix} \bar{N}_1 & \bar{N}_2 \end{pmatrix} \cdot \begin{pmatrix} m_1 & 0 \\ 0 & m_2 \end{pmatrix} \cdot \begin{pmatrix} N_1 \\ N_2 \end{pmatrix}.$$
(1.8)

В приближении $m_D \ll m_R, m_L = 0$, получим, что $m_1 = \frac{m_D^2}{m_R}, m_2 = m_R$.

Таким образом, в механизме **seesaw** рождаются легкое и тяжелое нейтрино.

Получившийся массовый член является майорановским [3].

1.1.2 БЕЗНЕЙТРИННЫЙ ДВОЙНОЙ БЕТА РАСПАД ($0\nu\beta\beta$)

Для некоторых ядер с четными A и Z одиночный β^- -распад энергетически запрещен, если m(A, Z) < m(A, Z + 1), или же подавлен при наличии большой разницы в угловых моментах начального и дочернего ядер. Это позволяет происходить так называемому двухнейтринному двойному бетараспаду $(2\nu\beta\beta)$, что может быть интерпретировано как два одновременно происходящих одиночных распада [4]: $(A, Z) \to (A, Z + 2) + 2e^- + 2\bar{\nu}_e$. Пока найдено 35 элементов, способных испытывать $2\nu\beta\beta$.

Случай, когда при двухнейтринном двойном бета распаде не испускаются антинейтрино, называется двойным безнейтринным бета распадом $(0\nu\beta\beta)$ [5]: $(A, Z) \rightarrow (A, Z+2) + 2e^-$. $0\nu\beta\beta$ запрещен в Стандартной Модели, так как нарушается закон сохранения лептонного числа ($\Delta L=2$). На рисунке 1.2 показаны энергетические спектры двух электронов для $0\nu\beta\beta$ и $2\nu\beta\beta$. В $2\nu\beta\beta$ спектр непрерывный, так как энергия распада поделена между двумя электронами и двумя нейтрино. Нейтрино не детектируются и уносят энергию. В случае же $0\nu\beta\beta$, вся энергия распределяется на два электрона. Так как суммарная энергия электронов измеряется, то сигнал, указывающий на $0\nu\beta\beta$, есть линия постоянной энергии при значении Q распада.

Диаграмма $0\nu\beta\beta$ показана на рисунке 1.3. В стандартной интерпре-



Рисунок 1.2 – Энергетический спектр двух электронов (не в масштабе)



Рисунок 1.3 – Диаграмма $0\nu\beta\beta$

тации при 0 $\nu\beta\beta$ происходит обмен легким нейтрино майорановской природы. Тогда период полураспада для этого процесса будет выражаться следующим образом:

$$(T_{1/2}^{0\nu})^{-1} = \Gamma_{0\nu} = G_{0\nu} |M_{0\nu}|^2 (\frac{m_{0\nu}}{m_e})^2.$$
(1.9)

В выражении (1.9) $G_{0\nu}$ - фазовый фактор, $|M_{0\nu}|$ - матричный элемент, $m_{0\nu}$ - эффективная майорановская масса нейтрино. $m_{0\nu} = \sum_{i=1}^{3} U_i^2 m_i$, где U — матрица смешивания, m_i - массовые состояния. Таким образом, по формуле (1.9) можно связать наблюдаемый период полураспада с эффективной майорановской массой нейтрино.

Итак, наличие $0\nu\beta\beta$ -распада опровергнет закон сохранения лептонного заряда, и следовательно, укажет на существование Новой физики за пределами СМ. Более того, в этом случае нейтрино будут являться частицами Майораны. Также обнаружение $0\nu\beta\beta$ может дать информацию о массах нейтрино и механизме их образования.

1.2 ДЕТЕКТИРОВАНИЕ $0\nu\beta\beta$ С ПОМОЩЬЮ ГЕРМАНИЕВЫХ ДЕТЕКТОРОВ

Эскспериментально измеряется суммарная энергия двух электронов. Как было показано выше, указанием на $0\nu\beta\beta$ -распад будет являться моноэнергетический пик при энергии распада Q.

Связь периода полураспада и количеством $0\nu\beta\beta$ -событий выражается следующей формулой:

$$T_{1/2}^{0\nu} = \frac{\ln 2 \cdot N_A \cdot a \cdot m \cdot t}{M \cdot N^{0\nu}}.$$
 (1.10)

В формуле 1.10 N_A — число Авогадро , a — степень обогащения $\beta\beta$ -изотопами, m - общая масса, t — время измерения, M — молярная масса, $N^{0\nu}$ — количество $0\nu\beta\beta$ -распадов.

Любой радиоактивный распад с энергией Q, большей, чем у $0\nu\beta\beta$, может выделять энергию в сигнальной области, и как следствие являться фоном. Так как ожидаемая доля $0\nu\beta\beta$ -распада меньше доли фоновой радиации, применяются техники уменьшения фона. Так, детекторы находятся глубоко под землей, чтобы обеспечить защиту от космической радиации: нейтронов, протонов и мюонов. Естественная радиоактивность детектируется от распада 40 K с соответствующей γ -линией на 1461 кэВ, а также от распадов 232 Th и 238 U. Так как доля $2\nu\beta\beta$ выше доли $0\nu\beta\beta$, это считается неудалимым фоном. В экспериментах по поиску $0\nu\beta\beta$ детекторы должны быть большими, содержать много $2\nu\beta\beta$ изотопов для обеспечения большого количества сигнальных событий. Фон должен быть минимальным. Поиск $0\nu\beta\beta$ на изотопе ⁷⁶Ge является многообещающим за счет энергетического разрешения детекторов из сверхчистого германия (HPGe); германиевые детекторы в этом случае будут являться одновременно и источниками сигнала, и детекторами.

В дальнейшем будут рассмотрены эксперименты GERDA и LEGEND, основанные на HPGe (high purity germanium) детекторах.

2 ЭКСПЕРИМЕНТЫ GERDA И LEGEND

Эксперименты GERDA и LEGEND созданы для поиска $0\nu\beta\beta$ в ⁷⁶Ge. В качестве области поиска $0\nu\beta\beta$ используется интервал энергий $Q_{\beta\beta} \pm 25$ кэВ (ROI — region of interest), энергией $0\nu\beta\beta$ является $Q_{\beta\beta} = 2039$ кэВ [1]. Энергический спектр, полученный в эксперименте GERDA, показан на рисунке 2.1.

Зарегистрированные в детекторах события разделяют на два типа: одноточечные и многоточечные. Сигнальные события от $0\nu\beta\beta$ и $2\nu\beta\beta$ распада выделяют энергию в пределах небольшого объема, так как энергия распада передается двум электронам, имеющим малые длины пробега в германии, а нейтрино (в случае $2\nu\beta\beta$) практически не взаимодействуют с веществом. Такие события называются одноточечными (Single-Site Event, SSE). Наоборот, в фоновых событиях от, например, фотонов, взаимодействующих через многократное комптоновское рассеяние, энергия часто выделяется в нескольких местах в детекторе на расстоянии нескольких сантиметров друг от друга. Такие события называются многоточечными (Multi-Site Event, MSE). Информация, кототорую несут зарядовые импульсы разных типов событий, применяется для анализа, в том числе для разделения сигнальных и фоновых событий.



Рисунок 2.1 – Энергетический спектр эксперимента GERDA

13

2.1 GERDA

Эксперимент GERDA вел поиск $0\nu\beta\beta$ -распада на изотопе ⁷⁶Ge. Эксперимент протекал в две фазы, которые различаются использованными типами детекторов, их количеством, общей массой ⁷⁶Ge, применением LAr (Liquid Argon, жидкий аргон)-вето. На заключительной стадии в GERDA был задействован 41 германиевый детектор общей массой 44,2 кг. Эксперимент располагался в Национальной Лаборатории Гран Сассо (INFN, Италия) на глубине 1400 метров под землей для защиты экспериментальной установки от космических лучей [6].

Эксперимент GERDA работал с массивом германиевых детекторов, размещенных в криостате из нержавеющей стали объемом $64m^3$. Криостат наполнен жидким аргоном (LAr), он служит для охлаждения детекторов до рабочей температуры (~ 90K) и одновременно защитой от внешнего излучения. Внутренняя стенка криостата покрыта слоем из ультрачистой меди, что обеспечивает защиту от излучения стенами криостата, обусловленного радиоактивными примесями, содержащимися в нержавеющей стали. Криостат дополнительно окружен баком с водой объемом $590m^3$, который просматривается фотоумножителями и используется в качестве активного мюонного вето и пассивной защиты от нейтронов, поступающих от окружающей эксперимент горной породы (рисунок 2.2).

В эксперименте применены различные техники по уменьшению фона. К ним относятся отбор полезных событий по форме импульса (Pulse Shape Discrimination, PSD), система антисовпадений, мюонное вето, основанное на черенковском излучении в воде, а также LAr-вето за счет сцинтилляций в жидком аргоне.

2.2 LEGEND

Эксперименты GERDA и MAJORANA закончили набор данных, и сейчас запущен новый эксперимент на основе их технологий - LEGEND, который будет проведен в две фазы: LEGEND-200 и LEGEND-1000. Чувствительность на $T_{1/2}^{0\nu}$ для ⁷⁶Ge будет увеличена с 10²⁶ лет (как в GERDA) до 10²⁸ лет, также будет значительно уменьшен фон. Для эксперимента LEGEND разработан



Рисунок 2.2 – Строение эксперимента GERDA

новый вид германиевых детекторов: Inverted Coaxial Point-Contact (ICPC) детектор. Он работает по аналогии с BEGe детекторами, однако является таким же массивным, как полукоаксиальные детекторы (до 4 кг).

В первой фазе эксперимента, LEGEND-200,
в которой в настоящее время уже начат набор данных, использована инфраструктура эксперимента
 GERDA с некоторыми модификациями и задействованы детекторы общей массой до 200 кг. Чувствительность по
 $T_{1/2}^{0\nu}$ во время первой фазы будет $\sim 10^{27}$ лет. В
торая фаза (LEGEND-1000) будет работать с детекторами общей массой до 1000 кг, тогда чувствительность по
 $T_{1/2}^{0\nu}$ будет увеличена до $\sim 10^{28}$ лет.

Несмотря на то что LEGEND имеет схожую техническую конструкцию с GERDA, для уменьшения фона сделаны следующие улучшения [7]:

- увеличена масса детекторов, что приводит к меньшему количеству подводящих кабелей и, как следствие, к снижению уровня фона
- в LEGEND будет использована электроника с низким уровнем шума из эксперимента MAJORANA
- улучшена техника детектирования сцинтилляционных вспышек
- используется более чистый LAr с лучшим световыходом
- добавлена система контроля качества аргона и возможность его очистки в процессе осуществления эксперимента

В эксперименте LEGEND будут использоваться несколько типов германиевых детекторов: как ранее использовавшиеся полукоаксиальные и BEGe (GERDA), PPC (MAJORANA), так и новые ICPC [8].

2.3 ГЕРМАНИЕВЫЕ ДЕТЕКТОРЫ

Германиевые детекторы в эксперименте GERDA используются по ряду причин. Во-первых, такие детекторы обладают хорошим энергетическим разрешением 0.2% при энергии $Q_{\beta\beta} = 2039$ кэВ. Во-вторых, германий является практически радио-чистым. В-третьих, он является одновременно и элементом детектора, и источником (так как изотоп ⁷⁶Ge испытывает двойной бета-распад).

2.3.1 ВЗАИМОДЕЙСТВИЕ ЧАСТИЦ С ВЕЩЕСТВОМ

При прохождении частицы через p-n переход выделяется энергия и появляются электронно-дырочные пары, которые потом могут быть зарегистрированы полупроводниковым детектором. Частицы, в зависимости от их природы, показывают разные результаты взаимодействия и, следовательно, разное энерговыделение.

- Тяжелые заряженные частицы, как α-частицы, испытывают в основном электромагнитное взаимодействие и теряют энергию в процессе ионизации и возбуждения атомов. Такие частицы часто взаимодействуют, поэтому потери энергии можно считать статистическим процессом. Частицы с энергией 1-10 МэВ могут пройти расстояние около 10 мкм.
- Легкие заряженные частицы, как, например, электроны или позитроны, ведут себя почти так же, как и тяжелые частицы, однако теряют меньше энергии. Так, электрон с энергией Q_{ββ} = 2039 кэВ может пройти расстояние около 2.5 мм до полной остановки, что значительно больше, чем расстояние для тяжелых частиц.
- Фотоны испускаются, когда возбужденные ядерные состояния, вызванные распадом исходного нуклида, переходят на более низкие уровни.

Дочернее ядро выходит из возбужденного состояния в свое устойчивое состояние после нескольких переходов между квантованными уровнями энергии, поэтому испускаемые фотоны обладают энергетическими характеристиками, свойственными конкретному изотопу. Взаимодействие с материей происходит по-разному в зависимости от энергии.

- В случае низких энергий происходит фотоэлектрическое поглощение γ -квантов (фотоэффект), которые взаимодействуют с атомами, отдавая всю энергию орбитальному электрону, вследствие чего появляется фотоэлектрон с кинетической энергией $T_e = h\nu - E_{bind}$, а атом ионизируется. Свободное место в электронной оболочке атома сразу же занимает другой электрон вследствие перераспределения электронов, и лишняя энергия выделяется либо в виде излучения, либо в виде электрона Оже. В конце концов процесс фотоэлектрического поглощения заканчивается выходом фотоэлектронов и нескольких электронов с малой энергией. Если вся кинетическая энергия электронов полностью поглощается в детекторе, то соответствующий сигнал в зарегистрированном спектре будет показывать пик полной энергии (Full Energy Peak, FEP), равный энергии изначального фотона.
- При средних энергиях преимущественно происходит комптоновское рассеяние между фотоном и электроном, что сопровождается частичным переносом энергии. В детекторах возможно рассеяние на любой угол, поэтому появляется непрерывное распределение от нуля до известного максимума. Это явление называется комптоновской границей в энергетическом спектре. Зона между комптоновской границей и FEP может быть заполнена событиями от многочисленного комптоновского рассеяния.
- Появление пар возможно только в электрическом поле вблизи атомных ядер и приводит к исчезновению фотона, вследствие чего появляется электрон-позитронная пара с суммарной энергией покоя 2m_ec². Поэтому у фотона должна быть энергия минимум 1022 кэВ, чтобы этот процесс был энергетически возможным. Излишняя энергия выше этого значения превращается в кинетическую

энергию, распределенную между электроном и позитроном. Так как позитрон не является устойчивым, при уменьшении его кинетической энергии он аннигилирует с другим электроном, и в результате появляются 2 аннигиляционных γ -кванта, движущихся в различных направлениях, по 511 кэВ каждый. Важно рассмотреть 3 предельных случая:

- * энергия двух γ -квантов поглощается в детекторе, тогда получается пик полного поглощения FEP (Full Energy Peak)
- * один γ-квант поглощается, другой уходит без взаимодействия с материалом детектора, тогда получается одиночный пик вылета (Single Escape Peak, SEP), который лежит на 511 кэВ ниже FEP.
- * оба γ-кванта покидают детектор без взаимодействия с веществом, тогда получается пик двойного вылета (Double Escape Peak, DEP). Такое событие считается одноточечным (Single-Site Event, SSE).

Спектр с изображениями DEP, FEP и SEP показан на рисунке 2.3.



Рисунок 2.3 – Пример энергетического спектра гамма-излучения

2.3.2 HPGE ДЕТЕКТОРЫ

Для полупроводников р типа n+ слой с большой концентрацией доноров играет роль p-n перехода, он сделан с помощью внедрения в германий атомов лития на поверхность детектора путем диффузии. Вследствие этого в детекторе появляется обедненная область при приложении отрицательного напряжения смещения. Сам n+ контакт представляет собой слой толщиной 1 мм, называемый мертвым слоем. Основным преимуществом является то, что такой толстый электрод эффективно поглощает внешние воздействия от α , β или γ излучений с низкой энергией, так как их длина пробега существенно меньше. Контакт p+, на котором собираются дырки и который используется как считывающий электрод, получается ионной имплантацией атомов бора, его толщина порядка 0.1 мкм [9].

В эксперименте GERDA были задействованы два основных типа детекторов: полукоаксиальные и BEGe, в эксперименте LEGEND-200 будут использоваться в основном ICPC детекторы, в LEGEND-1000 - только ICPC. Схемы этих детекторов с распределением поля внутри них можно видеть на рисунках 2.4 и 2.5.



Рисунок 2.4 – Схема полукоаксиальных, ВЕGe и ICPC детекторов (слева направо). Оранжевым цветом выделен р-электрод, n-электрод покрывает всю оставшуюся поверхность (кроме канавки)



Рисунок 2.5 – Распределения электрического поля в полукоаксиальных, ВЕСе и ICPC детекторах (слева направо). Оранжевыми кругами отмечены места выделения энергии, белыми линиями показы путь дырок (к рэлектроду) и путь электронов (к п-электроду)

Полукоаксиальная конфигурация: Из-за необходимости исследовать большие активные объемы вещества удобно использовать цилиндрические детекторы с отверстием в центре. Отверстие позволяет сделать соответствующую размерам детектора обедненную зону. Контакт p+ расположен внутри отверстия, контакт n+ расположен на боковой (внешней) поверхности. Контакты p+ и n+ отделены друг от друга специальной канавкой. На рисунке 2.5 можно видеть схему этих детекторов с учетом поля. Видно, что значительную часть детектора занимает область, в которой и электроны, и дырки имеют весомый вклад в формирование сигнала. Для PSD анализа для этого типа детекторов, то есть разделения фоновых и сигнальных событий по форме импульса, используются нейросети, однако эффективность разделения заметно хуже, чем у BEGe детекторов. Параметры детекторов: масса порядка 1-3 кг, диаметр и высота порядка 80 мм, энергетическое разрешение порядка 0.2% при $Q_{\beta\beta}$ [9].

BEGe конфигурация: Детекторы типа BEGe (broad energy germanium) были разработаны с целью улучшить разделение по форме импульса (PSD). Эти детекторы чувствительны к широкому интервалу энергий. Контакт р+ представляет собой небольшую площадь (точечный контакт) на основании цилиндра, контакт n+ расположен по всей поверхности детектора. Контакты p+ и n+ отделены друг от друга специальной канавкой. Размеры детекторов меньше полукоаксиальных. Так как внутри детектора поле более неоднородно, то BEGe детекторы показывают лучшее PSD разделение по сравнению с полукоаксиальными детекторами. Носители заряда перемещаются через область с резко меняющимся электрическим полем; электроны по пути к n+ электроду в основном перемещаются в области со слабым полем и практически не влияют на форму импульса, тогда как дырки перемещаются сквозь области с сильным полем по похожим траекториям вне зависимости от места выделения энергии. Из этого можно сделать вывод, что амплитуда А токового импульса примерно прямо пропорциональна выделившейся энергии, что удобно использовать при PSD анализе. Параметры детекторов: масса порядка 0.7 кг, диаметр порядка 70 мм, высота порядка 30 мм, энергетическое разрешение порядка 0.12% при $Q_{\beta\beta}$ [10].

ICPC конфигурация: ICPC (Inverted Coaxial Point-Contact) является новейшим типом детекторов. По размеру, массе и форме они сопоставимы с

полукоакиальным детекторами, но по энергетическому разрешению сопоставимы с BEGe. ICPC, как и полукоаксиальные, цилиндрические детекторы с отвестием в центре. Контакт n+ расположен на всей поверхности детектора, контакт p+ является небольшой областью (точечным контактом) на основании (как в случае BEGe детекторов); контакты p+ и n+ отделены друг от друга специальной канавкой [11]. Параметры детекторов: масса порядка 2 кг, диаметр и высота порядка 80 мм, энергетическое разрешение порядка 0.14% при $Q_{\beta\beta}$.

З РАЗДЕЛЕНИЕ СИГНАЛОВ ПО ФОРМЕ ИМПУЛЬСА В ЭКСПЕРИМЕНТАХ GERDA И LEGEND

Временная зависимость токового импульса детектора может быть использована для распознания фоновых и сигнальных событий. Как было показано выше, сигналы от $2\nu\beta\beta$ и $0\nu\beta\beta$ являются одноточечными, когда как сигналы от, например, многократного комптоновского рассеяния являются многоточечными (то есть фоновыми). PSD применяется в энергетическом интервале в 1930-2190 кэВ, в котором проводится анализ по $0\nu\beta\beta$. Интервалы 2099-2109 кэВ (SEP от ²⁰⁸Tl) и 2114-2124 кэВ (линия ²¹⁴Bi) исключаются из анализа по форме импульса. События в интервале энергии $Q_{\beta\beta} \pm 5$ кэВ (2034-2044 кэВ) также были скрыты для анализа, так как в этой области находится потенциальная информация о $0\nu\beta\beta$ [12].

3.1 РАЗДЕЛЕНИЕ СИГНАЛОВ ПО ФОРМЕ ИМПУЛЬСА ДЛЯ ДЕТЕКТОРОВ ТИПА BROAD ENERGY GERMANIUM И INVERTED COAXIAL POINT-CONTACT

Для этих типов детекторов сигнал формируется, когда дырки достигают считывающего электрода. Электроны, в свою очередь, вклад в сигнал почти не вносят, так как перемещаются в слабом поле (рисунок 2.5). Как видно из распределения поля, дырки достигают считывающего электрода по похожим траекториям вне зависимости от места выделения энергии, поэтому формы импульсов похожи между собой. Только события вблизи катода нарушают это явление, так как в этом случае электроны тоже играют роль в формировании сигнала. Такое распределение поля делает удобным использо-



Рисунок 3.1 – Определение параметра отбор
а $\rm A/E,$ полученного с учетом различия между сигналами SSE
и $\rm MSE$

вание отношения A/E для разделения по форме импульса, где A - амплитуда тока, а E - энергия (пропорциональна амплитуде заряда).

Для двойного бета-распада (это может быть как $0\nu\beta\beta$, так и $2\nu\beta\beta$) энергия выделяется в одном месте детектора (SSE). Для SSE ожидается почти гауссовское распределение параметра A/E.

Для MSE (например, это может быть комптоновское многократное рассеяние фотонов) выделение энергии будет в разных местах детектора, то есть будет разное дрейфовое время у дырок и электронов, соответственно, будут два или более разделённых во времени импульса. Иными словами, для MSE мы будем иметь меньшую по величине амплитуду токового сигнала по сравнению с SSE.

Для поверхностных событий вблизи p+ электрода амплитуда тока и, соответственно, A/E, больше, и пики раньше по времени, чем в стандартном SSE. Эта особенность позволяет эффективно распознавать эти сигналы.

Для поверхностных событий вблизи n+ электрода время нарастания сигналов увеличивается из-за медленно протекающей диффузии дырок через мертвый слой по сравнению с дрейфом носителей заряда, что тоже позволяет эффективно отделять такие события.

Различие между SSE и MSE сигналами показано на рисунке 3.1 [13].

Благодаря малой площади p+ контакта для BEGe (и ICPC) детекторов происходит хорошее разделение по форме импульса. Параметр A/E является

простой в разделении переменной с понятной физической интерпретацией, поэтому является приемлемым критерием отбора сигнальных событий. Пример применения критерия отбора по A/E показан на рисунке 3.2 [12].



Рисунок 3.2 – Пример энергетического спектра до и после применения критерия отбора для BEGe

3.2 РАЗДЕЛЕНИЕ СИГНАЛОВ ПО ФОРМЕ ИМПУЛЬСА ДЛЯ ПОЛУКОАКСИАЛЬНЫХ ДЕТЕКТОРОВ

В полукоаксиальных детекторах, как видно из распределения поля (рисунок 2.5), вклад в формирование сигнала в общем случае вносят как электроны, так и дырки. Траектории, по которым перемещаются носители заряда (и электроны, и дырки) сильно зависят от места выделения энергии в детекторе, поэтому формы импульсов имеют разнообразную форму (рисунок 3.4). Следовательно, А/Е не является эффективной для разделения переменной для полукоаксиальных детекторов. Вместо этого для PSD анализа в полукоаксиальных детекторах используются нейросети. Пример спектра калибровок на ²²⁸Th до и после отбора событий по форме импульса (с сохранением 90% сигнальных событий) можно видеть на рисунке 3.3. Стоит отметить, что из-за размера и распределения поля в полукоаксиальных детекторах эффективность такого метода заметно ниже, чем отбор событий для детекторов типа BEGe [12].



Рисунок 3.3 – Пример энергетического спектра до и после применения критерия отбора дла полукоаксиальных детекторов. В качестве критерия для нейросети выбран критерий 90% выживаемости DEP событий



Рисунок 3.4 – Возможные формы импульсов для разных мест выделения энергии в полукоаксиальном детекторе. Звездочками обозначены события, пунктиром - траектории, вдоль которых перемещаются дырки, сплошной линией - траектории, вдоль которых перемещаются электроны

4 КАЛИБРОВКА ДЕТЕКТОРОВ LEGEND

Общим для всех методов и для всех видов детекторов является использование калибровочных данных, которые собираются раз в неделю для контроля стабильности работы эксперимента, в том числе для проверки и тренировки алгоритмов. Спектр калибровок на ²²⁸Th (рисунок 4.1) содержит пик (FEP) на 2614.5 кэВ от распада ²⁰⁸Tl. Пик двойного вылета (DEP, 1592.5 кэВ) от этого распада используется как указатель на одноточечное событие (SSE), в то время как пик полного поглощения (FEP, 1620.7 кэВ) от распада ²¹²Bi указывает на многоточечные события (MSE). Получаемые детекторами импульсы (DEP от распада ²⁰⁸Tl и FEP от распада ²¹²Bi) являются данными для обучения нейросети. Отметим, что такие данные не являются чистыми из-за наличия комптоновских событий.

Недостатком является то, что DEP-события неравномерно распределены внутри детектора, как должно быть при $0\nu\beta\beta$. Из-за вылета двух фотонов с энергией 511 кэВ такие события происходят в основном близко к поверхности детектора. События, обусловленные комптоновским рассеянием, покрывают большой интервал энергий и содержат большую долю как SSE-событий, так и MSE-событий. События от $2\nu\beta\beta$ распределены равномерно, и это является дополнительной проверкой эффективности детектирования [12].



Рисунок 4.1 – Энергетический спектр ²²⁸Th

5 ПРИНЦИП РАБОТЫ НЕЙРОННОЙ СЕТИ

Нейронная сеть — математическая модель, построенная по принципу организации и функционирования сетей нервных клеток живого организма. На рисунке 5.1 представлена схема нейросети. Синим цветом обозначен входной слой (входные параметры), зеленым — скрытый слой и красным - выходной слой. Слоем называется совокупность нейронов (нейрон — вычислительная единица). В ходе тренировки нейросети входным параметрам присваиваются случайные веса w_i , и сумма входных параметров с учетом весов поступает на вход скрытому слою. Таким образом, входными данными для скрытого нейрона H_1 (рисунок 5.2) являются $H_{1input} = I_1 * w_1 + I_2 * w_2 + b$, где I_i — входные данные, b — свободный параметр. Далее в скрытом слое на полученные данные действуют функцией активации для нормализации результата [14].

Получив результат, нейросеть вычисляет ошибку (различие между полученным результатом и реальным) и затем начинает менять веса, минимизируя эту ошибку (например, методом градиентного спуска [14]). Таким образом, меняя веса, нейросеть пропускает данные определенное количество раз через все слои и тем самым обучается.

По завершении процесса обучения, например, в задаче классификации, нейросеть выдает «вероятность» каждого события принадлежать к тому или иному классу.

5.1 СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ

Сверточные нейронные сети — архитектура нейронных сетей, основанная на операции свертки, суть которой заключается в поочередном скалярном произведении подматриц входной матрицы на матрицу-фильтр (матрицу весов). Архитектура сверточной нейронной сети показана на рисунке 5.3.



Рисунок 5.1 – Схема нейросети с одним скрытым слоем



Рисунок 5.2 – Пример работы нейронной сети

Сверточные слои (convolutions) представляют собой применение операции свертки к выходам с предыдущего слоя, причем веса ядра свертки являются обучаемыми параметрами. Матрицы весов интерпретируются как кодирование определенных признаков входных данных. Пулинговые слои (pooling) призваны уменьшить размерность изображения, что позволяет сверточным слоям «сконцентрироваться» на отличных от ранее обработанных признаках. Наконец, в конце работы сверточной нейронной сети присутствуют один или несколько полносвязных слоев [15]. Стоит отметить, что в данном анализе применяются одномерные сверточные нейронные сети.



Рисунок 5.3 – Схема сверточной нейронной сети

5.2 МЕТОД ГЛАВНЫХ КОМПОНЕНТ

Метод главных компонент (Principal Component Analysis, PCA) — метод понижения размерности исходного набора данных с наименьшей потерей

информации, что математически представляет собой линейное ортогональное преобразование, отображающее данные из исходного пространства признаков в пространство меньшей размерности. Первая ось (первая главная компонента) нового пространства строится так, чтобы дисперсия данных (то есть информация) вдоль нее была бы максимальна, вторая ось — ортогонально первой, чтобы дисперсия данных вдоль нее была бы максимальной из оставшихся возможных и так далее. Математически собственные векторы исходной ковариационной матрицы являются направлениями главных компонент, а собственные значения - величиной связанной с ними дисперсии. Таким образом, исключая главные компоненты с наименьшей дисперсией данных, мы снижаем размерность нового пространства с наименьшей потерей информации. Недостатком метода является невозможность интерпретировать новые компоненты, так как они являются комбинацией нескольких исходных переменных [16].

6 ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНАЯ СЕТЬ

Генеративно-состязательные сети (Generative Adversarial Network, GAN) представляют собой подход к генеративному моделированию с использованием методов глубокого обучения. Они применяются для обнаружения закономерностей в распределении исходных данных, для того чтобы после процесса обучения сгенерировать новые примеры, которые могли бы правдоподобно присутствовать в оригинальном наборе данных.

Генеративно-состязательные сети состоят из двух подмоделей: генератора и дискриминатора. Модель генератора получает на вход шум (случайный вектор определенной длины, взятый из нормального распределения) и в процессе обучения на исходных данных генерирует правдоподобные примеры, так называемые синтетические данные. Модель дискриминатора является обычным бинарным классификатором. Ее задача состоит в том, чтобы отличить синтетические данные от реальных.

В процессе обучения веса генератора подбираются таким образом, чтобы дискриминатору было сложнее отличить реальные данные от синтетических. В то же время модель дискриминатора подбирает веса так, чтобы лучше отличать одно от другого.

Таким образом, состязательный процесс генератора и дискриминатора можно сформулировать в виде оптимизационной задачи: модель дискриминатора подбирает веса так, чтобы увеличить вероятность верной классификации реальных и синтетических данных (как в задаче бинарной классификации, где у реальных данных метка «1», а у синтетических — метка «0»), в то время как модель генератора подбирает веса так, чтобы вероятность классификации дискриминатором была минимальной. В идеальном случае, по окончании процесса обучения, генератор должен создавать неотличимые от реальных данных синтетические данные, а дискриминатор относит эти данные к тому или иному классу с вероятностью 50%. Во время обучения значение функции потерь (то есть разница между фактическим и прогнозируемым нейросетью значением) дискриминатора должно расти, в то время как для генератора значение функции потерь должно убывать. По этому критерию можно оценить состояние генеративно-состязательной сети. Важно отметить, что добиться стабильного обучения обеих моделей в рамках сети GAN трудно. Схема работы генеративно-состязательной сети показана на рисунке 6.1.



Рисунок 6.1 – Схема генеративно-состязательной нейронной сети

6.1 АЛГОРИТМ «МІΝІМАХ»

Этот подход является наиболее простым алгоритмом генеративносостязательных сетей. Оптимизационная задача выглядит следующим образом:

$$min_G max_D \{ log(D(x)) + log(1 - D(G(z))) \}.$$

В данных обозначениях D(x) — вероятность, выданная дикриминатором в процессе классификации, G(z) - данные, синтезированные генератором, z шум, поданный на вход генератору. Модель дискриминатора предсказывает **вероятность** попадания события в класс синтезированных данных или в класс реальных данных (то есть решается задача бинарной класификации).

Дискриминатор пытается максимизировать логарифм вероятности реальных данных и логарифм обратной вероятности синтетических данных: $max_D\{log(D(x)) + log(1 - D(G(z)))\}.$

Генератор, в свою очередь, пытается минимизировать логарифм обратной вероятности (полученной дискриминатором) синтетических данных: $min_G\{log(1 - D(G(z)))\}$. Таким образом, генератор учится выдавать события с маленькой вероятностью быть распознанными дискриминатором как

синтезированные.

На практике часто бывает так, что генератор обучается хуже дискриминатора. На ранних стадиях дискриминатор разделяет реальные данные от синтезированных очень легко, так как они сильно отличаются. Если дискриминатор обучился до оптимальных значений раньше генератора, то дискриминатор доходит до насыщения и перестает обучаться, что приводит к неудовлетворительным результатам генератора [17].

6.2 АЛГОРИТМ «WASSERSTEIN»

Для стабилизации процесса обучения GAN моделей можно использвать метод Вассерштейна, заключающийся в выборе отличной от minimax-подхода метрики для оптимизации весов. Утверждается, что, в отличие от minimaxподхода, новая метрика должна быть всегда гладкой, то есть наиболее подходящей для оптимизации весов [18]. Таким образом, решается оптимизационная задача следующего вида:

> $min_G max_{D \in \mathfrak{D}} \{ D(x) - D(G(z)) \},$ где \mathfrak{D} – класс функций 1-Липшица $(f \in \mathfrak{D}, \text{ если } \forall x, y \in \mathbb{R} \exists L : |f(x) - f(y)| < L \cdot |x - y|).$

Модель дискриминатора обучается в несколько раз чаще генератора и уже не предсказывает вероятность попадания события в конкретный класс (как в задаче бинарной классификации), а «оценивает» событие по реальным меткам класса. Другими словами, выход модели дискриминатора не подвергается активации и поэтому интерпретируется не как вероятность, а как количественная оценка входных данных. Функция потерь теперь определена как расчет среднего прогнозируемого значения по реальным и сгенерированным данным. Также стоит отметить, что, в отличие от классического minimaxподхода, эта модель обучается без учителя (unsupervised learning).

Для того чтобы учесть условие, что дискриминатор должен принадлежать к классу функций Липшица, надо потребовать, чтобы веса дискриминатора были небольшимии и находились в рамках какого-то интервала, который бы задавался гиперпараметрами, что иногда может привести к проблемам в обучении [19].

Для стабилизации обучения генератора можно использовать gradient penalty (gp). Метод заключается в дополнительном обучении модели генератора на интерполированных данных между реальными и сгенерированными данными и учет этого обучения в оптимизации весов дискриминатора [19].

В настоящем анализе использовались оба подхода: minimax GAN и Wasserstein-gp GAN.

6.3 АВТОКОДИРОВЩИК

Автокодировщик, или autoencoder, это нейронная сеть, которая восстанавливает объекты, принимаемые на вход сети. Схема этой сети показана на рисунке 6.2. В процессе обучения простой автокодировщик решает следующую оптимизационную задачу: $||X - g(f(X))||_2^2 \to min$, где g - декодировщик, f — кодировщик, X — исходная выборка.



Рисунок 6.2 – Схема автокодировщика



Рисунок 6.3 – Схема adversarial autoencoder

Объект обычно восстанавливается с потерями, так как в процессе кодировки в скрытом пространстве Н сохраняются только наиболее важные признаки. Кодировщик может использоваться для снижения размерности пространства, так как он запоминает только самые важные признаки, по которым потом можно восстановить исходную выборку. Стоит отметить, что автокодировщик относится к классу моделей без учителя.

В настоящем анализе использовался «состязательный» автокодировщик (adversarial autoencoder, AAE). Его схема показана на рисунке 6.3. Автокодировщик дополняется моделью-дискриминатором (D), что делает его похожим на генеративно-состязательную сеть, где в роли генератора выступает модель-кодировщик. В результате обучения код объекта, поданному на вход автокодировщику, подчиняется определенному распределению [20]. Таким образом, скрытое пространство признаков, которое получается при проходе объекта через кодировщик, становится более предсказуемым.

7 ДИФФУЗИОННАЯ МОДЕЛЬ

Диффузионные модели — еще один подход к генеративному моделированию, помимо генеративно-состязательных сетей. Схема диффузионной модели представлена на рисунке 7.1. Модель представляет собой «зашумле-



Рисунок 7.1 – Схема диффузионной модели

ние» исходных данных за определенное количество шагов (прямой процесс) с последующим последовательным переходом от зашумленного состояния к синтетическим данным, которые в идеальном случае должны быть похоже на реальные (обратный процесс) [21]. В такой последовательности каждый последующий шаг напрямую зависит от предыдущего, причем размерность промежуточных шагов не отличается от размерности реальных данных (в отличие от автокодировщика, где размерность закодированных данных зачастую меньше размерности реальных). Количество шагов выбирается таким образом, чтобы на последнем шаге исходные данные превратились в случайный шум. В отличие от генеративно-состязательных сетей, где обучаются сразу две модели нейронных сетей, диффузионная модель предполагает наличие одной модели, которая в течение обратного процесса предсказывает количества шума, добавленного к исходным данным на этом шаге. Прямой же процесс не требует обучения нейронных сетей. По завершении обучения полученная модель должна быть способна генерировать данные, которые правдоподобно присутствовали бы в оригинальном наборе данных, из случайного

шума. Прямой шаг можно описать следующими формулами:

$$\alpha_t = 1 - \beta_t, \tag{7.1}$$

$$\bar{\alpha_t} = \prod_{s=1}^T \alpha_s,\tag{7.2}$$

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \varepsilon. \tag{7.3}$$

Здесь T - количество шагов, β_t - шум, добавляемый на шаге t (увеличивается на каждом шаге, является параметром модели); x_0 - исходные данные; $\varepsilon \sim N(0, I)$ - случайный шум.

Обратный процесс можно примерно описать следующей формулой:

$$x_{t-1} \approx x_t - pred.noise. \tag{7.4}$$

Таким образом, диффузионная модель на обратном шаге пытается определить уровень шума, который был добавлен на прямом шаге. Переход к менее «зашумленному» состоянию производится вычитанием определенного моделью шума.

8 МОДЕЛИРОВАНИЕ СИГНАЛОВ ДЛЯ ДЕТЕКТОРОВ ТИПА INVERTED COAXIAL POINT-CONTACT ЭКСПЕРИМЕНТА LEGEND

Характеристики каждого из вновь произведенных детекторов (а, в особенности, эффективность отбора по форме импульса) было необходимо измерить. Такие измерения проводились в лаборатории HADES с помощью источника ²²⁸Th, и именно эти данные для детекторов типа ICPC были использованы в качестве выборки. Для обучения нейронной сети были использованы события при энергии DEP (double escape peak) от распада ²⁰⁸Tl. Пример входных данных показан на рисунке 8.1. Каждый зарядовый импульс состоит из 3748 точек, всего для обучения использовалось порядка 20000 импульсов.



Real DEP

Рисунок 8.1 – Пример входных зарядовых импульсов

Перед обучением все данные были приведены к стандартному виду таким образом, чтобы распределение каждого параметра было нормальным:

$$z = \frac{x - \mu}{\sigma},$$
$$\mu = \frac{1}{N} \sum_{i}^{N} x_{i},$$
$$\sigma = \sqrt{\frac{1}{N} \sum_{i}^{N} (x_{i} - \mu)^{2}},$$

где μ – среднее значение, σ – среднеквадратическое отклонение.



Рисунок 8.2 – Параметры, используемые для оценки правдоподобия синтезированных данных

В ходе работы были созданы несколько моделей генеративносостязательных сетей на базе библиотеки PyTorch с разными алгоритмами и особенностями. Так, в анализе использовались minimax GAN, Wasserstein-gp GAN, автокодировщик, применялся анализ главных компонент, а также использовалась диффузионная модель. В качестве генератора, дискриминатора и диффузионной модели использовались одномерные сверточные нейронные сети. Задачей было создание оптимальной модели.

Для оценки правдоподобия синтезированных данных использовались распределения следующих параметров:

- Амплитуда зарядового импульса
- Амплитуда токового импульса (токовый импульс получается путем дифференцирования по времени зарядового импульса)
- Время дрейфа (разница между 90% и 10% амплитуды зарядового импульса)
- Наклон «хвостовой» части зарядового импульса (tail slope)

На рисунке 8.2 показаны данные параметры. Очевидно, что в случае моделирования правдоподобных данных распределения параметров для синтезированных данных и реальных данных должны совпадать. Однако стоит отметить, что полное совпадение распределений параметров для синтетических и реальных данных будет требовать дополнительный анализ результатов, так как это может свидетельствовать о переобучении модели.

8.1 ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНАЯ СЕТЬ БЕЗ ИСПОЛЬЗОВАНИЯ АВТОКОДИРОВЩИКА

В этой секции будут рассмотрены результаты моделей minimax-GAN и Wasserstein-gp GAN без предварительной обработки данных (кроме стандартизации, о которой было упомянуто выше). В качестве исходных данных для обучения GAN были использованы стандартизованные формы импульсов, каждый импульс содержит 3748 точек.

8.1.1 АЛГОРИТМ «MINIMAX»

Была рассмотрена самая простая модель minimax-GAN. Примеры импульсов, полученные в результате обучения этой модели, показаны на рисунке 8.3, распределения параметров импульсов показаны на рисунке 8.4. По рисункам 8.3, 8.4 видно, что данная (самая простая) модель не способна синтезировать похожие на реальные формы импульсов.



Рисунок 8.3 – Примеры импульсов, полученные в результате обучения minimax-GAN



Рисунок 8.4 – Распределения параметров импульсов, полученных в результате обучения minimax-GAN

Fake DEP

8.1.2 АЛГОРИТМ «WASSERSTEIN-GP»

Было произведено усложнение модели до модели Wasserstein-gp; предполагалось, что это поможет стабилизировать работу генератора и, как следствие, генератор сможет моделировать правдоподобные данные. Примеры импульсов, полученные в результате обучения этой модели, показаны на рисунке 8.5, распределения параметров импульсов показаны на рисунке 8.6. По рисункам 8.5, 8.6 видно, что модель Wasserstein-gp дает, в целом, визуально более правдоподобные импульсы, а также генерирует данные с практически идеальным параметром tail slope, однако распределения других параметров синтезированных данных остаются неудовлетворительными.



Fake DEP

Рисунок 8.5 – Примеры импульсов, полученные в результате обучения Wasserstein-gp GAN



Рисунок 8.6 – Распределения параметров импульсов, полученных в результате обучения Wasserstein-gp GAN

8.2 ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНАЯ СЕТЬ С ИСПОЛЬЗОВАНИЕМ АВТОКОДИРОВЩИКА

По результатам обучения GAN без использования автокодировщика была выдвинута гипотеза, что, возможно, количество признаков в данных обучающей выборки (3748) слишком велико для обучения генеративносостязательной сети. В этой секции рассмотрены те же модели minimax GAN и Wasserstein-gp GAN, однако перед обучением самой генеративносостязательной сети, на исходных данных будет обучена «вспомогательная» модель — состязательный автокодировщик (AAE), состоящий из сверточных слоев. Таким образом, исходные данные будут закодированы в скрытое пространство из 234 (а не 3748) признаков с помощью модели кодировщика, GAN будет обучаться моделировать сигнал в скрытого пространстве, затем синтезированные данные будут преобразованы из скрытого пространства в исходное (из 3748 признаков) с помощью модели-декодировщика.

42

8.2.1 АЛГОРИТМ «МІNIMAX» С ПРИМЕНЕНИЕМ АВТОКОДИРОВЩИКА

Примеры импульсов, полученные в результате обучения minimax-GAN с предварительным обучением автокодировщика, показаны на рисунке 8.7, распределения параметров импульсов показаны на рисунке 8.8.



Fake DEP

Рисунок 8.7 – Примеры импульсов, полученные в результате обучения minimax-GAN с AAE

По рисункам 8.7, 8.8 видно, что, несмотря на большое количество визуально неприемлемых сгенерированных сигналов, в распределениях параметров есть пересечение, что говорит о том, что сеть может генерировать какое-то число импульсов так, чтобы распределения их параметров согласовались с реальными, однако такая сеть не является применимой.



Рисунок 8.8 – Распределения параметров импульсов, полученных в результате обучения minimax-GAN с ААЕ

8.2.2 АЛГОРИТМ «WASSERSTEIN-GP» С ПРИМЕНЕНИЕМ АВТОКОДИРОВЩИКА

Примеры импульсов, полученные в результате обучения Wasserstein-gp GAN с предварительным обучением автокодировщика, показаны на рисунке 8.9, распределения параметров импульсов показаны на рисунке 8.10. По рисункам видно, что модель, как и в случае Wasserstein-gp GAN без автокодировщика, смогла воссоздать сигналы с похожим на реальные сигналы параметром tail slope. Однако общий результат похож на результат minimax-GAN с применением AAE, то есть данная модель, несмотря на наличие сигналов с параметрами, похожими на параметры реальных импульсов, тоже не является применимой.

44

Fake DEP



Рисунок 8.9 – Примеры импульсов, полученные в результате обучения Wasserstein-gp GAN с AAE



Рисунок 8.10 – Распределения параметров импульсов, полученных в результате обучения Wasserstein-gp GAN с AAE

8.3 АЛГОРИТМ «MINIMAX» С ПРИМЕНЕНИЕМ МЕТОДА ГЛАВНЫХ КОМПОНЕНТ

По результатам обучения моделей GAN с автокодировщиком был сделан вывод, что гипотеза о необходимости снижения размерности пространства признаков является верной, так как результаты, в целом, улучшились. К простой модели minimax-GAN был применен простой метод снижения размерности — метод главных компонент (PCA). Так, размерность пространства признаков была уменьшена с 3748 до 256. Таким образом, модель GAN обучалась синтезировать данные в пространстве главных компонент, состоящим из 256 признаков, а затем к синтезированным данным было применено обратное преобразование, отображающее синтезированные данные в исходное пространство из 3748 признаков. Результаты показаны на рисунках 8.11, 8.12.

Fake DEP



Рисунок 8.11 – Примеры импульсов, полученные в результате обучения minimax-GAN с РСА



Рисунок 8.12 – Распределения параметров импульсов, полученных в результате обучения minimax-GAN с PCA

По рисункам 8.11, 8.12 можно сделать вывод, что синтезированные данные выглядят визуально приемлемо, также есть пересечения в распределениях параметров, что делает эту модель наилучшей из представленных выше. Можно применить критерии отбора, чтобы отсечь синтезированные импульсы, у которых распределения параметров не совпадают с распределениями параметров реальных импульсов. Были применены критерии отбора:

> 22270 a.u. < Charge amplitude < 22350 a.u. 1850 a.u./time < Current amplitude < 2000 a.u./time.

Полученные после применения отбора формы импульсов и распределения параметров показаны на рисунках 8.13, 8.14. Синтезированные формы импульсов, полученные после применения критерия отбора, согласуются с реальными формами. Стоит отметить, что применение критериев отбора сильно уменьшило статистику (примерно 80% синтезированных данных было отброшено).

Fake DEP



Рисунок 8.13 – Примеры импульсов, полученные в результате обучения minimax GAN с PCA после применения критериев отбора



Рисунок 8.14 – Распределения параметров импульсов, полученных в результате обучения minimax GAN с PCA после применения критериев отбора

8.4 ДИФФУЗИОННАЯ МОДЕЛЬ

Была также проверена диффузионная модель, обученная без применения анализа главных компонент. Так как эти модели рассчитаны на работу с двумерными картинками, для данной задачи использовалась простая модель (также из сверточных слоев) с 10 шагами. Примеры синтезированных импульсов показаны на рисунке 8.15.

Полученные распределения параметров показаны на рисунке 8.16. Синтезированные формы импульсов визуально согласуются с реальными данными. Распределение амплитуды токового импульса практически идеально согласуется с реальными распределениями, остальные же параметры согласуются плохо, поэтому можно заключить, что представленная выше генеративносостязательная сеть демонстрирует более приемлемый результат. Диффузионная модель является новым и перспективным методом для работы с двумерными изображениями (картинки), однако для одномерных задач она, скорее всего, является излишне сложной.



Fake DEP

Рисунок 8.15 – Примеры импульсов, полученные в результате обучения диффузионной модели



Рисунок 8.16 – Распределения параметров импульсов, полученных в результате обучения обучения диффузионной модели

8.5 ОБУЧЕНИЕ НЕЙРОННЫХ СЕТЕЙ НА ДАННЫХ, ПОЛУЧЕННЫХ НА ГЕРМАНИЕВЫХ ДЕТЕКТОРАХ ДРУГОЙ КОНФИГУРАЦИИ

Для обобщения результатов моделирования на другие виды детекторов помимо ICPC (и с иным набором задействованной электроники) было решено проверить самую успешную модель (генеративно-состязательную модель с использованием метода главных компонент) на данных, полученных на полупланарном детекторе (SP5020 ORTEC) в Объединенном институте ядерных исследований (ОИЯИ). Данные были получены с помощью ²²⁸Th источника. Параметры детектора: диаметр 50 мм, высота 20 мм, энергетическое разрешение 0.13% при энергии 1.3 МэВ. Схема детектора показана на рисунке 8.17.

50



Рисунок 8.17 – Схема полупланарного детектора ORTEC

В качестве входных данных использовались 2600 зарядовых импульса по 5000 точек каждый (рисунок 8.18). Для обучения нейронной сети были использованы события при энергии DEP (double escape peak) от распада ²⁰⁸Tl (так же, как и в моделировании сигнала для ICPC-детекторов).



Рисунок 8.18 – Пример входных зарядовых импульсов (ОИЯИ)

Была проверена модель с использованием метода главных компонент (PCA), причем размерность пространства признаков снизилась с 5000 до 256.

Полученные после обучения модели сигналы показаны на рисунке 8.19, а распределения параметров — на рисунке 8.20. На рисунках 8.19 и 8.20 видно, что распределения синтезированных данных лежат в пределах распределений реальных данных. Это свидетельствует о приемлемой работе модели PCA не только на данных ICPC детекторов. Отдельно стоит отметить, что диффузионную модель не получилось обобщить для детектора из ОИЯИ, поэтому наиболее приемлемой моделью из представленных является генеративносостязательная модель с использованием метода главных компонент.



Рисунок 8.19 – Примеры импульсов, полученные в результате обучения minimax-GAN с РСА (ОИЯИ)

Fake



Рисунок 8.20 – Распределения параметров импульсов, полученных в результате обучения обучения minimax-GAN с РСА (ОИЯИ)

8.6 ОЦЕНКА ЭФФЕКТИВНОСТИ МОДЕЛИ

Для количественной оценки эффективности наилучшей модели (до этого использовалась простейшая метрика — визуальное сходство распределений реальных и синтезированных параметров) использовалась величина Intersection over Union (IoU), или пересечение гистограмм, деленное на их объединение [22]. Пересечение считается как сумма минимумов из двух гистограмм для каждого бина, объединение — как сумма максимумов. IoU изменяется в пределах от 0 до 100%, где 0% означает отсуствие пересечения, а 100% означает полное пересечение. Качество работы модели неразрывно связано с данными, на которых она обучается, поэтому модель minimax-GAN с PCA проверялась отдельно на данных ОИЯИ и HADES. Рассчитывалось пересечение «реальных» и «синтезированных» распределений параметров отдельно для каждого из выбранных параметров (амплитуда зарядового импульса, амплитуда токового импульса, время дрейфа и угол наклона хвостовой части импульса). Качество работы любой нейронной сети зависит от изначально выбранных моделью весов, поэтому модели были обучены по 100 раз с разными исходными весами для оценки качества. Значения IoU, близкие к 0% означают, что распределения практически не пересекаются, однако значения IoU, близкие к 100%, тоже не являются удовлетворительными, так как это может свидетельствовать о переобучении модели.

Распределения IoU для модели minimax-GAN с PCA, обученной на данных HADES, показано на рисунке 8.21. Полученные значения IoU в случае данных HADES:

> Charge amplitude: $IoU = (27.5 \pm 12.8)\%$ Current amplitude: $IoU = (28.6 \pm 11.4)\%$ Tail slope: $IoU = (52.8 \pm 21.2)\%$ Drift time: $IoU = (29.3 \pm 14.6)\%$.



Рисунок 8.21 – Распределения IoU для модели minimax-GAN с PCA, обученной на данных HADES



Рисунок 8.22 – Распределения IoU для модели minimax-GAN с PCA, обученной на данных ОИЯИ

Распределения IoU для модели minimax-GAN с PCA, обученной на данных ОИЯИ, показано на рисунке 8.22. Полученные значения IoU в случае данных ОИЯИ:

> Charge amplitude: $IoU = (42.9 \pm 7.2)\%$ Current amplitude: $IoU = (39.8 \pm 11.3)\%$ Tail slope: $IoU = (50.5 \pm 18.3)\%$ Drift time: $IoU = (41.0 \pm 18.0)\%$.

Стоит отметить, что полученные распределения демонстрируют сильную зависимость модели GAN-PCA от изначальных весов. Большая погрешность объясняется тем, что обучение генеративно-состязательных сетей крайне нестабильно. Однако такие относительно небольшие значения IoU являются оптимальными, так как количество подходящих для конкретной цели синтезированных импульсов можно регулировать критериями отбора.

ЗАКЛЮЧЕНИЕ

В рамках настоящего проекта была исследована возможность моделирования сигналов для германиевых ICPC детекторов эксперимента LEGEND с помощью нейронных сетей. Модели обучались на калибровочных данных, полученных в лаборатории HADES для ICPC детекторов. Были исследованы два разных алгоритма генеративно-состязательных сетей (minimax-GAN и Wasserstein-GAN) и была подтверждена верность гипотезы о необходимости уменьшения пространства признаков, что осуществлялось с помощью автокодировщика и более простого анализа главных компонент (PCA). В результате наилучшей генеративно-состязательной моделью стала minimax-GAN с использованием PCA. Эта модель оказалась способной генерировать правдоподобные сигналы, однако для корректного моделирования данных необходимо дополнительно применять критерии отбора. Была также проверена перспективная диффузионная модель, результаты которой не являются приемлемыми, так как, по всей видимости, она является излишне сложной для работы с одномерными данными.

В рамках исследования применимости модели к данным германиевых детекторов других типов, лучшая модель (minimax-GAN с использованием PCA) была проверена на данных, полученных на полупланарном детекторе из ОИЯИ. Результаты анализа параметра IoU для модели minimax-GAN с использованием PCA на данных HADES и ОИЯИ являются похожими, что говорит о возможности обобщить данную модель на другие детекторы и другие задачи. Несмотря на то что генеративно-состязательная модель трудно обучается, что может привести к необходимости применения критериев отбора после моделирования (как в случае с данными ICPC детекторов), после обучения она способна быстро генерировать внушительные объемы данных, что может компенсировать потери из-за применения критерия отбора. Также было дополнительно проверено, что генеративно-состязательная сеть способна достойно обучаться на относительно небольшой выборке.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- Final Results of GERDA on the Search for Neutrinoless Double-β Decay / M. Agostini [et al.] // Phys. Rev. Lett. — 2020. — Vol. 125, issue 25. — P. 252502.
- Goldhaber M., Grodzins L., Sunyar A. W. Helicity of Neutrinos // Phys. Rev. — 1958. — Vol. 109, issue 3. — P. 1015–1017.
- Zuber K. Neutrino Physics. Boca Raton : Taylor & Francis, 2020. ISBN 978-1-351-76458-2, 978-1-315-19561-2, 978-1-03-224220-0, 978-1-138-71889-0.
- Goeppert-Mayer M. Double Beta-Disintegration // Phys. Rev. 1935. Vol. 48, issue 6. — P. 512–516.
- Furry W. H. On Transition Probabilities in Double Beta-Disintegration // Phys. Rev. — 1939. — Vol. 56, issue 12. — P. 1184–1193.
- Upgrade for Phase II of the Gerda experiment / M. Agostini [et al.] // The European Physical Journal C. — 2018. — Vol. 78, no. 5.
- LEGEND-1000 Preconceptual Design Report / LEGEND Collaboration [et al.]. — 2021.
- D'Andrea V. Neutrinoless Double Beta Decay Search with ⁷⁶Ge: Status and Prospect with LEGEND // 54th Rencontres de Moriond on Electroweak Interactions and Unified Theories. — 2019. — arXiv: 1905. 06572 [hep-ex].
- Kirsch A. Search for the neutrinoless double beta-decay in Gerda Phase I using a Pulse Shape Discrimination technique. — 2014.

- Characterization of 30 76Ge enriched Broad Energy Ge detectors for GERDA Phase II / M. Agostini [et al.] // The European Physical Journal C. — 2019. — Vol. 79.
- Characterization of inverted coaxial Ge detectors in GERDA for future double beta-decay experiments / M. Agostini [et al.] // The European Physical Journal C. — 2021. — Vol. 81, no. 6.
- Pulse shape discrimination for GERDA Phase I data / M. Agostini [et al.] // Eur. Phys. J. C. 2013. Vol. 73, no. 10. P. 2583. arXiv: 1307.2610 [physics.ins-det].
- Румянцева Н. С. Новые типы германиевых детекторов для поиска двойного безнейтринного бета-распада // Известия Российской академии наук. Серия физическая. — 2019.
- 14. Python Deep Learning / I. Vasilev [et al.]. Packt Publishing, 2019. —
 P. 378.
- Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach / S. Indolia [et al.] // Procedia Computer Science. — 2018. — Vol. 132. — P. 679–688. — ISSN 1877-0509. — International Conference on Computational Intelligence and Data Science.
- 16. Метод главных компонент. URL: https://wiki.loginom.ru/articles/ principal-component-analysis.html.
- Generative Adversarial Networks / I. J. Goodfellow [et al.]. 2014. arXiv: 1406.2661 [stat.ML].
- Arjovsky M., Chintala S., Bottou L. Wasserstein GAN. 2017. arXiv: 1701.07875 [stat.ML].
- 19. Improved Training of Wasserstein GANs / I. Gulrajani [и др.]. 2017. arXiv: 1704.00028 [cs.LG].
- 20. Adversarial Autoencoders / A. Makhzani [et al.]. 2015.
- Luo C. Understanding Diffusion Models: A Unified Perspective. 2022. arXiv: 2208.11970 [cs.LG].
- 22. Ad-hoc Pulse Shape Simulation using Cyclic Positional U-Net / A. Li [et al.]. 2022. arXiv: 2212.04950 [physics.ins-det].