

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение
высшего образования
«Национальный исследовательский ядерный университет «МИФИ»

УДК 53.01

**ОТЧЕТ
О НАУЧНО-ИССЛЕДОВАТЕЛЬСКОЙ РАБОТЕ**

**Моделирование сигналов с помощью
генеративно-состязательных нейронных сетей для ICPC
детекторов в эксперименте LEGEND**

Научный руководитель,
н.с. НИЦ «Курчатовский институт»

_____ А. Е. Черногоров

Выполнил

_____ Н. Д. Зарецкий

Москва 2023

СОДЕРЖАНИЕ

1	Физика нейтрино	3
1.1	Возможные расширения СМ	3
1.1.1	Массовые члены нейтрино	4
1.1.2	Безнейтринный двойной бета распад ($0\nu\beta\beta$)	6
1.2	Детектирование $0\nu\beta\beta$ на германиевых детекторах	7
2	Эксперименты GERDA и LEGEND	9
2.1	GERDA	9
2.2	LEGEND	10
2.3	Германиевые детекторы	11
2.3.1	Взаимодействие частиц с веществом	11
2.3.2	HPGe детекторы	13
3	Разделение по форме импульса для экспериментов GERDA и LEGEND	16
3.1	PSD для BEGe и ICPC детекторов	16
3.2	PSD для полукоаксиальных детекторов	18
4	Калибровка детекторов LEGEND	19
5	Принцип работы нейронной сети	21
5.1	Сверточные нейронные сети	22
5.2	Метод главных компонент	22
6	Генеративно-сопоставительная сеть (GAN)	23
6.1	Minimax GAN	24
6.2	Wasserstein GAN	24
6.3	Автокодировщик	25
7	Моделирование сигналов для ICPC детекторов эксперимента LEGEND	27
7.1	GAN без использования автокодировщика	29
7.1.1	Minimax GAN	29
7.1.2	Wasserstein-gp GAN	30
7.2	GAN с использованием автокодировщика	32
7.2.1	Minimax GAN с применением ААЕ	32
7.2.2	Wasserstein-gp GAN с применением ААЕ	33
7.3	Minimax GAN с применением метода главных компонент	35

7.4 Результаты	38
Список использованных источников	39
Список использованных источников	39

1. ФИЗИКА НЕЙТРИНО

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. В настоящее время в Стандартной Модели (СМ) нейтрино - это безмассовые, электрически нейтральные частицы со спином $s = \frac{1}{2}$. Однако экспериментальное подтверждение нейтринных осцилляций (то есть превращений нейтрино одного поколения (μ, e, τ) в нейтрино другого поколения) говорит о наличии у нейтрино массы, что не согласуется с СМ.

1.1. ВОЗМОЖНЫЕ РАСШИРЕНИЯ СМ

Материя состоит из фермионов (т.е. частиц со спином $s = \frac{1}{2}$), а с помощью калибровочных бозонов со спином $s = 1$ в СМ осуществляется взаимодействие фермионов. 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: $n \rightarrow p + e^- + \bar{\nu}_e$. 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) [10]. 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 [16]:

$$\mathcal{L}_\nu^{SM} = \sum_{\alpha=\mu,e,\tau} \left[\bar{\nu}_{\alpha L} i \not{\partial} \nu_{\alpha L} + \frac{g}{\sqrt{2}} (W_\mu^+ \bar{\nu}_{\alpha L} \gamma^\mu l_{\alpha L} + h.c) + \frac{g}{2 \cos \theta_w} Z_\mu \bar{\nu}_{\alpha L} \gamma^\mu \nu_{\alpha L} \right] \quad (1.1)$$

Первое слагаемое является кинетическим членом, далее идут слагаемые, описывающие взаимодействие. Если у нейтрино есть масса, то в лагранжиан должен быть добавлен массовый член.

generation	I	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	τ	
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				
	Z⁰	W[±]	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

1.1.1. МАССОВЫЕ ЧЛЕНЫ НЕЙТРИНО

Для расширения СМ, 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:

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

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

- **Вариант Дирака** заключается в том, чтобы добавить в СМ правое нейтрино, которое не участвует в калибровочных взаимодействиях. Тогда массовая компонента будет записана так:

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

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:

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

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 [16].

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:

$$\begin{aligned} \mathcal{L}_m = & m_D(\bar{\nu}_L\nu_R + \bar{\nu}_R\nu_L) + \\ & + \frac{1}{2}m_L(\bar{\nu}_L^c\nu_L + \bar{\nu}_L\nu_L^c) + \frac{1}{2}m_R(\bar{\nu}_R^c\nu_R + \bar{\nu}_R\nu_R^c) \end{aligned} \quad (1.5)$$

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

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

Тогда уравнение (1.5) можно записать в следующем виде:

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

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

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

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 [16].

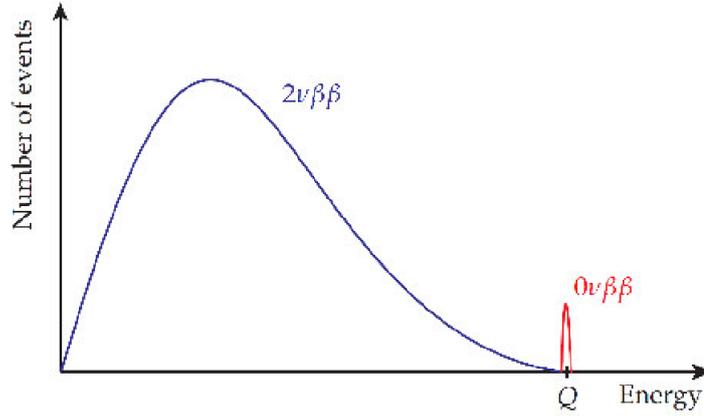


Рисунок 1.2 – Энергетический спектр двух электронов

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 двойному бета-распаду ($2\nu\beta\beta$), что может быть интерпретировано как два одновременно происходящих одиночных распада [9]: $(A, Z) \rightarrow (A, Z + 2) + 2e^- + 2\bar{\nu}_e$. Пока найдено 35 элементов, способных испытывать $2\nu\beta\beta$.

В случае же, если при двойном бета распаде не испускаются антинейтрино, он называется двойным безнейтринным бета распадом ($0\nu\beta\beta$) [7]: $(A, Z) \rightarrow (A, Z + 2) + 2e^-$. $0\nu\beta\beta$ 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 продолжительный, 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 интерпретации при $0\nu\beta\beta$ происходит обмен легким нейтрино майорановской природы. Тогда период полураспада для этого процесса будет выражаться следующим образом:

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

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. В отличие от дираковского нейтрино, где в матрице смешивания присутствует фаза δ , в случае майо-

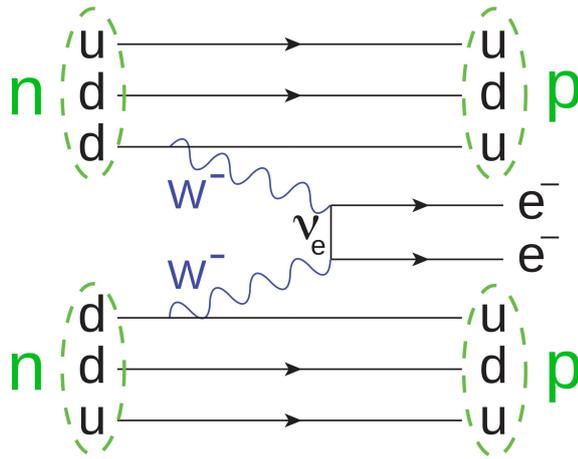


Рисунок 1.3 – Диаграмма $0\nu\beta\beta$

рановского нейтрино рассматривают 2 дополнительные фазы - α и β (они не влияют на осцилляции) [16]. 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 $0\nu\beta\beta$ НА ГЕРМАНИЕВЫХ ДЕТЕКТОРАХ

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

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

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

В формуле 1.10 N_A - число Авогадро, a - обогащение $\beta\beta$ -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 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 распадов ^{232}Th . От ^{208}Tl присутствует γ -линия при 2615 кэВ. Так как доля $2\nu\beta\beta$ выше доли $0\nu\beta\beta$, это считается неудаляемым фоном. В экспериментах по поиску $0\nu\beta\beta$ детекторы должны быть большими, содержать много $0\nu\beta\beta$ изотопов для обеспечения большого потока. Фон должен быть минимальным. Наиболее многообещающим изотопом для поиска $0\nu\beta\beta$ является ^{76}Ge , так как детекторы из сверхчистого германия (HPGe) являются одновременно и источниками, и детекторами [12].

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 ^{76}Ge . 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[6]. Энергетический спектр, полученный в эксперименте GERDA, показан на рисунке 2.1.

Зарегистрированные в детекторах события разделяют на два типа: однотоочечные и многотоочечные. 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 однотоочечными (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 многотоочечными (Multi-Site Event, MSE). Информация, которую несут зарядовые импульсы разных типов событий, применяется для анализа, в том числе для разделения сигнальных и фоновых событий.

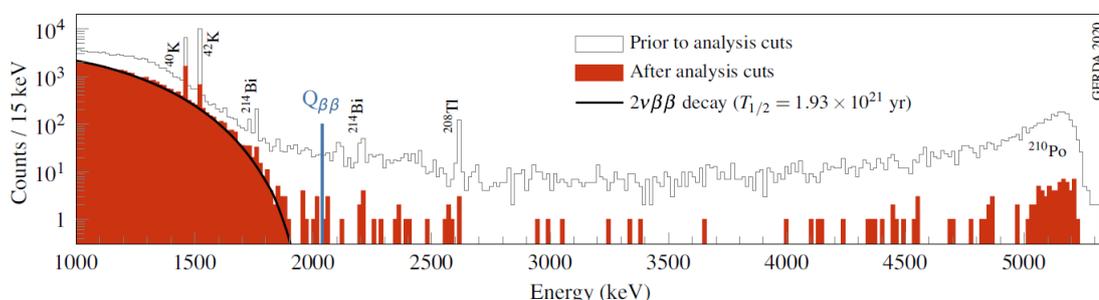


Рисунок 2.1 – Энергетический спектр с эксперимента GERDA

2.1. GERDA

Эксперимент GERDA вел поиск $0\nu\beta\beta$ на изотопе ^{76}Ge . Эксперимент протекал в две фазы, которые различаются используемыми детекторами. На заключительной стадии в GERDA был задействован 41 германиевый детектор общей массой 44,2 кг. Эксперимент расположен в Национальной Лаборатории Гран Сассо (INFN) на глубине 1400 метров под землей, так как горная порода является защитой от космических лучей [12].

Эксперимент GERDA работает с массивом германиевых детекторов,

размещенных в криостате из нержавеющей стали объемом 64 м^3 . Криостат наполнен жидким аргоном (LAr), он служит для охлаждения детекторов до рабочей температуры ($\sim 90\text{ K}$) и для экранирования 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 воды объемом 590 м^3 , который 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, а также мюонное вето, основанное на черенковском излучении и сцинтилляциях в жидком аргоне.

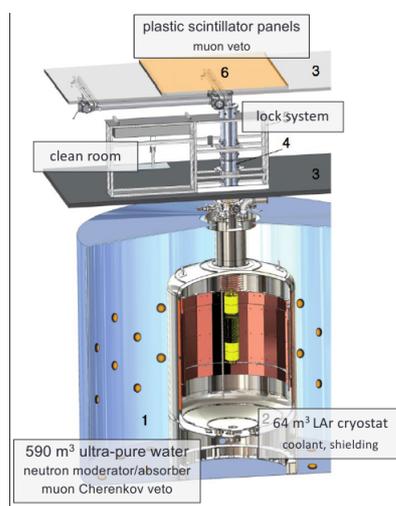


Рисунок 2.2 – Строение эксперимента GERDA

2.2. LEGEND

Эксперименты GERDA и MAJORANA закончили набор данных, и сейчас проектируется 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 ^{76}Ge будет увеличена с 10^{26} лет (как в GERDA) до 10^{28} лет, также будет значительно уменьшен фон. Для эксперимента LEGEND разработан новый вид детекторов: Inverted Coaxial Point Contact (ICPC) детектор. Он будет работать по аналогии с BEGe детекторами, но будет таким же массивным, как полукоаксиальные детекторы (до 4 кг).

В первой фазе эксперимента, LEGEND-200, которая в настоящее время вводится в эксплуатацию, будет использована инфраструктура эксперимента GERDA с некоторыми модификациями и будут задействованы детек-

торы общей массой до 200 кг. Чувствительность по $T_{1/2}^{0\nu}$ во время первой фазы будет $\sim 10^{27}$ лет. Вторая 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 планируется сделать следующие улучшения[13]:

- 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
- будет использоваться более чистый LAr с лучшим световыходом

В эксперименте LEGEND будут использоваться несколько типов германиевых детекторов: как ранее использовавшиеся полукоаксиальные и BEGe (GERDA), PPC (MAJORANA), так и новые ICPC [5].

2.3. ГЕРМАНИЕВЫЕ ДЕТЕКТОРЫ

Германиевые детекторы в эксперименте GERDA используются по ряду причин. Во-первых, германий дает отличное спектрографическое представление с 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 ^{76}Ge 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 $Q_{\beta\beta} = 2039$ 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 [12].
 - 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 $2m_e c^2$. 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.

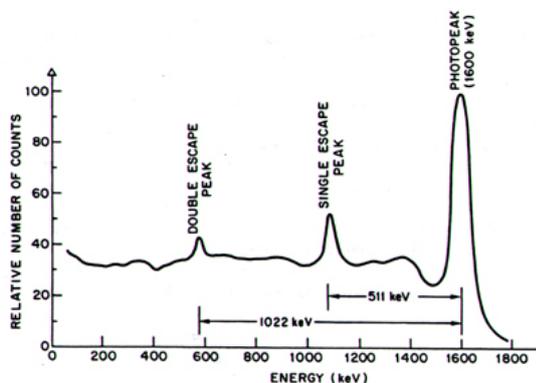


Рисунок 2.3 – Пример энергетического спектра

2.3.2. HPGE ДЕТЕКТОРЫ

Для полупроводников р типа n^+ слой с большой концентрацией доноров играет роль р-п перехода, он сделан с помощью внедрения в германий атомов лития путем диффузии в подходящие части детектора. Вследствие этого в детекторе появляется обедненная область при приложении отрицательного напряжения смещения. Сам n^+ слой представляет собой площадь толщиной 1 мм, которая называется мертвым слоем. Основным преимуществом является то, что такой широкий 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 внедрением атомов бора, его толщина порядка 0.1 мкм [12].

Для эксперимента GERDA применены две основные конфигурации: полукоаксиальная и BEGe, в эксперименте LEGEND будут использоваться в основном ICPC детекторы. Схемы этих детекторов можно видеть на рисунках 2.4 и 2.5.

Полукоаксиальная конфигурация: Из-за необходимости исследовать большие активные объемы вещества с управляемым напряжением смещения 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 специальными канавками. На рисунке 2.4 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 $Q_{\beta\beta}$ [12].

BEGe конфигурация: Для увеличения активной массы были разработаны детекторы типа BEGe (broad energy germanium). Эти детекторы чувствительны к широкому интервалу энергий. Контакт $p+$ представляет собой небольшую площадь (точечный контакт) на основании цилиндра, контакт $n+$ расположен по всей поверхности детектора. Контакты $p+$ и $n+$ отделены друг от друга специальными канавками. Размеры детекторов в 2-3 раза меньше полукоаксиальных. Так как внутри детектора поле более неоднородно, то BEGe детекторы показывают лучшее PSD представление 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 A 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 $Q_{\beta\beta}$ [12].

ICPC конфигурация: ICPC (inverted coaxial point contact) является новейшим типом детекторов. По размеру, массе и форме они сопоставимы

с полукоаксиальными детекторами, но по энергетическому разрешению сопоставимы с ВЕGe. Это, как и полукоаксиальные, цилиндрические детекторы с отверстием в центре. Контакт n+ расположен на всей поверхности детектора, контакт p+ является небольшой областью (точечным контактом) на основании (как в случае ВЕGe детекторов); контакты p+ и n+ отделены друг от друга специальными канавками [3]. Параметры детекторов: масса порядка 2 кг, диаметр и высота порядка 80 мм, энергетическое разрешение порядка 0.14% при $Q_{\beta\beta}$.

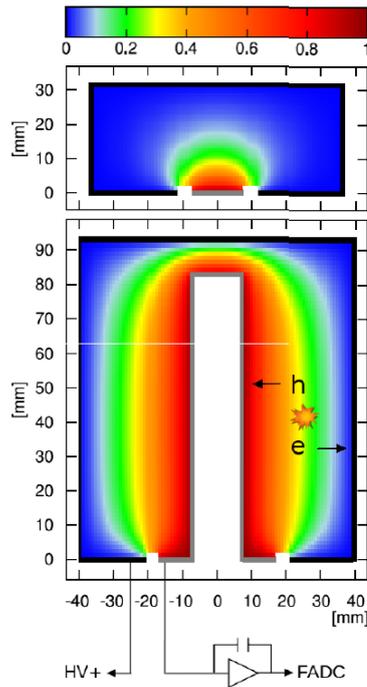


Рисунок 2.4 – Схема полукоаксиальных (снизу) и ВЕGe (сверху) детекторов. Серым цветом обозначен считывающий p-электрод, черным цветом обозначен n-электрод

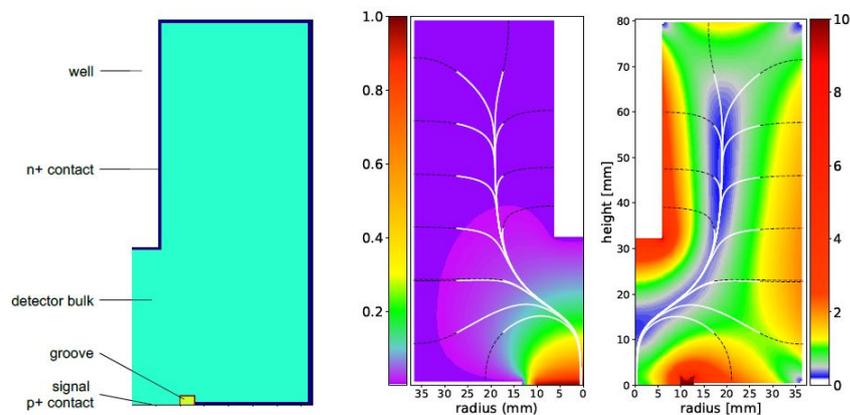


Рисунок 2.5 – Схема ICPC детекторов. Черными пунктирными линиями показаны траектории движения электронов; белыми сплошными линиями показаны траектории движения дырок к считывающему электроду

3. РАЗДЕЛЕНИЕ ПО ФОРМЕ ИМПУЛЬСА ДЛЯ ЭКСПЕРИМЕНТОВ GERDA И LEGEND

Временная зависимость токового импульса детектора может быть использована для распознавания фоновых и сигнальных событий. Как было показано выше, сигналы от $2\nu\beta\beta$ и $0\nu\beta\beta$ являются односточечными, 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 ^{208}Tl) и 2114-2124 кэВ (линия ^{214}Bi) исключаются из анализа по форме импульса. События в интервале энергии $Q_{\beta\beta} \pm 5\text{кэВ}$ (2034-2044 кэВ) также скрыты для анализа, так как в этой области находится потенциальная информация о $0\nu\beta\beta$ [14].

3.1. PSD ДЛЯ BEGE И ICPC ДЕТЕКТОРОВ

Для этого типа 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 2.4). Как видно из распределения поля, дырки достигают считывающего электрода по похожим траекториям вне зависимости от места выделения энергии, поэтому можно считать, что для локализованного выделения энергии амплитуда импульса прямо пропорциональна энергии. Только события вблизи катода нарушают эту зависимость, так как в этом случае электроны тоже играют роль в формировании сигнала. Такое распределение поля делает удобным использование 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, со-

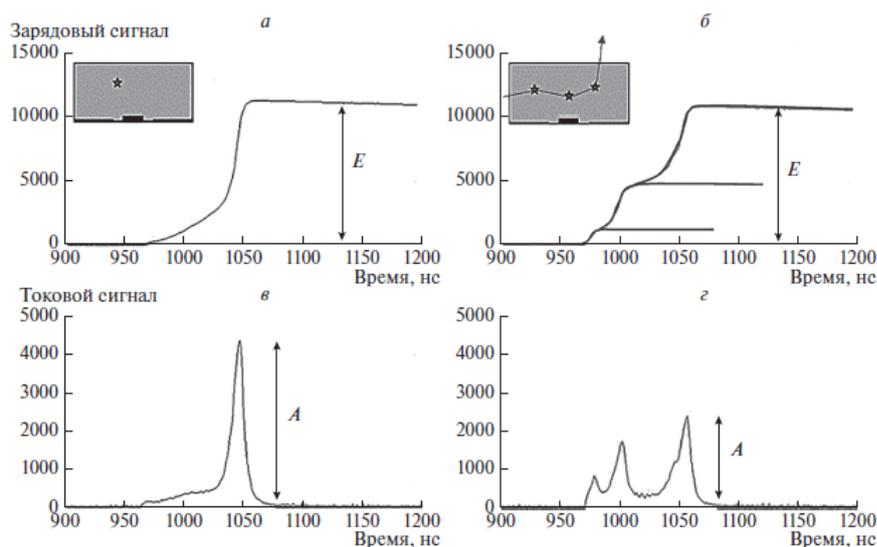


Рисунок 3.1 – Определение параметра отбора A/E , полученного с учетом различия между сигналами SSE и MSE

ответственно, A/E , больше, и пики раньше по времени, чем в стандартном SSE. Эта особенность позволяет эффективно распознавать эти сигналы.

Для поверхностных событий вблизи $p+$ 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 [18].

Благодаря меньшей 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 [14].

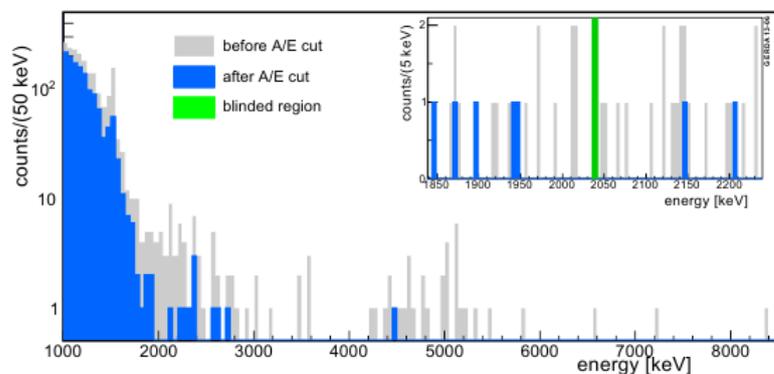


Рисунок 3.2 – Пример энергетического спектра до и после применения критерия отбора для BEGe

Стоит отметить, что для разделения MSE и SSE событий в ICPC де-

текторах также используется параметр A/E .

3.2. PSD ДЛЯ ПОЛУКОАКСИАЛЬНЫХ ДЕТЕКТОРОВ

В полукоаксиальных детекторах, как видно из распределения поля, вклад в формирование сигнала в общем случае вносят как электроны, так и дырки. Однако, при выделении энергии вблизи поверхности детектора есть некоторые особенности. Так, при выделении энергии вблизи поверхности $p+$ только дырки вносят вклад в сигнал. Для поверхностных событий на $p+$ максимумы токовых импульсов достигаются раньше по времени, так как дырки достигают считывающего p -электрода намного быстрее. Таким образом, в основном объеме детектора формы импульсов могут иметь различную форму, так как и электроны, и дырки вносят вклад в формирование сигнала. Следовательно, A/E не является эффективной для разделения переменной для полукоаксиальных детекторов. Вместо этого для PSD анализа в полукоаксиальных детекторах используются нейросети. Пример спектра калибровок на ^{228}Th 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 [14].

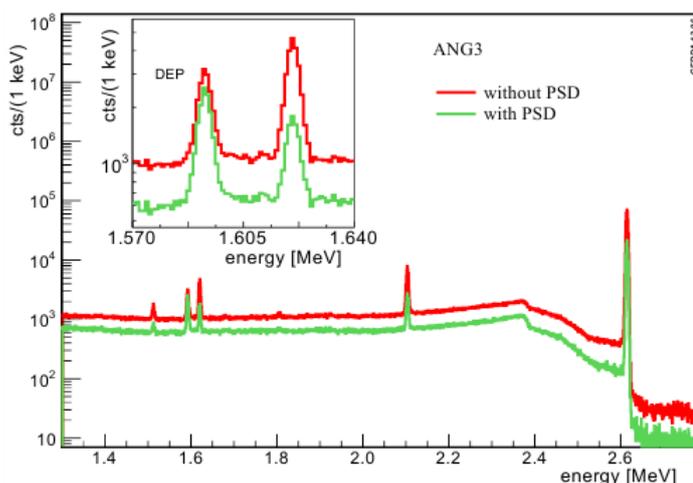


Рисунок 3.3 – Пример энергетического спектра до и после применения критерия отбора для полукоаксиальных детекторов. В качестве критерия для нейросети выбран критерий 90% выживаемости DEP событий

4. КАЛИБРОВКА ДЕТЕКТОРОВ LEGEND

Общим для всех методов и для всех видов детекторов является использование калибровочных данных, которые собирались раз в неделю для проверки и тренировки алгоритмов. Спектр калибровок на ^{228}Th (рисунок 4.1) содержит пик (FEP) на 2614.5 кэВ от распада ^{208}Tl . 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 ^{212}Bi указывает на многоточечные события (MSE). Получаемые детекторами импульсы (DEP от распада ^{208}Tl и FEP от распада ^{212}Bi) 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 [14].

Цепочка распада ^{228}Th показана на рисунке 4.2

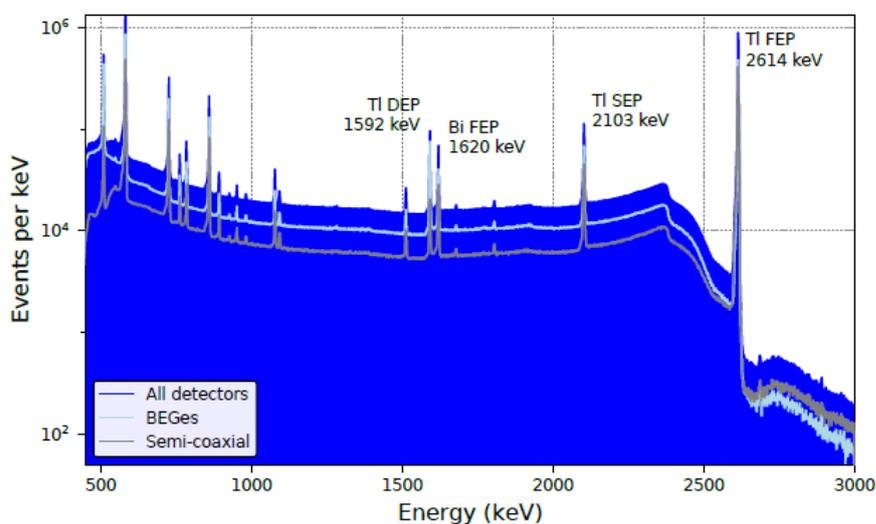


Рисунок 4.1 – Энергетический спектр ^{228}Th

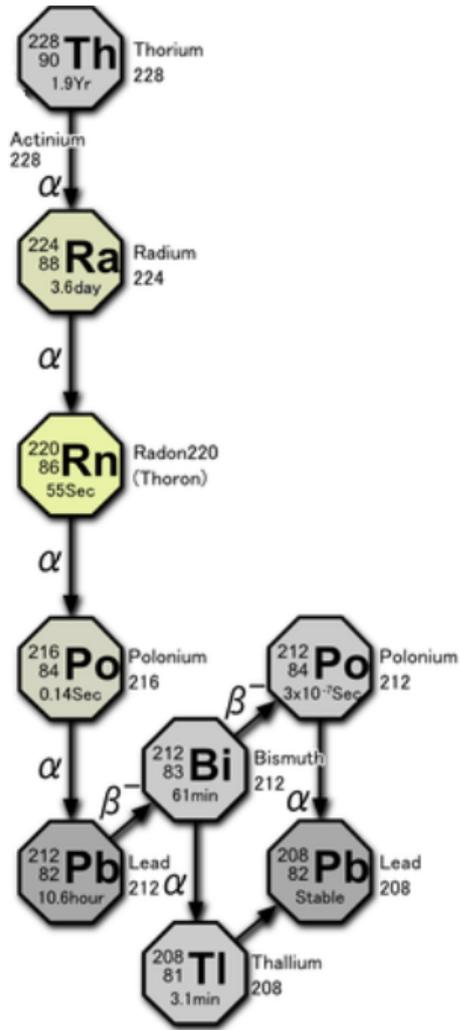


Рисунок 4.2 – Цепочка распада ^{228}Th

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 b - свободный параметр. Далее в скрытом слое на полученные данные действуют функцией активации для нормализации результата [15].

Получив результат, нейросеть вычисляет ошибку (различие между полученным результатом и реальным) и затем начинает менять веса, минимизируя эту ошибку (например, методом градиентного спуска). 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.

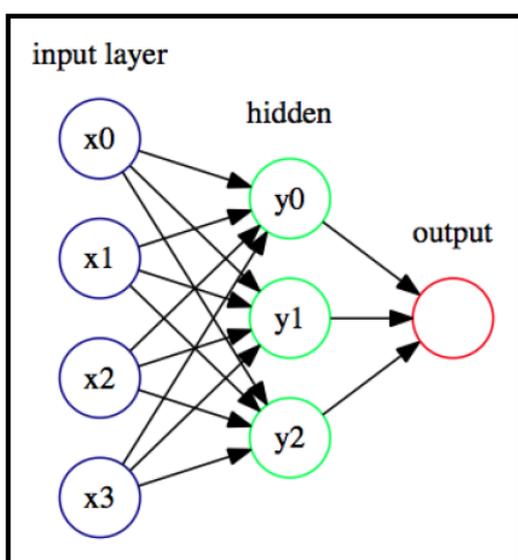


Рисунок 5.1 – Схема нейросети с одним скрытым слоем

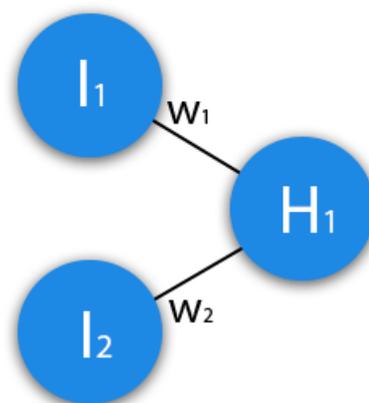


Рисунок 5.2 – Пример работы нейронной сети

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. Сверточные слои (convolutions) представляют собой применение опе-

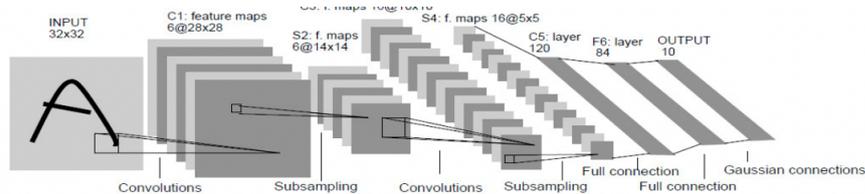


Рисунок 5.3 – Схема сверточной нейронной сети

рации 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 [4]. Стоит отметить, что в данном анализе применяются одномерные сверточные нейронные сети, которые обучаются хуже, чем двумерные.

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 максимальной, 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 [17].

6. ГЕНЕРАТИВНО-СОСТЯЗАТЕЛЬНАЯ СЕТЬ (GAN)

Генеративно-сопязательные 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-сопязательные 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-сопязательной сети. Важно отметить, что добиться стабильного обучения обеих моделей в рамках сети GAN трудно.

6.1. MINIMAX GAN

Этот подход является наиболее простым алгоритмом генеративно-сопоставительных 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 дискриминатором 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 классификации).

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 [8].

6.2. WASSERSTEIN GAN

Для стабилизации процесса обучения GAN моделей можно использовать метод Вассерштейна, заключающийся в выборе отличной от minimax-подхода метрики для оптимизации весов. Утверждается, что, в отличие от minimax-подхода, новая метрика должна быть всегда гладкой, то есть наиболее подходящей для оптимизации весов [2]. 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.

Для того чтобы учесть условие, что дискриминатор должен принадлежать к классу функций Липшица, надо потребовать, чтобы веса дискриминатора были небольшими и находились в рамках какого-то интервала, который бы задавался гиперпараметрами, что иногда может привести к проблемам в обучении [11].

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 [11].

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 6.1. В процессе обучения простой автокодировщик решает следующую оптимизационную задачу: $\|X - g(f(X))\|_2^2 \rightarrow \min$, где g - декодировщик, f - кодировщик, X - исходная выборка. Объект обычно вос-

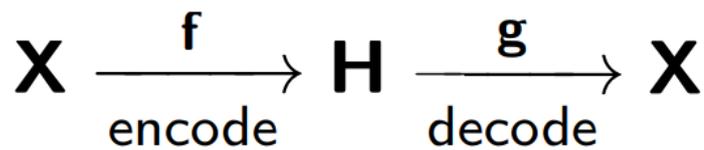


Рисунок 6.1 – Схема автокодировщика

становливается с потерями, так как в процессе кодировки в скрытом пространстве H 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 "сопостязательный" автокодировщик (adversarial autoencoder, ААЕ). Его схема показана на рисунке 6.2. Автокодировщик дополняется моделью-дискриминатором (D), что делает его

похожим на генеративно-сопоставительную сеть, где в роли генератора выступает модель-кодировщик. В результате обучения код объекта, поданному на вход автокодировщику, подчиняется определенному распределению [1]. Таким образом, скрытое пространство признаков, которое получается при проходе объекта через кодировщик, становится более предсказуемым.

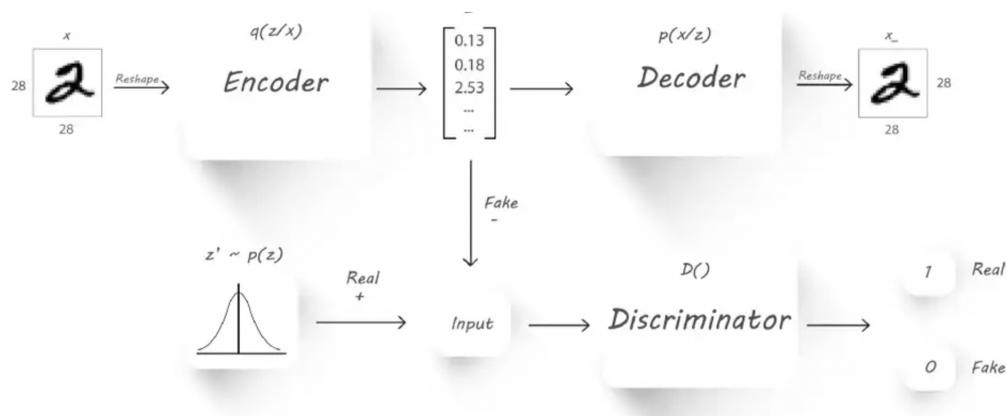


Рисунок 6.2 – Схема adversarial autoencoder

7. МОДЕЛИРОВАНИЕ СИГНАЛОВ ДЛЯ ICPC ДЕТЕКТОРОВ ЭКСПЕРИМЕНТА LEGEND

Целью работы было моделирование сигнала для ICPC детекторов в эксперименте LEGEND с помощью генеративно-состязательных нейронных сетей. Генеративная сеть могла бы стать альтернативой или дополнением Монте-Карло моделированию, так как процесс моделирования данных с помощью нейронных сетей занимает гораздо меньше времени.

В качестве выборки были использованы калибровочные данные для ICPC детекторов, полученные в лаборатории NADES с помощью ^{228}Th источника. Для обучения нейронной сети были использованы события при энергии DEP (double escape peak) от распада ^{208}Tl . Пример входных данных показан на рисунке 7.1. Каждый зарядовый импульс состоит из 3748 точек, всего для обучения использовалось порядка 20000 импульсов.

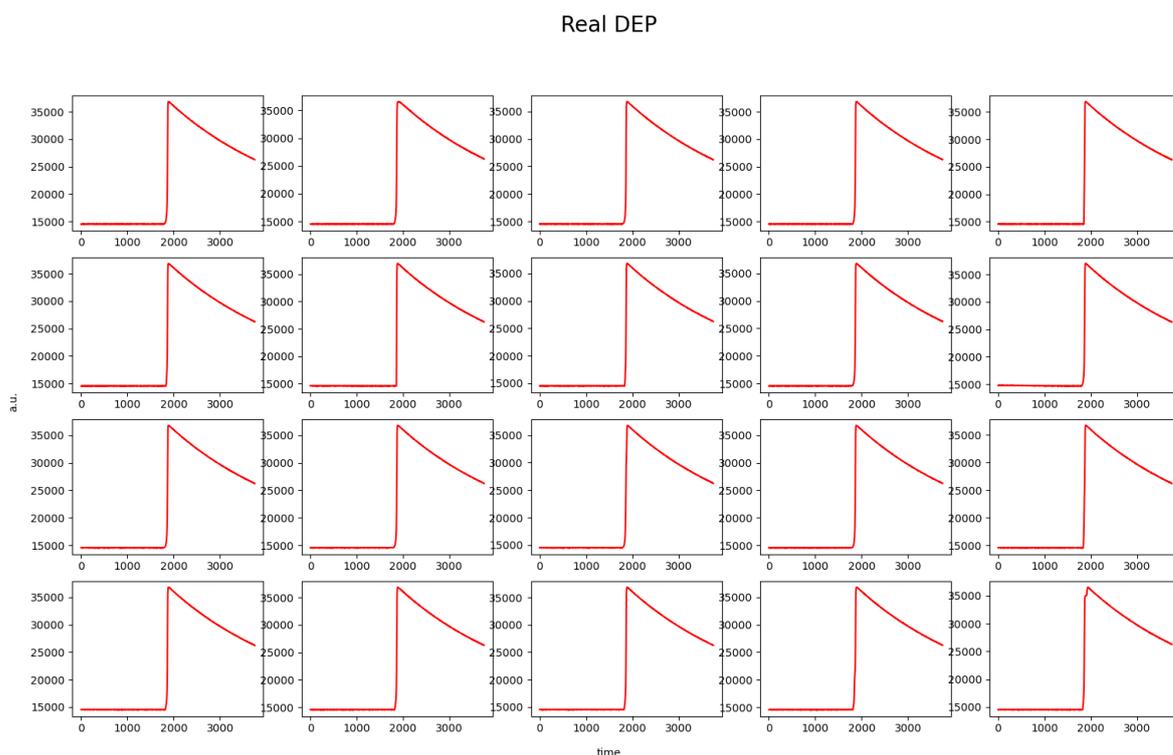


Рисунок 7.1 – Пример входных зарядовых импульсов

Перед обучением все данные были приведены к стандартному виду та-

ким 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

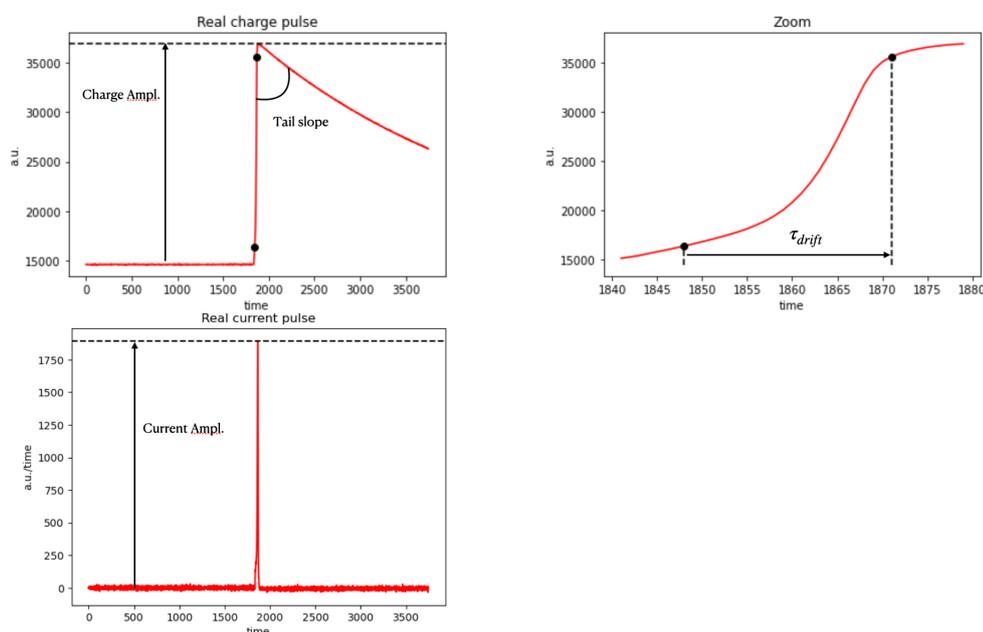


Рисунок 7.2 – Параметры, используемые для оценки правдоподобия синтезированных данных

В ходе работы были созданы несколько моделей генеративно-состязательных сетей на базе библиотеки PyTorch с разными алгоритмами и особенностями. Так, в анализе использовались minimax GAN, Wasserstein-gp GAN, автокодировщики, также применялся анализ главных компонент. В качестве генератора и дискриминатора использовались одномерные сверточные нейронные сети.

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 7.2 показаны данные параметры. Очевидно, что в случае моделирования правдоподобных данных распределения параметров для синтезированных данных и реальных данных должны совпадать.

7.1. GAN БЕЗ ИСПОЛЬЗОВАНИЯ АВТОКОДИРОВЩИКА

В этой секции будут рассмотрены результаты моделей minmax GAN и Wasserstein-gr 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 признаков.

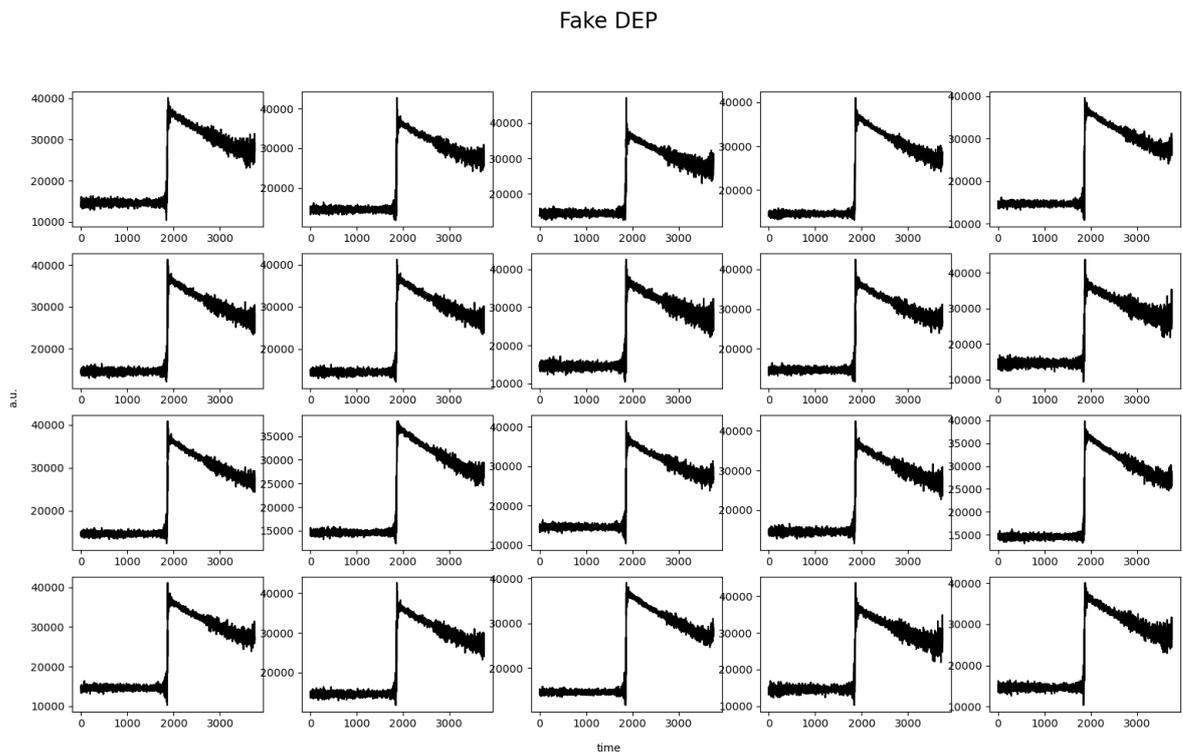


Рисунок 7.3 – Примеры импульсов, полученные в результате обучения minmax GAN

7.1.1. MINIMAX GAN

Была рассмотрена самая простая модель minmax-GAN. Примеры импульсов, полученные в результате обучения этой модели, показаны на рисунке 7.3, распределения параметров импульсов показаны на рисунке 7.4.

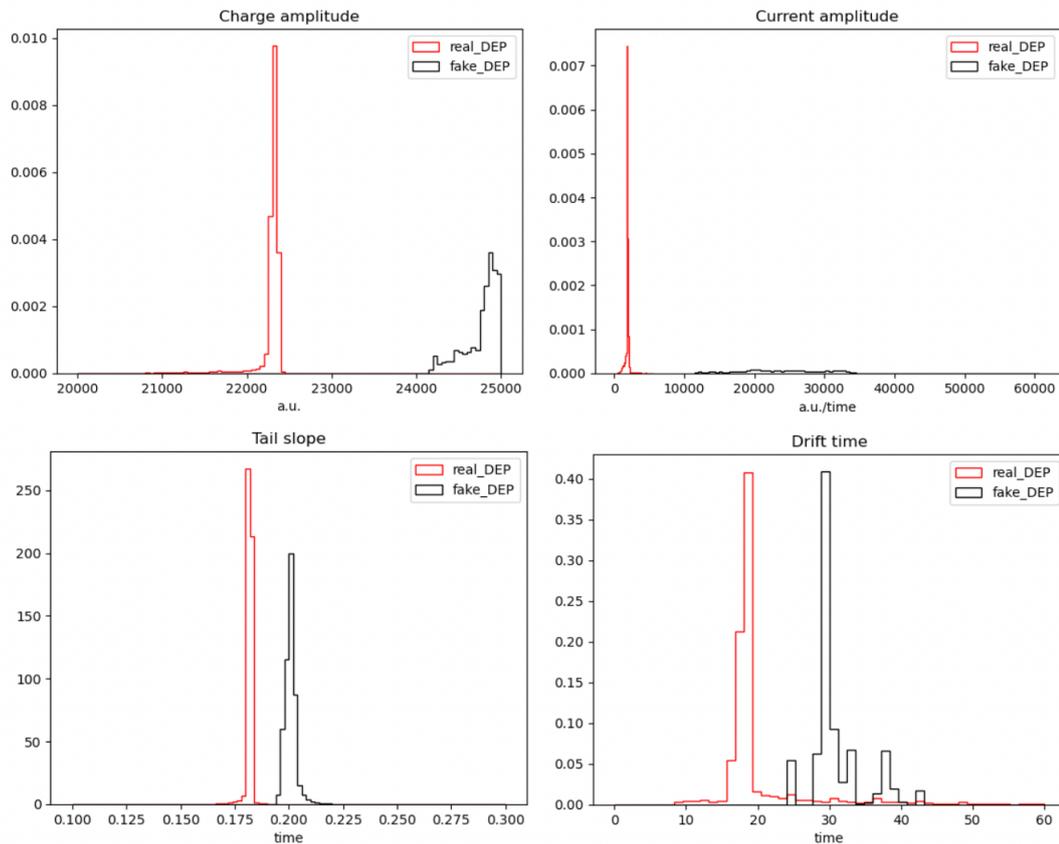


Рисунок 7.4 – Распределения параметров импульсов, полученных в результате обучения minmax GAN

По рисункам 7.3, 7.4 видно, что данная (самая простая) модель не способна синтезировать похожие на реальные формы импульсов.

7.1.2. WASSERSTEIN-GP GAN

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 7.5, распределения параметров импульсов показаны на рисунке 7.6. По рисункам 7.5, 7.6 видно, что модель Wasserstein-gp дает, в целом, визуальную более правдоподобные импульсы, а также генерирует данные с практически идеальным параметром tail slope, однако распределения других параметров синтезированных данных остаются неудовлетворительными.

Fake DEP

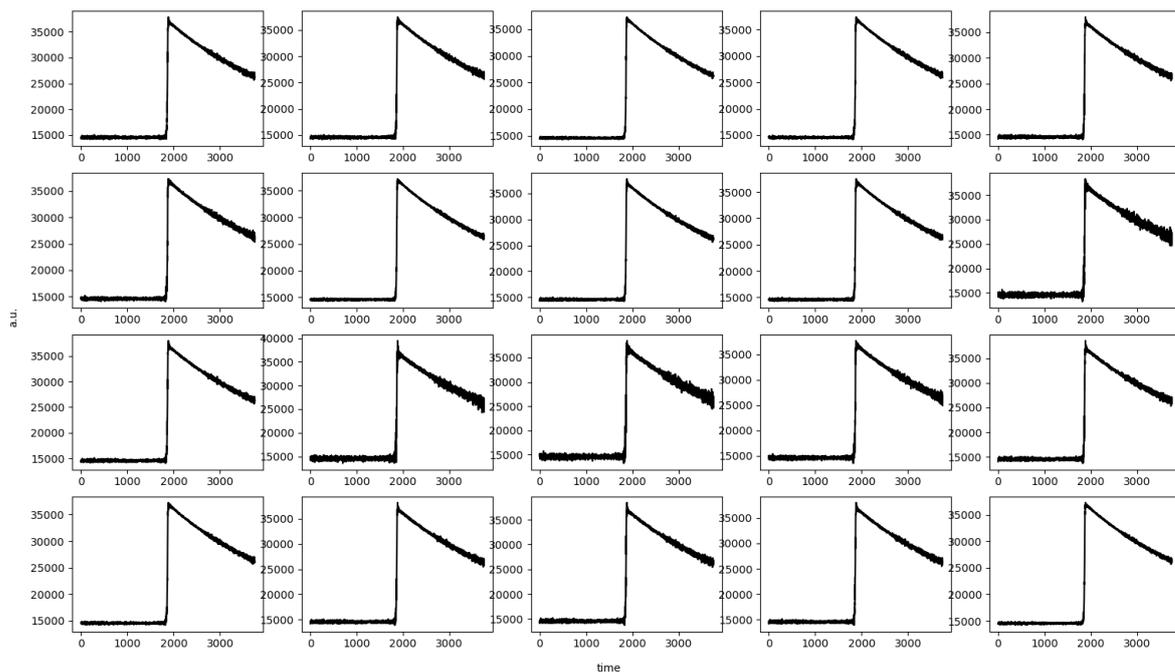


Рисунок 7.5 – Примеры импульсов, полученные в результате обучения Wasserstein-gp GAN

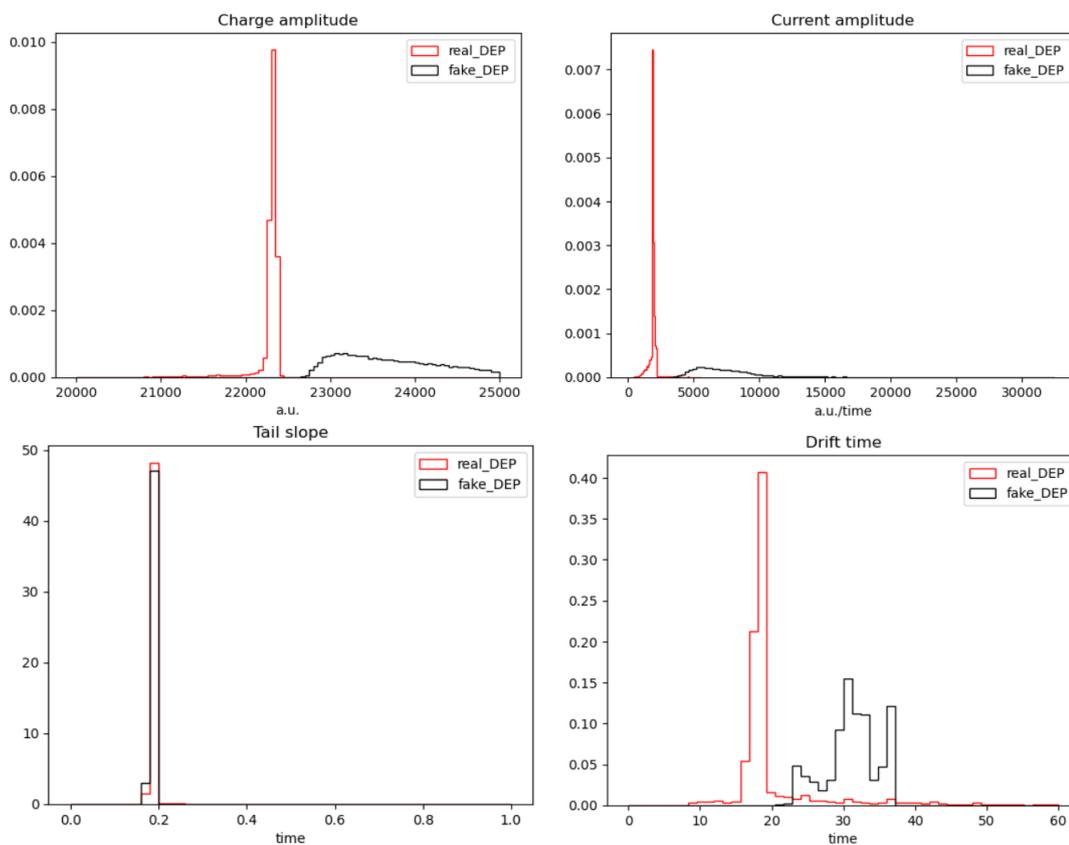


Рисунок 7.6 – Распределения параметров импульсов, полученных в результате обучения Wasserstein-gp GAN

7.2. GAN 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 генеративно-состязательной сети. В этой секции рассмотрены те же модели minimax GAN и Wasserstein-gp GAN, однако перед обучением самой генеративно-состязательной 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 скрытом пространстве, затем синтезированные данные будут преобразованы из скрытого пространства в исходное (из 3748 признаков) с помощью модели-декодировщика.

7.2.1. MINIMAX GAN С ПРИМЕНЕНИЕМ ААЕ

Примеры импульсов, полученные в результате обучения Minimax GAN с предварительным обучением автокодировщика, показаны на рисунке 7.7, распределения параметров импульсов показаны на рисунке 7.8.

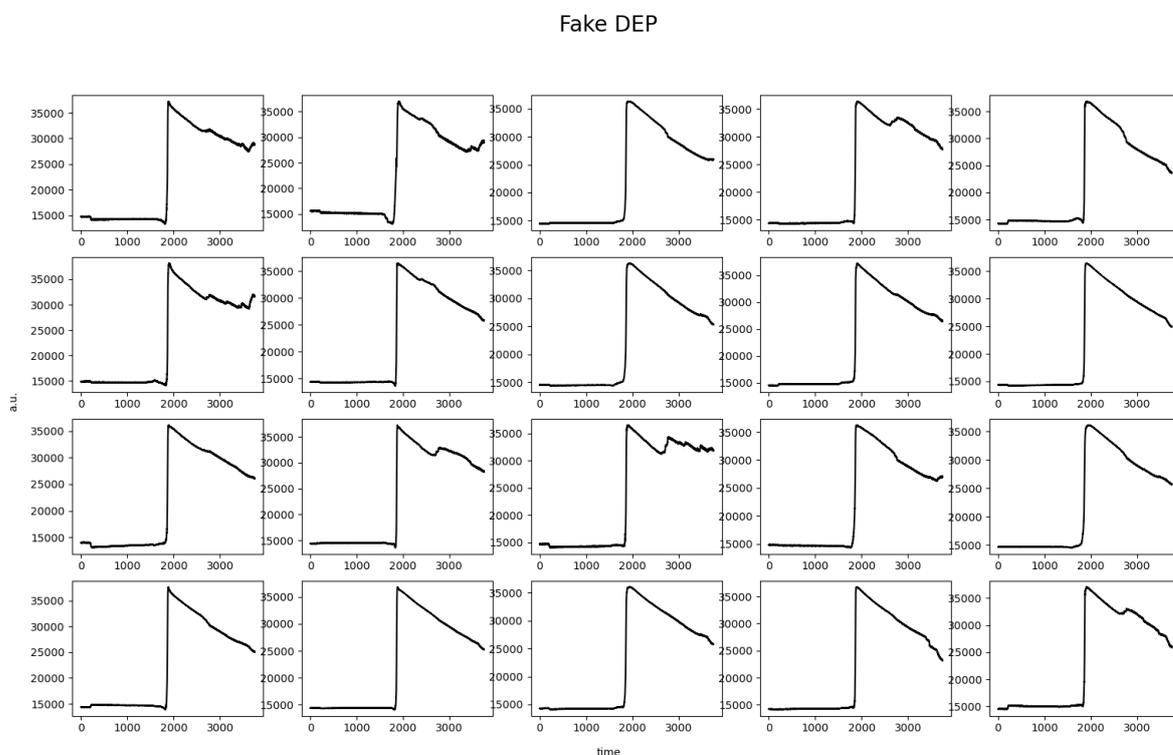


Рисунок 7.7 – Примеры импульсов, полученные в результате обучения minimax GAN с ААЕ

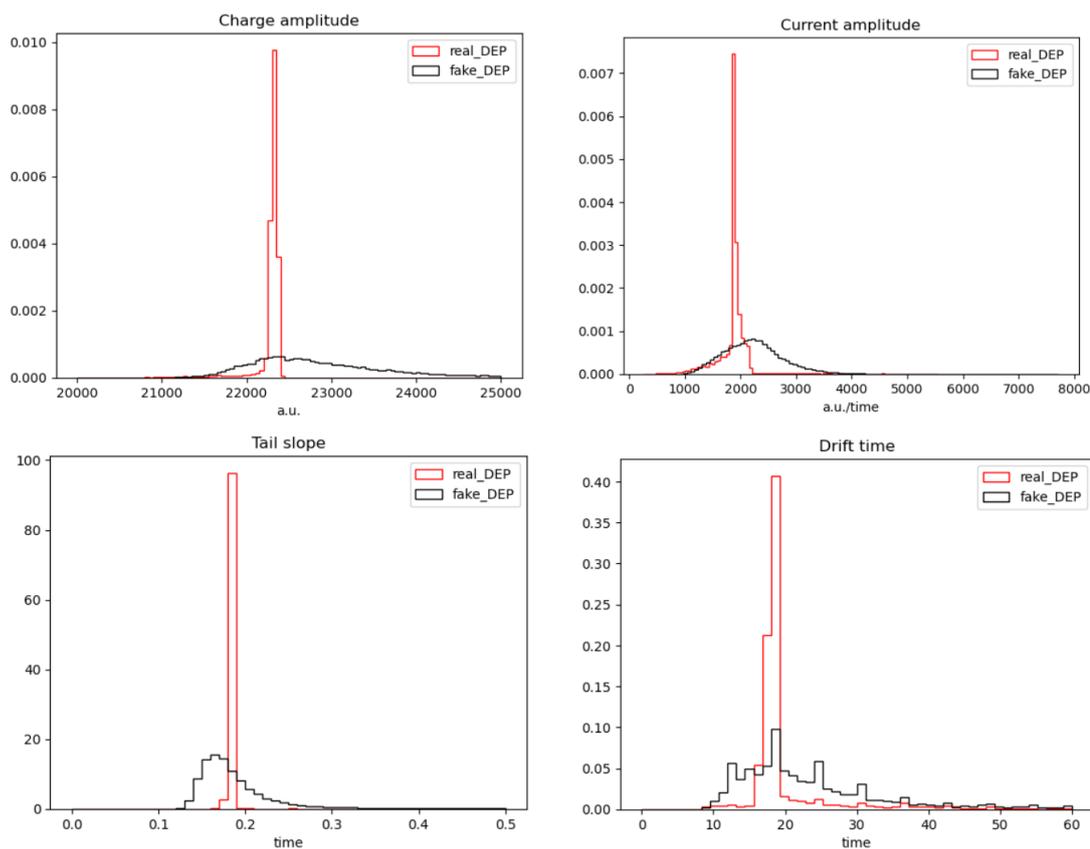


Рисунок 7.8 – Распределения параметров импульсов, полученных в результате обучения minimax GAN с AAE

По рисункам 7.7, 7.8 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 совпались с реальными, однако такая сеть не является применимой.

7.2.2. WASSERSTEIN-GP GAN С ПРИМЕНЕНИЕМ AAE

Примеры импульсов, полученные в результате обучения Wasserstein-gp GAN с предварительным обучением автокодировщика, показаны на рисунке 7.9, распределения параметров импульсов показаны на рисунке 7.10. 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, не является применимой.

Fake DEP

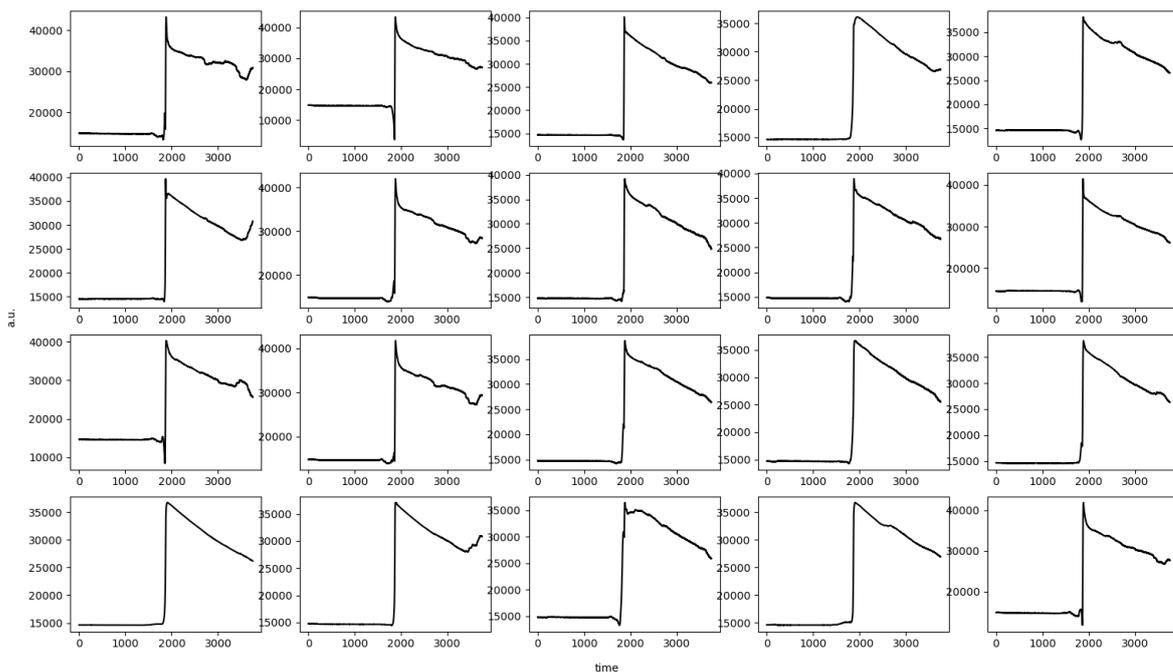


Рисунок 7.9 – Примеры импульсов, полученные в результате обучения Wasserstein-gp GAN с AAE

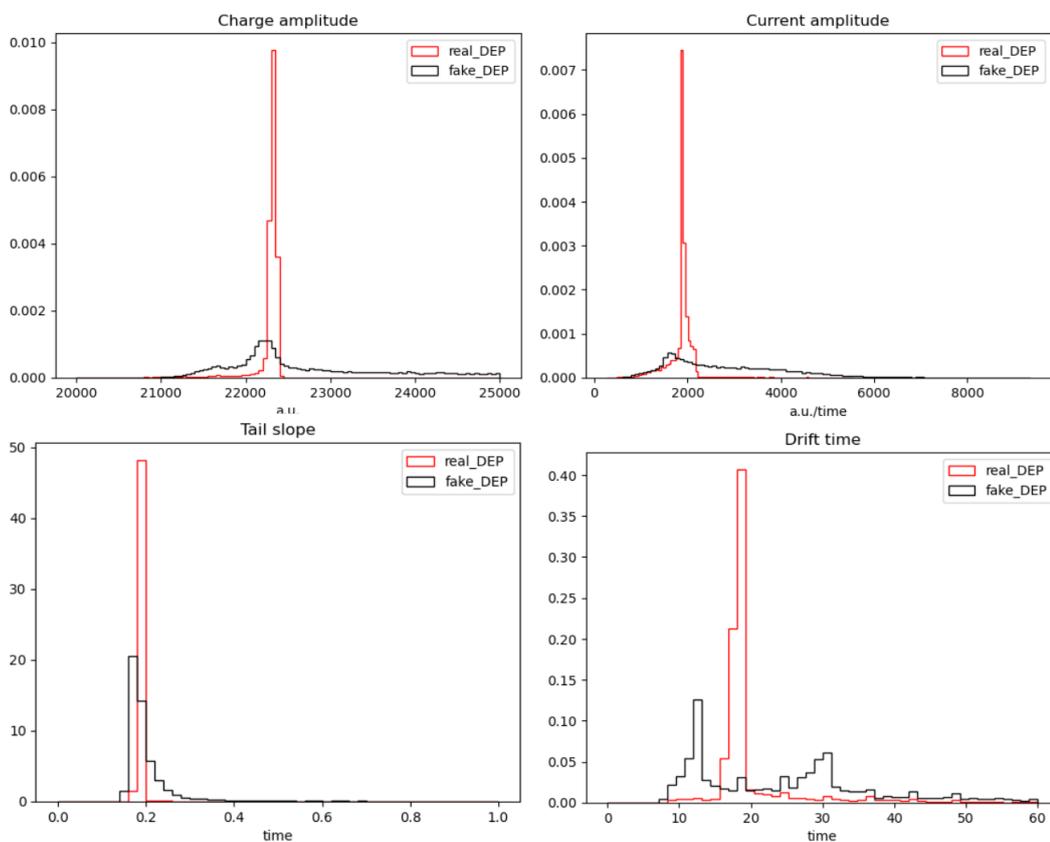


Рисунок 7.10 – Распределения параметров импульсов, полученных в результате обучения Wasserstein-gp GAN с AAE

7.3. MINIMAX GAN 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 7.11, 7.12.

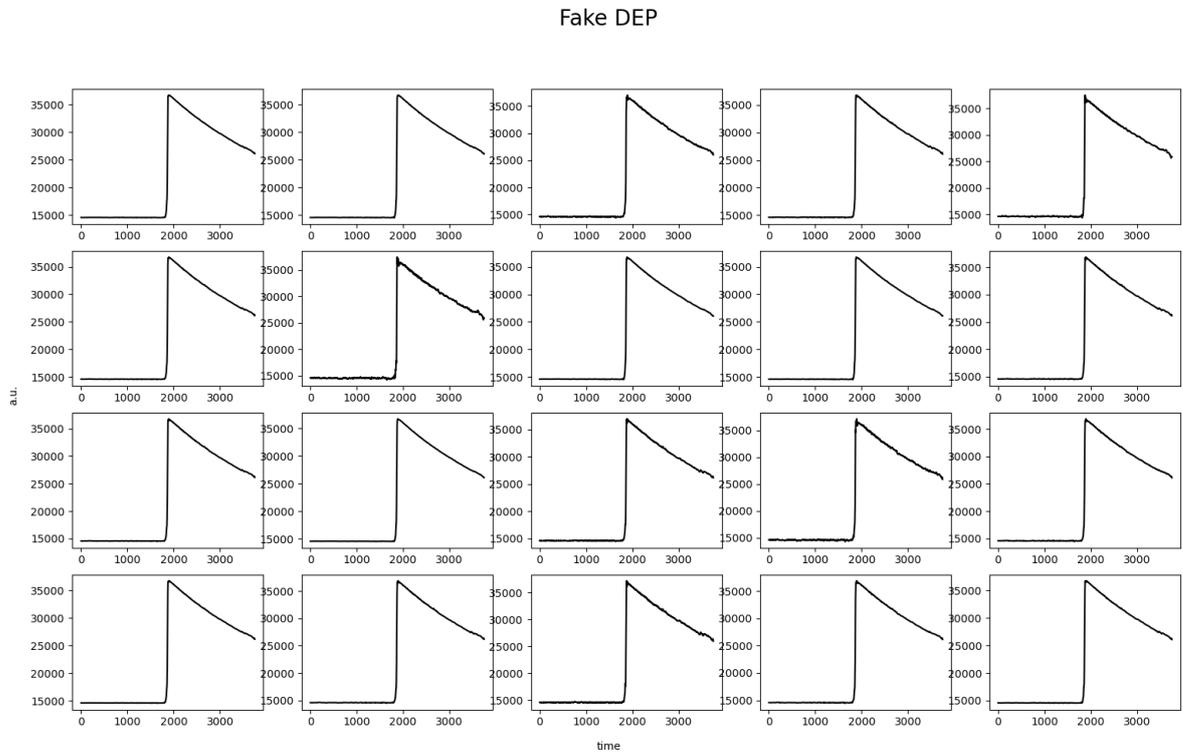


Рисунок 7.11 – Примеры импульсов, полученные в результате обучения minimax GAN с PCA

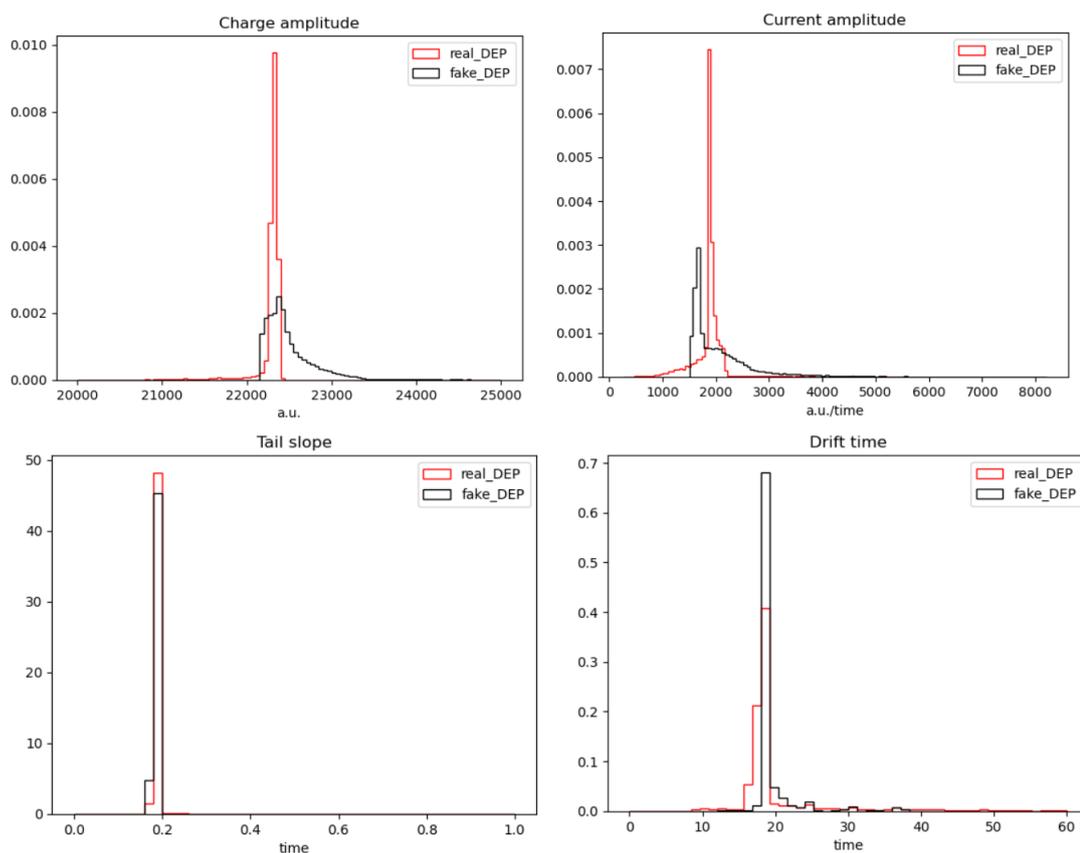


Рисунок 7.12 – Распределения параметров импульсов, полученных в результате обучения minmax GAN с PCA

По рисункам 7.11, 7.12 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 отсеять синтезированные импульсы, у которых распределения параметров не совпадают с распределениями параметров реальных импульсов. Были применены критерии отбора:

$$22270 \text{ a.u.} < \text{Charge amplitude} < 22350 \text{ a.u.}$$

$$1850 \text{ a.u./time} < \text{Current amplitude} < 2000 \text{ a.u./time}$$

Полученные после применения отбора формы импульсов и распределения параметров показаны на рисунках 7.13, 7.14. 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

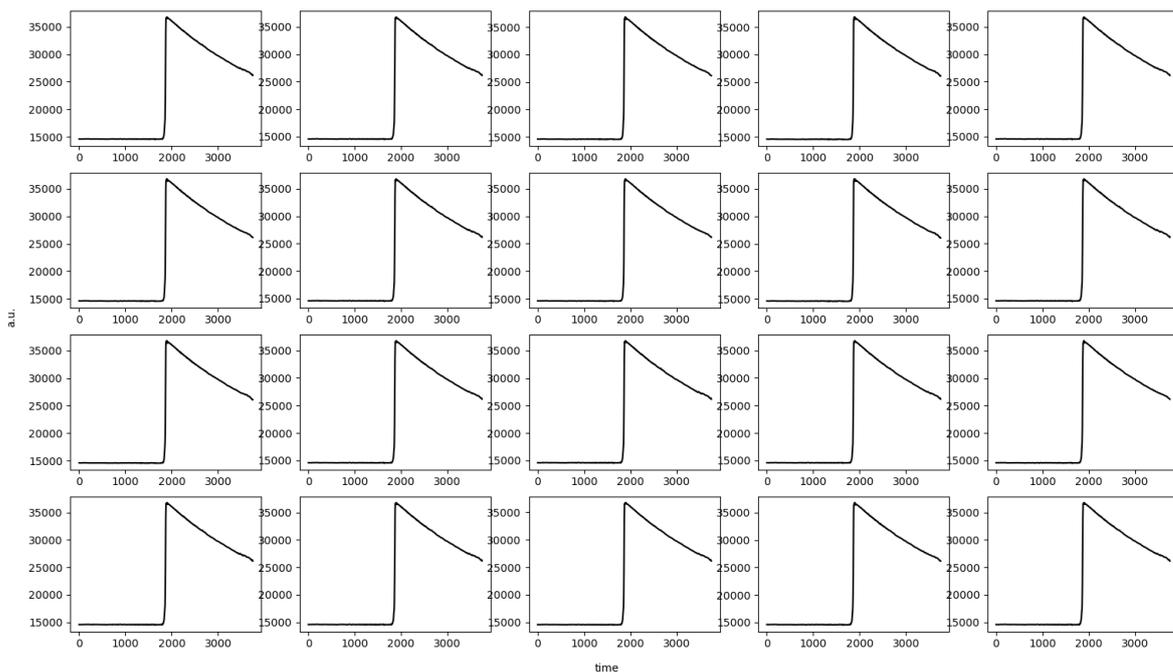


Рисунок 7.13 – Примеры импульсов, полученные в результате обучения minimax GAN с PCA после применения критериев отбора

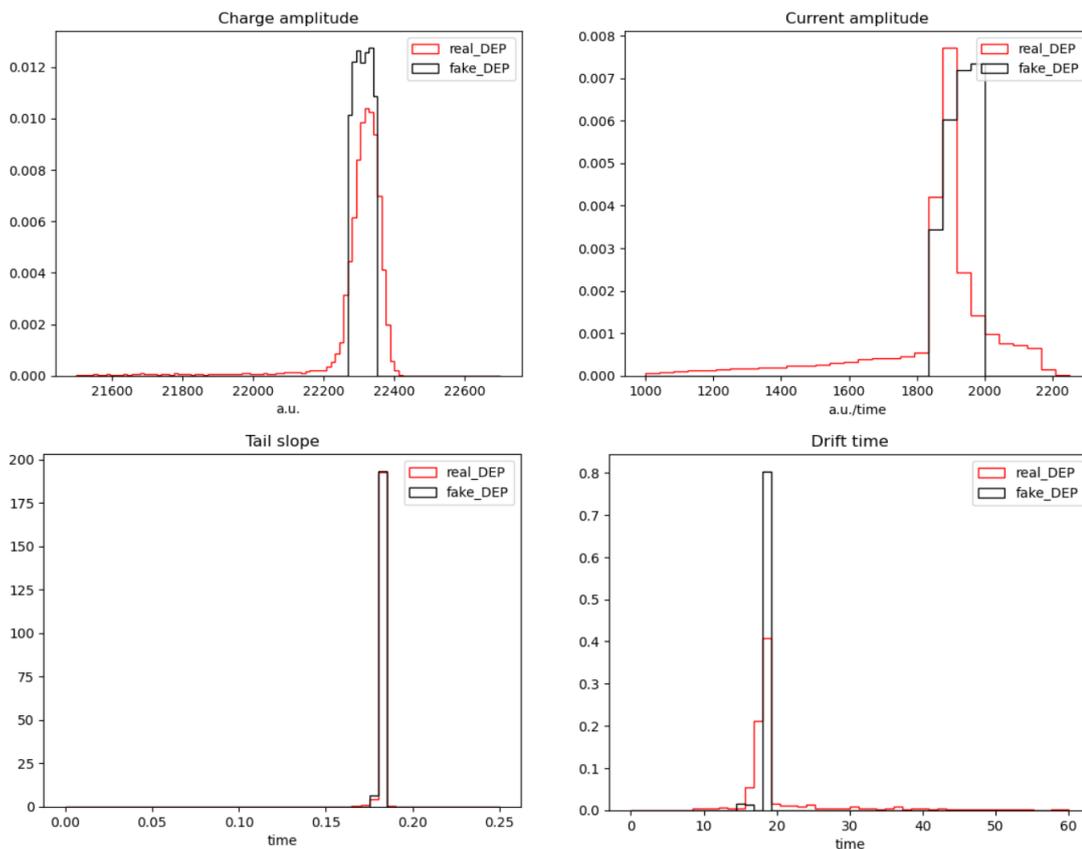


Рисунок 7.14 – Распределения параметров импульсов, полученных в результате обучения minimax GAN с PCA после применения критериев отбора

7.4. РЕЗУЛЬТАТЫ

В ходе работы было проведено моделирование форм импульсов, полученных на ICPC детекторах эксперимента LEGEND, с помощью различных алгоритмов генеративно-состязательных сетей. По итогам обучения простых моделей была верно сформулирована гипотеза о необходимости снижения размерности пространства признаков. Наиболее приемлемый результат обеспечивается в модели *minimax GAN* при предварительном применении к данным метода главных компонент, а также при применении к синтезированным данным критериев отбора. Однако, несмотря на сходство синтезированных и реальных данных, применение критериев отбора сильно сокращает выборку. Возможно, проблемы с генерацией данных связаны со сложностями при обучении генеративно-состязательных сетей, поэтому в дальнейшем будут использованы генеративные диффузионные модели, которые основаны не на состязательном процессе генератора и дискриминатора, что, возможно, позволит избежать проблем с обучением генеративной модели и получить правдоподобный результат. Также планируется обобщить данный анализ на другие типы детекторов.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Adversarial Autoencoders / A. Makhzani [et al.]. — 2015.
2. *Arjovsky M., Chintala S., Bottou L.* Wasserstein GAN. — 2017.
3. Characterization of inverted coaxial Ge detectors in GERDA for future double beta-decay experiments / M. Agostini [et al.] // The European Physical Journal C. — 2021. — June. — Vol. 81, no. 6.
4. Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach / S. Indolia [et al.] // Procedia Computer Science. — 2018. — Vol. 132. — P. 679–688 ; — International Conference on Computational Intelligence and Data Science.
5. *D'Andrea V.* Neutrinoless Double Beta Decay Search with ^{76}Ge : Status and Prospect with LEGEND // 54th Rencontres de Moriond on Electroweak Interactions and Unified Theories. — 05/2019.
6. Final Results of GERDA on the Search for Neutrinoless Double- β Decay / M. Agostini [et al.] // Phys. Rev. Lett. — 2020. — Dec. — Vol. 125, issue 25. — P. 252502.
7. *Furry W. H.* On Transition Probabilities in Double Beta-Disintegration // Phys. Rev. — 1939. — Dec. — Vol. 56, issue 12. — P. 1184–1193.
8. Generative Adversarial Networks / I. J. Goodfellow [et al.]. — 2014.
9. *Goepfert-Mayer M.* Double Beta-Disintegration // Phys. Rev. — 1935. — Sept. — Vol. 48, issue 6. — P. 512–516.
10. *Goldhaber M., Grodzins L., Sunyar A. W.* Helicity of Neutrinos // Phys. Rev. — 1958. — Feb. — Vol. 109, issue 3. — P. 1015–1017.
11. Improved Training of Wasserstein GANs / I. Gulrajani [и др.]. — 2017.
12. *Kirsch A.* Search for the neutrinoless double beta-decay in Gerda Phase I using a Pulse Shape Discrimination technique. — 2014. — Jan.
13. LEGEND-1000 Preconceptual Design Report / LEGEND Collaboration [et al.]. — 2021.
14. Pulse shape discrimination for GERDA Phase I data / M. Agostini [et al.] // Eur. Phys. J. C. — 2013. — Vol. 73, no. 10. — P. 2583.
15. Python Deep Learning / I. Vasilev [et al.]. — Packt Publishing, 2019. — P. 378.

16. *Wagner V.* Pulse Shape Analysis for the GERDA Experiment to Set a New Limit on the Half-life of Neutrinoless Double Beta Decay of Ge-76 : PhD thesis / Wagner Victoria. — 01/2017.
17. Метод главных компонент. — URL: <https://wiki.loginom.ru/articles/principal-component-analysis.html>.
18. *Румянцева Н. С.* Новые типы германиевых детекторов для поиска двойного безнейтринного бета-распада // Известия Российской академии наук. Серия физическая. — 2019.