

СОФИЙСКИ УНИВЕРСИТЕТ „СВ. КЛИМЕНТ ОХРИДСКИ“  
ФИЗИЧЕСКИ ФАКУЛТЕТ  
КАТЕДРА АТОМНА ФИЗИКА



---

Прилагане на машинно обучение за  
реконструиране на събития в  
електромагнитния калориметър на  
експеримента РАDME

---

*Калина Красмирова Димитрова*  
Дипломна работа за придобиване на ОКС „Магистър“

Научен ръководител: доц. д-р Венелин Кожухаров

02 март 2023 г.  
София

---

# Съдържание

<b>1</b>	<b>Въведение</b>	<b>3</b>
<b>2</b>	<b>Експериментът PADME</b>	<b>6</b>
2.1	Активна мишена . . . . .	7
2.2	Детектори за заредени частици . . . . .	8
2.3	Калориметри . . . . .	10
2.4	Система за набор на данни . . . . .	13
2.5	Обработка и реконструкция на данните . . . . .	13
2.6	Изисквания към характеристиките на реконструираните обекти . . . . .	15
<b>3</b>	<b>Описание на сигналите в електромагнитния калориметър на PADME чез невронни мрежи</b>	<b>17</b>
3.1	Симулации на сигнали . . . . .	17
3.2	Класифициране на събития с невронна мрежа . . . . .	18
3.3	Невронна мрежа с архитектура на автоенкодер . . . . .	21
3.4	Модифициран автоенкодер за определяне параметрите на сигнали . . . . .	22
3.5	Реконструиране на параметрите на сигналите . . . . .	25
<b>4</b>	<b>Резултати от реконструкцията на събитията</b>	<b>26</b>
4.1	Реконструкция на времето . . . . .	26
4.2	Разпознати и неразпознати сигнали . . . . .	27
4.3	Реконструкция на амплитудата . . . . .	28
<b>5</b>	<b>Заклучение</b>	<b>31</b>
	<b>Литература</b>	<b>32</b>

# Глава 1

## Въведение

Търсенето на обяснение за съществуването на Тъмната материя води до появата на различни хипотези за разширение на Стандартния модел в последните години. Сред тях са слабо взаимодействащите масивни частици (Weakly Interacting Massive Particles, WIMPs) [1], аксионоподобните частици [2] и други. Липсата на наблюдавани състояния с маси от порядъка на 100 GeV, обаче, кара учените да търсят други обяснения за природата на Тъмната материя.

Едно от възможните обяснения за състава на Тъмната материя е съществуването на „скрит сектор“ от частици, които не участват във взаимодействията от Стандартния модел. Връзката между частиците от скрития сектор и тези от Стандартния модел най-често се осъществява посредством други частици - медиатори.

Едно възможно решение е въвеждането на нова  $U(1)'$  калибровъчна симетрия по аналогия с електромагнитното взаимодействие. Калибровъчният векторен бозон, асоцииран с тази симетрия, е така нареченият тъмен фотон  $A'$ , който може да взаимодейства като медиатор с частици от двата сектора. Най-простият Лагранжиан на взаимодействието между тъмния фотон и електрона има вида

$$\mathcal{L} \sim \epsilon e \bar{\psi}_e \gamma^\mu \psi_e A'_\mu, \quad (1.1)$$

където взаимодействието с  $A'$  е  $\epsilon$  пъти по слабо от електромагнитното взаимодействие на електроните.

В случай, че  $m_{A'} \geq 2m_e$  е възможно да се наблюдава разпад  $A' \rightarrow e^+e^-$ , което би позволило експериментално наблюдение. При наличие на частица  $\chi$  от скрития сектор с маса  $m_\chi \leq 1/2m_{A'}$  тъмният фотон се разпада до двойка  $\chi\chi$  в крайно състояние ( $A' \rightarrow \chi\chi$ ) и обикновено не може да бъде експериментално наблюдаван пряк сигнал от  $A'$ .

PADME (Positron Annihilation into Dark Matter Experiment) е експеримент в Националната лаборатория във Фраскати, Италия, чиято основна цел е търсенето на  $A'$  при процес на аниhilация на позитрони от позитронен сноп с електрони във фиксирана мишена [3]:


$$e^+e^- \rightarrow A'\gamma. \quad (1.2)$$

Ако се знаят четириимпулсите на позитроните от снопа, електроните в покой и излъчените след взаимодействието фотони, то липсващата маса  $M_{miss}^2$  а оттам и масата на тъмния фотон може да бъде определена чрез

$$M_{miss}^2 = (P_{e^+} + P_{e^-} - P_\gamma)^2 \quad (1.3)$$

независимо от това дали  $A'$  се разпада до видими или невидими частици.

Схематично представяне на основния принцип на експеримента е показано на фигура 1.1.



**Фигура 1.1:** Схематично представяне на принципа на експеримента PADME. Позитроните от снопа взаимодействат с електроните в мишената, вследствие на което се ражда фотон  $\gamma$ , който може да бъде регистриран от детекторите и тъмен фотон  $A'$ , който не може да бъде детектиран, но масата му може да бъде възстановена.

За целите на PADME се използва позитронен сноп от линейния ускорител на комплекса DAΦNE [4]. Заредените частици се ускоряват на групи, които оттук наетне ще наричаме „бънчове“. Линейният ускорител осигурява 50 бънча за секунда. Всеки бънч съдържа около  $2 \times 10^4$  частици и продължителността на бънчовете може да бъде варирана, с типични стойности 200-300 ps. Максималната енергия на позитроните е 550 MeV, което дава горна граница на възможната стойност на липсващата маса -  $M_{miss} \leq 23.7$  MeV.

Основните процеси, формиращи фона, са двуфотонната и трифотонната аниhilация  $e^+e^- \rightarrow \gamma\gamma(\gamma)$  и спиращото лъчение  $e^+N \rightarrow e^+N\gamma$ . За да се потисне ефектът от първия процес е необходимо експериментът да има висока ефективност за регистриране на фотони. За филтриране на събитията на спиращо лъчение е необходимо да бъде регистриран излъчващият фотон и с голяма точност да бъде съвпаднал по време с регистрираните фотони от това излъчване.

Пълната симулация на експеримента в Geant4 [5] показва, че чувствителността на PADME в термини на константата на взаимодействието  $\alpha'$  между тъмния фотон  $A'$  и електрона може да достигне до  $10^{-8}$  [6], при наличието на детектори с достатъчно висока ефективност (над 99 %) и разделителна способност по време, по-добра от 1 ps. Поради големия брой частици в бънча е необходимо всички детектори да притежават способност за разделяне на припокриващи се сигнали.

Алгоритмите, базирани на машинно обучение, и по-конкретно невронните мрежи, могат да бъдат използвани за разпознаване на сигнали във вълновите форми, записани при изчитането на детекторите. Сигналите могат да бъдат симулирани с цел да се контролират параметрите на набора от данни, използван при тренирането на невронните мрежи. Цялостно задачата може да се сведе до откриване на конкретната форма, описваща сигнала, и разпознаването ѝ навсякъде, където се среща в записаната от детектора вълнова форма.


В настоящата дипломна работа е разгледан накратко експериментът PADME и са описани както основните му детекторни компоненти, така и системата за събиране и запис на данните. Съществена част от изследванията е посветена на реконструкцията на сигналите, дължащи се на преминали през детекторните компоненти йонизиращи частици. Описани са три алгоритъма, представляващи невронни мрежи за анализ на събития в електромагнитния калориметър на експеримента PADME. Първият от тях е с цел класификация на събитията според броя сигнали в тях, а

другите два имат за цел описване на сигналите и определяне техните параметри. В глава 2 е изложено описание на основните детектори, от които е съставен самият експеримент, в глава 3 са описани методът на симулация на данните, използвани за трениране на невронните мрежи и същността на трите създадени алгоритъма. Резултатите от прилагането на третия алгоритъм са описани в глава 4, последвани от заключение.

## Глава 2

# Експериментът PADME

Основната цел на експеримента PADME е търсенето на медиатора между скрития и видимия сектор - тъмния фотон  $A'$  посредством пресмятането на липсващата маса в процеса на аниhilация на ускорени позитрони в мишена. За тази цел се реконструират четириимпулсите на излъчените фотони и заредени частици след взаимодействието на позитроните от снопа с мишената [7]. Приема се, че електроните в мишената са в покой и по този начин може да се пресметне липсващата маса при събития, при които в крайно състояние е регистриран единствен фотон. Схема на експеримента с основните му компоненти е представена на фигура 2.1.



Фигура 2.1: Схема на основните компоненти на експеримента PADME.


Първият детектор на пътя на ускорения позитронен сноп представлява активна мишена, служеща едновременно като среда за процеса на аниhilация и като детектор за определяне параметрите на снопа. Позитроните от снопа, които не взаимодействат с електроните в мишената, навлизат във вътрешността на диполен магнит и се отклоняват към детектора за високоенергетични позитрони, разположен непосредствено след магнита.

твено до изходния прозорец на снопа. Ако тези позитрони загубят съществена част от енергията си поради някакъв процес, то те се отклоняват към детектора за позитрони, разположен във вътрешността на магнита. Противоположно на детектора за позитрони е разположен детекторът за електрони, който може да регистрира електрони, родили се при хипотетичен разпад на тъмен фотон. Така описаните детектори са разположени във вакуумна камера, като в края ѝ, срещуположно на мишената, са разположени електромагнитният калориметър и калориметъра за малки ъгли.

## 2.1 Активна мишена

Активната мишена (фигура 2.2) представлява поликристален диамант с дебелина на  $100 \mu\text{m}$  и дължина и ширина  $20 \text{ mm}$  [8]. Малкото атомно число  $Z$  (в случая  $Z=6$ ) е необходимо, за да се осигури голямо отношение на сечението за аниhilация към това за спирачно лъчение.

Освен че представлява среда за процеса на аниhilация, мишената служи и за измерване на броя частици в снопа и на XY профила му, което е от значение за точността на определяне на липсващата маса. За целта върху мишената чрез  $193 \text{ nm}$  UV ArF лазер са гравирани 16 хоризонтални и 16 вертикални електрода от графит с ширина  $1 \mu\text{m}$ , което прави мишената изцяло въглеродна.

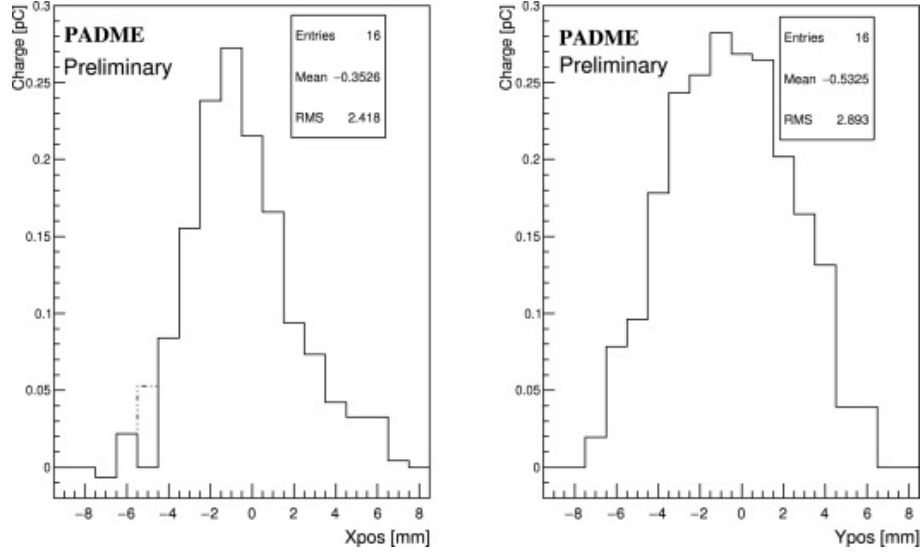


**Фигура 2.2:** Активната мишена, използвана в експеримента PADME. Тя служи за среда за осъществяване на аниhilацията и като детектор за измерване профила и броя частици в позитронния сноп.

Основен параметър за оценяване на способността за регистриране на частици в диамантените детектори е разстоянието за натрупване на заряд CCD (charge collection distance):

$$CCD = L \cdot Q_c / Q_g, \quad (2.1)$$

където  $L$  е дебелината на мишената,  $Q_g$  е зарядът, генериран от релативистка заредена частица и  $Q_c$  е зарядът, който е натрупан върху електродите. В случая на мишената на PADME този параметър е определен от тестов набор на данни с  $N_{active} = 3630 \pm 180$  [9] среден брой позитрони, преминаващи през мишената за един



**Фигура 2.3:** Профил на отделен бънч от снопа, съставен от около 20 000 позитрона с енергия 545 MeV, измерен по x и y осите [11].

бънч. Тъй като средният брой двойки електрон-йон, създадени от частица, преминаваща през диамант, е  $36 e^-/\mu m$  [10], получаваме

$$CCD = \frac{Q_c [fC] \cdot 6250 [e^-/fC]}{36 [e^-/\mu m] \cdot N_{active}}, \quad (2.2)$$

където пълният заряд  $Q_c$  е сумата от натрупаните заряди върху всички електроди в дадено направление. В резултат се получава  $CCD \approx 11 \mu m$ .

Главната цел на мишената като детектор е да предоставя информация за позицията на снопа за всеки бънч, както и за броя частици в него, за да може да бъде изчислен броят позитрони, попаднали в нея за всеки индивидуален набор на данни. Типичен профил на снопа е показан на фигура 2.3. Средната позиция на снопа по x и y осите е определена като

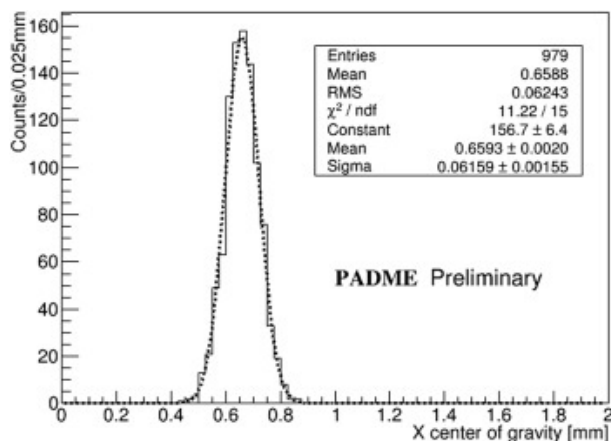
$$\langle x \rangle = \frac{\sum_{i=1}^{N_x} Q_i^x x_i}{\sum_{i=1}^{N_x} Q_i^x}; \quad \langle y \rangle = \frac{\sum_{i=1}^{N_y} Q_i^y y_i}{\sum_{i=1}^{N_y} Q_i^y}, \quad (2.3)$$

където  $N_{x(y)}$  е броят електроди по съответното направление,  $x(y)_i$  и  $Q_i^{x(y)}$  са съответно поредният номер и натрупаният заряд за всеки електрод. Разпределението на позицията на снопа по x (фигура 2.4) е използвано за определяне пространствената разделителна способност на мишената като детектор, като резултатът е 0.06 mm [11].

## 2.2 Детектори за заредени частици


Три групи детектори регистрират заредените частици (фигура 2.5) [12]. Позитроните от снопа е възможно да преминат през мишената и губейки енергия да излъчат фотони (спирачно лъчение), които да попаднат в калориметъра. За да бъ-





**Фигура 2.4:** Разпределение на позицията на центъра на снопа за близо 1000 събития. Всеки бънч съдържа около 20 000 позитрона с енергия 545 MeV [11].


дат идентифицирани такъв тип събития е необходимо да се регистрира позитронът, който е загубил енергия. Именно тези позитрони биват регистрирани от детектора за позитрони и детектора за високоенергетични позитрони. В случай че тъмен фотон  $A'$  се разпадне до двойка  $e^+e^-$ , електронът ще бъде регистриран от детектора за електрони.



**Фигура 2.5:** Детектори за заредени частици в експеримента PADME. **Ляво:** Детекторите за позитрони и електрони, намиращи се вътре в магнита. **Дясно:** Детекторът за високоенергетични позитрони, намиращ се до изходния прозорец за снопа.

И трите детектора за заредени частици са съставени от пластмасови сцинтилатори с размери  $10 \times 10 \times 178 \text{ mm}^3$ . Светлината се отвежда от WLS влакна до  $3 \times 3 \text{ mm}^2$  Hamamatsu S13360 силициеви фотоумножители с размер на пиксела  $25 \mu\text{m}$  и са поставени в  $10^{-5} \text{ mbar}$  вакуум. Детекторите за позитрони и електрони са разположени вътре в магнита и са съставени съответно от 90 и 96 сцинтилационни пръти, като и двата детектора регистрират частици с импулси между 50 и 450 MeV. Детекторът за високоенергетични позитрони е разположен непосредствено до изходния прозорец за снопа и е съставен от 16 сцинтилационни пръти, като изсветванията се регистрират и от двете им страни. Той регистрира частици с импулси между 450 и 500 MeV.

Разделителната способност по време на детекторите за заредени частици е 700 ps. Прецизното измерване на времето е необходимо, за да се идентифицират събития, при които позитрони, попаднали в детектора за заредени частици, съвпадат по



**Фигура 2.6:** Калибровка по време на детектора за позитрони и калориметъра за малки ъгли [12].

време с клъстери, породени от попаднали в калориметъра спирачно излъчени високоенергетични фотони (фигура 2.6).

Сегментирането на детекторите за заредени частици дава възможност за измерване на импулса на  $e^+/e^-$  с разделителна способност  $\approx 5\%$  за частици с енергия 100 MeV.


## 2.3 Калориметри

Системата от калориметри на експеримента PADME е съставена от сцинтилационен електромагнитен калориметър и черенковски калориметър за малки ъгли.

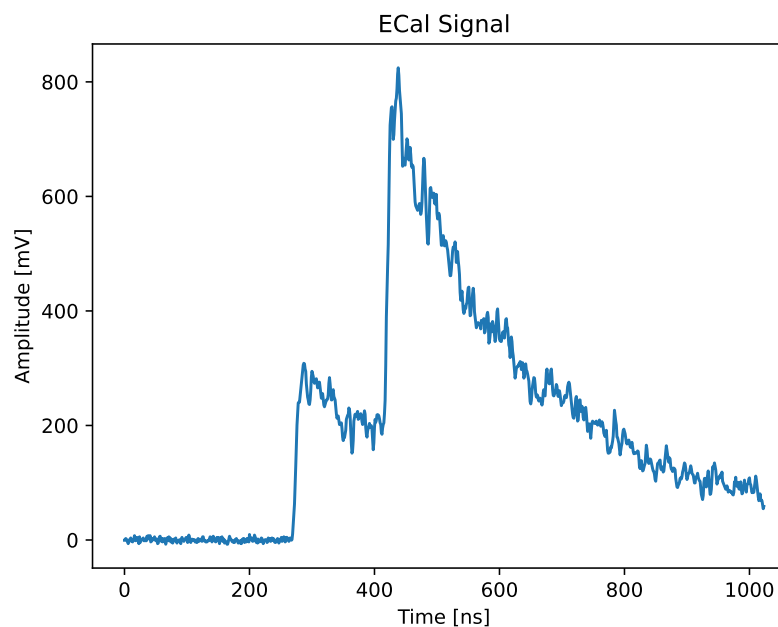
Електромагнитният калориметър е съставен от 616 BGO кристала с размери  $2.1 \times 2.1 \times 23 \text{ cm}^3$ , свързани с HZC 1912 фотоумножители (фигура 2.7) [13]. Оптична изолация на кристалите е постигната чрез покриването им с  $\text{TiO}_2$  боя и допълнително с фолио от Tedlar<sup>®</sup> с дебелина 50–100  $\mu\text{m}$ . Електромагнитният калориметър се намира на 3.45 m от мишената и радиусът му е 29 cm. Това позволява регистрирането на фотони, излъчени под ъгли между 15 и 84 mrad. Долното ограничение е поради факта, че в центъра на електромагнитния калориметър е оставен отвор, който се покрива от калориметъра за малки ъгли, разположен зад него. Времето за изсветване на BGO кристалите е около 300 ns.

Типична форма на сигнал в електромагнитния калориметър е показана на фигура 2.8.

Преди сглобяването на калориметъра е осъществена калибровка с  $^{22}\text{Na}$  източник, излъчващ позитрони, които впоследствие анихилират и се излъчват фотони с  $E_\gamma = 511 \text{ keV}$ . Сцинтилаторите, подлежащи на калибриране, са окомплектовани под формата на  $5 \times 5$  матрица от сглобени BGO кристали. При последователното преместване на източника пред кристалите са набрани данни за различни стойности на напрежението и са построени разпределения на заряда и зависимости на натрупания заряд от напрежението.

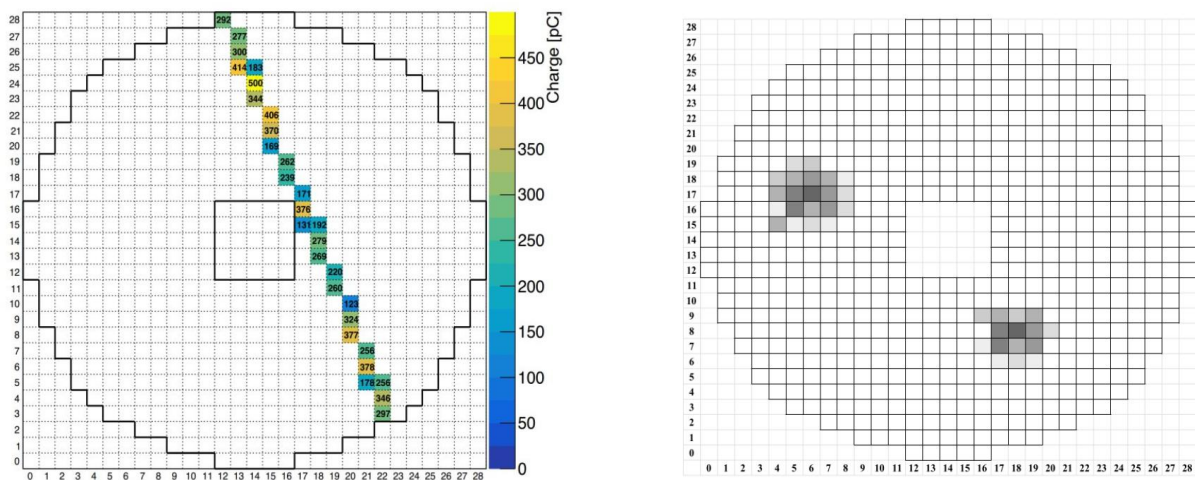


**Фигура 2.7:** Електромагнитният калориметър на PADME, съставен от 616 BGO кристала.



**Фигура 2.8:** Типична форма на сигнала в електромагнитния калориметър на PADME. В конкретния случай в калориметъра са попаднали два фотона, поради което има два припокриващи се сигнала.

След сглобяването на калориметъра за калибровка се използват космични лъчи, като за целта под и над калориметъра са поставени плочи от пластмасов сцинтилатор, които да служат за тригер. На фигура 2.9 е показан пример за мюон, преминал през целия калориметър, в сравнение с две лавини, предизвикани от двойка аниhilационни фотони. Калибровката се извършва, като се изследва разпределението на заряда в кристалите, през които е преминал мюонът. Използват се само случаите на вертикално преминаване. За целта се проверява дали в конкретното събитие мюонът е преминал през поне три кристала, разположени в колона един под друг и дали има други сигнали в конкретните редове, на които са разположени тези сигнали. В крайна сметка за пресмятането се използва само сигналът в централния от трите кристала.



**Фигура 2.9:** Натрупан заряд в електромагнитния калориметър. **Ляво:** При преминало космично лъчение. **Дясно:** При развиване на лавини от два фотона. [13]

Преди поставянето на калориметъра са извършени и измервания на разделителната му способност, отново върху  $5 \times 5$  матрица от кристали, към която е насочван сноп от средно един позитрон на бънч с различни енергии. Резултатът е


$$\frac{\sigma(E)}{E} = \frac{2.0\%}{\sqrt{E[GeV]}} \oplus \frac{0.003\%}{E[GeV]} \oplus 1.1\%, \quad (2.4)$$

което дава разделителна способност  $\sim 7\%$  за  $E_\gamma = 100$  MeV.

Калориметърът за малки ъгли се намира зад електромагнитния калориметър и регистрира главно фотони, излъчени чрез спиращо лъчение [14]. Големият им брой не би могъл да бъде поет от най-вътрешните кристали на електромагнитния калориметър, но може лесно да бъде регистриран от Черенковски детектор поради кратката дължина на сигналите (около 3 ns). За да се отхвърлят тези събития, данните от калориметъра за малки ъгли се съпоставят по време с данните от детекторите за заредени частици. Калориметърът за малки ъгли регистрира също така фотони от аниhilации с два или три фотона. Той е съставен от 25 кристала от  $\text{PbF}_2$  с размери  $3 \times 3 \times 14$  cm<sup>3</sup> и има ъглово покритие между 0 и 15 mrad.

## 2.4 Система за набор на данни

Системата за набор на данни на експеримента се състои от 29 CAEN V1742 [15] АЦП модула (фигура 2.10), всеки от които включва 32 аналогови и 2 тригерни канала и използва DRS4 чип, способен да записва входния сигнал с честота 750 MS/s, 1 GS/s, 2.5 GS/s и 5 GS/s. В случая се записват вълнови форми с дължина 1024 стойности за всеки канал, базирани на тригерен сигнал, отключван от снопа. Електромагнитният калориметър използва семплиране от 1 GS/s, което дава около  $1 \mu\text{s}$  дължина на записаната вълнова форма.



Фигура 2.10: Модулът CAEN V1742, използван в експеримента PADME [16]

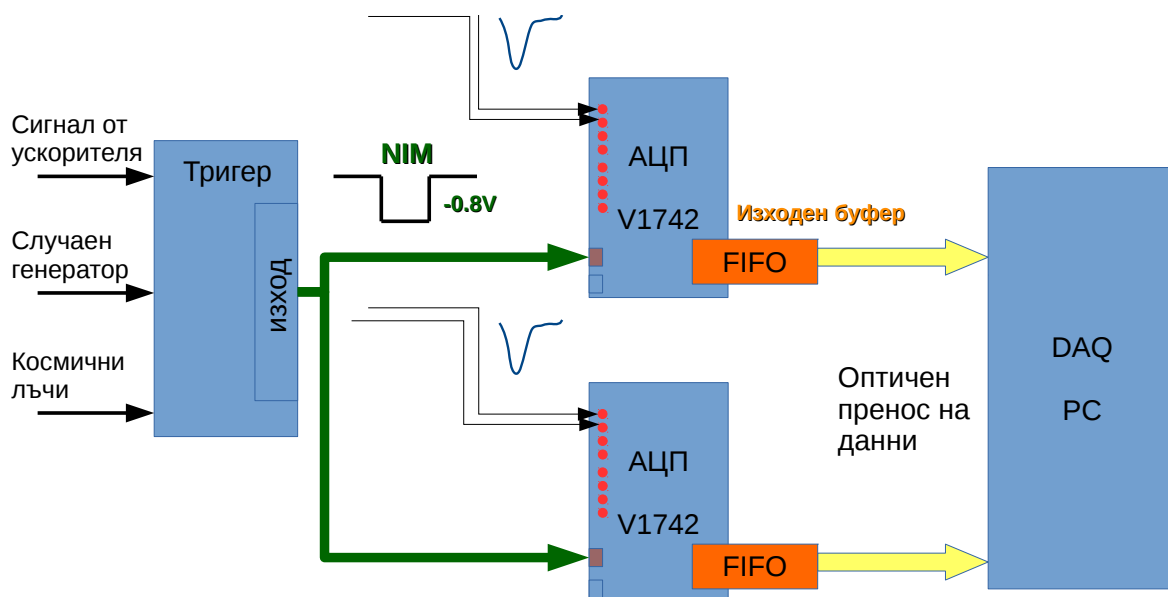
Цялата система за набор на данни се състои от 897 канала, като разпределението им е описано в таблица 2.1. Системата за разпределяне на тригера (Trigger Distribution System) генерира общ тригерен сигнал, който може да е базиран на тригера от снопа, на космични лъчи, когато се осъществява калибровка, или на софтуерен/случаен тригер. Този общ тригерен сигнал се разпределя към всички АЦП модули (фигура 2.11). Цифровите данни от модулите се изчитат и съхраняват както пристигат последователно от всеки детектор. За да се формират крайните изходни файлове със сурови структури от данни се осъществява сливане (фигура 2.12) като данните от всички детектори за конкретен тригер се събират в отделно събитие [16].

Детектор	Брой канали
Активна мишена	32
Електромагнитен калориметър	616
Калориметър за малки ъгли	25
Детектори за заредени частици	224
Общо	897

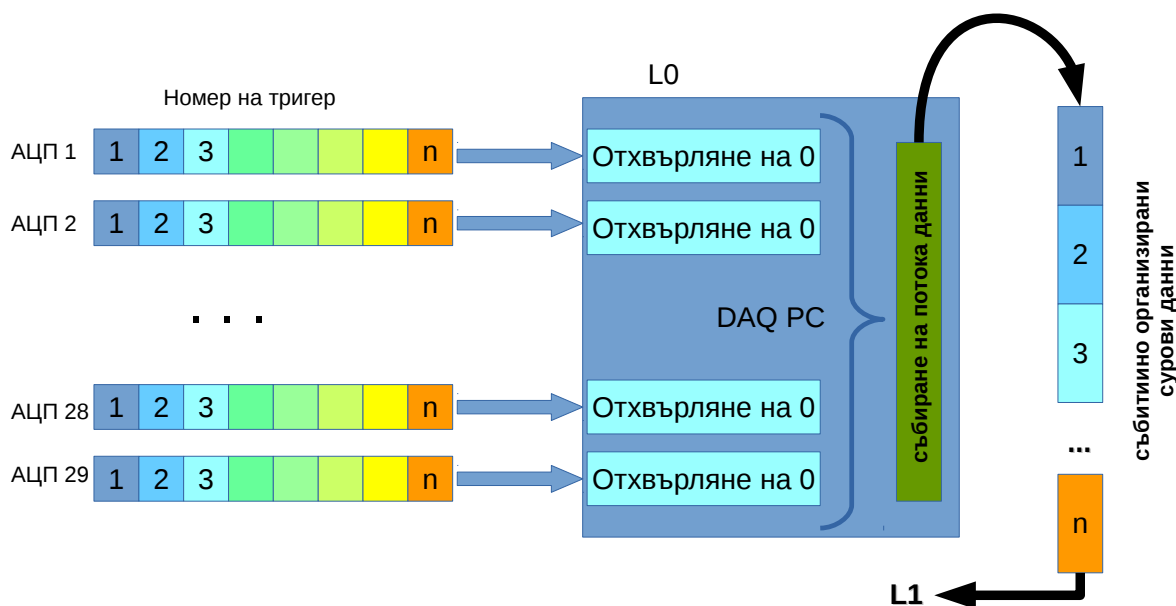
Таблица 2.1: Разпределение на каналите в системата за набор на данни на PADME [16].

## 2.5 Обработка и реконструкция на данните

Записаните сурови данни от експеримента преминават през софтуер за реконструкция (PadmeReco), написан на езика C++ [18]. Софтуерът за реконструкция има



Фигура 2.11: Схема на системата за набор на данни на PADME [17].



Фигура 2.12: Преобразуване на структурите от записани данни от детекторно към събитийно ориентирани [17].

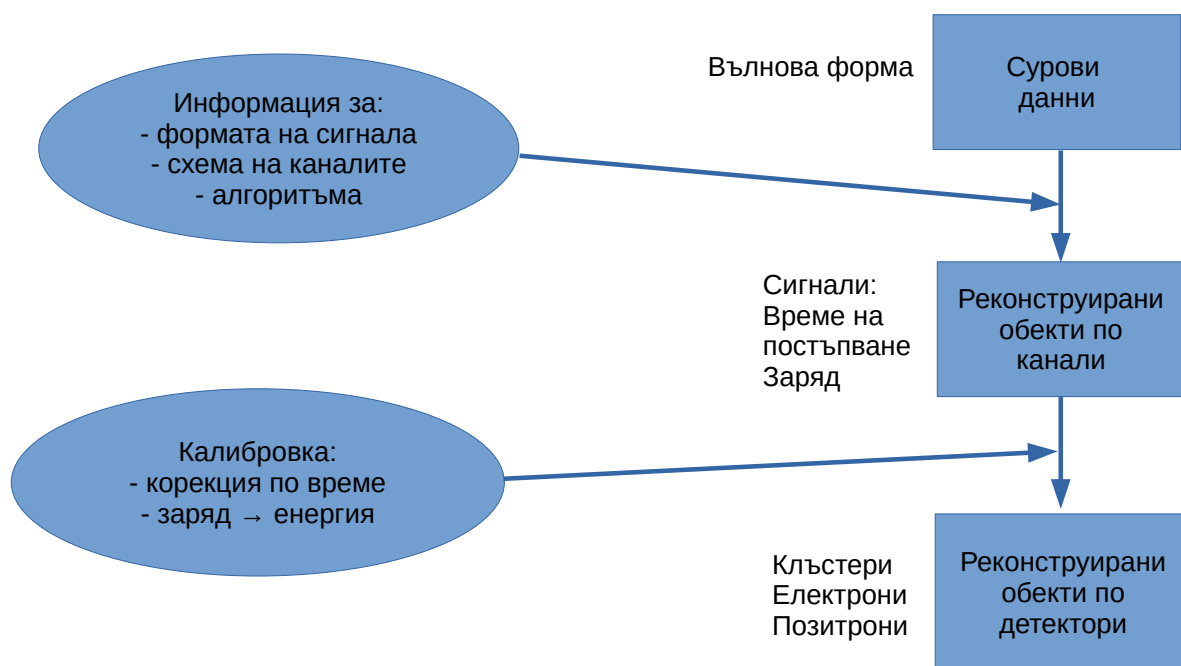
за цел да преобразува суровите данни в систематизирана физична информация за събитията, която да бъде подадена към софтуера за анализ. Схема на етапите на реконструкция е представена на фигура 2.13.

Алгоритъмът за реконструкция на експеримента осигурява последователното обхождане на всеки един логически разграничен детектор. Класовете, отговорни за конкретните алгоритми за реконструкция на всеки един детектор, наследяват общ виртуален клас за реконструкция, като имплементират различни виртуални методи. За всеки детектор е обособен конфигурационен файл, в който е записана схема на каналите, както и стойностите на необходимите за реконструкцията параметри.

Първият етап от реконструкцията представлява отделянето на постъпилите сигнали във всеки отделен канал, като целта е да се определи времето на настъпване и амплитудата им. При тази стъпка може да бъде избран желаният метод за реконструкция.

Получената информация за сигналите преминава през корекция по времена на база тригера. Тя е необходима заради разликата между тригера и тактовата честота на АЦП модулите. Следва калибровка на стойността на амплитудата, която се извършва според канала, информацията от който се реконструира. Целта е стойността за натрупания заряд да бъде преобразувана в стойност на депозираната енергия.

Последната стъпка в реконструкцията е клъстеризацията, при която информацията от отделните канали се групира в структури (клъстери). При последващия анализ на данните, клъстерите от отделните детектори се асоциират, за да се формират физичните събития, към които те принадлежат.




**Фигура 2.13:** Схема на основните етапи на реконструкция на суровите данни от експеримента PADME.

## 2.6 Изисквания към характеристиките на реконструирани обекти

За да бъде достигната планираната чувствителност на експеримента ( $\epsilon \sim 10^{-6}$ , фигура 2.14) е необходимо прецизното реконструиране на липсващата маса. Използвайки енергията на регистрирания от калориметъра фотон  $E_\gamma$  и ъгъла между направлението на излъчения фотон и посоката на позитронния сноп  $\theta_\gamma$ , липсващата маса може да се запише като

$$M_{miss}^2 = 2(E_{e^+}m_e - 2E_\gamma E_{e^+} \sin^2 \frac{\theta_\gamma}{2}), \quad (2.5)$$

където  $E_{e^+}$  е енергията на позитроните от снопа, а  $m_e$  е инвариантната маса на позитрона. За прецизното определяне на  $M_{miss}^2$  е необходимо енергията на лавините в електромагнитния калориметър да бъде реконструирана с достатъчно добра разделителна способност (под 5% за енергии от порядъка на 100 MeV). Ъгълът  $\theta_\gamma$  се определя от точката на попадането на позитронния сноп в мишената и реконструираниите напречни координати на центъра на електромагнитната лавина, породена от фотона. Поради тази причина е желателно пространствената разделителна способност на калориметъра да е сравнима с тази на активната мишена - от порядъка на милиметър.



**Фигура 2.14:** Очаквана чувствителност на експеримента PADME [3].

Тъй като големият брой попаднали в мишената частици води до много припокриващи се събития, е необходимо броят на частиците в снопа да бъде не повече от 100 частици за 1 ns. В допълнение е необходимо да бъде постигната разделителна способност по време на детекторите, по-добра от 1 ns.

За да бъдат постигнати описаните стойности, е необходимо в реконструкцията на суровите данни от експеримента да бъде приложен достатъчно надежден алгоритъм. В настоящата дипломна работа са описани разработените алгоритми, използващи машинно обучение, които ще бъдат имплементирани в реконструкцията чрез паралелна версия на електромагнитния калориметър. Такъв алгоритъм следва да се използва както за данните от електромагнитния калориметър, така и за данните от детекторите за заредени частици.



## Глава 3

# Описание на сигналите в електромагнитния калориметър на PADME чрез невронни мрежи

Високият брой частици в позитронния сноп, използван в експеримента PADME, в комбинация с кратката продължителност на бънча водят до пристигането на много сигнали в кратък времеви интервал и до наличието на много припокриващи се сигнали в записаните събития. Един от начините за справяне с този проблем е използването на невронни мрежи за установяване бройката сигнали в дадено събитие, за идентифициране и разделяне на припокриващите се сигнали и за получаване на конкретните им параметри - времето на пристигане на сигнала и неговата амплитуда.

За реализирането на всички невронни мрежи е използвана платформата за машинно обучение TensorFlow [19] на езика Python [20] чрез библиотеката Keras [21]. За анализ на резултатите от прилагането на невронните мрежи е използвана библиотеката за анализ на данни ROOT [22], както и Python библиотеката matplotlib [23].

### 3.1 Симулации на сигнали

За тренирането на невронна мрежа за анализ на данните от електромагнитния калориметър на PADME е разработен алгоритъм за симулиране на сигнали, с възможност за генериране на набор на данни с необходимия размер, предварително зададен за конкретната задача [24]. Използването на симулирани сигнали позволява лесно вариране на параметрите с цел максимално подобие на истинските данни. Основно преимущество на тренирането на невронни мрежи с този подход е, че точните стойности на параметрите на сигналите са известни. При тренирането върху реални данни от детекторите е необходимо предварително да се определят параметрите на всяко събитие чрез алтернативни алгоритми, които имат определена точност и не гарантират пълна достоверност.

Всеки симулиран набор от данни съдържа събития, представляващи времеви редове под формата на вектори от 1024 стойности на амплитудата на сигнала през 1 ns. Всяко събитие съдържа различен брой сигнали с различни времена на пристигане и амплитуди. Бройката сигнали в събитията следва равномерно разпределение между 0 и предварително зададен максимален брой, като във всички представени невронни мрежи са използвани събития с максимум 4 сигнала.

Формата на сигнала е различна за различните детектори, като в конкретния случай е избрана такава, която максимално много да наподобява сигналите в електромагнитния калориметър на PADME. Тя се описва като разликата на две експоненти, умножена по константа:

$$A(t) = A_0 \left( e^{-\frac{(t-t_0)}{\tau_1}} - e^{-\frac{(t-t_0)}{\tau_2}} \right) = A_0 e^{-\frac{(t-t_0)}{\tau_1}} \left( 1 - e^{-(t-t_0)\left(\frac{1}{\tau_2} - \frac{1}{\tau_1}\right)} \right), \quad t \geq t_0, \quad (3.1)$$

където

- $t_0$  е случайно генерирано време на пристигане на сигнала, следващо равномерно разпределение,
- $\tau_1$  е времето за намаляване на сигнала, с типични стойности  $O(100 \text{ ns})$  за неорганични сцинтилатори и  $O(20 \text{ ns})$  за пластмасови сцинтилатори, свързани с конвенционални фотодетектори (SiPM или PMT) [25],
- $\tau_2$  представлява времето на нарастване на сигнала, което зависи от системата за набор на данни и има типични стойности между 7 и 10 ns,
- $A_0$  е случайно генерирана амплитуда на сигнала, следваща Гаусово разпределение.

За трениране на представените алгоритми са използвани стойности на параметрите на сигналите  $100 \text{ ns} < t_0 < 400 \text{ ns}$ ,  $\tau_1 = 300 \text{ ns}$ ,  $\tau_2 = 10 \text{ ns}$  и  $A_0$  със средна стойност  $200 \text{ mV}$  и  $\sigma = 200 \text{ mV}$ . Допълнително е наложено ограничение за стойността на амплитудата, така че да се гарантира отличаването на сигналите над шума. Всички генерирани сигнали във всички събития имат едни и същи стойности на  $\tau_1$  и  $\tau_2$ , тъй като те са специфични за конкретния детектор, а стойностите на времето на пристигане и амплитудата са различни, тъй като те отговарят за дадено физично събитие.


Всяко събитие съдържа и Гаусов шум със стойности между 0 и 10 mV. На фигура 3.1 са показани два примера за симуирани събития, като лявата част представлява събитие без сигнали, единствено шум, а дясната - събитие с два припокриващи се сигнала и шум.

Заедно със симулирането на събитията, алгоритъмът създава и вектори с етикети за всяко събитие, съдържащи информация за търсените параметри като резултат от прилагането на невронната мрежа.

## 3.2 Класифициране на събития с невронна мрежа

Една от задачите, които могат да бъдат изпълнени с невронна мрежа е класифицирането на данните в даден брой категории. За целта могат да бъдат използвани мрежи с конволюционни филтри [26], чийто принцип на работа е базиран на преместването на прозорец с даден размер върху данните (фигура 3.2). Всеки параметър в прозореца се умножава със стойността на съответната позиция във входните данни и изходът се формира като сума от произведенията за всички параметри в прозореца, прекарана през активационна функция, след което прозорецът се премества:

$$y_a = f\left(\sum_{i=0}^k w_i \times x_{a+i-\frac{k-1}{2}}\right), \quad (3.2)$$




**Фигура 3.1:** Примери за симулирани сигнали от електромагнитния калориметър на PADME, използвани за трениране и тестване на невронни мрежи. (Ляво) Събитие без сигнали, съдържащо единствено Гаусов шум. (Дясно) Събитие с два сигнала и Гаусов шум. [24]

където  $k$  е размерът на прозореца. Теглата  $w_i$  подлежат на трениране в отделните епохи.

Активационната функция може да приема различен вид в зависимост от целта на алгоритъма. Във всички описани алгоритми е използвана функцията ReLU (Rectified Linear Unit) [27]:

$$f(u) = \max(0, u). \quad (3.3)$$




**Фигура 3.2:** Формиране на изхода на конволюционен слой на невронна мрежа.

Често в архитектурите на подобни мрежи освен конволюционни слоеве се използват и класически напълно свързани (Dense) слоеве. При тях изходът се формира чрез всички стойности в предходния слой, умножени по конкретни тегла, които се тренират през отделните епохи, като сумата отново се приема като аргумент на активационна функция:

$$y_a = f\left(\sum_{i=1}^n x_i w_i^a\right). \quad (3.4)$$

Принципът на работа на напълно свързаните слоеве е показан на фигура 3.3.

Класифицирането на събитията от електромагнитния калориметър на експеримента PADME се осъществява на базата на броя сигнали в тях. За целта е разработете-




**Фигура 3.3:** Формиране на изхода на напълно свързан слой на невронна мрежа.

на конволюционна невронна мрежа с единствен конволюционен слой и три напълно свързани слоя, разпределяща събитията в 5 категории между 0 и 4 сигнала. Архитектурата на класификационната мрежа е представена в таблица 3.1 и на фигура 3.4.

Слой	Форма на изхода	Брой параметри
conv1d (Conv1D)	(None, 102, 2)	22
flatten (Flatten)	(None, 204)	0
dense (Dense)	(None, 128)	26240
dense_1 (Dense)	(None, 32)	4128
dense_2 (Dense)	(None, 5)	165

**Таблица 3.1:** Архитектура на конволюционна невронна мрежа за класификация на сигнали от електромагнитния калориметър на PADME в 5 категории [24].




**Фигура 3.4:** Архитектура на конволюционна невронна мрежа за класификация на сигнали от електромагнитния калориметър на PADME в 5 категории.

Входните данни представляват едномерни вектори от 1024 стойности (вълновата форма на всяко събитие), а търсеният изход представлява вектор от 5 стойности, от които стойността на позицията, съвпадаща с реалната бройка сигнали в събитието е

1, а всички останали са 0. Така търсеният изход за примерно събитие без нито един сигнал ще бъде  $\{1\ 0\ 0\ 0\ 0\}$ , а за друго примерно събитие с три сигнала ще бъде  $\{0\ 0\ 0\ 1\ 0\}$ .

Разработеният модел е обучен върху набор от 100 000 симулирани събития и тестван върху статистически независим набор също с размер 100 000 събития. На фигура 3.5 е представена постигната ефективност при събития, съдържащи два сигнала, като функция на разликата във времената им на пристигане  $\Delta t = |t_2 - t_1|$ , където  $t_2$  и  $t_1$  са съответните моменти за двата сигнала. Ефективността е 50% за  $\Delta t = 10$  ns и практически 100% за  $\Delta t > 50$  ns.



**Фигура 3.5:** Ефективност на невронна мрежа за класификация за събития с два сигнала като функция на разликата във времената им на пристигане. Зависимостта е описана с функция  $\text{Eff} = \frac{2}{(1+\exp(-\Delta t/70))} - 0.5$  (сигмоид, червено). За сигнали с  $\Delta t = 10$  ns ефективността е 50%. Ефективността достига 100% при  $\Delta t > 50$  ns [28].

### 3.3 Невронна мрежа с архитектура на автоенкодер


Един възможен начин за реализиране на конволюционни невронни мрежи е с архитектура на автоенкодер [29]. В този случай задачата на изхода не е категоризация на входните данни, а тяхното повторение. Автоенкодерите се състоят от две части: енкодер, който намалява размерността на входните данни, последван от декодер, който възстановява входните данни в оригиналната им размерност.

За обработка на сигналите от електромагнитния калориметър на PADME е създаден конволюционен автоенкодер с архитектура, представена в таблица 3.2 и на фигура 3.6. В този случай и входните данни, и желаният изход представляват едни и същи вектори от 1024 стойности, представляващи вълновите форми на сигналите. Енкодерът представлява три конволюционни слоя с намаляващ брой филтри, а декодерът представлява огледална структура от три деконволюционни слоя с нарастващ брой филтри. На последно място стои деконволюционен слой с единствен филтър, използван подобно на напълно свързаните слоеве, които обикновено се използват в

конвенционалните конволюционни невронни мрежи с цел изходът да придобие желаната размерност.

Слой	Форма на изхода	Брой параметри
conv1d (Conv1D)	(None, 1024, 128)	2176
conv1d_1 (Conv1D)	(None, 1024, 64)	114752
dropout (Dropout)	(None, 1024, 64)	0
conv1d_2 (Conv1D)	(None, 1024, 32)	24608
conv1d_transpose (Conv1DTranspose)	(None, 1024, 32)	12320
dropout_1 (Dropout)	(None, 1024, 32)	0
conv1d_transpose_1 (Conv1DTranspose)	(None, 1024, 64)	28736
conv1d_transpose_2 (Conv1DTranspose)	(None, 1024, 128)	147584
conv1d_transpose_3 (Conv1DTranspose)	(None, 1024, 1)	2305

**Таблица 3.2:** Архитектура на конволюционен автоенкодер за обработка на сигнали в електромагнитния калориметър на PADME [24].




**Фигура 3.6:** Архитектура на конволюционен автоенкодер за обработка на сигнали в електромагнитния калориметър на PADME.

Мрежата е тренирана върху набор 100 000 симулирани събития и след това приложена върху независим набор от събития. Тъй като входът и изходът на мрежата преставляват едни и същи данни и няма отделно дефинирани изходни стойности за всяко събитие, подадено на входа, то това може да се разглежда като пример за неконтролирано обучение. Прилагането му е полезно, тъй като резултатът е съществено потискане на шума в регионите на сигналите, както се вижда на фигура 3.7.

### 3.4 Модифициран автоенкодер за определяне параметрите на сигнали

Резултатите от прилагането на автоенкодера показват, че алгоритъмът успява да отличи сигналите от шума. Вследствие на това е разработена невронна мрежа, използваща описаната архитектура на автоенкодер, но осъществяваща контролирано обучение. Наричана отгук нататък модифициран автоенкодер, мрежата използва



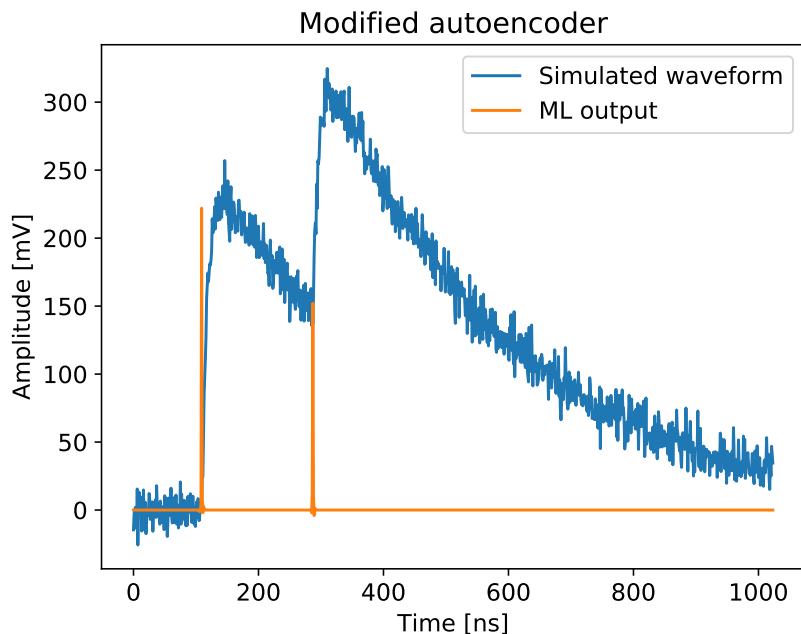
**Фигура 3.7:** Резултати от прилагането на автоенкодер върху симулирано събитие в електромагнитния калориметър на PADME. Симулираната вълнова форма (от десния панел на фигура 3.1) е показана в синьо, а изходът след прилагане на невронната мрежа е показан в оранжево. Резултатът след прилагане на автоенкодера е повторение на вълновата форма с потискане на шума в регионите на сигналите [24].

специално генерирани изходни вектори за обучение. Размерността им съвпада с размерността на входните вектори (1024 стойности), като на всички позиции стоят нули, освен в моментите на пристигане на сигнал, където стойността е стойността на амплитудата на сигнала. По този начин изходът на невронната мрежа съдържа всички необходими параметри на събитието: броят ненулеви стойности (или стойности над определен праг) отразява броя регистрирани сигнали, позициите на ненулеви стойности отразяват моментите на настъпване на сигналите, а самите стойности на тези позиции - амплитудите на сигналите.

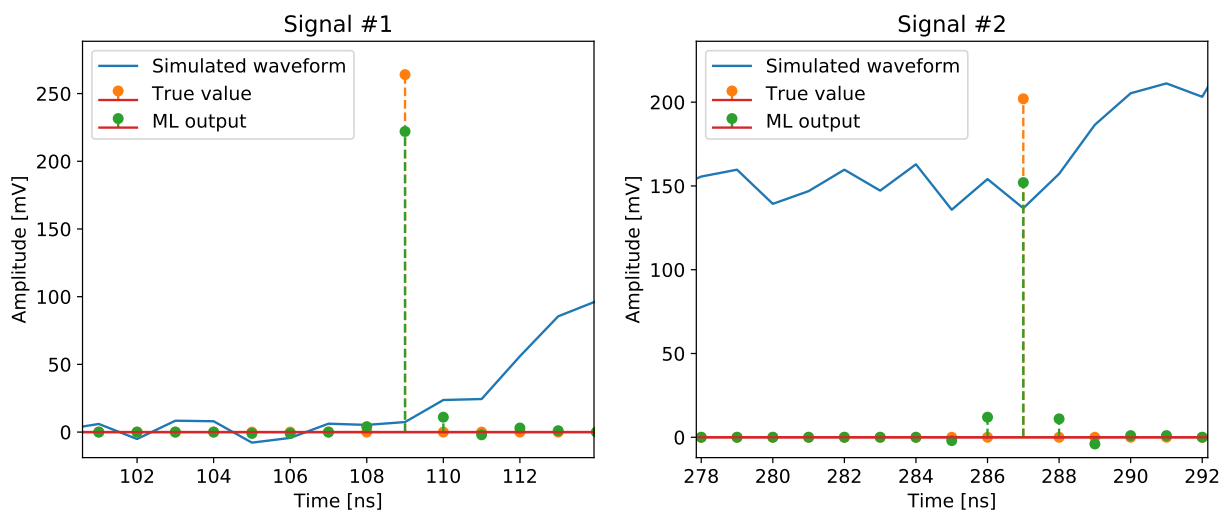
Модифицираният автоенкодер също е трениран върху набор от 100 000 събития, след което е приложен върху статистически независим набор също с размер 100 000 събития. Резултатът от прилагането на модифицирания автоенкодер върху дадено събитие може да се види на фигура 3.8.

При сравнение на резултатите от прилагане на модифицирания автоенкодер с оригиналните вектори на търсения изход се забелязва, че докато желаният изход представлява единствена стойност на точното положение на пристигане на сигнал, то изходът на невронната мрежа представлява една максимална стойност и няколко ненулеви стойности от двете ѝ страни (фигура 3.9).

За да се отчете наличието на ненулеви стойности около откритите максимуми е разработен специален алгоритъм за реконструкция на резултатите, който се прилага едновременно върху генерираните заедно със симулацията вектори на желания изход и върху генерираните при прилагането на невронната мрежа вектори с резултати. Докато във векторите с желания изход близки стойности с ненулеви сигнали



**Фигура 3.8:** Резултати от прилагането на модифициран автоенкодер върху симулирано събитие в електромагнитния калориметър на PADME. Симулираната вълнова форма е показана в синьо, а изходът след прилагане на невронната мрежа е показан в оранжево. Резултатът след прилагане на модифицирания автоенкодер показва стойностите на амплитудите на сигналите, позиционирани в моментите на пристигането им [24].



**Фигура 3.9:** Сравнение между желанния изход и изхода след прилагане на модифицирания автоенкодер за събитие с два сигнала в електромагнитния калориметър на PADME. Показани са двата открити сигнала в събитието от десния панел на фигура 3.1. Максимумите във векторите, генерирани след прилагане на невронната мрежа (зелено) съвпадат с истинските търсени стойности (оранжево), но съседните позиции също съдържат ненулеви стойности.



съществуват заради истински сигнали, пристигането на които е близко във времето, то в изходните вектори на невронната мрежа това се получава заради естеството на този тип алгоритми.

### 3.5 Реконструиране на параметрите на сигналите

Действието на алгоритъма за реконструкция е както следва:

- Векторът се обхожда в търсене на локални максимуми.
- При откриване на локален максимум се отчита сигнал.
- Пълната амплитуда на сигнала се дефинира като сума на максимума с трите стойности преди него и трите стойности след него.
- За време на настъпване на сигнала се дефинира позицията на максимума.

След прилагането на този алгоритъм върху симулираните изходни вектори и реалните изходни вектори за всяко събитие, резултатите се сравняват. Всеки сигнал от реалния изход на невронната мрежа се сравнява с най-близкия открит в симулираните изходни вектори. Разлика във времето на пристигане на този сигнал в изходния вектор на невронната мрежа и в симулирания изходен вектор се отчита с цел да се определи точността на определяне времето на настъпване. Накрая се отчита разликата между амплитудата, получена от прилагането на невронната мрежа и оригинално симулираната амплитуда.

## Глава 4

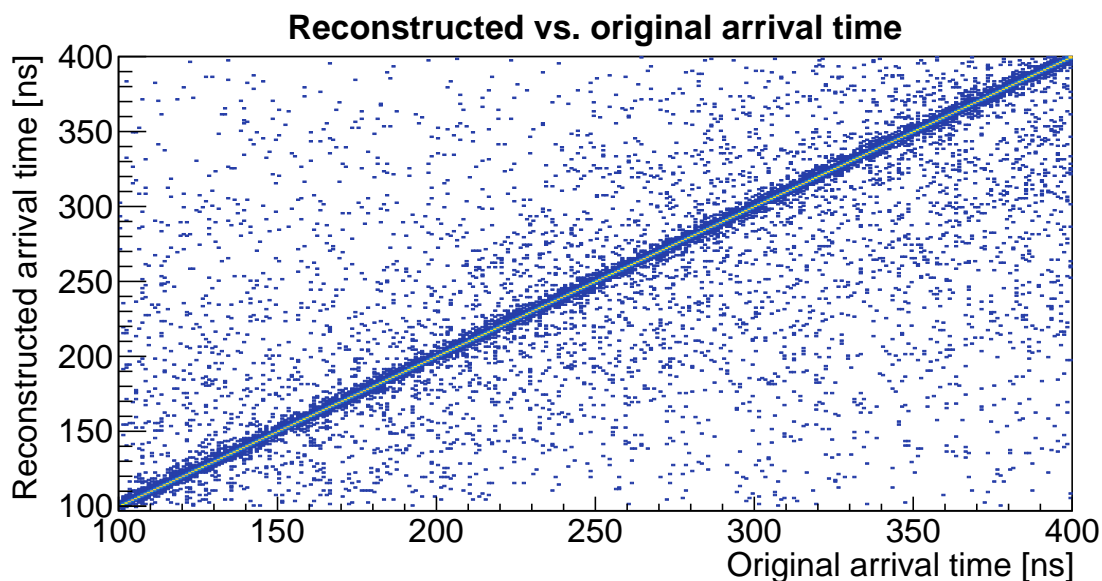
# Резултати от реконструкцията на събитията

След прилагане на алгоритъма за реконструкция на резултатите върху тестови набор от 100 000 събития, различен от набора, върху който невронната мрежа е тренирана, са сравнени крайните резултати със симулираните изходни вектори [28]. Вероятността даден сигнал да бъде разпознат и точността на определяне на параметрите му са изследвани, като първо е разгледана точността на реконструиране на времето на пристигане на сигнала, тъй като то е основен критерий за това открит от невронната мрежа сигнал да бъде съвпаднал с реално симулиран такъв. След това за всички събития, в зависимост от реалния брой сигнали в тях е разгледано какъв брой сигнали са разпознати. Отделени са конкретно събитията с два симулирани сигнала в тях, за да се оцени в зависимост от разликата в пристигането на сигналите дали те са идентифицирани в два отделни, или са слети в един. За извадката от симулирани събития, в които има само един сигнал е разгледана стойността на амплитудата като критерий за откриването на сигнала от невронната мрежа. Накрая е анализирана точността на определяне на самата амплитуда на разпознатите сигнали.


### 4.1 Реконструкция на времето

За да се изследват способностите на невронната мрежа за разделяне на два сигнала (double pulse separation), всеки сигнал от реалния изходен вектор е асоцииран с най-близкия по време сигнал от симулирания изходен вектор. Фигура 4.1 показва реалното (симулирано) и реконструираното време на пристигане на сигнала за всички съпоставени сигнали в набора от 100 000 събития. Откроява се тясна ивица, отговаряща на реконструирано време, равно или много близко до реалното, но са видими и сигнали със сериозни отклонения, което е индикация, че сигналът не е реконструиран и виждаме времето до най-близкия следващ сигнал.

Разликата  $\Delta t$  между реконструираното и реалното време на пристигане на сигналите е пресметната, като разпределението на събитията по  $\Delta t$  е представено на фигура 4.2. Разпределението е симетрично, като Гаусовият пик е със  $\sigma \sim 520$  ps. Съществуват и не-Гаусови опашки от двете страни, които водят до  $\text{RMS} \sim 3.2$  ns. Те се дължат на вече споменатите неидентифицирани сигнали, при които на реалните данни е съпоставен друг открит сигнал. На базата на тези резултати е определена прагова стойност за разликата от 2 ns, под която се смята, че даден сигнал е коректно идентифициран.



**Фигура 4.1:** Реално и реконструирано време на пристигане на сигналите в тестовия набор от данни. По-голямата част от сигналите са разположени в тясната диагонална ивица, но се наблюдават и единични сигнали с големи отклонения.




**Фигура 4.2:** Разпределение на сигналите в тестовия набор според разликата в реалното и реконструираното време на пристигане. Червената крива представлява Гаусова апроксимация със  $\sigma \approx 520$  ps и средна стойност 0.

## 4.2 Разпознати и неразпознати сигнали

Броят коректно идентифицирани сигнали във всяко събитие е съпоставен с реалния брой сигнали в него. Резултатите от тази съпоставка са представени на фигура 4.3.

При идеално действие на алгоритъма, всички събития ще имат равен брой реконструирани и реални сигнали и ще бъдат разпределени в клетките по диагонала на фигура 4.3. В случая, обаче, има събития с по-малък брой идентифицирани сигнали.



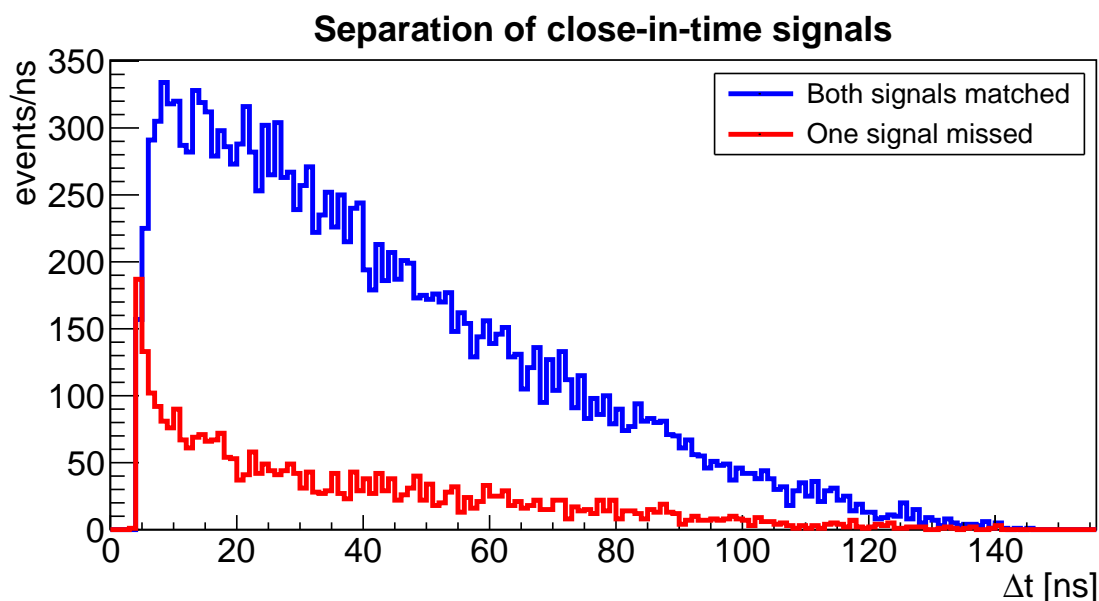
**Фигура 4.3:** Съпоставка между броя коректно идентифицирани и реалния брой сигнали в тестовия набор от събития. В клетките по диагонала са събитията, в които всички сигнали са коректно идентифицирани. В клетките под диагонала са събитията, в които са идентифицирани по-малко от реалния брой сигнали.

Разгледани са две причини даден сигнал да бъде пропуснат. Първата причина е, че два или повече сигнала могат да пристигат твърде близо във времето, съответно да бъдат слети още при прилагането на невронната мрежа или при прилагането в следствие на алгоритъма за реконструкция на резултатите. За да се изследва това е взета тази част от тестовия набор от данни, оригинално съдържаща по два сигнала в събитие и е определено в колко от тези случаи е реконструиран само по един сигнал. Построено е разпределение на събитията в зависимост от разликата във времето между пристигането на единия и другия сигнал (фигура 4.4), като от него става ясно, че при разлика в пристигането на двата сигнала, по-малка от 10 ns, в голяма част от събитията сигналите са слети.

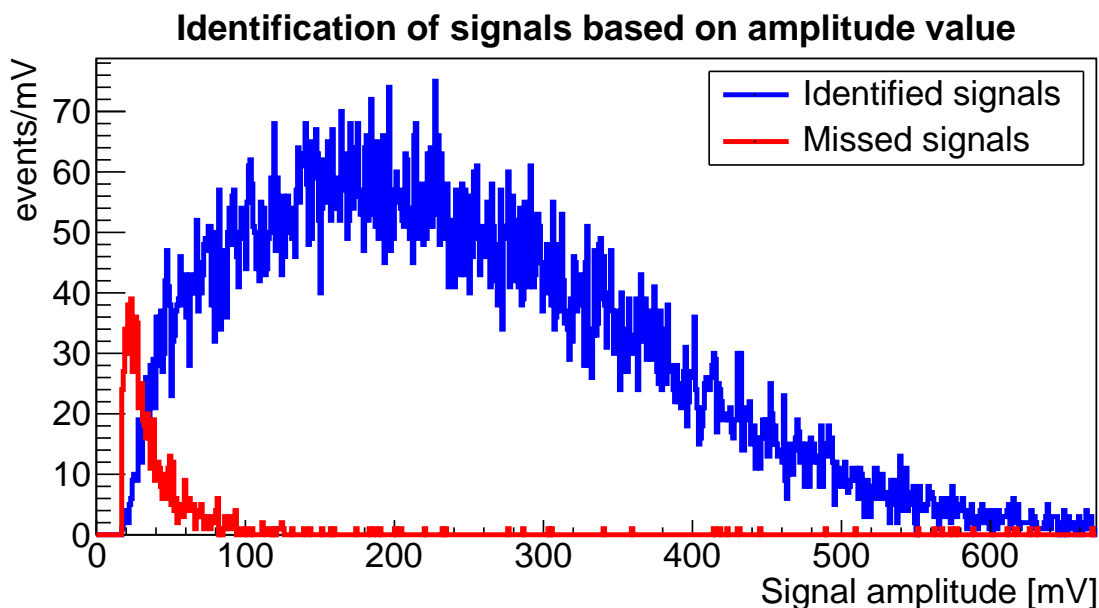
Дори при големи разлики в моментите на пристигане на сигналите, на фигура 4.4 се виждат събития, в които е реконструиран само един сигнал. Причината за това може да бъде твърде ниската амплитуда на сигналите и неразграничаването им от шума. За да се изследва този ефект е разгледана извадката от тестовите данни, съдържаща събития само с един симулиран сигнал и е определено в кои от тях този сигнал е реконструиран. Построено е разпределение на събитията в зависимост от амплитудата на сигнала в тях (фигура 4.5), което показва, че при амплитуда на сигнала под 50 mV е много вероятно сигналът да не бъде реконструиран.

### 4.3 Реконструкция на амплитудата

Възможностите на невронната мрежа за реконструкция на стойността на амплитудата на сигнала са изследвани, като за всички коректно идентифицирани сигнали е сравнена реконструираната с реалната стойност на амплитудата. Това сравнение е представено на фигура 4.6. Забелязва се добре изразена корелация между двете стойности. За по-добра оценка на способността за реконструиране на амплитуда е пресметната разликата между средната стойност на реконструираната амплитуда и




**Фигура 4.4:** Разпределение на събитията от тестовия набор от данни, оригинално съдържащи два сигнала, в зависимост от разликата във времето на пристигане на сигналите  $\Delta t$ . В синьо са събитията с коректно идентифицирани два сигнала, а в червено са събитията, при които е реконструиран само един сигнал.



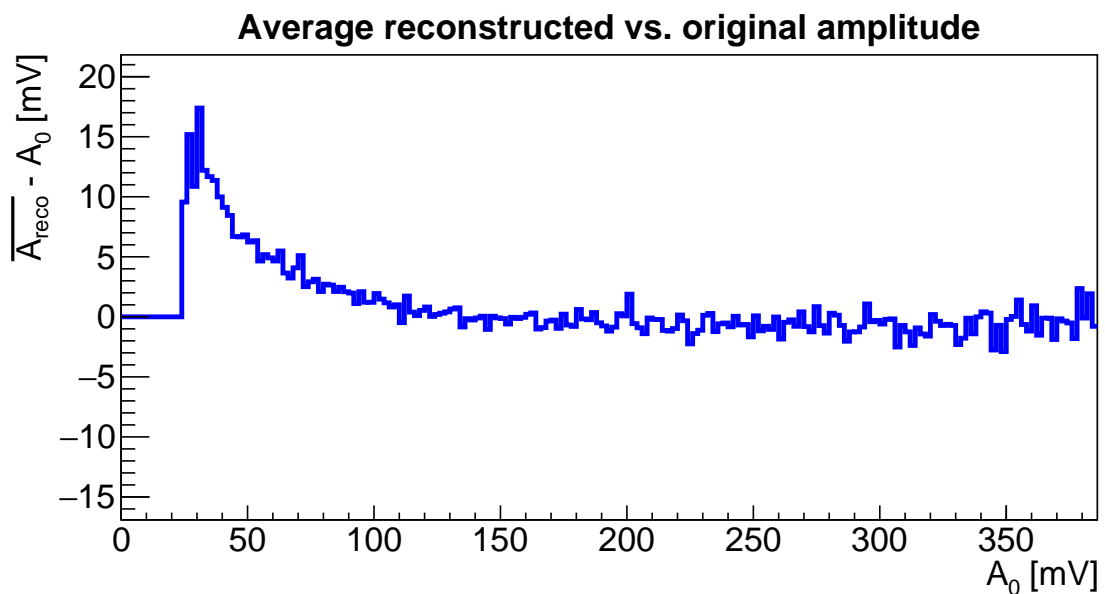
**Фигура 4.5:** Разпределение на събитията от тестовия набор от данни, оригинално съдържащи един сигнал, в зависимост от амплитудата на сигнала. В синьо са събитията, в които сигналът е идентифициран, а в червено са събитията, в които сигналът не е открит от невронната мрежа.

реалната стойност на амплитудата за всеки интервал от 2 mV реална стойност (фигура 4.7). Разгледани са стойности под 400 mV, тъй като броят сигнали с амплитуди над тази стойност започва да става все по-малък, поради което такъв тип представяне няма да е показателно за тях. Забелязва се отклонение при малките стойности на амплитудата, което би могло да се компенсира с допълнителна калибровка. За амплитудата

литудите над 100 mV резултатите са близки до нулата, което говори за задоволително ниво на реконструкция.



**Фигура 4.6:** Реална и реконструирана амплитуда на сигналите в тестовия набор от данни.



**Фигура 4.7:** Разлика между средната стойност на реконструираната амплитуда на сигналите в тестовия набор от данни и реалната стойност на амплитудата за всеки интервал от 2 mV реална стойност. При малки стойности на амплитудата се наблюдават отклонения, които с нарастване на амплитудата са все по-незначителни.

## Глава 5

# Заключение

Големият брой попаднали частици в електромагнитния калориметър на експеримента PADME изискват точни алгоритми за реконструкция с цел да се постигне разделителна способност по време, по-добра от 1 ns. Няколко алгоритъма, базирани на машинно обучение са разработени и успешно използвани за разпознаване на сигнали и установяване на техните параметри. Конволюционна невронна мрежа с един конволюционен и три напълно свързани слоя е използвана за класифициране на събития в категории на база броя сигнали, които те съдържат. Друга конволюционна невронна мрежа с архитектура на автоенкодер е използвана за успешно реконструиране на самите вълнови форми. На базата на нейната архитектура е създаден модифициран автоенкодер, чрез който могат да се определят времената на пристигане и амплитудите на сигналите.

Използването на симулирани данни позволява резултатите от прилагането на модифицирания автоенкодер да се анализират чрез специално създаден алгоритъм за сравняването им с реалните стойности. Този анализ показва, че използването на тази невронна мрежа дава разделителна способност по време  $\sim 500$  ps, а амплитудата на сигналите се реконструира успешно в интервала 30-700 mV.

Описаните в настоящата дипломна работа методи и резултати са представени в следните научни публикации:

- K. Dimitrova on behalf of the PADME Collaboration. “Using Artificial Intelligence in the Reconstruction of Signals from the PADME Electromagnetic Calorimeter”. *Instruments* 6 (2022), p. 46
- K. Dimitrova et al. “Pattern recognition and signal parameters extraction using machine learning methods”. Submitted for publication in *Journal of Physics: Conference series* (2023)

# Библиография

- [1] Jim Alexander et al. “Dark Sectors 2016 Workshop: Community Report”. *FERMILAB-CONF-16-421* (Aug. 2016). arXiv: 1608.08632 [hep-ph].
- [2] Federica Giacchino. “A light dark matter portal: The axion-like particle”. *Frascati Phys. Ser.* 69 (2019). Ed. by G. Corcella et al., pp. 206–211.
- [3] Mauro Raggi and Venelin Kozhuharov. “Proposal to Search for a Dark Photon in Positron on Target Collisions at DAΦNE Linac”. *Adv. High Energy Phys.* v. 2014 (2014), p. 959802. DOI: 10.1155/2014/959802. arXiv: 1403.3041 [physics.ins-det].
- [4] P. Valente et al. “Linear Accelerator Test Facility at LNF Conceptual Design Report” (2016). DOI: 10.48550/ARXIV.1603.05651. arXiv: 1603.05651 [physics.acc-ph].
- [5] S. Agostinelli et al. “GEANT4—a simulation toolkit”. *Nucl. Instrum. Meth. A* 506 (2003), pp. 250–303. DOI: 10.1016/S0168-9002(03)01368-8.
- [6] Mauro Raggi, Venelin Kozhuharov, and P. Valente. “The PADME experiment at LNF”. *EPJ Web Conf.* 96 (2015). Ed. by G. Giardina et al., p. 01025. DOI: 10.1051/epjconf/20159601025. arXiv: 1501.01867 [hep-ex].
- [7] P. Albicocco et al. “Commissioning of the PADME experiment with a positron beam” (May 2022). arXiv: 2205.03430 [physics.ins-det].
- [8] G. Chiodini. “A diamond active target for the PADME experiment”. *Journal of Instrumentation* 12 (2017), p. C02036.
- [9] R. Assiro et al. “Performance of the diamond active target prototype for the PADME experiment at the DAΦNE BTf”. *Nucl. Instrum. Methods Phys. Res. A: Accel. Spectrom. Detect. Assoc. Equip.* 898 (2018), pp. 105–110.
- [10] L. Pan and D. Kania. “Diamond: electronic properties and applications” (1995).
- [11] F. Oliva. “Operation and performance of the active target of PADME”. *Nucl. Instrum. Methods Phys. Res. A: Accel. Spectrom. Detect. Assoc. Equip.* 958 (2020). Proceedings of the Vienna Conference on Instrumentation 2019, p. 162354.
- [12] F. Ferrarotto et al. “Performance of the Prototype of the Charged-Particle Veto System of the PADME Experiment”. *IEEE Transactions on Nuclear Science* 65 (2018), pp. 2029–2035.
- [13] P. Albicocco et al. “Characterisation and performance of the PADME electromagnetic calorimeter”. *Journal of Instrumentation* 15 (2020), T10003.
- [14] A. Frankenthal et al. “Characterization and performance of PADME’s Cherenkov-based small-angle calorimeter”. *Nucl. Instrum. Meth. A* 919 (2019), pp. 89–97. DOI: 10.1016/j.nima.2018.12.035. arXiv: 1809.10840 [physics.ins-det].



- [15] CAEN V1742 Data Sheet. URL: <https://www.caen.it/products/v1742/>.
- [16] E. Leonardi, M. Raggi, and P. Valente. “Development and test of a DRS4-based DAQ system for the PADME experiment at the DAΦNE BTF”. *Journal of Physics: Conference Series* 898.3 (2017), p. 032024. DOI: 10.1088/1742-6596/898/3/032024. URL: <https://dx.doi.org/10.1088/1742-6596/898/3/032024>.
- [17] Lyudmila Ivanova. *Bachelor thesis, Sofia University "St. Kliment Ohridski"* (2019).
- [18] Bjarne Stroustrup. *The C++ Programming Language*. Reading, Mass. :Addison-Wesley. 1995.
- [19] Martín Abadi et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. Software available from <https://tensorflow.org>. 2015. DOI: 10.5281/zenodo.4724125. URL: <https://www.tensorflow.org/>.
- [20] Guido Van Rossum and Fred L. Drake. *Python 3 Reference Manual*. Scotts Valley, CA: CreateSpace, 2009. ISBN: 1441412697.
- [21] François Chollet et al. *Keras*. <https://keras.io>. 2015.
- [22] R. Brun and F. Rademakers. “ROOT: An object oriented data analysis framework”. *Nucl. Instrum. Meth. A* 389 (1997), pp. 81–86.
- [23] J. D. Hunter. “Matplotlib: A 2D Graphics Environment”. *Computing in Science & Engineering* 9 (2007), pp. 90–95.
- [24] K. Dimitrova et al. “Pattern recognition and signal parameters extraction using machine learning methods”. *Submitted for publication in Journal of Physics: Conference series* (2023).
- [25] P. A. Zyla and others (Particle Data Group). “Review of Particle Physics”. *Progress of Theoretical and Experimental Physics* 2020.8 (2020).
- [26] Keiron O’Shea and Ryan Nash. “An Introduction to Convolutional Neural Networks” (2015). DOI: 10.48550/ARXIV.1511.08458. arXiv: 1511.08458 [cs.NE].
- [27] Abien Fred Agarap. “Deep Learning using Rectified Linear Units (ReLU)” (2018). DOI: 10.48550/ARXIV.1803.08375. URL: <https://arxiv.org/abs/1803.08375>.
- [28] K. Dimitrova on behalf of the PADME Collaboration. “Using Artificial Intelligence in the Reconstruction of Signals from the PADME Electromagnetic Calorimeter”. *Instruments* 6 (2022), p. 46.
- [29] Yifei Zhang. “A better autoencoder for image: Convolutional autoencoder”. *ICONIP17-DCEC*. 2018.