

UNIVERSIDADE FEDERAL DE SÃO JOÃO DEL-REI  
DEPARTAMENTO DE CIÊNCIAS NATURAIS

Aria Santos Diniz

ANÁLISE DA PRODUÇÃO DE UM ÚNICO NEUTRINO DE  
MAJORANA NO ILC UTILIZANDO INTELIGÊNCIA ARTIFICIAL

São João del-Rei—MG  
11 de julho de 2021

Aria Santos Diniz

ANÁLISE DA PRODUÇÃO DE UM ÚNICO  
NEUTRINO DE MAJORANA NO ILC  
UTILIZANDO INTELIGÊNCIA ARTIFICIAL

Dissertação apresentada ao Programa de Pós-Graduação em Física da Universidade Federal de São João del-Rei, em associação ampla com a Universidade Federal de Alfenas, como requisito parcial para a obtenção do título de Mestre em Ciências.

Área de Concentração: Física de Partículas e Campos

Orientador: Fernando Marroquim Leão de Almeida Júnior

Co-orientadora: Maria Aline Barros do Vale

São João del-Rei—MG  
Departamento de Ciências Naturais  
11 de julho de 2021



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DE SÃO JOÃO DEL-REI  
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA

**NOMEAÇÃO DE BANCA EXAMINADORA Nº 18 / 2021 - PPGF (13.29)**

Nº do Protocolo: 23122.027716/2021-14

São João del-Rei-MG, 10 de agosto de 2021.

A dissertação de mestrado "Análise da Produção de um Único neutrino de Majorana no ILC utilizando Inteligência Artificial" elaborada por Aria Santos Diniz e aprovada por todos os membros da banca examinadora, foi aceita pelo Programa de Pós-graduação em Física da Universidade Federal de São João del-Rei como requisito parcial à obtenção do título de

## **MESTRE EM FÍSICA**

Prof. Dr. Fernando Marroquim Leão de Almeida Júnior  
Assinado por concordância de acordo com ata enviada por email

Prof. Dr. Sérgio Martins de Souza - UFLA  
Assinado por concordância de acordo com ata enviada por email

*(Assinado digitalmente em 11/08/2021 06:53 )*

ANDRE LUIZ MOTA  
PROFESSOR DO MAGISTERIO SUPERIOR  
DCNAT (12.12)  
Matricula: 1217987

Para verificar a autenticidade deste documento entre em <https://sipac.ufsj.edu.br/public/documentos/index.jsp> informando seu número: **18**, ano: **2021**, tipo: **NOMEAÇÃO DE BANCA EXAMINADORA**, data de emissão: **10/08/2021** e o código de verificação: **a1f759a37b**

Ficha catalográfica elaborada pela Divisão de Biblioteca (DIBIB)  
e Núcleo de Tecnologia da Informação (NTINF) da UFSJ,  
com os dados fornecidos pelo(a) autor(a)

D585a      Diniz, Aria.  
            Análise da produção de um único neutrino de  
Majorana no ILC utilizando inteligência artificial /  
Aria Diniz ; orientador Fernando Leão de Almeida  
Júnior; coorientadora Maria Aline Barros do Vale. --  
São João del-Rei, 2021.  
            137 p.

            Dissertação (Mestrado - Física) -- Universidade  
Federal de São João del-Rei, 2021.

            1. Neutrino Pesado de Majorana. 2. Inteligência  
Artificial. 3. Física de Partículas. I. Leão de Almeida  
Júnior, Fernando, orient. II. Barros do Vale, Maria  
Aline, co-orient. III. Título.

# Agradecimentos

Chega ao fim mais uma jornada de desafios e obstáculos, porém com inúmeras conquistas. Mesmo com os diversos problemas e impecílios esta etapa da minha vida é vencida. Como disse Machado de Assis: *Palavra puxa palavra, uma ideia traz outra, e assim se faz um livro, um governo, ou uma revolução. Alguns dizem que assim é que a Natureza compôs as suas espécies.* E foi assim, palavra por palavra, que finalizei este trabalho. Gostaria de agradecer ao meu orientador e a minha coorientadora, Professor Doutor Fernando e Professora Doutora Maria Aline, que me instruíram, ensinaram, apoiaram e continuaram ao meu lado ao longo de toda essa jornada. Agradeço a Deus por me dar esta oportunidade e, principalmente, ter me dado forças para continuar. Agradeço à CAPES pelo apoio e incentivo financeiro, o qual teria sido impossível me sustentar sem durante o curso. Agradeço à minha mãe por sempre ter me apoiado em tudo e me incentivado na vida acadêmica, ao meu irmão Renzo por todos os momentos de descontração em casa e ao meu pai, que mesmo sem estudo, me incentivou e apoiou até o seu último suspiro em Setembro. Agradeço aos amigos pelos momentos de diversão e pelo apoio nos momentos difíceis, ao meu namorado Harrison por ter estado ao meu lado nos momentos bons e ruins, e com quem espero me casar em breve. E por último porém tão importantes quanto, a todos meus professores da graduação e pós graduação, principalmente os professores Edson Dias, Pedro Guarinho e Ana Cláudia, que não só me instruíram ao longo de minha formação como também foram grandes amigos.

# Resumo

Este trabalho teve como objetivo desenvolver uma inteligência artificial capaz de separar Neutrinos Pesados de Majorana produzidos por uma Extensão do Modelo Padrão utilizando as características do acelerador de partículas International Linear Collider (ILC) de outros eventos já presentes no Modelo Padrão. Este acelerador ainda será construído e a expectativa é de que o *software* desenvolvido possa auxiliar futuramente na remoção de eventos de background dos resultados experimentais. O *software* apresentou uma precisão de 91,27% na fase de treino com uma rede neural treinada apenas para eventos contendo múons, apresentando resultados finais com poucos eventos de background. Os resultados apresentados neste trabalho podem ser muito melhorados refinando o *software* desenvolvido e testando outras definições de erro.

# Abstract

This work aimed to develop an artificial intelligence capable of separating Heavy Majorana Neutrinos produced by an Extension of the Standard Model using the characteristics of the International Linear Collider (ILC) particle accelerator from other events already present in the Standard Model. This accelerator will still be built and the expectation is that the *software* developed may help in the future to remove background events from the experimental results. The *software* showed an accuracy of 91.27% in the training phase with a neural network trained only for events containing muons, presenting final results with few background events. The results presented in this work can be greatly improved by refining the developed *software* and testing other error definitions.

# Sumário

<b>1</b>	<b>Introdução</b>	<b>16</b>
<b>2</b>	<b>Conceitos Fundamentais</b>	<b>20</b>
2.1	Física de Partículas . . . . .	20
2.1.1	Relatividade Restrita . . . . .	20
2.1.2	Forças Fundamentais . . . . .	24
2.1.3	Número Leptônico . . . . .	24
2.2	Física de Partículas Experimental . . . . .	25
2.2.1	Seção de Choque . . . . .	25
2.2.2	Luminosidade e luminosidade Integrada . . . . .	25
2.3	Modelo Padrão . . . . .	27
2.4	O problema da Oscilação de neutrinos . . . . .	30
2.5	Extensões além do Modelo Padrão e o Neutrino de Majorana . . . . .	30
2.5.1	O Neutrino de Majorana . . . . .	30
2.6	Mecanismo Seesaw . . . . .	32
<b>3</b>	<b>Colisores Lineares e o ILC</b>	<b>34</b>
3.1	Colisores Lineares . . . . .	35
3.1.1	CLIC . . . . .	35
3.1.2	ILC . . . . .	36
<b>4</b>	<b>O CalcHEP</b>	<b>37</b>
4.0.1	Modelo Utilizado Neste Trabalho . . . . .	38
<b>5</b>	<b>Aprendizagem de Máquina e Inteligência Artificial</b>	<b>39</b>
5.1	Conceitos Fundamentais . . . . .	39
5.2	Algoritmos de Aprendizagem de Máquina . . . . .	39
5.2.1	Redes Neurais . . . . .	39
5.3	Tipos de Redes Neurais . . . . .	41
5.4	Tratamento dos Dados e Data Pipelines . . . . .	43



<b>6</b>	<b>Objetivos</b>	<b>44</b>
6.1	Largura do Neutrino de Majorana . . . . .	45
6.2	Produção de um único e do Par . . . . .	46
<b>7</b>	<b>Geração e Separação dos Eventos</b>	<b>48</b>
7.1	Geração dos Eventos . . . . .	48
7.2	Classificação dos Eventos . . . . .	49
<b>8</b>	<b>Análise dos Eventos Utilizando Inteligência Artificial</b>	<b>53</b>
8.1	Eventos do Canal A . . . . .	53
8.2	Eventos do Canal B . . . . .	59
8.3	Eventos do Canal B treinando separadamente Múons e Elétrons	80
8.3.1	Eventos apenas com Elétrons . . . . .	85
8.3.2	Eventos apenas com Múons . . . . .	87
<b>9</b>	<b>Conclusões</b>	<b>125</b>
	<b>Appendices</b>	<b>128</b>
<b>A</b>		<b>129</b>
A.1	Biblioteca Base . . . . .	129
A.2	Rede Neural . . . . .	133

# Lista de Figuras

2.1	Números leptônicos dos léptons e suas anti partículas . . . . .	25
2.2	Histograma da reconstrução da massa invariante para os eventos gerados com energia de centro de massa de 1000GeV e Massa do neutrino pesado de 100GeV . . . . .	32
3.1	Colisor Cosmotron. Operou no laboratório Brookhaven Lab de 1952 até 1966. Imagem retirada de <a href="https://www.bnl.gov/about/history/images/cosmotron">https://www.bnl.gov/about/history/images/cosmotron</a>	
3.2	Colisor linear LINAC 4 no CERN. Imagem retirada de <a href="https://cds.cern.ch/images/CERN/PHOTO-201704-093-3/file?size=large">https://cds.cern.ch/images/CERN/PHOTO-201704-093-3/file?size=large</a> . . . . .	35
3.3	Ilustração do acelerador CLIC, ainda não construído. Imagem retirada de <a href="http://clic-study.web.cern.ch/">http://clic-study.web.cern.ch/</a> . . . . .	36
3.4	Ilustração do colisor ILC. Imagem retirada de <a href="https://ilchome.web.cern.ch/sites/ilchome.rendering.jpg">https://ilchome.web.cern.ch/sites/ilchome.rendering.jpg</a> . . . . .	36
5.1	Ilustração do funcionamento de uma rede neural. Imagem retirada de <a href="http://www.decom.ufop.br/imobilis/fundamentos-de-redes-neurais/">http://www.decom.ufop.br/imobilis/fundamentos-de-redes-neurais/</a> . . . . .	40
5.2	Comparação dos resultados entre a rede supervisionada e não supervisionada. Imagem retirada de <a href="https://towardsdatascience.com/deep-learning-for-image-classification-why-its-challenging-where-we-ve-been-and-whats-next-93b56948fcef">https://towardsdatascience.com/deep-learning-for-image-classification-why-its-challenging-where-we-ve-been-and-whats-next-93b56948fcef</a> . . . . .	42
5.3	Estrutura de um autoencoder-decoder. Imagem retirada de <a href="https://towardsdatascience.com/generating-images-with-autoencoders-77fd3a8dd368">https://towardsdatascience.com/generating-images-with-autoencoders-77fd3a8dd368</a> . . . . .	43
6.1	Alguns diagramas de Feynman representando a reação $e^+ e^- \rightarrow \nu e^+ W^-$ no MP (a) e na extensão com Majorana (b), respectivamente . . . . .	45
6.2	Largura do Neutrino de Majorana em função de sua massa . . . . .	46
6.3	Seção de Choque da Produção de um Par de Neutrinos (a) e Seção de Choque da Produção de um Único Neutrino (b) . . . . .	47

7.1	Seção de Choque do Canal $e^+e^- \rightarrow \nu, lepton, W$ em função da massa do neutrino N. . . . .	49
7.2	Seção de Choque do Canal $e^+e^- \rightarrow \nu, lepton, jet, jet$ em função da massa do neutrino N. . . . .	49
7.3	Erro dos eventos do MP (a) e de Majorana (b) do Canal A ao passarem pela rede . . . . .	52
7.4	Erro dos eventos de Majorana do canal A com a linha de threshold . . . . .	52
8.1	Eventos separados pela rede. Acima da linha horizontal estão os eventos classificados como do tipo Majorana. . . . .	54
8.2	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, W$ a partir do $lep$ e $W$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 100 GeV. b) após passar pela rede neural para separar eventos contendo Majorana. . . . .	55
8.3	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, W$ a partir do $lep$ e $W$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 150 GeV. b) após passar pela rede neural para separar eventos contendo Majorana. . . . .	56
8.4	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, W$ a partir do $lep$ e $W$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 200 GeV. b) após passar pela rede neural para separar eventos contendo Majorana. . . . .	57
8.5	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, W$ a partir do $lep$ e $W$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 500 GeV. b) após passar pela rede neural para separar eventos contendo Majorana. . . . .	58
8.6	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, jet, jet$ após passar pela rede AriaNN. b) Gráfico da separação do mesmo processo e energia feito pelo TensorFlow . . . . .	59
8.7	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ para o Modelo Padrão contendo apenas Múons. b) Gráfico anterior contendo apenas Elétrons. . . . .	60

8.8	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 100 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	61
8.9	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 150 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	62
8.10	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 200 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	63
8.11	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 250 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	64
8.12	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 300 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	65
8.13	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 350 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	66

8.14	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 400 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	67
8.15	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 450 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	68
8.16	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 500 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	69
8.17	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 550 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	70
8.18	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 600 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	71
8.19	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 650 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	72

8.20	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 700 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	73
8.21	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 750 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	74
8.22	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 800 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	75
8.23	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 850 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	76
8.24	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 900 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	77
8.25	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) antes de passar pela rede neural para massa de 950 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana. . . . .	78
8.26	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ apenas com $lep$ =elétrons para massa de 200 GeV. b) Gráfico da separação do mesmo processo apenas com $lep$ =múons.	80

8.27	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 200 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com múons. . . . .	82
8.28	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 200 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	83
8.29	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 200 GeV após passar pela rede AriaNN treinada com múons contendo apenas eventos com múons. b) Gráfico anterior após passar pela rede AriaNN treinada apenas com elétrons contendo apenas elétrons. . . . .	84
8.30	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 100 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	89
8.31	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 150 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	90
8.32	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 200 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	91

8.33	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 250 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	92
8.34	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 300 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	93
8.35	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 350 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	94
8.36	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 400 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	95
8.37	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 450 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	96
8.38	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 500 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	97



8.39	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 550 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	98
8.40	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 600 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	99
8.41	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 650 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	100
8.42	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 700 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	101
8.43	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 750 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	102
8.44	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 800 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	103

8.45	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 850 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	104
8.46	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 900 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	105
8.47	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 950 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	106
8.48	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 100 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	107
8.49	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 150 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	108
8.50	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 200 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	109

8.51	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 250 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	110
8.52	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 300 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	111
8.53	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 350 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	112
8.54	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 400 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	113
8.55	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 450 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	114
8.56	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 500 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	115

8.57	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 550 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	116
8.58	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 600 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	117
8.59	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 650 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	118
8.60	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 700 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	119
8.61	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 750 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	120
8.62	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow \nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 800 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	121

8.63	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 850 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	122
8.64	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 900 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	123
8.65	a) Gráfico da reconstrução da massa invariante do canal $e^+e^- \rightarrow nu, lep, jet, jet$ a partir do $lep$ e dois $jets$ (Partículas em que o neutrino de Majorana N decaiu) para massa de 950 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons. . . . .	124
9.1	a) Gráfico da comparação do número teórico de eventos de sinal com o número da diferença entre Eventos Classificados como Majorana e a Contaminação para o canal $e^+e^- \rightarrow nu, lep, jet, jet$ apenas com elétrons. b) Gráfico da comparação do número teórico de eventos de sinal com o número da diferença entre Eventos Classificados como Majorana e a Contaminação para o canal $e^+e^- \rightarrow nu, lep, jet, jet$ apenas com múons. . . . .	126

# Lista de Tabelas

2.1	Modelo Padrão: Bósons . . . . .	24
2.2	Modelo Padrão: Léptons . . . . .	25
2.3	Modelo Padrão: Quarks . . . . .	27
2.4	Ângulos de mistura do acoplamento do Neutrino Pesado com elétron, múon e tau, respectivamente. Limite superior com 95% de CL (Confidence Level). . . . .	33
7.1	Número de eventos esperados em função da massa de Majorana do Canal $e^+e^- \rightarrow \nu, lepton, W$ . . . . .	50
7.2	Número de eventos esperados em função da massa de Majorana do Canal $e^+e^- \rightarrow \nu, lep, jet, jet$ . . . . .	51
8.1	Estrutura da rede neural utilizada para o canal A . . . . .	54
8.2	Estrutura da rede neural utilizada para o canal B . . . . .	59
8.3	Número de eventos esperados para cada massa de Majorana do Canal $e^+e^- \rightarrow \nu, lep, jet, jet$ . . . . .	79
8.4	Número de eventos esperados em função da massa de Majorana do Canal $e^+e^- \rightarrow \nu, lep, jet, jet$ apenas com elétrons . . . . .	85
8.5	Número de eventos esperados para cada massa de Majorana do Canal $e^+e^- \rightarrow \nu, lep, jet, jet$ após passar pela rede treinada apenas com Elétrons . . . . .	86
8.6	Número de eventos esperados em função da massa de Majorana do Canal $e^+e^- \rightarrow \nu, lep, jet, jet$ apenas com múons . . . . .	87
8.7	Número de eventos esperados para cada massa de Majorana do Canal $e^+e^- \rightarrow \nu, lep, jet, jet$ após passar pela rede treinada apenas com Múons . . . . .	88

# Capítulo 1

## Introdução

De acordo com o Modelo Padrão (MP), neutrinos não possuem massa devido à falta de quiralidade dextrógena. Porém resultados experimentais recentes sobre oscilação de neutrinos comprovaram que neutrinos possuem sim massa[1], o que abre espaço para descobrir uma física além do MP.[2]

Extendendo o MP adicionando um singlete de neutrino dextrógeno para cada geração, violando-se o número leptônico é possível produzir um único neutrino contendo um termo de massa de Majorana em sua lagrangiana[3], possibilitando o estudo dos canais a)  $e^+ + e^- \rightarrow \nu, W, l$  e b)  $e^+ + e^- \rightarrow \nu, jet, jet, l$

onde  $\nu = \nu_e, \nu_\mu, \nu_\tau$  (neutrinos do elétron, múon e tau, respectivamente)  
 $l^{+-} = \text{elétrons e múons}$   
 $W = \text{Bósons } W^+ \text{ e } W^-$   
 $jet = \text{quarks}$

O acelerador ILC (International Linear Collider)[4], será um acelerador com feixes de elétrons e pósitrons colidindo com uma energia do centro de massa (ECM) na faixa de 0.1 a 1TeV[4]. Sua localização ainda não está definida, mas poderá ser tanto no Japão como na Europa, e mais recentemente a China surgiu também como candidata a sediar este acelerador. A definição do local ainda pode demorar algum tempo, mas diversos tipos de estudos utilizando as características do acelerador já estão sendo realizados. Colisões elétron-pósitron permitem fazer análises das colisões com excelente precisão pois os eventos interessantes são mais limpos com reduzidíssimos eventos de fundo (“background”) fornecendo assim a possibilidade de detectar claramente uma nova Física, além do Modelo Padrão(MP). Diversos parâmetros do MP poderão ser medidos com altíssima precisão restringindo assim as diversas propostas de modelos além do MP. Espera-se então, com os dados obtidos, responder a algumas perguntas fundamentais do MP, como por

exemplo a oscilação de neutrinos, e de suas possíveis extensões. A idéia de usar agora um acelerador linear, em vez de circular, tem dois motivos principais. O primeiro é que a perda de energia  $\Delta E$  por radiação síncrotron é dada pela expressão

$$\Delta E \propto \frac{E^4}{m_e^4 R}, \quad (1.1)$$

onde  $E$ ,  $R$  e  $m_e$  são a energia do feixe, o raio do acelerador e a massa do elétron, ou seja a perda de energia é proporcional a quarta potência da energia do feixe, enquanto que em um acelerador linear a perda é proporcional apenas à segunda potência. O segundo motivo é que para um acelerador circular o custo é proporcional a  $E^2$  enquanto que para um acelerador linear o custo proporcional a  $E$ , ou seja é mais barato aumentar a energia de um acelerador linear. É esperado que a luminosidade integrada atinja  $1000 \text{ fb}^{-1}$  após um período de 5 a 6 anos. Com a grande energia de centro de massa do acelerador e luminosidade integrada abre-se uma grande possibilidade de se detectar novas partículas. Essas medidas precisas possibilitarão aumentar o conhecimento sobre o MP e/ou descobrir a existência de uma nova Física através de novas partículas ou interações. Estas novas partículas são previstas por diversas extensões do MP no intuito de responder algumas questões ainda em aberto, tais como a assimetria matéria-antimatéria, o número de famílias de quarks e leptons, entre muitas outras. Em várias extensões, prevê-se a possibilidade da existência de novos neutrinos pesados do tipo de Majorana. Em 2012, foi descoberta no CERN a partícula denominada de Higgs, responsável por dar massa às outras partículas, prevista pelo MP. Espera-se que o ILC também produza novidades na Física de Partículas Elementares já que ele deverá complementar alguns resultados do LHC[5].

Este projeto dedica-se ao estudo da possibilidade de detectar novas partículas neutras pesadas do tipo de Majorana[6] no ILC, caso elas existam, usando eventos gerados através de simulações Monte Carlo (MC) de acordo com uma extensão do MP e com características do acelerador ILC. Serão usadas diversas simulações MC para a geração de eventos descrevendo interações de partículas elementares, conforme proposto por um modelo de extensão do MP, abaixo descrito, indo até a descrição de seus decaimentos. Serão feitos cálculos das seções de choque totais e parciais e da procura por sinais e distribuições de algumas variáveis que permitam caracterizar a existência de uma partícula do tipo de Majorana e também como o detector altera estas distribuições devido à sua limitada eficiência e resolução na detecção de partículas. Este estudo é feito através de simulações de modo a servir de orientação para a futura análise de dados com eventos reais detectados pelo ILC.



Cortes de seleção, medidas e distribuições de diversas variáveis tais como seções de choque, massas invariantes, larguras, momento transverso, distribuição angular no centro de massa, etc, ou combinação delas podem nos fornecer detalhes importantes sobre o MP e/ou o aparecimento de novas partículas. Estas informações são muito importantes na teoria eletrofraca que descreve a mistura entre as interações fraca e eletromagnética. O estudo será a comparação da produção de um único neutrino de Majorana  $N$  devido as reações:

$$\begin{aligned} a) & e^+ + e^- \rightarrow \nu, W, l \\ b) & e^+ + e^- \rightarrow \nu, jet, jet, l \end{aligned}$$

onde o neutrino de Majorana  $N$  está decaindo da seguinte forma:  $N \rightarrow l^{+\nu}, W^{+\nu}$  e o  $W \rightarrow jet, jet$ .

Estas reações têm como característica principal e original a possibilidade de violação do numero leptônico no estado final, já que o neutrino de Majorana é a sua própria antipartícula. Esta violação seria uma assinatura bem clara da existência do neutrino de Majorana, pois ela não é prevista no MP. Uma parte do estudo destes canais implica em cálculos simbólicos e numéricos de centenas de gráficos de Feynmann envolvendo bastante tempo de computação, espaço em disco e memória RAM. Além da análise usual de cortes e variáveis acima mencionada, tem-se como objetivo classificar usando métodos de aprendizagem de máquina.

Aprendizagem de máquina com redes neurais profundas vem sendo usada ultimamente em diversos ramos da ciência e em aplicações práticas com bastante sucesso, inclusive no diagnóstico de doenças raras. Neste caso será utilizada para a detecção de eventos raros. A área de física de partículas também tem se mostrado apropriada para a introdução de métodos de aprendizado de máquinas. Em altas energias, especialmente, o grande volume e a grande complexidade dos dados coletados tem se mostrado como ideais para a aplicação dessas técnicas.[7] O método de aprendizado de máquina[8] dá aos computadores a habilidade de aprender a classificar e corrigir os dados sem terem sido explicitamente programados para isso. Essa técnica tem sido utilizada em áreas que são muito complexas para o tratamento convencional ou para as quais não existe um algoritmo conhecido. Em física de partículas, a principal ferramenta de aprendizado de máquinas tem sido as redes neurais artificiais com várias camadas intermediárias, capazes de aprendizado profundo. Essas redes são versáteis e poderosas, ideais para lidar com tarefas altamente complexas, normalmente associadas aos problemas de classificação. Algumas das variáveis acima mencionadas poderão caracterizar a existência deste novo neutrino de Majorana que irá orientar a análise dos dados experimentais. Acredita-se que o modelo padrão não seja a última palavra em termos de

teoria, assim este projeto tem como objetivo caracterizar esta nova partícula, o neutrino pesado de Majorana de acordo com uma extensão do MP seja via a análise tradicional de dados e/ou via aprendizagem de máquina.

Na Introdução foram discutidas as motivações do trabalho e uma visão geral do que foi feito. No Capítulo 2 serão discutidos conceitos fundamentais necessários para o entendimento do trabalho e dos procedimentos realizados. Serão explicados os colisores de partículas e o ILC, o colisor utilizado para os estudos deste trabalho no Capítulo 3. Ao longo do Capítulo 4 será discutido o *software* CalcHEP, utilizado para gerar os eventos estudados utilizando as características do Colisor ILC. Serão discutidos os conceitos e funcionamento de uma Inteligência Artificial no Capítulo 5. No Capítulo 6 serão discutidos os Objetivos do trabalho. Serão discutidos os métodos de geração e separação dos eventos estudados durante o Capítulo 7. Será feita a análise dos resultados obtidos no Capítulo 8. Finalmente no Capítulo 9 serão discutidas as conclusões atingidas e o que poderá ser feito para melhorar os resultados obtidos.

# Capítulo 2

## Conceitos Fundamentais

Neste capítulo serão discutidos conceitos essenciais para a compreensão deste trabalho.

### 2.1 Física de Partículas

Na física de partículas se trabalha, na grande maioria das vezes, com altas energias, o que requer uma formulação relativística dos problemas tratados.

#### 2.1.1 Relatividade Restrita

Nesta sessão serão discutidos alguns conceitos que foram utilizados no trabalho para simular as interações e determinar a massa dos neutrinos de Majorana.

##### **Transformadas de Lorentz**

Na relatividade o tempo ( $t$ ) passa a ser tratado como uma dimensão, e assim como a dimensão espacial, sofre alterações em velocidades próximas à velocidade da luz no vácuo ( $c$ )[9]. Einstein quando formulou a teoria baseou-se em dois postulados, que são a base da teoria da relatividade restrita, sendo estes

- As leis da física são as mesmas em todos os referenciais inerciais. Portanto não existe referencial absoluto.
- A velocidade da luz no vácuo é absoluta. Ou seja, é a mesma independente do referencial inercial.

Utilizando as Transformadas de Galileu <sup>1</sup> para dois referenciais inerciais distintos S e S'

$$x' = x - vt, \quad y' = y, \quad z' = z, \quad t' = t, \quad (2.1)$$

Para o caso relativístico, utilizando os postulados da relatividade, temos que para um ponto na frente de onda de um pulso de luz emitido no instante de tempo  $t' = t = 0$  satisfaz as equações para S  $x^2 + y^2 + z^2 = (ct)^2$  e para S'  $x'^2 + y'^2 + z'^2 = (ct')^2$ , fazendo com que o intervalo espaço-tempo

$$\Delta s^2 = (c\Delta t)^2 - \Delta x^2 - \Delta y^2 - \Delta z^2, \quad (2.2)$$

seja invariante, as coordenadas de S e S' respeitam as seguintes relações:

$$\begin{aligned} x' &= \frac{x - vt}{\sqrt{1 - \frac{v^2}{c^2}}} \\ y' &= y \\ z' &= z \\ t' &= \frac{t - \frac{vx}{c^2}}{\sqrt{1 - \frac{v^2}{c^2}}} \end{aligned} \quad (2.3)$$

O conjunto de Equações 2.3 é conhecido como transformações de Lorentz, onde  $v$  é a velocidade de S' em relação à S e  $c$  é a velocidade da luz no vácuo[10]. As Equações 2.3 são válidas para o caso particular em que  $v$  tem a direção de  $x$ .

## Representações covariante e contravariante e o espaço de Minkowski

Na relatividade o tempo  $t$  passa a ser tratado como uma dimensão, e portanto, ao se definir vetores passa-se a considerar o tempo como um elemento desses vetores,

$$a^\mu = (ct, \vec{r}), \quad a_\mu = (ct, -\vec{r}), \quad (2.4)$$

sendo  $a^\mu$  e  $a_\mu$  contravariante e covariante respectivamente, onde  $\vec{r}$  representa as coordenadas espaciais  $(x, y, z)$ , e o índice  $\mu$  pode assumir quaisquer valores inteiros do conjunto  $[0, 1, 2, 3]$ , sendo 0 para a coordenada  $ct$ , 1 para  $x$ , 2 para  $y$ , e 3 para  $z$ .

---

<sup>1</sup>As Transformadas de Galileu são transformações não relativísticas entre dois referenciais inerciais.

A Equação 2.2 é utilizada como a métrica da Relatividade Restrita, e este espaço é denominado espaço de Minkowski.[10]

De acordo com esta métrica, as componentes da representação contravariante podem ser escritas como

$$\begin{aligned}x^0 &= ct \\x^1 &= x \\x^2 &= y \\x^3 &= z\end{aligned}\tag{2.5}$$

e da covariante como

$$\begin{aligned}x_0 &= ct \\x_1 &= -x \\x_2 &= -y \\x_3 &= -z\end{aligned}\tag{2.6}$$

e portanto, pode-se escrever  $x_\mu = g_{\mu\nu}x^\nu$  onde  $g_{\mu\nu}$  é

$$g_{\mu\nu} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & -1 \end{pmatrix}\tag{2.7}$$

em que  $g_{\mu\nu}$  é chamado de tensor métrico [10] e índices repetidos implicam em um somatório neste índice.

### Transformadas de Lorentz na forma Tensorial

Considerando um sistema de quatro coordenadas  $\tilde{x}^\mu$  onde  $\mu = 0, 1, 2, 3$  e um outro sistema de quatro coordenadas  $x(\tilde{x})$  obtém-se o diferencial  $dx^\mu$  pela regra da cadeia[11]

$$dx^\mu = \frac{\delta x^\mu}{\delta \tilde{x}^\alpha} d\tilde{x}^\alpha.\tag{2.8}$$

Um vetor que se transforma desta maneira é chamado de 4-vetor contravariante[11]

$$V^\mu = \frac{\delta x^\mu}{\delta \tilde{x}^\alpha} \tilde{V}^\alpha.\tag{2.9}$$

onde  $\tilde{V}$  é o vetor no sistema  $\tilde{x}$  e  $V$  é o vetor no sistema  $x$ . [11]

De maneira similar, um 4-vetor covariante pode ser escrito como

$$V_\mu = \frac{\delta x^\alpha}{\delta \tilde{x}^\mu} \tilde{V}_\alpha. \quad (2.10)$$

Desta maneira, podemos transformar 4-vetores covariantes em contravariantes e vice versa da seguinte maneira[11], como foi explicado na subseção anterior

$$\tilde{V}_\mu = g_{\mu\nu} V^\nu \quad V_\mu = g_{\mu\nu} V^\nu, \quad (2.11)$$

onde  $g_{\mu\nu}$  é o tensor métrico.

Desta maneira, pode-se generalizar a equação 2.11 para tensores da seguinte maneira[11]

$$V_{\mu\nu} = g_{\mu\alpha} g_{\nu\beta} V^{\alpha\beta}. \quad (2.12)$$

### Massa Invariante

Escrevendo o momento na forma de 4-vetor temos  $p^\mu = (\frac{E}{c}, \vec{p})$  e  $p_\nu = (\frac{E}{c}, -\vec{p})$ . Na física de partículas é comum usarmos o sistema natural de unidades, tomando  $c = 1$ . Portanto fazendo o produto interno de  $p$  temos

$$\begin{aligned} p_\mu p^\mu &= \frac{E^2}{c^2} - \vec{p}^2 \\ &= \frac{\vec{p}^2 c^2 + m^2 c^4}{c^2} - \vec{p}^2 \\ &= m^2 c^2 \\ &= m^2 \quad \text{utilizando } c = 1 \end{aligned} \quad (2.13)$$

onde  $m^2$  é a massa invariante ao quadrado.[10] Esta definição pode ser utilizada para um sistema de partículas de tal forma que se uma partícula decaiu em  $k$  partículas podemos reconstruir a massa invariante da partícula que decaiu. Usando conservação de energia e momento temos

$$P^\mu = \sum_{i=0}^k P_i^\mu,$$

então

$$P^\mu P_\mu = M^2.$$

Esta definição foi utilizada para reconstruir a massa do neutrino de Majorana N tanto no canal a) onde decaiu em duas partículas,  $(l, W)$ , como no canal b) onde decaiu em três partículas,  $(l, jet, jet)$ .

## 2.1.2 Forças Fundamentais

Atualmente são conhecidas quatro forças fundamentais na Natureza, sendo estas a força forte, a força fraca, a força eletromagnética e a força gravitacional.

- A força forte é a força de maior intensidade conhecida, porém seu alcance é da ordem de  $10^{-15}$  metros. Sua partícula mediadora é o Glúon. Esta força é responsável por manter os quarks juntos formando os nucleóons (Prótons e Neutrons).
- A força eletromagnética é uma força existente entre duas partículas com cargas elétricas não nulas, e sua partícula mediadora é o fóton. A teoria que descreve esta força foi formulada por Maxwell no século XIX, e é chamada de eletrodinâmica.
- A força fraca é a força responsável pelo decaimento de partículas pesadas em partículas mais leves e pela troca de sabor dos quarks, e sua partícula mediadora são os Bósons  $W^+$ ,  $W^-$  e  $Z^0$ . Esta força é melhor explicada pela Teoria Eletrofraca, que será discutida posteriormente neste trabalho.

As quatro forças naturais, com exceção da gravitacional, são descritas na Tabela 2.1 junto com o bóson de Higgs em ordem decrescente e com suas respectivas partículas mediadoras.

Bósons	
Força Forte	Glúon
Força Eletromagnética	Fóton
Força Fraca	Bósons Z e W
Massa	Higgs

Tabela 2.1: Modelo Padrão: Bósons

## 2.1.3 Número Leptônico

Assim como na Mecânica Clássica, várias leis de conservação já foram descobertas empiricamente na Mecânica Quântica, sendo uma dessas a conservação do número leptônico, cuja violação é essencial para a existência do neutrino de Majorana.

Na física de partículas existem vários números quânticos associados a diferentes tipos de partículas, sendo o número leptônico um desses números, que é associado aos léptons. Para cada lépton descrito na Tabela 2.2 existe um número leptônico como mostra a Figura 2.1

$Q/e$	$L_e = -1$	$L_\mu = -1$	$L_\tau = -1$
0	$\begin{pmatrix} \bar{\nu}_e \\ e^+ \end{pmatrix}$	$\begin{pmatrix} \bar{\nu}_\mu \\ \mu^+ \end{pmatrix}$	$\begin{pmatrix} \bar{\nu}_\tau \\ \tau^+ \end{pmatrix}$
$Q/e$	$L_e = 1$	$L_\mu = 1$	$L_\tau = 1$
0	$\begin{pmatrix} \nu_e \\ e^- \end{pmatrix}$	$\begin{pmatrix} \nu_\mu \\ \mu^- \end{pmatrix}$	$\begin{pmatrix} \nu_\tau \\ \tau^- \end{pmatrix}$

Figura 2.1: Números leptônicos dos léptons e suas anti partículas

Léptons		
1 <sup>a</sup> Geração	Elétron	Neutrino do Elétron
2 <sup>a</sup> Geração	Múon	Neutrino do Múon
3 <sup>a</sup> Geração	Tau	Neutrino do Tau

Tabela 2.2: Modelo Padrão: Léptons

## 2.2 Física de Partículas Experimental

### 2.2.1 Seção de Choque

Com origem na mecânica clássica, a Seção de Choque ( $\sigma$ ) na física de partículas experimental tem um papel muito importante na determinação da probabilidade de uma reação acontecer.

Na mecânica clássica a sessão de choque pode ser definida como a área da superfície de um objeto atingido por um feixe, e sua unidade é dada em metros quadrados ( $m^2$ ). Na mecânica quântica porém a seção de choque é proporcional à probabilidade de interação entre as partículas.

Como na física de partículas trabalha-se com medidas muito pequenas a unidade de medida utilizada é o barn ( $b$ ) definida como

$$b = 10^{-28}m^2, \quad (2.14)$$

As seções de choque em física de partículas são muitas vezes expressas em *femtobarn* ( $b^{-15}$ ) devido à baixa probabilidade de ocorrência da reação.

### 2.2.2 Luminosidade e luminosidade Integrada

Os aceleradores de partículas possuem uma característica chamada luminosidade, que representa a razão entre o número de partículas por unidade de área em um intervalo de tempo[12], que pode ser determinada pela equação 2.15.



$$L = \frac{1}{\sigma} \frac{dN}{dt}, \quad (2.15)$$

onde  $\frac{dN}{dt}$  é o número de eventos por segundo e  $\sigma$  a seção de choque.

Esta grandeza é utilizada para medir a eficiência dos aceleradores, e sua unidade de medida geralmente é expressa em  $fb^{-1}s^{-1}$

Se integrarmos a Equação 2.15 no tempo, obtemos o que chamamos de Luminosidade Integrada, onde sua relação com a seção de choque nos fornece o número de eventos.

$$N = \mathcal{L}\sigma \quad (2.16)$$

Onde  $\mathcal{L}$  é a Luminosidade Integrada e tem dimensão  $fb^{-1}$ . A luminosidade é uma característica técnica de cada acelerador.

## 2.3 Modelo Padrão

O Modelo Padrão (MP) é a teoria que descreve a interação entre as partículas que compõe todo o universo. Criado na segunda metade do século XX, o MP descreve três das quatro interações fundamentais da Natureza, e desde sua criação sofreu algumas alterações, em sua maior parte para incluir novas partículas descobertas posteriormente à sua versão original. Estas três forças fundamentais da Natureza são descritas matematicamente por um grupo de simetria chamado Grupo de Gauge. A combinação do eletromagnetismo, mecânica quântica e relatividade especial levaram Dirac a chegar à equação que atualmente é conhecida como Equação de Dirac.

Atualmente o MP é composto por dois tipos de partículas, os bósons de gauge e férmions. Os férmions são partículas de spin não inteiro, e são responsáveis pela composição de toda a matéria do universo. Este grupo respeita a estatística de Fermi-Dirac e ainda pode ser dividido em dois subgrupos, quarks e léptons.

Os quarks são as partículas que interagem fortemente através da troca de Glúons, e são eles quem compõe os hadrons (como os prótons e nêutrons).[9] A teoria que lida com as interações fortes é chamada de Cromodinâmica Quântica (QCD).

Quarks		
1ª Geração	Up	Down
2ª Geração	Charm	Strange
3ª Geração	Top	Bottom

Tabela 2.3: Modelo Padrão: Quarks

O sub grupo dos léptons é composto por seis partículas e suas respectivas antipartículas que não interagem fortemente e possuem spin semi inteiro, e assim como os quarks, os léptons compõe grande parte das partículas conhecidas como mostra a Tabela 2.2.[9]

Os bósons de gauge são partículas de spin inteiro e que respeitam a estatística de Bose-Einstein. São as partículas responsáveis por "transportar" as forças fundamentais da Natureza, e estão presentes nas interações nucleares e eletromagnéticas, por exemplo, como mostra a Tabela 2.1.

Do ponto de vista da Teoria de Grupos, o Modelo Padrão é uma teoria descrita em termos de classes de simetria, sendo sua simetria interna a simetria de gauge do grupo  $G_{SM}$ . Este grupo pode ser escrito como  $SU(3)_C \otimes SU(2)_L \otimes U(1)_Y$ , sendo  $SU(3)_C$  o grupo que representa as interações fortes e  $SU(2)_L \otimes U(1)_Y$  o que representa a interação eletrofraca, onde o subíndice

C indica o grupo SU(3) como um grupo de cor da cromodinâmica quântica (QCD), o subíndice L indicando a quiralidade do grupo SU(2) como levógiro (LH) ou destrógiro (RH) como mostra a relação abaixo, e o subíndice Y se referindo ao grupo de hipercarga U(1).

$$\begin{aligned}
& \begin{pmatrix} \nu_e \\ e \end{pmatrix}_L \begin{pmatrix} u \\ d \end{pmatrix}_L (e)_R (u)_R (d)_R \\
& \begin{pmatrix} \nu_\mu \\ \mu \end{pmatrix}_L \begin{pmatrix} c \\ s \end{pmatrix}_L (\mu)_R (c)_R (s)_R \\
& \begin{pmatrix} \nu_\tau \\ \mu \end{pmatrix}_L \begin{pmatrix} t \\ b \end{pmatrix}_L (\tau)_R (t)_R (b)_R,
\end{aligned} \tag{2.17}$$

Como é possível ver todos os neutrinos no MP possuem quiralidade levógena (LH). Esta observação é extremamente importante para a existência dos neutrinos de Majorana.

A lagrangiana do MP pode ser dividida em quatro partes, sendo elas de Higgs, Yukawa, gauge e dos férmions.

$$\mathcal{L}_{MP} = \mathcal{L}_{Higgs} + \mathcal{L}_{Yukawa} + \mathcal{L}_{gauge} + \mathcal{L}_{fermions} \tag{2.18}$$

O termo  $\mathcal{L}_{gauge}$  é responsável pelo acoplamento dos bósons  $W^+$ ,  $W^-$  e  $Z^0$ , e do fóton com os léptons e seus respectivos neutrinos e dos glúons com os quarks e seus antiquarks. O termo  $\mathcal{L}_{fermions}$  descreve as partículas de matéria, embora não contenha termos de massa. O termo  $\mathcal{L}_{Higgs}$  inclui os termos de massa dos bósons e o termo  $\mathcal{L}_{Yukawa}$  inclui a massa dos férmions.

A lagrangiana do Modelo Padrão pode ser escrita de modo simplificado como

$$\mathcal{L}_{MP} = -\frac{1}{4}B_{\mu\nu}B^{\mu\nu} - \frac{1}{2}tr(W_{\mu\nu}W^{\mu\nu}) - \frac{1}{2}tr(G_{\mu\nu}G^{\mu\nu}), \tag{2.19}$$

onde G é o tensor de campo dos glúons SU(3), W o tensor de campo de gauge de SU(2) e B o tensor de campo de gauge de U(1).

Embora o MP seja eficaz em prever e descrever inúmeros fenômenos, acredita-se que ele não é a última palavra em termos de teoria, isso porque além de não prever a oscilação de neutrinos, como o espectro dos neutrinos solares, o MP também não consegue explicar a interação gravitacional[9], uma das quatro forças fundamentais da Natureza, dentre outros problemas.

- **Força Gravitacional:** O MP não explica a força gravitacional e todas as tentativas de se adicioná-la ao modelo não reproduziram resultados experimentais.

- **Oscilação de Neutrinos:** Ao contrário do que se diz o MP, experimentos de oscilação de neutrinos confirmaram a existência de massa dos mesmos.
- **Assimetria matéria-antimatéria:** De acordo com o MP, a criação do universo deveria ter dado origem às mesmas quantidades de matéria e antimatéria, porém existe uma quantidade muito maior de matéria.
- **Matéria Escura:** Embora cerca de 26% da matéria presente no universo seja matéria escura[13], o MP não prevê sua existência e não possui nenhuma partícula que seja uma boa candidata à matéria escura.

## 2.4 O problema da Oscilação de neutrinos

Embora tenham sido postulados por Pauli na primeira metade do século XX pouco se sabia sobre os neutrinos até meados da década de 90, sabendo-se apenas que eram muito leves ou até mesmo sem massa e que existiam três sabores de neutrinos; um para o elétron, um para o múon e outro para o tau. Estas partículas se tornaram ainda mais misteriosas quando na década de 60 um experimento para detectar neutrinos produzidos no sol detectou apenas 1/3 dos neutrinos previstos experimentalmente.

Este experimento foi feito para detectar neutrinos solares, que são neutrinos do elétron produzidos pelas fusões nucleares que ocorrem no Sol, e o baixo número de neutrinos do elétron detectados foi considerado uma evidência experimental da oscilação de neutrinos, um fenômeno em que o neutrino troca de sabor ao percorrer grandes distâncias [14].

## 2.5 Extensões além do Modelo Padrão e o Neutrino de Majorana

Como dito no tópico sobre o Modelo Padrão, o MP possui alguns problemas que nos fazem acreditar que ele não seja a palavra final em termos de teoria. Afim de resolver estes problemas, inúmeras extensões do MP foram propostas ao longo dos anos para diferentes problemas apresentados pelo modelo. Uma dessas extensões por exemplo, chamada de *Grand Unification Theory* (GUT), se inspira na unificação da Teoria Eletromagnética com a força fraca, chamada de Teoria Eletrofraca, para unificar também a força forte[15].

### 2.5.1 O Neutrino de Majorana

A partir da quebra de simetria do número leptônico de léptons carregados é possível obter férmions do tipo Majorana, como foi proposto por Ettore Majorana em 1937.

Se opondo ao conceito do "mar de Dirac", Majorana propôs uma correção da equação desconsiderando que toda partícula deveria ter uma anti partícula diferente de si mesma, o que causava problema com os neutrinos já que eles não possuem carga[16]. O objetivo de Majorana era, além de dar uma forma simétrica à teoria do elétron e do pósitron, criar uma nova teoria para partículas eletricamente neutras.

De acordo com o MP, os neutrinos não possuem massa, porém com uma extensão do MP é possível que algumas interações de Yukawa permitam massas de Dirac para léptons carregados e neutrinos, tornando possível que

os neutrinos tenham em sua Lagrangiana um termo de massa pesada do tipo Majorana, como pode ser visto abaixo [17]

$$\begin{aligned}
\mathcal{L}_{Majorana} = & \frac{1}{2} \left( \sum_{l=e\mu\tau} \frac{-g}{2\sqrt{2}} [\bar{\nu}_l \gamma^\mu (1 - \gamma^5) l \cos\theta_l + \bar{N} \gamma^\nu (1 - \gamma^5) l \sin\theta_l] W_\nu - \right. \\
& - \frac{g}{2\cos\theta_w} [\bar{\nu}_l \gamma^\mu (g_{\nu l} - g_{A l} \gamma^5) \nu_l + \frac{1}{2} \cos\theta_l \sin\theta_l \bar{N} \gamma^\mu (1 - \gamma^5) \nu_l + \\
& \left. + \frac{1}{2} \sin^2\theta_l \bar{N} \gamma^\mu (1 - \gamma^5) N] Z_\mu + h.c \right)
\end{aligned} \tag{2.20}$$

onde N é o neutrino pesado de Majorana.

Como o neutrino pesado tem um tempo de vida muito curto, torna-se ainda mais difícil detectá-lo. Porém neste trabalho estão sendo estudados dois canais específicos, e em ambos o neutrino pesado decai em um lépton carregado e um bóson W. A partir da reconstrução da massa invariante dessas duas partículas no estado final podemos obter a massa do neutrino pesado, podendo assim detectar indiretamente a existência deste neutrino.

Recentemente pesquisadores do Department of Physics and Astronomy na University College London e outros [18], conseguiram determinar o limite superior da massa do neutrino do elétron em 0,8eV usando dados de cosmologia. Este resultado, que contraria o Modelo Padrão, é mais uma evidência das falhas do modelo atual e também uma inspiração para a continuidade das buscas por um neutrino pesado.

Na interação reproduzida na Figura 6.1a é produzido um Neutrino de Majorana que decai em um múon e um bóson W+. Este neutrino é um neutrino pesado, ou seja, possui massa, característica também não prevista pelo MP, e para produzi-lo é necessária uma colisão de alta energia.

Ao reconstruirmos a massa invariante do par W-lépton a partir de seus quadrimomentos de todos os eventos gerados deve ser observado no histograma um pico em uma determinada massa, que representa a massa do neutrino pesado, como pode ser visto na Figura 2.2.




Figura 2.2: Histograma da reconstrução da massa invariante para os eventos gerados com energia de centro de massa de 1000 GeV e Massa do neutrino pesado de 100 GeV

## 2.6 Mecanismo Seesaw

Atualmente o mecanismo seesaw é o modelo utilizado para compreender a massa dos neutrinos. Este mecanismo funciona comparando a massa observada do neutrino com a de partículas mais pesadas, como quarks e léptons[19]. Embora os neutrinos detectados dessa maneira podem ser tanto partículas de Dirac quanto de Majorana, ambos terão os termos de massa de Dirac e Majorana.[20]

Os neutrinos da Lagrangiana 2.20 também são uma mistura de neutrinos, porém são uma mistura de neutrinos do MP ( $\tilde{\nu}$ ) e os novos neutrinos pesados ( $N_0$ ), da seguinte maneira

$$\begin{pmatrix} \nu \\ N \end{pmatrix} = \begin{pmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{pmatrix} \begin{pmatrix} \tilde{\nu} \\ N_0 \end{pmatrix} \quad (2.21)$$

O mecanismo seesaw utilizados neste trabalho é conhecido como Mecanismo Seesaw tipo I. Neste mecanismo, é considerada a existência de um neutrino destrógiro  $\nu_R$  que se transforma como um singlete do grupo de Gauge do Modelo Padrão,  $SU(3)_C \otimes SU(2)_L \otimes U(1)_Y$ , que possui massa de Majorana  $M_{\nu_R}$  e que interage com uma única geração de léptons do MP  $\nu_0$  através de acoplamento de Yukawa  $y_\nu$ . Após a mistura de massas e assumindo que  $M_{\nu_R}$  é bem maior que o acoplamento  $y_\nu \nu_0$ , a massa do neutrino pode ser estimada como[21]

$$m_\nu \approx \frac{y_\nu^2 \nu_0^2}{M_{\nu_R}} \quad (2.22)$$

Os ângulos de mistura utilizado para gerar os eventos deste trabalho são representados na Tabela 2.4. Estes ângulos são determinados pelos limites

experimentais atuais [22].

$\theta_{electron}$	0,0550
$\theta_{muon}$	0,0565
$\theta_{tau}$	0,0775

Tabela 2.4: Ângulos de mistura do acoplamento do Neutrino Pesado com elétron, múon e tau, respectivamente. Limite superior com 95% de CL (Confidence Level).



## Capítulo 3

# Colisores Lineares e o ILC

Os aceleradores de partículas aceleram partículas carregadas, como prótons, elétrons e múons, utilizando campos elétricos e/ou magnéticos. Estes aceleradores são utilizados amplamente na atualidade e para diversas finalidades, como por exemplo produção de Raios-X através do efeito Bremsstrahlung. Na física os aceleradores de partículas são amplamente utilizados como colisores de partículas. Ao se colidir duas partículas com alta energia estas partículas podem se aniquilar e dar origem a novas partículas, revelando informações sobre sua Natureza.

Até hoje os aceleradores são muito utilizados na física de partículas, sendo o maior e mais conhecido o Large Hadron Collider (LHC). Neste tipo de acelerador o feixe de partículas percorre um caminho fechado em loop guiado por campos magnéticos.




Figura 3.1: Colisor Cosmotron. Operou no laboratório Brookhaven Lab de 1952 até 1966. Imagem retirada de <https://www.bnl.gov/about/history/images/cosmotron.jpg>

## 3.1 Colisores Lineares

Um outro modelo de acelerador que vem sendo amplamente utilizado são os aceleradores lineares. Neste acelerador o feixe de partículas é submetido a vários potenciais elétricos oscilantes ao longo de um caminho retilíneo.




Figura 3.2: Colisor linear LINAC 4 no CERN. Imagem retirada de <https://cds.cern.ch/images/CERN-PHOTO-201704-093-3/file?size=large>

A vantagem de se utilizar um colisor linear em relação a um colisor circular é que, reduzindo o feixe de partículas a um pequeno feixe até o ponto de interação diminui consideravelmente o tamanho do colisor[23].

### 3.1.1 CLIC

Atualmente um colisor que está para ser construído e é conhecido como Compact Linear Collider (CLIC) é uma colaboração internacional trabalhando com um conceito de máquina que colide elétrons e pósitrons. Este acelerador utiliza radiofrequência para acelerar dois feixes de partículas um contra o outro, e a expectativa é que atinja energias de centro de massa entre 380 GeV até 3 TeV[24]. Ele será projetado para trabalhar inicialmente com 380 GeV para estudo de quarks top e bósons de Higgs, e posteriormente será otimizado para energias maiores para o estudo de novas teorias além do MP, como acoplamento fraco por exemplo.

Espera-se que futuramente, trabalhando com mais altas energias de centro de massa, o acelerador seja capaz de nos dar mais dados e informações sobre a física além do modelo padrão, sendo capaz de reproduzir experimentos já realizados e até mesmo nos dar novas informações sobre o bóson de Higgs e singletos pesados[24].

O Acelerador CLIC fará parte da colaboração CERN com o objetivo primário de determinar os acoplamentos de Higgs e a massa do quark top com um custo financeiro bem reduzido[24].



Figura 3.3: Ilustração do acelerador CLIC, ainda não construído. Imagem retirada de <http://clic-study.web.cern.ch/>

### 3.1.2 ILC

O International Linear Collider (ILC) é um projeto de acelerador linear que deve ser construído nos próximos anos. O objetivo é que ele seja o colisor a trabalhar como um auxiliar do Large Hadron Collider (LHC), trazendo grandes expectativas para o descobrimento de uma nova física.

Até o momento tem-se a expectativa de que o ILC seja construído no Japão, porém nada ainda foi confirmado. Espera-se que inicialmente o acelerador tenha um comprimento de aproximadamente 31 km e trabalhe com uma energia de centro de massa de 500 GeV, chegando a 50 km e até 1 TeV no segundo estágio do projeto.




Figura 3.4: Ilustração do colisor ILC. Imagem retirada de <https://ilchome.web.cern.ch/sites/ilchome.web.cern.ch/files/ILC-rendering.jpg>

O objetivo principal deste acelerador no primeiro estágio será auxiliar o LHC no estudo do campo de Higgs, e nos estágios seguintes, com maior energia de centro de massa, o estudo de novas físicas.

# Capítulo 4

## O CalcHEP

O CalcHEP [25] é um pacote programado para realizar cálculos eficientes no estudo das seções de choque de produção e larguras de decaimento dentro de vários modelos teóricos da física de partículas. Neste software é possível inserir a Lagrangiana da interação que deseja estudar como também algumas características de um acelerador em particular.

As notações usadas no calcHEP são muito semelhantes às utilizadas em física de partículas. O programa permite que o usuário modifique seus modelos teóricos já inclusos e ainda permite que sejam implementados novos modelos.

No calcHEP, pode-se escolher entre o gauge de Feynman ou o gauge unitário no cálculo de diagramas de Feynman, o que fornece uma verificação poderosa da implementação do modelo e dos resultados numéricos. Ainda permite calcular larguras de decaimentos de partículas instáveis. No modo interativo, escolher um diagrama de Feynman, e até excluir diagramas específicos. Devido à grande flexibilidade do calcHEP e sua facilidade para implementar novos modelos, é possível trabalhar com uma variedade de modelos além do MP, como foi feito neste trabalho.

O MP já está incluído na distribuição do programa, porém, vários modelos e extensões estão disponíveis para serem baixados, importados e utilizados no calcHEP. O conjunto completo de modelos disponíveis pode ser encontrado no High Energy Physics Model Database (HEPMDB)[26].

O calcHEP trabalha em dois modos, o simbólico e o numérico. No modo simbólico, o usuário pode trabalhar de forma interativa com um modelo físico, calcular a matriz quadrada de elementos de matriz, exportar seus resultados como um código C e compilar este código C em um executável chamado *n<sub>c</sub>alcHEP*. O módulo numérico realiza o cálculo de integrais ao longo do espaço de fase para determinar a seção de choque ou a largura de decaimento de processos definidos pelo usuário. Além disso, o calcHEP pode

ser executado no modo não-interativo, usando vários scripts fornecidos pelo usuário, incluindo a interface batch que chama as rotinas das duas primeiras partes e coleta os resultados para obtenção das seções de choque transversais finais. As instruções para o cálculo através desta interface são escritas em um arquivo de texto. A interface em batch lê as instruções e executa-as de forma não interativa automatizando o cálculo dos processos de produção e de decaimento, combinando os resultados dos processos de produção com os decaimentos, para produzir um arquivo de evento final no formato Les Houches Event (LHE)[27].

O arquivo .lhe final pode ser usado em outro software, como por exemplo, o software desenvolvido neste trabalho, pois nesse arquivo consta as informações de todos os eventos como os momentos das partículas, suas energias *etc.*

#### 4.0.1 Modelo Utilizado Neste Trabalho

O Modelo utilizado neste trabalho contém os termos de interação entre os bósons de Gauge e o neutrino pesado de Majorana  $N$  inclusos na Lagrangiana do MP de acordo com a Equação 2.20. Este modelo é chamado de SM +  $N_{FG}$ .

# Capítulo 5

## Aprendizagem de Máquina e Inteligência Artificial

### 5.1 Conceitos Fundamentais

O aprendizado de máquina pode ser definido como um processo em que, a partir da análise de um banco de dados, o computador consegue identificar e correlacionar as variáveis, mesmo sem ter sido explicitamente programado para isso, sendo considerado um tipo de Inteligência Artificial <sup>1</sup> (IA). Hoje em dia algoritmos de Aprendizagem de Máquina são vastamente utilizados em diversas áreas e aplicações, indo de filtro de emails a até mesmo controle e automação de máquinas na indústria.

### 5.2 Algoritmos de Aprendizagem de Máquina

#### 5.2.1 Redes Neurais

Normalmente os algoritmos de Aprendizagem de Máquina são redes neurais, códigos que simulam o funcionamento do cérebro humano para processar todos os tipos de dados.

Como pode ser observado na Figura 7 a camada inicial (composta pelas variáveis  $x$ ) é a camada que receberá os parâmetros a serem processados. A partir desta etapa os dados serão distribuídos entre os nodos da camada

---

<sup>1</sup>Algoritmos de inteligência artificial são programas de computador que, simulando o funcionamento do cérebro humano, são capazes de aprender por tentativa e erro utilizando números gerados aleatoriamente para realizar as tentativas e, comparando o resultado obtido com o resultado "real", repetem o procedimento inúmeras vezes ajustando as tentativas posteriores até obter um resultado próximo com o real.




Figura 5.1: Ilustração do funcionamento de uma rede neural. Imagem retirada de <http://www.decom.ufop.br/imobilis/fundamentos-de-redes-neurais/>

seguinte. Cada um destes nodos (ou neurônios) é uma função de ativação que irá transformar o dado recebido que então será transferido para a camada posterior, e o processo será repetido até atingir a camada final. É importante lembrar que cada neurônio de uma camada é "ligado" a todos os neurônios da camada seguinte, e que todos os neurônios de uma camada possuem a mesma função de ativação.

Cada neurônio é composto de uma função (neste trabalho foi utilizado a tangente hiperbólica) e uma segunda variável chamada de bias ( $B_1$ ). Neste trabalho a função de ativação utilizada é

$$f(x) = \tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1}, \quad (5.1)$$

Os dados para treinar a rede, chamados de Input, formam a camada inicial da rede. Matematicamente são expressos por uma matriz  $X_{1,n}$ , onde  $n$  é o número total de variáveis.

Cada neurônio é conectado a todos os neurônios anteriores e posteriores, onde cada uma dessas conexões recebe um peso inicial  $W$ , determinado aleatoriamente. Como o Input é passado várias vezes pela rede, os pesos são reajustados a cada ciclo.

O valor inicial de  $B_1$  é a média do valor das variáveis do Input.

A probabilidade prevista ( $P$ ) para cada neurônio pode ser calculada então da seguinte forma

$$P = f(WX + B_1), \quad (5.2)$$

para uma rede composta de um Input de uma única variável e com um único neurônio. Para múltiplas variáveis podemos definir  $P$  como

$$P = B_1 + \sum_1^n W X_n, \quad (5.3)$$

Porém esta equação descreve uma rede com Input com um número  $n$  de variáveis e um único neurônio. Usualmente as redes possuem múltiplas camadas com múltiplos neurônios. Generalizando  $P$  para este caso, podemos escrevê-lo então como

$$\begin{pmatrix} p_1 \\ p_2 \\ \cdot \\ \cdot \\ \cdot \\ p_n \end{pmatrix} = \begin{pmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,n} \\ w_{2,1} & w_{2,2} & \dots & w_{2,n} \\ \cdot & & & \\ \cdot & & & \\ \cdot & & & \\ w_{n,1} & w_{n,2} & \dots & w_{n,n} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ \cdot \\ x_n \end{pmatrix} + \begin{pmatrix} B_0 \\ B_1 \\ \cdot \\ \cdot \\ \cdot \\ B_n \end{pmatrix} \quad (5.4)$$

Este processo é repetido várias vezes até se obter o Output, ou valores finais de  $P$ . Indiretamente a rede faz a interpolação dos valores das variáveis, buscando uma função que contenha todos os valores do Input em sua curva. Porém é praticamente impossível encontrar uma função analítica na maioria dos casos, então tenta-se encontrar a função que mais se aproxima da ideal, e para isso calculamos o erro da rede. A função utilizada neste trabalho é o erro quadrado médio ( $Er$ ) que é calculado da seguinte maneira

$$Er = \frac{1}{n} \sum^n (P_n - X_n)^2 \quad (5.5)$$

O erro é utilizado como indicador de precisão, com um valor baixo de erro indicando uma rede muito precisa.

### 5.3 Tipos de Redes Neurais

Os dois tipos mais comuns de redes neurais são de aprendizado supervisionado e aprendizado não supervisionado. As redes de aprendizado supervisionado são geralmente utilizadas para tarefas mais simples. Neste tipo de rede, na etapa de treino é passado junto com cada variável um outro valor numérico, chamado de label, que indica o que ela representa, e este valor pode ser constante ou não[28]. Depois de ser treinada desta maneira a rede será capaz de determinar o valor do label para cada variável a ser classificada, tornando este um excelente método para tarefas de classificação mais simples, como por exemplo, determinar se uma imagem contém um cachorro ou não, ou tarefas do tipo.



Já as redes não supervisionadas funcionam de uma maneira um pouco diferente. Como elas são treinadas sem os labels elas são obrigadas a determinar os pesos de cada variável automaticamente, tornando o processo de treinamento um pouco mais demorado. Porém ela é capaz de identificar padrões e correlacionar variáveis a partir da reconstrução dos dados de entrada.




Figura 5.2: Comparação dos resultados entre a rede supervisionada e não supervisionada. Imagem retirada de <https://towardsdatascience.com/deep-learning-for-image-classification-why-its-challenging-where-we-ve-been-and-what-s-next-93b56948fcef>

Um método de aprendizagem não supervisionada muito utilizado é o autoencoder-decoder. Este método basicamente consiste em diminuir o número de neurons progressivamente em cada camada e então refazer o caminho, reconstruindo os valores inseridos na entrada[29].

Matematicamente os autoencoders podem ser definidos como uma função

$$g(f(x)) = r, \quad (5.6)$$

onde  $r$  é o mais próximo possível de  $x$ ,  $x$  representa os dados iniciais e  $g$  e  $f$  funções de transformação.

Utilizando o método autoencoder-decoder o algoritmo é capaz de separar e classificar os eventos na sua menor camada intermediária, e então reconstruir os valores iniciais na camada final. Este será o método utilizado neste trabalho para separar os eventos do Modelo Padrão e os eventos contendo um neutrino de Majorana, poupando horas de trabalho manual dos pesquisadores.




Figura 5.3: Estrutura de um autoencoder-decoder. Imagem retirada de <https://towardsdatascience.com/generating-images-with-autoencoders-77fd3a8dd368>

## 5.4 Tratamento dos Dados e Data Pipelines

Embora os algoritmos de Aprendizado de Máquina (ML) sejam excelentes para identificar relações entre variáveis e prever resultados, os dados de treino, teste e avaliação precisam ser tratados antes. Um banco de dados muitas vezes possui erros, valores em branco ou uma escala inadequada para um algoritmo de ML. Neste caso é preciso fazer o tratamento de dados para que estes erros sejam corrigidos. Por exemplo, deletar linhas que contém algum valor em branco ou errado, ou então normalizar os valores de uma variável.

No caso de um banco de dados muito grande (como o utilizado neste trabalho) é completamente inviável fazer isto manualmente. Neste caso é criado um algoritmo para realizar estas tarefas. Este algoritmo é conhecido como Data Pipeline.

# Capítulo 6

## Objetivos

O objetivo principal deste projeto é, a partir de dados gerados pelo software CalcHEP comparar a reconstrução das massas invariantes do neutrino pesado antes e depois da seleção dos eventos por uma rede neural treinada das reações

$$a) e^+ + e^- \rightarrow \nu, N \rightarrow \nu, W^\pm, l^\mp$$

$$b) e^+ + e^- \rightarrow \nu, N \rightarrow \nu, W^\pm, l^\mp \rightarrow \nu, jet, jet, l^\mp$$

onde  $\nu = \nu_e, \nu_\mu, \nu_\tau$  (*antineutrinos do elétron, múon e tau, respectivamente*)

$l^{+-} = \text{elétrons e múons}$

$jet = quarks$

Onde o neutrino de Majorana:  $N \rightarrow l^{-+}, W^{+-}$ .

Uma das características dos canais a) e b) é a violação do número leptônico já que o neutrino de Majorana N é sua própria antipartícula.

No Canal a) temos 24 subprocessos com amplitudes de 1 a 16 diagramas de Feynman enquanto no Canal b) temos 216 subprocessos com amplitudes variando entre 1 a 24 diagramas. Assim o cálculo das seções de choque e geração de eventos são demorados, demandando bastante poder computacional.

A rede será treinada apenas com eventos do MP com a finalidade de reconhecê-los, de forma que quando analisar um evento que não seja do MP (um evento contendo Majorana, por exemplo) ela classifique este evento de maneira diferente dos demais, fazendo assim automaticamente a seleção dos eventos interessantes para estudos na área.

Atualmente este "filtro" é feito manualmente, demandando horas de trabalho realizando cortes (relativos às características do colisor e da cinemática e dinâmica dos processos) nos dados, que devem ser refeitos para cada massa de Majorana.

Caso o software consiga "aprender" a classificar os eventos corretamente e com boa precisão, ele poupará horas de trabalho futuro no estudo de física de partículas, tornando o trabalho dos pesquisadores mais rápido, mais eficiente, mais preciso e se obtendo limites mais restritivos para o acoplamento.

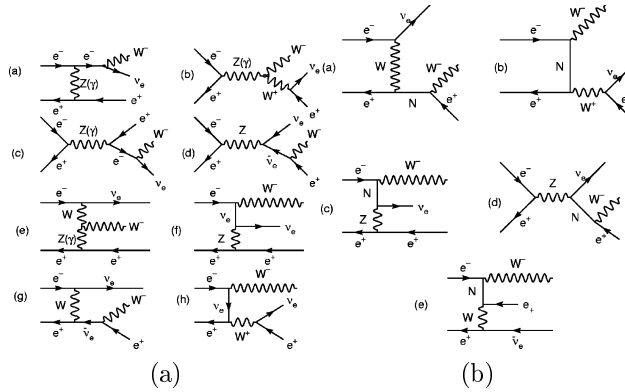


Figura 6.1: Alguns diagramas de Feynman representando a reação  $e^+ e^- \rightarrow \nu e^+ W^-$  no MP (a) e na extensão com Majorana (b), respectivamente

## 6.1 Largura do Neutrino de Majorana

Como poderá ser observado a altura da ressonância diminui em função da massa do neutrino. Isto ocorre porque a ressonância possui uma largura que cresce com a massa do neutrino de Majorana, como pode ser visto pelo gráfico da Figura 6.2. No intervalo de massa estudado (100 a 1000 GeV), o aumento de largura é de aproximadamente  $10^3$  vezes.




Figura 6.2: Largura do Neutrino de Majorana em função de sua massa

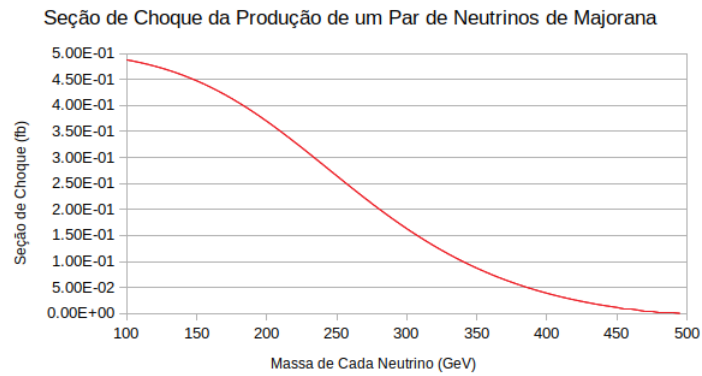
É possível observar que em alguns gráficos o pico de massa ficou distribuído entre vários bins<sup>1</sup> vizinhos, e a soma do número de eventos destes bins reproduz os resultados de eventos de Majorana previstos pela Tabela 8.3. Isso se deve ao aumento da largura da ressonância em função da massa do neutrino discutida anteriormente.

## 6.2 Produção de um único e do Par

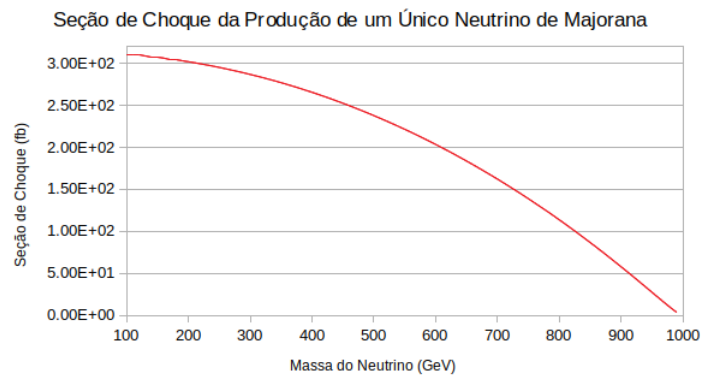
Neste trabalho está sendo analisado a produção de um único neutrino pesado de Majorana ao invés de um par de neutrinos. Isso se deve ao fato de que a seção de choque da produção de um único neutrino é aproximadamente  $10^3$  vezes maior que a seção de choque da produção do par como pode ser visto nos gráficos das Figuras 6.3a e 6.3b, e portanto teremos muito mais eventos produzindo um neutrino. Como também pode ser visto nessas figuras, a produção de um par de Neutrinos gera dois Neutrinos de Majorana onde a massa de cada um tem um limite máximo de 500 GeV, enquanto a produção de um único Neutrino de Majorana pode originar um Neutrino com a massa de até 1000 GeV. Como o objetivo desta pesquisa é testar a viabilidade do uso de inteligência artificial para a separação destes eventos, os canais de produção de um único neutrino são mais eficazes para o teste de precisão da rede, já que possuem uma quantidade maior de eventos produzindo neutrinos

<sup>1</sup>Ao se montar um histograma, a série de dados é dividida em N intervalos, onde cada um desses intervalos possui uma amplitude igual ao número de eventos que se encaixa neste intervalo. Cada um desses intervalos é chamado de “bin”

pesados de Majorana e é possível estudar massas de até 1000 GeV. A produção de um par de Neutrinos pesados de Majorana ocorre via  $e^+, e^- \rightarrow N, N$ , enquanto a produção de um único Neutrino pesado de Majorana ocorre via  $e^+, e^- \rightarrow \nu, N$ , onde  $\nu = \nu_{e,\mu,\tau}$ . Lembrando que o neutrino pesado de Majorana é sua própria antipartícula, então ele acopla com todos os neutrinos e antineutrinos do MP.



(a)



(b)

Figura 6.3: Seção de Choque da Produção de um Par de Neutrinos (a) e Seção de Choque da Produção de um Único Neutrino (b)

# Capítulo 7

## Geração e Separação dos Eventos

Neste capítulo serão discutidas a geração e classificação dos eventos.

### 7.1 Geração dos Eventos

Utilizando o software CalcHEP, já discutido anteriormente, foram gerados os eventos de colisão para os canais A,  $e^+e^- \rightarrow \nu, lepton, W$ , e B,  $e^+e^- \rightarrow \nu, lepton, jet, jet$ , e calculada a seção de choque para cada massa do neutrino estudada.

Para gerar os eventos fizemos cortes nos resultados devido às características do detector.

- **$|\text{Cos}(\theta)| < 0,999$** : Este corte foi utilizado porque as partículas espalhadas na direção do eixo de colisão não são detectadas, onde  $\theta$  é o ângulo entre qualquer uma das partículas finais e a direção do feixe. Isto corresponde a  $2,56^\circ < \theta < (180^\circ - 2,56^\circ)$ .
- **Energia das partículas no estado final  $> 5$  GeV**: Este corte foi utilizado porque partículas com energia muito baixa não são detectadas.

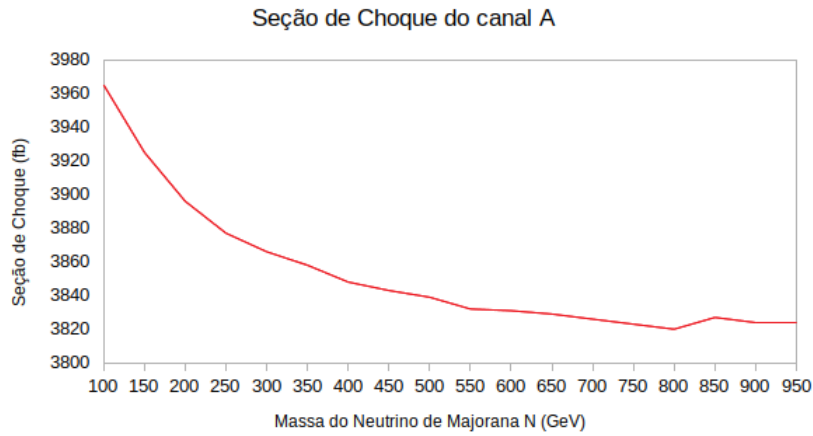


Figura 7.1: Seção de Choque do Canal  $e^+e^- \rightarrow \nu, lepton, W$  em função da massa do neutrino N.




Figura 7.2: Seção de Choque do Canal  $e^+e^- \rightarrow \nu, lepton, jet, jet$  em função da massa do neutrino N.

Os eventos foram gerados utilizando as características do acelerador estudado, como a luminosidade, energia de centro de massa e os cortes acima mencionados.

## 7.2 Classificação dos Eventos

A partir do método de aprendizagem de máquina, já discutido, será construído uma rede neural que fará a classificação dos eventos desejados. Treinando o algoritmo com apenas eventos do Modelo Padrão, espera-se que ele consiga



reconhecer corretamente boa parte destes eventos. Ao avaliar um evento diferente, como por exemplo, um evento contendo um neutrino pesado de Majorana, como é o foco do trabalho, o algoritmo deverá classificá-lo como diferente, designando um marcador àquele evento.

A seção de choque do MP para o canal  $e^+e^- \rightarrow \nu, lepton, W$  é de  $3814,4 fb$ . Utilizando a Equação 2.15 e o valor já conhecido da luminosidade integrada do acelerador de  $1000 fb^{-1}$ , podemos calcular o número de eventos esperados para o MP, que é 3814400 eventos.

De maneira similar podemos calcular o número de eventos esperados<sup>1</sup> para diferentes massas de Majorana para o modelo contendo Majorana para o canal  $e^+e^- \rightarrow \nu, lepton, W$ , como mostra a Tabela 7.1.

Massa (GeV)	Total	Sinal
100	4026200	211800
150	3894800	80400
200	3824500	10100
250	3857600	43200
300	3892600	78200
350	3884200	69800
400	3818800	4400
450	3867600	53200
500	3784000	-30400
550	3846400	32000
600	3848500	34100
650	3895100	80700
700	3829200	14800
750	3877300	62900
800	3807800	-6600
850	3866900	52500
900	3908100	93700
950	3862100	47700

Tabela 7.1: Número de eventos esperados em função da massa de Majorana do Canal  $e^+e^- \rightarrow \nu, lepton, W$

O Número de Eventos de Sinal é calculado como a diferença entre o número total de eventos e o número de eventos do MP.

---

<sup>1</sup>Os números negativos nos eventos de Sinal são resultados das flutuações estatísticas para massas maiores, e também devido ao canal A ser apenas uma primeira aproximação. Houve também uma limitação nos recursos computacionais quando foi feita a integração utilizando o método de Monte Carlo na Tabela 7.1.

Fazendo o mesmo para o canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a seção de choque do MP para o canal é de 2789,6 fb. Utilizando a Equação 2.15 e o valor já conhecido da luminosidade do acelerador de  $1000 fb^{-1}$ , podemos calcular o número de eventos esperados para o MP, que é 2789600 eventos.

De maneira similar podemos calcular o número de eventos esperados para diferentes massas de Majorana para o modelo contendo Majorana para o canal  $e^+e^- \rightarrow \nu, lep, jet, jet$ , como mostra a Tabela 7.2.

Massa (GeV)	Total	Sinal
100	2953100	163500
150	2965300	175700
200	2974400	184800
250	2973400	183800
300	2978700	189100
350	2966700	177100
400	2964500	174900
450	2960700	171100
500	2954300	164700
550	2941400	151800
600	2928400	138800
650	2919800	130200
700	2907900	118300
750	2886300	96700
800	2869300	79700
850	2852700	63100
900	2831000	41400
950	2811700	22100

Tabela 7.2: Número de eventos esperados em função da massa de Majorana do Canal  $e^+e^- \rightarrow \nu, lep, jet, jet$

O Número de Eventos de Sinal é calculado como a diferença entre o número total de eventos e o número de eventos do MP.

Posteriormente ao processo de classificação, será feito o histograma das massas dos eventos marcados como errados. Como discutido anteriormente, é calculado o erro quadrado médio da rede para cada evento afim de medir sua precisão. Como a rede neural foi treinada apenas com eventos do MP, espera-se que eventos contendo Majorana apresentem erros muito maiores. Portanto, eventos com erro muito acima da média serão considerados eventos contendo um Neutrino de Majorana.




Figura 7.3: Erro dos eventos do MP (a) e de Majorana (b) do Canal A ao passarem pela rede

Os eventos do MP tendem a ter um erro muito baixo, e portanto se concentram na parte inferior dos gráficos. Utilizando a média dos erros, é possível determinar uma tolerância (Threshold), onde qualquer evento acima da linha de tolerância é classificado como Majorana como mostra a Figura 7.4.




Figura 7.4: Erro dos eventos de Majorana do canal A com a linha de threshold

O resultado ideal seria que todos os eventos do MP ficassem abaixo da linha de threshold e os eventos contendo neutrino de Majorana ficassem acima dessa linha.

O processo será feito com vários tipos de redes neurais, com várias arquiteturas e tempos de treino diferentes, comparando cada um deles para se criar um software final o mais preciso possível.

# Capítulo 8

## Análise dos Eventos Utilizando Inteligência Artificial

Inicialmente foram feitas separações utilizando apenas o canal A,  $e^+e^- \rightarrow nu, lep, W$ . Este canal foi utilizado inicialmente para testar a eficiência da rede. Como neste canal não se calcula o decaimento do W seus cálculos são muito mais rápidos, e portanto foi o canal utilizado para se "calibrar" a rede e testar a viabilidade da ideia.

O canal B é o canal que realmente queremos calcular, e seus resultados serão apresentados após os resultados do canal A.

Como não é possível determinar quais eventos são ou não de fato de Majorana, os erros foram calculados à partir do erro de treino das redes neurais. Estes erros foram calculados a partir do erro quadrado médio, comparando os resultados da rede na etapa de treino com os eventos do Modelo Padrão como discutido na Equação 5.5.

### 8.1 Eventos do Canal A

Afim de separar os eventos contendo Majorana dos eventos do MP, foi criada uma rede neural que foi treinada apenas com os eventos do MP utilizando o canal (a) descrito nos Objetivos. A ideia principal é que ela reconheça apenas eventos do MP, classificando assim como Majorana quaisquer eventos com erro muito alto. Para isso foi criada uma rede neural sequencial utilizando o método autoencoder-decoder. Várias estruturas foram testadas, e até agora a que apresentou os melhores resultados foi a representada na Tabela 8.1 (Ainda utilizando o tensorflow).

Estrutura da Rede	
Nome	Camada
Entrada	17
Saída	12
Saída	8
Saída	12
Saída	17

Tabela 8.1: Estrutura da rede neural utilizada para o canal A

Os dados chamados de Entrada na Tabela 8.1 são as informações das partículas no estado final do Canal A sendo essas os seus quadri-momentos, os números de identificação das partículas e a reconstrução da massa invariante do lépton com o W. Não foram utilizados os 4-momentos do neutrino, pois ele não é detectado.






Figura 8.1: Eventos separados pela rede. Acima da linha horizontal estão os eventos classificados como do tipo Majorana.

Os eventos classificados como de Majorana foram agrupados acima da linha de threshold, que teve um valor de 0,956. Porém alguns eventos de background também foram separados como pode ser visto no gráfico da reconstrução de massa.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.2: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, W$  a partir do  $lep$  e  $W$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 100 GeV. b) após passar pela rede neural para separar eventos contendo Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.3: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, W$  a partir do  $lep$  e  $W$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 150 GeV. b) após passar pela rede neural para separar eventos contendo Majorana.




(a) Antes de passar pela rede



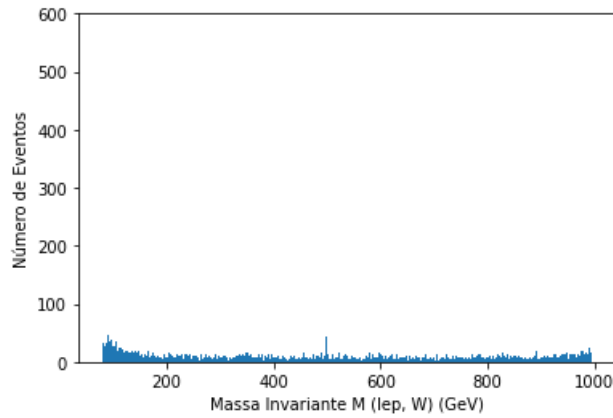
(b) Depois de passar pela rede

Figura 8.4: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, W$  a partir do  $lep$  e  $W$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 200 GeV. b) após passar pela rede neural para separar eventos contendo Majorana.





(a) Antes de passar pela rede



(b) Depois de passar pela rede

Figura 8.5: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, W$  a partir do  $lep$  e  $W$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 500 GeV. b) após passar pela rede neural para separar eventos contendo Majorana.

Analisando qualitativamente os resultados do Canal A chegou-se à conclusão que a separação por Inteligência Artificial é viável pois separou grande parte dos eventos de background, porém a abordagem utilizada até o momento se mostrou ineficiente para massas de Majorana acima de 500 GeV. Para massas maiores que 500 GeV os eventos de background tornaram impossível a identificação do pico que indica a concentração dos eventos de Majorana.

Após várias tentativas utilizando a biblioteca TensorFlow chegou-se à conclusão que a criação de uma biblioteca específica para este problema seria necessária para obter resultados com menos eventos de background.

## 8.2 Eventos do Canal B

Durante o desenvolvimento do código foi observado, que a rede neural montada utilizando a biblioteca TensorFlow estava apresentando muitos falsos positivos. Então foi desenvolvida uma biblioteca autoral batizada de AriaNN para tratar deste problema de classificação.




Figura 8.6: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  após passar pela rede AriaNN. b) Gráfico da separação do mesmo processo e energia feito pelo TensorFlow

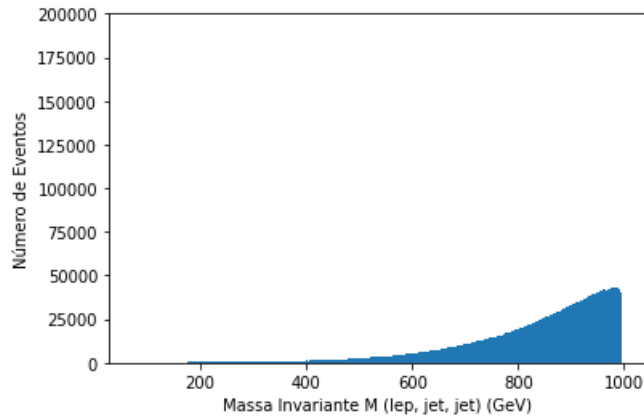
Como pode ser observado comparando os gráficos na Figura 8.6 tanto a biblioteca AriaNN quanto a biblioteca Tensorflow apresentaram contaminação nos resultados finais. Porém a Biblioteca AriaNN apresentou uma contaminação menor, embora o pico de ressonância também tenha diminuído. Além disso essa biblioteca apresentou um tempo de execução muito menor que o Tensorflow.

A arquitetura da rede utilizada no canal B é ilustrada na Tabela 8.2.

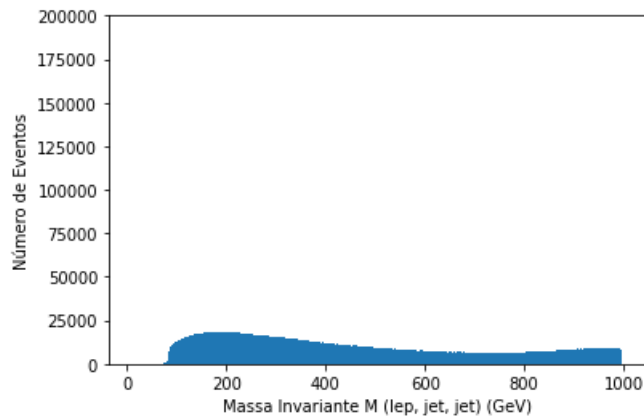
Estrutura da Rede	
Nome	Camada
Entrada	23
Saída	10
Saída	23

Tabela 8.2: Estrutura da rede neural utilizada para o canal B

Para a etapa de treino foram gerados separadamente eventos do MP apenas com múons e apenas com elétrons no estado final, e a mesma quantidade de eventos com as duas partículas foi misturada em um único arquivo final para treino. Como os eventos com múons são mais raros, treinar a rede sem este procedimento faria com que a rede pudesse identificar qualquer evento com muon como um falso positivo.



(a) Eventos do MP apenas com Múons

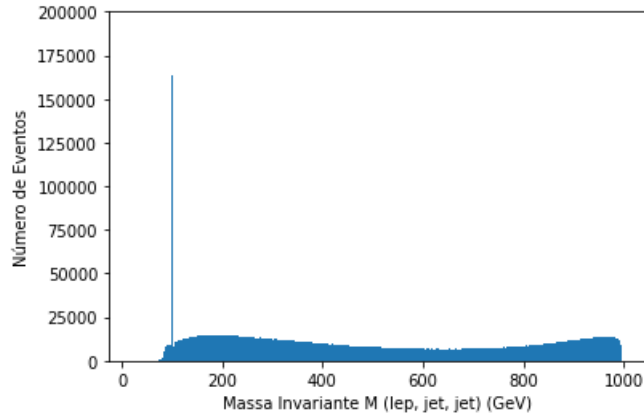


(b) Eventos do MP apenas com Elétrons


Figura 8.7: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  para o Modelo Padrão contendo apenas Múons. b) Gráfico anterior contendo apenas Elétrons.

Os eventos gerados com múons no estado final foram gerados separadamente dos eventos com elétrons no estado final com o objetivo de treinar a rede utilizando o mesmo número de eventos de ambos os casos. Isso é feito para que a rede não fique "viciada" em apenas um tipo de evento. O erro de treino

foi de 17,5% a contaminação foi de 680419 eventos classificados erroneamente. O threshold para este processo foi de 0,75.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.8: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 100 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.9: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 150 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.10: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 200 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.11: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 250 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.12: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 300 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.






(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.13: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, \text{lep}, \text{jet}, \text{jet}$  a partir do  $\text{lep}$  e dois  $\text{jets}$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 350 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.14: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 400 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.15: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 450 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.16: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 500 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.

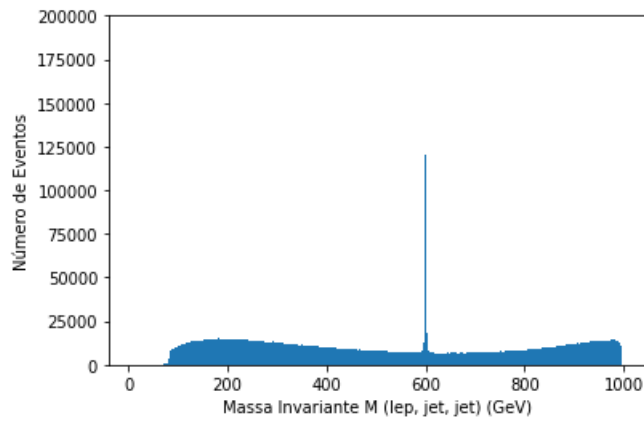


(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.17: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 550 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.18: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 600 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.19: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 650 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.20: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 700 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.






(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.21: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 750 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.22: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 800 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.23: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 850 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.




(a) Antes de passar pela rede




(b) Depois de passar pela rede

Figura 8.24: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, \text{lep}, \text{jet}, \text{jet}$  a partir do  $\text{lep}$  e dois  $\text{jets}$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 900 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.



(a) Antes de passar pela rede



(b) Depois de passar pela rede

Figura 8.25: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) antes de passar pela rede neural para massa de 950 GeV. b) Gráfico anterior após passar pela rede neural para separar eventos contendo Majorana de eventos que não contem Majorana.

Comparando os resultados dos canais A e B, pode-se verificar que para o canal B é possível observar o pico de ressonância associado ao neutrino de Majorana até uma massa de 950 GeV enquanto no canal A apenas até uma massa de 500 GeV, apesar de o canal B ter quatro partículas no estado final e o canal A ser mais simples contendo apenas três.

Massa (GeV)	Contaminação	Classificados como Majorana	Diferença	Sinal
100	680419	814388	133939± 23466	163500
150	680419	805268	124849± 21874	175700
200	680419	982137	301718± 52861	184800
250	680419	795909	115490± 20234	183800
300	680419	971577	237158± 41550	189100
350	680419	857992	177573± 31111	177100
400	680419	793053	112634± 19733	174900
450	680419	820915	142396± 24948	171100
500	680419	786078	105659± 18511	164700
550	680419	924255	243836± 42720	151800
600	680419	921539	241120± 42244	138800
650	680419	1038496	358077± 62735	130200
700	680419	990240	309821± 54281	118300
750	680419	892187	211768± 37102	96700
800	680419	999458	319039± 55896	79700
850	680419	785809	105390± 18464	63100
900	680419	840408	159989± 28030	41400
950	680419	928390	247971± 43445	22100

Tabela 8.3: Número de eventos esperados para cada massa de Majorana do Canal  $e^+e^- \rightarrow \nu, lep, jet, jet$

A contaminação é calculada passando os eventos do MP na rede treinada. Desta maneira, qualquer evento que seja classificado como Majorana é considerado contaminação, pois os eventos do MP não possuem neutrino de Majorana.

Analisando a Tabela 8.3 observa-se que a diferença entre o número de eventos classificados como Majorana e a Contaminação os resultados chegaram próximo dos resultados esperados para massas menores, porém a contaminação atual ainda é alta e prejudica a separação dos eventos. A grande flutuação no erro também prejudica a classificação. A precisão desta rede na etapa de treino foi de 82,48%, indicando um erro de 17,52%.

### 8.3 Eventos do Canal B treinando separadamente Múons e Elétrons

No intuito de melhorar os resultados anteriores, o canal B será separado em duas partes. Uma com elétrons e outra com múons nos estados finais, já que detectores conseguem fazer uma ótima separação entre múons e elétrons.

Durante a análise preliminar foi observado que nos eventos do canal B apenas com múons no estado final o pico da ressonância foi relativamente maior que nos eventos apenas com elétrons no estado final para a massa de 200 GeV como pode ser visto na Figura 8.26.

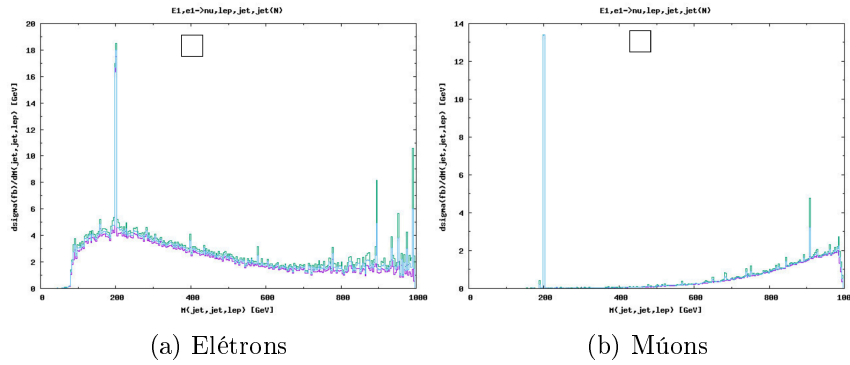


Figura 8.26: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  apenas com lep=elétrons para massa de 200 GeV. b) Gráfico da separação do mesmo processo apenas com lep=múons.

Calculando a seção de choque apenas para eventos do Modelo Padrão do canal B contendo elétrons no estado final obteve-se o resultado de 2353,5  $fb$ , e para eventos contendo Neutrinos de Majorana obteve-se o resultado de 2424,8  $fb$ . Tomando a diferença entre estes dois valores e multiplicando pela luminosidade integrada do colisor de 1000  $fb^{-1}$  obtemos o número esperados de eventos contendo Majorana, de 71300 para a massa de 200 GeV. Este número é aproximadamente 2,94% do número total de eventos apenas com elétrons.


Fazendo o mesmo para os eventos do canal B com múons obteve-se a seção de choque de 431,75  $fb$  para o Modelo Padrão e 534,57  $fb$  para o modelo contendo Majorana, o que indica um número de eventos esperados contendo Majorana de 102820. Este número é aproximadamente 19,23% do número total de eventos apenas com múons para a massa de 200 GeV.

Analisando estes resultados é possível concluir que mesmo contendo um número menor de eventos com múons, os eventos com múons possuem uma


relação sinal/background muito maior que os eventos contendo elétrons, fazendo com que os eventos contendo múons talvez sejam muito mais fáceis de separar pela rede.

Afim de reduzir a contaminação do resultado final foram treinadas duas novas redes, uma apenas com múons e outra apenas com elétrons. Como a relação sinal/background dos eventos com múons é bem melhor que dos eventos com elétrons, espera-se que a rede treinada apenas com múons seja capaz de separar melhor os eventos apenas com múons do que com a rede treinada com elétrons e múons. Devido à relação sinal/background, espera-se que a rede treinada apenas com elétrons para separar eventos com elétrons tenha desempenho pior que a rede treinada com elétrons e múons. Para estes casos, a rede criada com a biblioteca Tensorflow mostrou resultados melhores que a rede criada com a biblioteca AriaNN como pode ser visto de maneira qualitativa nas Figuras 8.27 até 8.29.






(a) Antes




(b) Depois

Figura 8.27: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 200 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com múons.




(a) Antes




(b) Depois

Figura 8.28: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 200 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.



(a) Muon



(b) Eletron

Figura 8.29: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 200 GeV após passar pela rede AriaNN treinada com múons contendo apenas eventos com múons. b) Gráfico anterior após passar pela rede AriaNN treinada apenas com elétrons contendo apenas elétrons.

Foi feita uma comparação entre as bibliotecas AriaNN e Tensorflow e chegou-se a conclusão que neste caso em que se separa os estudos de elétrons e múons no estado final a biblioteca Tensorflow apresentou uma melhor performance na separação de eventos contendo neutrino de Majorana, embora a biblioteca AriaNN ainda tenha apresentado menor tempo de execução.

### 8.3.1 Eventos apenas com Elétrons

A seção de choque do MP para o canal  $e^+e^- \rightarrow \nu, lepton, jetjet$  apenas com elétrons é de  $2354,3 fb$ . Utilizando a Equação 2.15 e o valor já conhecido da luminosidade integrada do acelerador de  $1000 fb^{-1}$ , podemos calcular o número de eventos esperados para o MP apenas com elétrons, que é 2354300 eventos.

De maneira similar podemos calcular o número de eventos esperados<sup>1</sup> para diferentes massas de Majorana para o modelo contendo Majorana para o canal  $e^+e^- \rightarrow \nu, lepton, jet, jet$  apenas com elétrons, como mostra a Tabela 8.4.

Massa (GeV)	Total	Sinal
100	2431000	76700
150	2394200	39900
200	2413800	59500
250	2485500	131200
300	2417400	63100
350	2398400	44100
400	2437500	83200
450	2416700	62400
500	2415900	61600
550	2398300	44000
600	2388800	34500
650	2420000	65700
700	2412100	57800
750	2387300	33000
800	2360700	6400
850	2387400	33100
900	2332100	-22200
950	2336100	-18200

Tabela 8.4: Número de eventos esperados em função da massa de Majorana do Canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  apenas com elétrons

As Figuras de 8.30 até 8.47 foram obtidas da mesma forma mencionada acima quando os estados finais do canal b) possuíam eventos com elétrons e múons misturados nos estados finais. Foi treinada uma rede autoencoder-decoder com a mesma arquitetura da Tabela 8.2, porém treinada apenas com elétrons no estado final. O threshold para este processo foi de 0,28.

<sup>1</sup>Os números negativos nos eventos de Sinal são resultados das flutuações estatísticas para massas maiores.

A contaminação da rede treinada apenas com elétrons foi de 401226. Este resultado reforça a hipótese de que a rede treinada apenas com elétrons é menos precisa devido à relação sinal/background dos eventos com elétrons ser bem menor que a dos eventos com múons, como discutido anteriormente.

Massa (GeV)	Contaminação	Classificados como Majorana	Diferença	Sinal
100	401226	517145	115919±24552	76700
150	401226	502462	101236±21442	39900
200	401226	489214	87988±18636	59500
250	401226	494495	93269±19754	131200
300	401226	478823	77597±16435	63100
350	401226	497896	96670±20475	44100
400	401226	484929	83703±17728	83200
450	401226	495900	94674±20052	62400
500	401226	501431	100205±21223	61600
550	401226	513573	112347±23795	44000
600	401226	523312	122086±25858	34500
650	401226	515533	114307±24210	65700
700	401226	507983	106757±22611	57800
750	401226	504948	103722±21968	33000
800	401226	503291	102065±21617	6400
850	401226	492079	90853±19243	33100
900	401226	491764	90538±19176	-22200
950	401226	481984	80758±17105	-18200

Tabela 8.5: Número de eventos esperados para cada massa de Majorana do Canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  após passar pela rede treinada apenas com Elétrons

Analisando a Tabela 8.5 é perceptível a diminuição na contaminação em relação à Tabela 8.3 referente à rede treinada com elétrons e múons. A rede treinada apenas com elétrons apresentou uma contaminação 41,04% mais baixa que a treinada com múons e elétrons, porém durante a separação vários eventos de Majorana foram classificados como MP, o que indica uma baixa precisão da rede. Na etapa de treino a rede obteve precisão de 78,82%, o que indica um erro absoluto de 21,18%. Este resultado reforça a hipótese de que a relação sinal/background dos eventos impacta diretamente na qualidade e precisão da rede treinada. Como pode ser visto qualitativamente o resultado se deteriora com o aumento da massa.

### 8.3.2 Eventos apenas com Múons

A seção de choque do MP para o canal  $e^+e^- \rightarrow \nu, lepton, jetjet$  apenas com múons é de 435,31 fb. Utilizando a Equação 2.15 e o valor já conhecido da luminosidade integrada do acelerador de  $1000 fb^{-1}$ , podemos calcular o número de eventos esperados para o MP apenas com múons, que é 435310 eventos.

De maneira similar podemos calcular o número de eventos esperados para diferentes massas de Majorana para o modelo contendo Majorana para o canal  $e^+e^- \rightarrow \nu, lepton, jet, jet$  apenas com múons, como mostra a Tabela 8.6.

Massa (GeV)	Total	Sinal
100	526590	91280
150	516600	81290
200	529630	94320
250	518600	83290
300	523770	88460
350	526840	91530
400	526430	91120
450	531140	95830
500	507160	71850
550	505160	69850
600	510560	75250
650	499270	63960
700	497350	62040
750	524990	89680
800	468290	32980
850	473970	38660
900	464540	29230
950	447070	11760

Tabela 8.6: Número de eventos esperados em função da massa de Majorana do Canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  apenas com múons


As Figuras de 8.48 até 8.65 foram obtidas da mesma forma mencionada acima quando os estados finais do canal b) possuíam eventos com elétrons e múons misturados nos estados finais. Foi treinada uma rede autoencoder-decoder com a mesma arquitetura da Tabela 8.2, porém treinada apenas com elétrons no estado final. O threshold deste processo foi de 0,42.

A contaminação da rede treinada apenas com múons foi de 72304. Este resultado reforça a hipótese de que a rede treinada apenas com múons é mais precisa devido à relação sinal/background dos eventos com múons ser bem maior que a dos eventos com elétrons, como discutido anteriormente.


Massa (GeV)	Contaminação	Majorana	Diferença	Sinal
100	72304	161958	89654± 7827	91280
150	72304	169523	97219± 8487	81290
200	72304	174913	102609± 8958	94320
250	72304	177411	105107± 9176	83290
300	72304	181190	108886± 9506	88460
350	72304	182448	110144± 9616	91530
400	72304	183634	111330± 9719	91120
450	72304	184003	111699± 9751	95830
500	72304	175333	103029± 8994	71850
550	72304	167734	95430± 8331	69850
600	72304	161481	89177± 7785	75250
650	72304	155489	83185± 7262	63960
700	72304	151246	78942± 6892	62040
750	72304	145084	72780± 6354	89680
800	72304	140406	68102± 5945	32980
850	72304	134034	61730± 5389	38660
900	72304	126498	54194± 4731	29230
950	72304	119932	47628± 4158	11760

Tabela 8.7: Número de eventos esperados para cada massa de Majorana do Canal  $e^+e^- \rightarrow nu, lep, jet, jet$  após passar pela rede treinada apenas com Múons

Analisando a Tabela 8.7 é possível observar que a contaminação é muito menor que na Tabela 8.3 referente à rede treinada com eventos contendo elétrons e múons e também menor que a Tabela 8.5 contendo apenas elétrons no estado final. A rede treinada apenas com eventos contendo múons obteve uma contaminação 89,38% menor do que a rede treinada com elétrons e múons sem apresentar perda de eventos de Majorana, mostrando boa separação de eventos como pode ser visto comparando com a Tabela 8.6. Aqui também pode ser visto que o resultado se deteriora com o aumento da massa do neutrino de Majorana.




(a) Antes




(b) Depois

Figura 8.30: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 100 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.






(a) Antes




(b) Depois

Figura 8.31: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 150 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.32: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 200 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.33: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 250 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.34: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 300 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.35: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 350 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.36: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 400 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.37: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 450 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.38: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 500 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.






(a) Antes




(b) Depois

Figura 8.39: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 550 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.40: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 600 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.41: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 650 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.42: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 700 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.43: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 750 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.44: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 800 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.45: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 850 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.46: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 900 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.






(a) Antes




(b) Depois

Figura 8.47: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 950 GeV, contendo apenas eventos com elétrons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.48: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 100 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.49: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 150 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.50: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 200 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.51: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 250 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.52: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 300 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.53: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 350 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.54: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 400 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.






(a) Antes




(b) Depois

Figura 8.55: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 450 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.56: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 500 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.57: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 550 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes

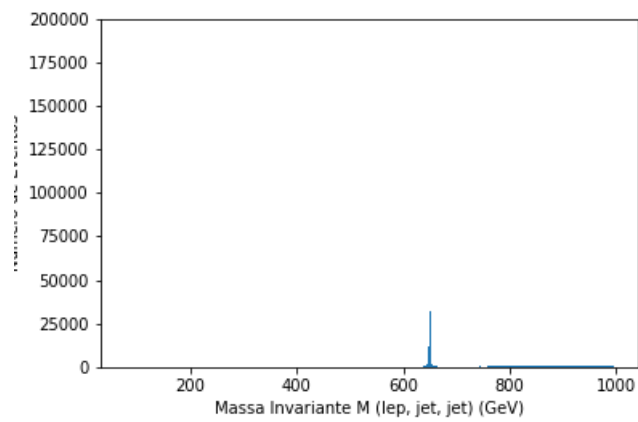


(b) Depois

Figura 8.58: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 600 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.59: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 650 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.60: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 700 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.61: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 750 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.62: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 800 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.






(a) Antes




(b) Depois

Figura 8.63: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 850 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.




(a) Antes




(b) Depois

Figura 8.64: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 900 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.



(a) Antes



(b) Depois

Figura 8.65: a) Gráfico da reconstrução da massa invariante do canal  $e^+e^- \rightarrow \nu, lep, jet, jet$  a partir do  $lep$  e dois  $jets$  (Partículas em que o neutrino de Majorana  $N$  decaiu) para massa de 950 GeV, contendo apenas eventos com múons. b) Gráfico anterior após passar uma rede criada utilizando a biblioteca Tensorflow treinada apenas com elétrons.

# Capítulo 9

## Conclusões

A detecção de um neutrino pesado do tipo Majorana seria um enorme passo para o descobrimento de uma nova física e para o esclarecimento de grandes perguntas ainda em aberto. A determinação do limite superior para a massa do neutrino do elétron e da existência da oscilação de neutrinos[18] é um grande incentivo não só para este trabalho, mas para todos os cientistas e pesquisadores da área de partículas e campos.

Com este trabalho de mestrado espera-se que possa reduzir o trabalho manual dos pesquisadores nos aceleradores de partículas, separando "automaticamente" os eventos raros dos eventos comuns nas colisões realizadas.

Não é possível atingir uma precisão ideal de 100% devido à Natureza estatística do processo. Na rede treinada com elétrons e múons foi obtida uma precisão de 82,48%. Na rede treinada apenas com elétrons foi obtida uma precisão de 78,82%. Porém na rede treinada apenas com eventos contendo múons foi atingida uma precisão de 91,27% na etapa de treino, o que significa que 8,73% dos eventos do MP estejam sendo classificados erroneamente como Majorana, tornando esta ferramenta um bom filtro inicial para remover eventos indesejados em eventos com apenas múons.




Figura 9.1: a) Gráfico da comparação do número teórico de eventos de sinal com o número da diferença entre Eventos Classificados como Majorana e a Contaminação para o canal  $e^+e^- \rightarrow nu, lep, jet, jet$  apenas com elétrons. b) Gráfico da comparação do número teórico de eventos de sinal com o número da diferença entre Eventos Classificados como Majorana e a Contaminação para o canal  $e^+e^- \rightarrow nu, lep, jet, jet$  apenas com múons.

Devido à baixa ocorrência de eventos de Majorana nos eventos contendo elétrons a rede neural não se mostrou eficiente na separação destes eventos. Futuramente pode ser desenvolvida uma nova técnica ou ferramenta para tratar deste problema.

A Figura 9.1 representa um resumo dos resultados obtidos que estão representados pelas duas colunas à direita nas Tabelas 8.5 e 8.7. Em um caso ideal o número de eventos de sinal (círculo) deveria coincidir com o número de eventos selecionados pela rede (quadrado).

A partir da análise dos resultados é possível concluir que a rede neural não se mostrou eficiente para classificação de eventos com baixa relação sinal/background, como no caso de eventos com elétrons. Para eventos com uma relação sinal/background mais significativa, como no caso dos múons, a rede foi capaz de excluir grande parte dos eventos de background sem excluir eventos de Majorana, como pode ser visto na Figura 9.1.

A ideia básica dessa dissertação foi mostrar que podemos identificar eventos raros além do MP de uma maneira mais simples utilizando Inteligência Artificial.

- Não é necessário fazermos cortes tradicionais chamados de "retangulares" que mudam cada vez que se muda os parâmetros (massas, acoplamentos, etc) da extensão do MP.
- Não é necessário treinar diferentes redes neurais para diferentes valores

de parâmetros.

- Basta treinar uma única rede neural para um determinado canal do MP fixando a identificação das partículas no estado final. Esta rede pode ser utilizada para qualquer extensão do MP desde que as partículas no estado final sejam idênticas as da rede treinada com o MP.
- Basta um único corte, "threshold", feito automaticamente pelo software, que é obtido pela "distância" entre os eventos originais e os eventos reconstruídos pela rede.

Os resultados obtidos com este trabalho podem ser muito melhorados pois aqui foi utilizada a chamada "distância D" Euclidiana entre o evento original e o reconstruído pela rede. Quando a distância é pequena classifica-se o evento como do MP e quando a distância é grande classificamos como um evento além do MP.

$$D(x, y) = \sum_{i=1}^n (x_i - y_i)^2, \quad (9.1)$$

onde  $x_i$  e  $y_i$  são os dados de entrada e saída da rede treinada, respectivamente, e  $n$  é o número de entrada e saída da rede. O número de entradas e saídas de uma rede encoder-decoder é igual.

Na realidade existem mais de dez definições de distância entre eventos que podem ser utilizadas e acredita-se que os resultados aqui apresentados podem ser muito melhorados. Cada uma destas distâncias tem suas vantagens e desvantagens e precisam ser analisadas e testadas para cada caso.

Uma simulação mais próxima da realidade seria hadronizar os jets utilizando o pacote de *software* Pythia mas isso traz outros problemas. A multiplicidade é diferente para cada evento e a energia e momento linear não são totalmente conservados, o que traz novos desafios.

# Appendices

# Apêndice A

Durante o desenvolvimento deste trabalho percebeu-se que a biblioteca TensorFlow não era a melhor opção para montar a rede neural para selecionar os eventos, devido à quantidade grande de eventos de background no resultado final. O código neste apêndice foi o código desenvolvido inteiramente pela mestranda afim de aplicá-lo neste trabalho.

## A.1 Biblioteca Base

Este código é a biblioteca base que serve como um "esqueleto" para se montar a rede neural da maneira desejada. Os códigos apresentados neste apêndice não formam a biblioteca completa.

```

                                                                    AriaNN
"""
Aria Santos Diniz
"""

import numpy as np

class AriaNN:

    def __init__(self):
        self.wgt = np.random.random()

    #Activation Functions

    def relu(self, x):
        self.grad = lambda a: (1./(1 + np.exp(a)))*np.
            exp(a)
        return np.log(1 + np.exp(x))
```



```

def sigmoid(self, x):
    self.grad = lambda a: a*(1 - a)
    return (lambda z: 1./(1+np.exp(-z)))(x)

def tanh(self, x):
    self.grad = lambda a: (np.cosh(a)*np.cosh(a)-np
        .sinh(a)*np.sinh(a))/(np.cosh(a)*np.cosh(a))
    return np.tanh(x)

#Error functions

def mse(self, label, output_data):
    return np.power(np.mean(output_data - label,
        axis=1), 2)

def linear(self, label, output_data):
    return np.mean(output_data - label, axis=1)

#Model

def neuron(self, activation, dataset, wgt):
    return np.array(activation(dataset @ wgt))

def train(self, data, label, arch, error, nsess=1):
    self.data = np.array(data)
    self.label = np.array(label)
    self.arch = arch
    self.layers = len(self.arch)

    if (self.arch[-1].neurons != self.label.shape
        [1]):
        raise Exception("Dimensao_de_saida_
            diferente_dos_labels")

    con = 1
    for a in self.arch:
        if a.input_layer == False:
            a.label(self.label, self.data, error,
                con)
            con = a.neurons

```

```

        else:
            a.label(self.label, self.data, error)
            con = a.neurons

    for i in range(nsess):
        for a in self.arch:
            if a.input_layer:
                out = a.layer(self.neuron, self.data)
            else:
                a.input = out.reshape((out.shape
                    [1], out.shape[0], out.shape[2],
                    out.shape[3]))
                out = a.layer(self.neuron, self.data)
            print('Session: _{}/{}'.format(i, nsess))

    self.out = np.mean(np.mean(self.arch[-1].out,
        axis=0), axis=0)
    self.global_wgt = self.arch[-1].global_wgt
    self.global_err = np.mean([a.global_error for a
        in self.arch])
    self.actv = self.arch[-1].activation

    print('Erro_de_treino: _{}'.format(self.global_err))

def predict(self, data):
    data = np.array(data)
    prediction = self.actv(data @ self.global_wgt)
    return prediction

class AriaLayer:

    def __init__(self, num_neurons, activation,
        input_layer=False):
        self.neurons = num_neurons
        self.activation = activation
        self.input_layer = input_layer
        self.grad = lambda a: a*(1 - a)

```

```

def label(self, label, data, error, con=1):
    self.input = label
    self.err = error
    self.data_shape = data.shape
    self.con = con
    self.wgt = np.random.random((self.con, self.
        neurons, data.shape[1], self.input.shape[1])
        )
    self.out = np.zeros((self.con, self.neurons,
        self.input.shape[0], self.input.shape[1]))
    self.error = np.zeros((self.con, self.neurons,
        self.input.shape[0], self.input.shape[1]))

def layer(self, neuron, inp):
    self.neuron = neuron

    if self.input_layer:
        for i in range(self.con):
            temp_wgt = self.wgt[i]
            self.out[i] = np.array([self.neuron(
                self.activation, inp, temp_wgt[a])
                for a in range(self.neurons)])
            self.out = np.reshape(self.out, (self.con,
                np.array(self.out).shape[1], self.
                data_shape[0], -1))
            for i in range(self.con):
                temp_out = self.out[i]
                self.error[i] = np.reshape(np.array([
                    self.err(self.input, temp_out[a])
                    for a in range(self.out.shape[1])]),
                    (-1, self.input.shape[0], self.
                    input.shape[1]))

            for i in range(self.con):
                temp_out = self.out[i]
                temp_error = self.error[i]
                self.wgt[i] -= np.array([np.dot(inp.T,
                    (np.array(temp_error[a]).T * self.
                    grad(temp_out[a]).T).T) for a in
                    range(self.neurons)])

```

```

        self.global_error, self.global_wgt = np.
            mean(self.error), np.mean(np.mean(self.
                wgt, axis=0), axis=0)
    return self.out

else:
    for i in range(self.con):
        temp_wgt = self.wgt[i]
        self.out[i] = np.array([self.neuron(
            self.activation, inp, temp_wgt[a])
            for a in range(self.neurons)])
    self.out = np.reshape(self.out, (self.con,
        np.array(self.out).shape[1], self.
        data_shape[0], -1))
    for i in range(self.con):
        temp_out = self.out[i]
        temp_input = self.input[i]
        self.error = np.reshape(np.array([self.
            err(temp_input, temp_out[a]) for a
            in range(self.out.shape[1])]), (-1,
            self.input.shape[0], self.input.
            shape[1]))
    for i in range(self.con):
        temp_out = self.out[i]
        temp_error = self.error[i]
        self.wgt[i] -= np.array([np.dot(inp.T,
            (np.array(temp_error[a]).T * self.
            grad(temp_out[a]).T).T) for a in
            range(self.neurons)])

    self.global_error = np.mean(self.error)
    return self.out

```

## A.2 Rede Neural

Código da rede neural utilizada ao longo do trabalho, criado com a biblioteca AriaNN.

"""

*Aria Santos Diniz*

```

"""

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.preprocessing import StandardScaler
from aria_v4 import AriaNN, AriaLayer

scaler = StandardScaler()
data = pd.read_csv('dataset.csv')
data = data.sample(frac=1).reset_index(drop=True)
data = data.head(3000)
data = scaler.fit_transform(data)
pred = scaler.transform(pd.read_csv('data.csv'))

model = AriaNN()

arch = [AriaLayer(data.shape[1], model.sigmoid,
                 input_layer=True),
        AriaLayer(data.shape[1], model.sigmoid)]

model.train(data, data, arch, model.linear, nsess=50)

res = model.predict(pred)

mse = np.mean(np.power(pred - res, 2), axis=1)
threshold = np.mean(mse)
nmse = pd.DataFrame(mse)

plt.plot(nmse.index, mse, marker='o', linestyle='',
         markersize=1, label='Events')
#plt.hlines(threshold, -1, pred.shape[0] + 200, colors
           ='r', zorder=100, label='Threshold')
plt.legend()
plt.show()

with open('results.dat', 'w') as o:
    [o.write(str(x) + '\n') for x in map(lambda z: 0 if
                                         z > threshold else 1, mse)]

```

# Referências Bibliográficas

- [1] Kamiokande Collaboration et al. Determination of solar neutrino oscillation parameters using 1496 days of super-kamiokande-i data. *arXiv preprint hep-ex/0205075*, 2002.
- [2] Anupama Atre, Tao Han, Silvia Pascoli, and Bin Zhang. The search for heavy majorana neutrinos. *Journal of High Energy Physics*, 2009(05):030, 2009.
- [3] Simon Bray, Jae Sik Lee, and Apostolos Pilaftsis. Heavy majorana neutrino production at  $e^- \gamma$  colliders. *Physics Letters B*, 628(3-4):250–261, 2005.
- [4] T Barklow, J Brau, K Fujii, J Gao, J List, N Walker, and K Yokoya. Ilc operating scenarios. *arXiv preprint arXiv:1506.07830*, 2015.
- [5] G. Weiglein et al. Physics interplay of the lhc and ilc. *Phys. Rept.* 426, pages 47–358, 2006.
- [6] F. M. L. Almeida, Y. A. Coutinho, J. A. Martins Simões, and M. A. B. do Vale. Neutral heavy lepton production at next high energy  $e^+e^-$  linear colliders. *Phys. Rev. D*, 63:075005, Mar 2001.
- [7] Dan Guest, Kyle Cranmer, and Daniel Whiteson. Deep learning and its application to lhc physics. *Annual Review of Nuclear and Particle Science*, 68:161–181, 2018.
- [8] Aurélien Géron. *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*. "O'Reilly Media, Inc.", 2017.
- [9] David Griffiths. *Introduction to elementary particles*. John Wiley & Sons, 2008.
- [10] João Barcelos Neto. *Matemática para físicos com aplicações: Vetores, tensores e spinores*. Livraria da Física, 2010.

- [11] James Rich. *Fundamentals of cosmology*. Springer Science & Business Media, 2009.
- [12] Werner Herr and Bruno Muratori. *Concept of luminosity*. 2006.
- [13] Hsi-Yu Schive, Ming-Hsuan Liao, Tak-Pong Woo, Shing-Kwong Wong, Tzihong Chiueh, Tom Broadhurst, and WY Pauchy Hwang. Understanding the core-halo relation of quantum wave dark matter from 3d simulations. *Physical review letters*, 113(26):261302, 2014.
- [14] JJ Sakurai. *Modern quantum mechanics 2nd edition. Person New International edition*, 2014.
- [15] H Arason, DJ Castano, B Kesthelyi, S Mikaelian, EJ Piard, Pierre Ramond, and BD Wright. Renormalization-group study of the standard model and its extensions: the standard model. *Physical Review D*, 46(9):3945, 1992.
- [16] Daniel Parrochia. Majorana equation and its consequences in physics and philosophy. *arXiv preprint arXiv:1907.11169*, 2019.
- [17] Anupama Atre, Tao Han, Silvia Pascoli, and Bin Zhang. The search for heavy majorana neutrinos. *Journal of High Energy Physics*, 2009(05):030, 2009.
- [18] Arthur Loureiro, Andrei Cuceu, Filipe B Abdalla, Bruno Moraes, Lorne Whiteway, Michael McLeod, Sreekumar T Balan, Ofer Lahav, Aurélien Benoit-Lévy, Marc Manera, et al. Upper bound of neutrino masses from combined cosmological observations and particle physics experiments. *Physical Review Letters*, 123(8):081301, 2019.
- [19] E Kh Akhmedov, GC Branco, and MN Rebelo. Seesaw mechanism and structure of neutrino mass matrix. *Physics Letters B*, 478(1-3):215–223, 2000.
- [20] Robert D. Klauber. Quantum field theory. <http://www.quantumfieldtheory.info/TheSeesawMechanism.htm>.
- [21] Tong Li Yi Cai, Tao Han and Richard Ruiz. frontiers in physics. <https://www.frontiersin.org/articles/10.3389/fphy.2018.00040/full>.
- [22] F Del Aguila, J De Blas, and M Perez-Victoria. Effects of new leptons in electroweak precision data. *Physical Review D*, 78(1):013010, 2008.

- [23] I Wilson. The compact linear collider clic. *Physics Reports*, 403:365–378, 2004.
- [24] Aleksander Filip Zarnecki. News on the clic physics potential. *arXiv preprint arXiv:1908.04671*, 2019.
- [25] Alexander Belyaev, Neil D. Christensen, and Alexander Pukhov. CalcHEP 3.4 for collider physics within and beyond the Standard Model. *Comput. Phys. Commun.*, 184:1729–1769, 2013.
- [26] <http://hepmdb.soton.ac.uk/>.
- [27] Johan Alwall, Alessandro Ballestrero, P Bartalini, Sergey Belov, E Boos, Andy Buckley, Jonathan M Butterworth, L Dudko, Stefano Frixione, L Garren, et al. A standard format for les houches event files. *Computer Physics Communications*, 176(4):300–304, 2007.
- [28] Sotiris B Kotsiantis, I Zaharakis, and P Pintelas. Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160:3–24, 2007.
- [29] João Marcelo Lamim Ribeiro, Pablo Bravo, Yihang Wang, and Pratyush Tiwary. Reweighted autoencoded variational bayes for enhanced sampling (rave). *The Journal of chemical physics*, 149(7):072301, 2018.
- [30] Teste de hipótese. <https://www.inf.ufsc.br/~andre.zibetti/probabilidade/teste-de-hipoteses.html>.