

# Uso de Aprendizagem de Máquina para Detecção Online de Fótons de Altas Energias

J. L. Marin<sup>1</sup>, E. F. de Simas Filho<sup>2</sup>, B. S.M. Peralva<sup>3</sup>  
E. E. P. de Souza<sup>4</sup>, J. M. de Seixas<sup>5</sup>

<sup>1</sup> *Coordenação de Eletrônica, IFBA campus Vitória da Conquista*

<sup>2</sup> *Laboratório de Sistemas Digitais, PPGEE/UFBA*

<sup>3</sup> *Instituto Politécnico (PPGMC/UERJ)*

<sup>4</sup> *LPNHE, CNRS, Sorbonne Université*

<sup>5</sup> *Laboratório de Processamento de Sinais, COPPE/POLI, UFRJ*

juan.marin@ifba.edu.br<sup>1</sup>, eduardo.simas@ufba.br<sup>2</sup>, bernardo.peralva@uerj.br<sup>3</sup>  
edmar.egidio@cern.ch<sup>4</sup>, seixas@lps.ufrj.br<sup>5</sup>

**Resumo**—A correta identificação de partículas é um dos principais objetivos de experimentos de física de altas energias. Devido a alta taxa de eventos no Grande Colisor de Hádrons (LHC), o experimento ATLAS tem empregado técnicas baseadas em aprendizado de máquina a fim de encontrar eventos raros em grandes massas de dados. Entre eles está o NeuralRinger, um conjunto classificador de rede neural projetado para detecção rápida de elétrons com base em anéis concêntricos de calorímetro (sistema de medição de energia). Nesse contexto, o presente trabalho propõe a avaliação desta técnica, incluindo o uso de rede neurais profundas, para a detecção rápida de fótons. Os resultados com dados simulados mostram a eficiência do método proposto no ambiente do experimento ATLAS.

**Palavras-chave**—Redes Neurais, NeuralRinger, Física de Altas Energias, Identificação de partículas

## I. INTRODUÇÃO

Por se assemelhar ao modo como seres vivos reconhecem padrões, a engenharia tem usado sistemas inteligentes de decisão e classificação na solução de diversos problemas do cotidiano. Em ambientes de alto volume de dados, principalmente em instrumentação científica, classificadores neurais têm sido amplamente utilizados principalmente na busca de eventos raros [1]–[4]. Regressores neurais também são utilizados para estimar incertezas sistemáticas na identificação de partículas em experimentos de física de altas energias [5], [6]. Em ambientes com alto volume de dados, é desejado que os classificadores produzam alta eficiência e baixa aceitação de dados que não produzam informação relevante, além do requisito de operação em uma janela pequena de tempo, em geral, de maneira síncrona com a produção de eventos.

Ao longo dos anos, as redes neurais têm ocupado espaço em experimentos de física de altas energias [7]. A busca por partículas exóticas, não descritas no Modelo Padrão de Física de Partículas, também conta com o uso desse tipo de classificador [8]. O experimento ATLAS (do inglês, *A Toroidal LHC Apparatus*), é um dos maiores experimentos de física de altas energias em operação no mundo, localizado em Genebra, na Suíça. Na linha de feixe do acelerador LHC (do inglês, *Large Hadron Collider*), o ATLAS recebe uma alta taxa de eventos, em função da taxa de colisões próton-próton do LHC [9]. O

intuito do acelerador LHC e do experimento é explorar as fronteiras do conhecimento científico no tocante à composição do universo, levando à novas descobertas que possam integrar o Modelo Padrão, teoria mais aceita da descrição das partículas elementares que compõem a matéria [10]. As colisões no LHC ocorrem a cada 25 ns produzindo, aproximadamente, 70 TB/s de informação [9]. Por essa razão, o ATLAS necessita de um sistema de seleção *online* de eventos que possua a restrição temporal de operar de maneira síncrona com as colisões do LHC. O programa de pesquisa do ATLAS busca por uma série de partículas raras, previstas ou não, no Modelo Padrão. Essas partículas possuem um tempo de vida curto, muitas vezes decaindo em outras partículas tais como: elétrons, fótons e múons num intervalo menor que alguns nanossegundos. Em particular, a primeira observação do bóson de Higgs<sup>1</sup> foi feita através do decaimento deste em um par de fótons [11]. Essa descoberta rendeu a Peter Higgs e François Englert o prêmio Nobel em Física no ano de 2013. Nesse sentido, a correta classificação de fótons pelo experimento ATLAS é de suma importância para a compreensão da composição do universo. Recentemente, um novo decaimento deste mesmo bóson foi observado, sendo uma das partículas resultantes um fóton [12]. Usualmente, o ruído de fundo associado aos fótons é composto por jatos hadrônicos que podem falsear a assinatura de fótons.

Na atual tomada de dados do experimento ATLAS, denominada de *Run3*, espera-se que haja um aumento gradual da energia, bem como da quantidade de interações por cruzamento de feixe a cada colisão produzida pelo LHC, aumentando ainda mais a quantidade de dados produzidos por evento. Esse efeito, denominado de empilhamento de sinais (ou *pileup*), é um dos principais fenômenos que degradam o desempenho dos algoritmos de identificação de partículas, surgindo a necessidade de torná-los cada vez mais robustos a esse fenômeno.

O algoritmo NeuralRinger [13], que opera desde o ano de 2017 na seleção de elétrons no *trigger* do ATLAS, faz uso de

<sup>1</sup>O bóson de Higgs é uma partícula teorizada em 1960 por Peter Higgs e François Englert, sendo esta responsável por conferir massa às partículas elementares, através da manifestação do seu respectivo campo.

variáveis que tentam capturar as características das partículas quando essas interagem com o calorímetro. Essas assinaturas são usadas como entrada de um classificador neural, visando a identificação de elétrons. Uma vez que os perfis de deposição de energia em sistemas de calorimetria são similares entre elétrons e fótons, a adaptação da técnica NeuralRinger para a identificação de fótons torna-se uma possibilidade para sistemas de seleção de eventos.

Nesse contexto, o objetivo desse trabalho é adaptar a técnica NeuralRinger para a seleção rápida de fótons, fazendo uso do mesmo procedimento adotado para o cenário de elétrons. O texto está organizado da seguinte forma: a Seção II descreve o experimento ATLAS, o seu sistema de seleção de eventos e o algoritmo NeuralRinger. Já a Seção III descreve a metodologia utilizada. A Seção IV discute os resultados e impactos do uso do NeuralRinger nas cadeias de fótons. As discussões são sumarizadas na Seção V.

## II. O EXPERIMENTO ATLAS

Figurando como maior experimento do LHC, o ATLAS [14] foi um dos responsáveis, em 2012, pela descoberta do bóson de Higgs [11], enaltecendo seu papel nas principais descobertas científicas atuais. É composto por diversos subsistemas, ilustrados na Fig. 1, apoiando-se fortemente em medidas do calorímetro (subsistema de medição da energia das partículas) [15]. Nessa figura, pode-se observar o calorímetro eletromagnético, em amarelo, que é responsável por medir principalmente energia de partículas eletromagnéticas como elétrons e fótons. É dividido em três camadas e possui aproximadamente 200 mil canais de leitura. Já o calorímetro hadrônico, em cinza, é responsável por prover medidas que auxiliam na caracterização de partículas hadrônicas, como prótons e píons, possuindo também três camadas e aproximadamente 10 mil canais de leitura. O ATLAS adota um sistema de coordenadas cilíndrica, sendo as variáveis  $\eta$  e  $\phi$  as principais <sup>2</sup>.

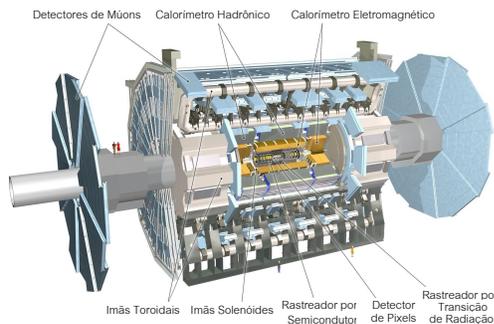


Figura 1: Experimento ATLAS e seus diversos subsistemas (adaptado de [14]).

<sup>2</sup>O ATLAS usa um sistema de coordenadas baseado na mão direita, com sua origem no ponto de interação (PI) no centro do detector e o eixo z ao longo do feixe de prótons. O eixo x é direcionado a partir do PI até o centro do anel do LHC e o eixo y é perpendicular a este plano. As coordenadas cilíndricas ( $r$ ,  $\phi$ ) são usadas no plano transversal, com  $\phi$  sendo o ângulo azimutal em torno do eixo z. A pseudo rapidez é definida em termos do ângulo polar  $\theta$  como  $\eta \equiv -\ln[\tan(\theta/2)]$ .

O ATLAS, através de seu sistema de seleção de eventos *on-line* (*trigger*), utiliza algoritmos para garantir que as partículas associadas a seu programa de pesquisa sejam corretamente identificadas [16].

### A. Seleção de Eventos no experimento ATLAS

O método atual de seleção de fótons do experimento ATLAS opera aplicando cortes lineares em variáveis discriminantes, calculadas em diversas seções dos calorímetros eletromagnético e hadrônico [17]. Os eventos de interesse do experimento ATLAS (*trigger*) passam por um sistema de seleção que é dividido em dois níveis [18]. O primeiro, L1, é implementado em *hardware* dedicado e é responsável por coletar os sinais gerados pelos canais de leituras dos calorímetros e prover medidas de energia das partículas incidentes. O segundo, HLT (do inglês, *High Level Trigger*), é implementado em software distribuído e usa as informações fornecidas pelo L1 para identificar as partículas de interesse [17], [18]. A Fig. 2 ilustra o HLT para as cadeias responsáveis por identificação de fótons.

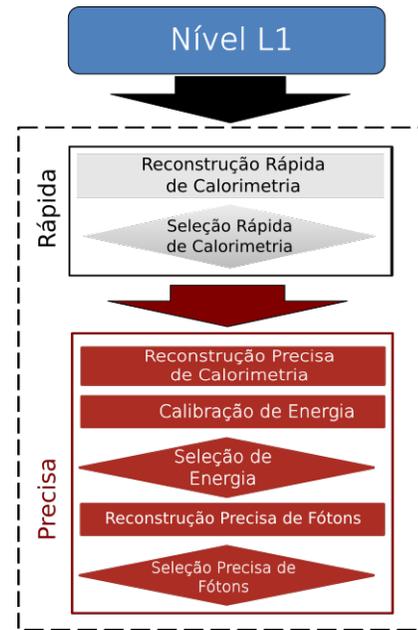


Figura 2: Sistema de seleção de eventos em cadeias de fótons no experimento ATLAS (adaptada de [17]).

O L1 entrega informações de energia e posição da partícula incidente para a etapa Rápida do HLT. Esta, por sua vez, faz uma avaliação rápida das variáveis de calorimetria e decide se aquela partícula é um candidato a fóton. Caso a etapa rápida decida por rejeitar um determinado candidato, toda a informação relacionada a esse evento é descartada, reduzindo o custo computacional atribuído para a etapa Precisa. Essa última, por sua vez, opera com etapas de calibração, reconstrução e seleção de partículas que serão posteriormente analisadas de maneira *offline*, caso o candidato a fóton seja aprovado também por essa etapa [17].

As variáveis utilizadas pelo atual sistema de seleção de fótons são baseadas em medidas de energia como: razão de energia hadrônica, espalhamento lateral da energia depositada pela partícula, dentre outros. Conforme a taxa de colisões próton-próton, ou o número médio de interações por cruzamento de feixes, aumenta, maior a probabilidade da ocorrência de empilhamento de sinais lidos eletronicamente no calorímetro. Quando isso ocorre, os métodos de estimação de energia operam de forma sub-ótima, comprometendo as medidas de calorimetria utilizadas pela etapa Rápida e Precisa. Como consequência direta desse fenômeno, o desempenho dos algoritmos presentes nestas etapas é também degradado [17]. Dessa forma, busca-se constantemente que os algoritmos do sistema de *trigger* do experimento ATLAS tornem-se resilientes ao empilhamento de sinais.

O sistema de seleção de fótons opera com três critérios: o mais rigoroso, *tight*, o menos rigoroso, *loose* e um nível intermediário denominado de *medium*. O critério *tight*, quando aprova um candidato a fóton, indica que aquela partícula possui uma alta probabilidade de ser um fóton. Já quando um candidato é rejeitado pelo critério *loose*, o sistema de *trigger* indica que aquela partícula tem uma probabilidade elevada de não ser um fóton. Entretanto, há o cenário em que uma partícula é rejeitada pelo critério *tight* e aprovada pelo *loose*. Essa situação é usada quando se deseja acumular muitos eventos em estados finais, para aumentar a quantidade de dados a serem analisados, sacrificando um pouco a pureza do conjunto de eventos coletados.

### B. Algoritmo NeuralRinger

O algoritmo NeuralRinger foi originalmente proposto em [13], como uma alternativa aos métodos usuais de identificação de elétrons em sistemas de calorimetria. O algoritmo, como mostrado na Fig. 3, monta anéis concêntricos utilizando como centro a célula que possui maior energia (em vermelho).

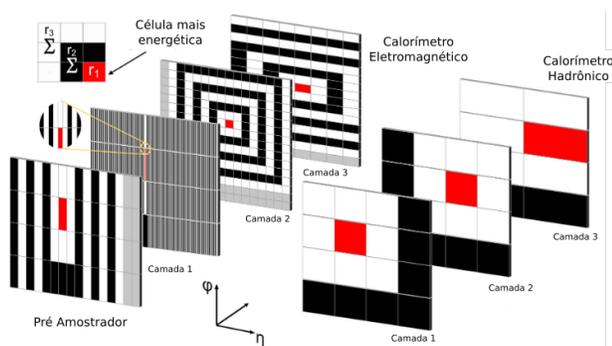


Figura 3: Construção dos anéis em cada camada do sistema de calorimetria (extraído de [17]).

O algoritmo então monta os anéis no PS (do inglês, *Pre-Sampler*), nas três camadas do calorímetro eletromagnético (E1-E3) e para as nas três camadas do calorímetro hadrônico (H1-H3). A quantidade de anéis montados em cada camada é detalhada na Tabela I.

Tabela I: Quantidade de anéis por camada do sistema de calorimetria do experimento ATLAS.

Camadas	PS	EM1	EM2	EM3	H1	H2	H3
Anéis	8	64	8	8	4	4	4

Em seguida, as células pertencentes a cada anel são somadas, gerando um total de 100 medidas de energia que capturam, indiretamente, informação de lateralidade e profundidade do espalhamento de energia depositada pela partícula durante a interação da mesma com a matéria. Essas medidas são então concatenadas em um vetor que alimenta um classificador binário.

A partir de 2017, o algoritmo NeuralRinger tornou-se a técnica padrão de identificação na etapa Rápida nas cadeias de elétrons no experimento ATLAS, operando com um classificador neural MLP [19]. A estrutura da rede neural utilizada para este cenário consiste em apenas uma camada escondida e um neurônio na camada de saída, a fim de realizar a discriminação elétron/jato.

O experimento ATLAS hoje opera com um conjunto de redes neurais, para diversas faixas de energia,  $E_T$ , e posição,  $\eta$ , do sistema de calorimetria [20], [21]. O sucesso do NeuralRinger aplicado ao problema de classificação de elétrons é uma combinação do alto poder discriminante da estrutura em anéis aliado a eficiência do uso de redes neurais MLP em problemas de classificação binária. Devido ao fato de elétrons e fótons possuírem comportamento similares do ponto de vista de calorimetria [15], esse trabalho propõe a adaptação do algoritmo NeuralRinger para a identificação de fótons no experimento ATLAS.

### III. MÉTODO

Para o projeto do do NeuralRinger para fótons, foram obtidas assinaturas em anéis de fótons e objetos físicos incorretamente classificados como fótons, sendo os jatos hadrônicos em maior predominância, advindos de dados de simulação de Monte Carlo do ambiente computacional do experimento ATLAS. Os dados simulados emulam o decaimento de partículas, como bóson de Higgs, interação dos mesmos com os diversos materiais existentes no experimento ATLAS, a geometria dos detectores, passando por uma precisa emulação de todos os sistemas de instrumentação até o desempenho dos algoritmos de seleção *online* de eventos. O uso do algoritmo visa o processo de classificação binária sendo a classe de sinal, ou positiva, composta por fótons, majoritariamente fótons isolados, e a classe negativa, ou *background*, de jatos hadrônicos que falseiam a assinatura de fótons, majoritariamente composta por mésons  $\eta$  e  $\pi^0$ . O uso de dados advindos de simulação computacional apresenta a vantagem de que não há dúvida sobre o tipo de cada partícula envolvida<sup>3</sup>, tratando-se de um problema de aprendizado supervisionado, o que

<sup>3</sup>Durante a tomada de dados experimentais, não há nenhuma caracterização prévia de partículas. A identificação das mesmas se baseia em modelos teóricos e para reduzir a incerteza das medidas envolvidas usa-se um alto volume de dados.

não é possível quando se avalia dados advindos de colisões reais. Portanto, para endereçar cada assinatura para a classe positiva e negativa, a informação da verdade da simulação, que determina tanto a origem quanto o tipo de partícula, foi utilizada.

O sistema de calorimetria do ATLAS apresenta diferentes características para vários valores de energia e coordenada  $\eta$  da partícula que interage com o material [14]. Por essa razão, as análises para identificação de partículas são feitas separadamente para diferentes valores de energia transversa e  $\eta$ , gerando assim um plano abstrato denominado de espaço de fase. Aqui, o mesmo espaço de fase do NeuralRinger para elétrons foi adotado, uma vez que essa estratégia encontra-se consolidada desde 2017 no HLT. As faixas adotadas no espaço de fase são mostradas na Tabela II.

Tabela II: Regiões do plano  $\eta \times E_T$  utilizadas no desenvolvimento do NeuralRinger para fótons.

$E_T$ [GeV]	[15,20]	[20,30]	[30,40]	[40,50]	[50,∞)
$ \eta $	[0;0.8]	[0.8;1.37]	[1.37;1.54]	[1.54;2.37]	[2.37;2.5]

Diferentes arquiteturas de redes neurais foram consideradas para o treinamento do classificador. Uma delas é a rede MLP, de maneira similar ao realizado para o caso de elétrons. A essa estrutura foi avaliado também o uso da Análise de Componentes Principais (PCA) [22], considerando quatro níveis de compressão da informação: 95%, 97.5%, 99% e 99.9%. Os modelos MLP possuem apenas uma camada escondida e um neurônio na camada de saída, utilizando neste último a função de ativação  $\tanh(\cdot)$ . Dessa forma, para os candidatos a sinal foram atribuídos a saída +1 e aos jatos foi atribuído a saída -1.

As redes neurais convolucionais [23], [24] foram também avaliadas dentro do contexto de seleção de fótons. Para isso, foi adotado uma estrutura unidimensional com dois filtros de 2 e 4 coeficientes. Essa escolha foi adotada devido ao fato de, ao considerar a estrutura em anéis usada pelo algoritmo NeuralRinger, um filtro de 2 coeficientes equivale a uma janela  $3 \times 3$  nas camadas do calorímetro, enquanto o uso do filtro com 4 coeficientes equivale a uma janela  $7 \times 7$ . Esses tamanhos de janelas foram considerados devido ao fato do método baseado em cortes lineares utilizar os mesmos tamanhos para suas variáveis discriminantes do sistema padrão de seleção de fótons no ATLAS, já que os filtros convolucionais fazem uma varredura em todos os 100 anéis, perpassando por todas as camadas do calorímetro.

Para avaliar o desempenho do modelo, utiliza-se o índice soma-produto [25], [26]:

$$SP = \sqrt{\frac{P_D + (1 - P_F)}{\sqrt{P_D(1 - P_F)}}} \quad (1)$$

em que  $P_D$  é a probabilidade de detecção medida sobre a classe de sinal e  $P_F$  é a probabilidade de falso alarme medida sobre a classe de jato. O índice  $SP$  é uma interessante medida para avaliar o desempenho de um modelo através de

medidas diretas associadas à qualidade da classificação. O procedimento de treinamento adotado utiliza como critério de parada a maximização do índice  $SP$ , o  $SP_{max}$ . Os parâmetros de treinamento estão sumarizados na Tabela III

Tabela III: Parâmetros de treinamento do NeuralRinger.

Inicializações	10
Função custo ( <i>loss</i> )	<i>Mean Square Error</i> (MSE)
Parada	$SP_{max}$
Otimizador	Adam [27]
Paciência	25
Validação Cruzada	$k$ -Fold estratificado ( $k = 10$ )

Devido ao fato de o empilhamento de sinais degradar a eficiência na identificação de partículas, após o treinamento é realizada a correção por empilhamento. Esse procedimento consiste em, após obter o melhor modelo para cada região do plano  $\eta \times E_T$ , remover a função de ativação da camada de saída e tornar o limiar de decisão da rede neural como função do empilhamento da amostra. Atualmente, essa correção é feita de maneira linear, seguindo a relação:

$$\sigma(\langle \mu \rangle) = a \langle \mu \rangle + b \quad (2)$$

em que  $\langle \mu \rangle$  é o empilhamento médio da amostra e  $\sigma$  é o limiar de decisão da rede neural. Os coeficientes  $a$  e  $b$  são ajustados no procedimento de correção do empilhamento. O diagrama na Fig. 4 ilustra o processo de identificação de fótons divididos em todas as 25 regiões do plano  $\eta \times E_T$ .

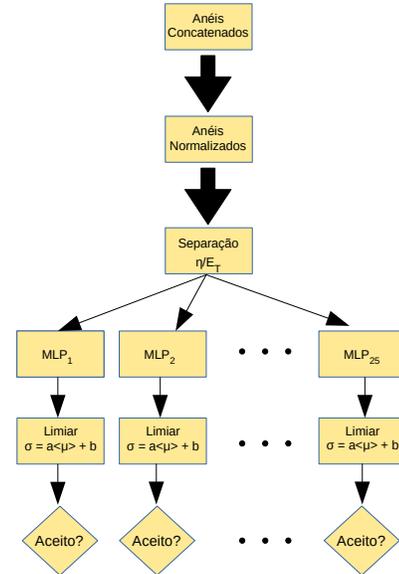


Figura 4: Diagrama ilustrativo da operação do conjunto de redes neurais com correção de empilhamento.

Uma vez que este trabalho ambienta-se no experimento ATLAS, o impacto do NeuralRinger foi avaliado nas cadeias de fótons através de uma emulação destas, a fim de verificar se a probabilidade de falso alarme é reduzida entre a etapa Rápida e a etapa Precisa. Foi verificado também se a eficiência

de todo o sistema de filtragem é mantida, bem como a redução de falsos candidatos a fótons aprovados pelo HLT.

#### IV. RESULTADOS

A Figura 5 mostra o perfil médio dos sinais em anéis extraídos de fótons, em azul, e jatos hadrônicos em vermelho, em que as áreas sombreadas representam a dispersão associada às assinaturas. Observa-se nesta figura que os anéis montados para fótons possuem mais energia nas camadas eletromagnéticas EM1 e EM2, enquanto os jatos hadrônicos comparativamente, mais energia nas camadas hadrônicas.

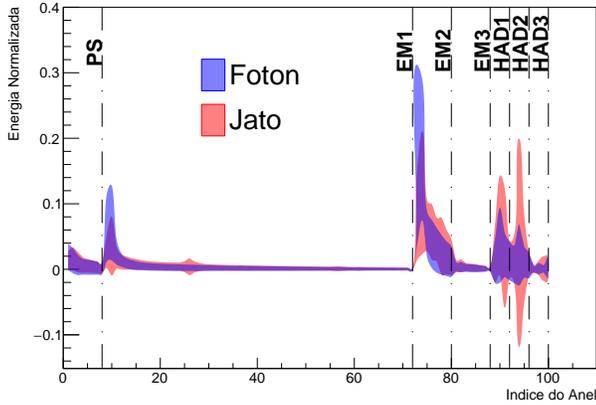


Figura 5: Perfil médio dos anéis de fótons e jatos hadrônicos.

A Figura 6 mostra a distribuição das 20 primeiras componentes no domínio PCA para a classe de fótons e jatos hadrônicos. Observa-se que a primeira e mais energética componente obtida para a classe de fótons apresenta um maior espalhamento do que a primeira componente obtida para jatos hadrônicos. As demais componentes apresentam uma separação menor do que a primeira componente, a exemplo da quarta componente. Nota-se também que a classe de fótons apresenta um maior espalhamento na vigésima componente quando comparada com a classe de jatos hadrônicos.

A Figura 7b mostra a evolução do índice SP ao longo da etapa de teste. Da mesma forma como ilustrado na Figura 7a, a linha preta vertical indica o maior índice SP obtido para esse modelo, em torno da 26ª época. Nota-se que, após esta, não houve aumento do índice SP e, por consequência disso, o treinamento continuou até a 51ª época. Nota-se ainda que, na 9ª época, há um leve aumento da curva de teste na Figura 7a, levando a uma leve queda do índice SP. Isso mostra que essa medida provê boa informação a cerca da evolução do MSE com a adição de contabilizar em um único valor os parâmetros,  $P_D$  e  $P_F$ , relacionados com a qualidade da classificação. Os demais treinamentos, incluindo as MLP com pré-processamento e as CNN, apresentaram comportamentos similares ao exposto na Figura 7 e por essa razão não há necessidade de mostrar as demais curvas de treinamento.

O resultado da avaliação de modelos com diferentes quantidades de neurônios na camada oculta, para a região explorada,

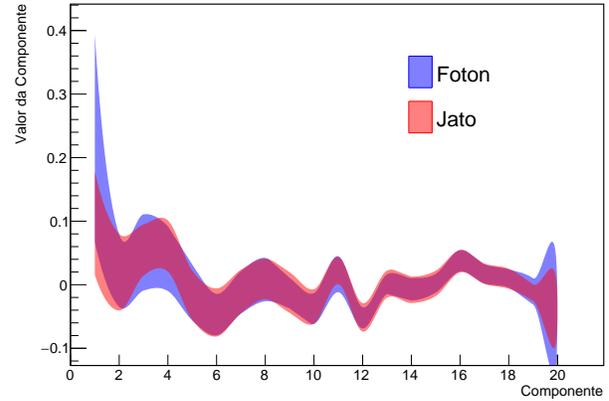


Figura 6: Distribuição das componentes do domínio da PCA para  $0,8 < |\eta| < 1,37$  e  $20 < E_T < 30\text{GeV}$  para fótons e jatos hadrônico.

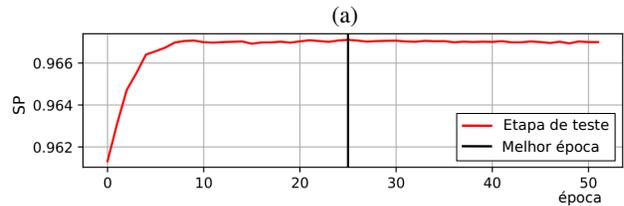
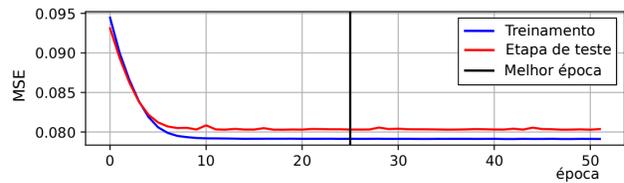


Figura 7: (a): Evolução do MSE ao longo das épocas durante a fase de treinamento e fase de teste, avaliado sobre um modelo de 2 neurônios na camada oculta, no quarto subconjunto da validação cruzada. Esse modelo foi treinado usando os dados da região  $0,8 < |\eta| < 1,37$  e  $20 < E_T < 30\text{ GeV}$ . (b): Evolução do índice SP para a mesma região de operação e mesmo modelo.

é mostrado na Tabela IV, comparando com o atual método de seleção baseado cortes lineares (Referência). Aqui, a probabilidade de detecção dos modelos é fixada no mesmo ponto da referência, a fim de avaliar o impacto no falso alarme.

Como observa-se, considerando apenas os modelos MLP com 100 entradas (relativo a assinatura em anéis), o Neural-Ringer reduziu aproximadamente em 51% a taxa de aceitação de falsos fótons quando comparado ao método de cortes lineares, sendo esse resultado alcançado através do uso de 8 neurônios na camada escondida. Dessa forma, para todas as configurações estudadas, observa-se também o aumento correspondente do índice  $SP$ . O modelo MLP escolhido para operar nessa região no critério *medium* é o que utiliza 8

Tabela IV: Comparação de diferentes modelos com o atual método de seleção de fótons ( $20 < E_T < 30$  GeV e  $0,8 < |\eta| < 1,37$ ) para o critério *medium*.

Classificador	$P_D$ [%]	$P_F$ [%]	$SP$ [%]
Cortes Lineares	94,24	25,88	83,88
MLP 2 Neurônios	94,24±0,00	13,46±0,06	90,35±0,69
MLP 3 Neurônios	94,24±0,00	12,94±0,03	90,61±0,57
MLP 4 Neurônios	94,24±0,00	13,04±0,04	90,56±0,64
MLP 5 Neurônios	94,24±0,00	12,84±0,06	90,66±0,63
MLP 6 Neurônios	94,24±0,00	12,76±0,03	90,70± 0,58
MLP 7 Neurônios	94,24±0,00	12,73±0,04	90,71± 0,62
<b>MLP 8 Neurônios</b>	<b>94,24±0,00</b>	<b>12,70±0,03</b>	<b>90,73± 0,54</b>
MLP 9 Neurônios	94,24±0,00	12,82±0,05	90,67± 0,67
MLP 10 Neurônios	94,24±0,00	12,86±0,04	90,65± 0,59
PCA(14) + MLP 8	94,24±0,00	11,04±0,06	91,58±0,57
<b>PCA(20) + MLP 8</b>	<b>94,24±0,00</b>	<b>10,82±0,05</b>	<b>91,69±0,61</b>
PCA(26) + MLP 8	94,24±0,00	11,44±0,02	91,37±0,54
PCA(35) + MLP 8	94,24±0,00	12,14±0,05	91,02±0,55
<b>CNN</b>	<b>94,24±0,00</b>	<b>8,47±0,06</b>	<b>92,88±0,63</b>

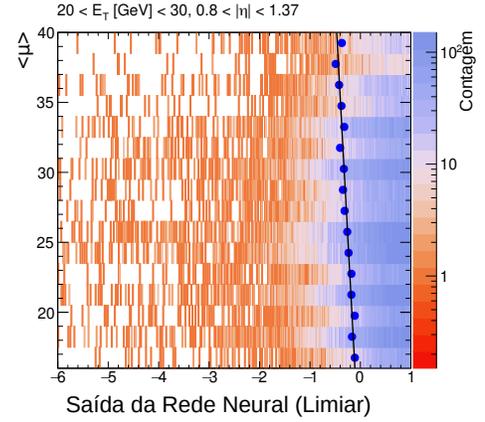
neurônios na camada escondida. Vale ressaltar ainda que, para as demais regiões do espaço de fase e os demais critérios de seleção, o modelo que obteve a menor taxa de aceitação de falsos fótons foi também aquele com 8 neurônios. A região destacada pela Tabela III foi a que apresentou a menor redução percentual de  $P_F$ . As demais regiões apresentaram uma redução maior do que a evidenciada.

Para a avaliação do desempenho do NeuralRinger com o pré-processamento por PCA, a rede MLP com 8 neurônios na camada escondida foi utilizada, já que foi a que apresentou menor  $P_F$  sem nenhum tipo de pré-processamento. Dentre os quatro valores de variância explicada, a configuração que obteve a menor taxa de falso alarme foi a que utilizou 20 componentes, obtidas com 97,5% da variância explicada, da projeção para o domínio PCA, superando a performance dos modelos neurais sem pré-processamento. Isso pode ser explicado pelo fato de que, ao projetar as assinaturas em anéis no domínio PCA, a primeira e a vigésima componentes, conforme mostrado na Figura 6, apresentaram diferentes intervalos de valores das componentes entre as classes, além do fato de que a PCA pode também remover as redundâncias existentes nas assinaturas em anéis, a exemplo dos anéis mais externos presentes na primeira camada eletromagnética (vide Figuras 5).

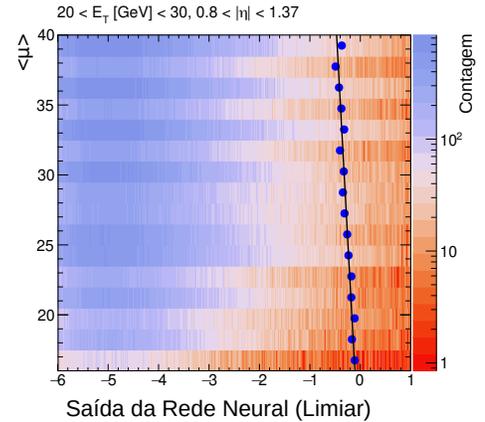
Já o modelo convolucional foi o que apresentou a maior redução de falso alarme entre todos os modelos, obtendo  $P_F = 8,47\%$ , resultando em uma redução percentual de aproximadamente 67% com relação ao método baseado em cortes lineares para essa região do plano  $E_T \times \eta$ . O desempenho alcançado por esse tipo de arquitetura pode ser justificado pelo fato de redes CNN conseguirem extrair características relevantes, usando sua estrutura interna de filtragem, onde há redundância de informação nos sinais utilizados na etapa de treinamento, característica presente, por exemplo, em problemas de classificação usando imagens.

A correção por empilhamento é mostrada na Fig. 8. Nos gráficos mostrados nesta, é destacado o ajuste da reta por valores de empilhamento, bem como a concentração de candi-

dados a fótons e jatos, mostrados nas Fig. 8a e 8b. Os pontos (em azul escuro) são posicionados para manter o mesmo  $P_D$  para todas as faixas de empilhamento. Nesse caso, o valor de  $P_D$  foi ajustado para 94,4%, mesmo valor obtido pelo atual método de seleção rápida nas cadeias de fótons no experimento ATLAS para essa região de operação. Nota-se, na Fig. 8a, que a maior quantidade de sinais está a direita da reta ajustada pelos pontos, indicando que a maioria dos sinais foram corretamente classificados pelo modelo. De maneira similar, observa-se na Fig. 8b que a maioria das partículas que compõe os jatos estão a esquerda da mesma reta, indicando que estes também foram corretamente classificados pelo NeuralRinger.



(a)



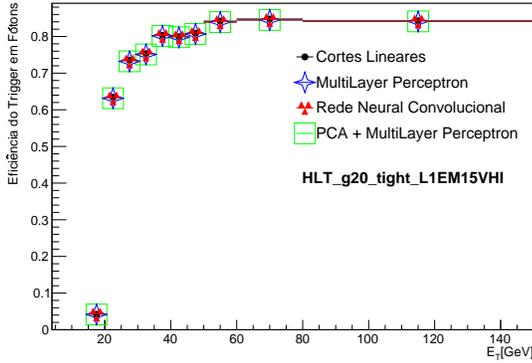
(b)

Figura 8: Correção por empilhamento considerando as distribuições de(a): fótons (b): jatos.

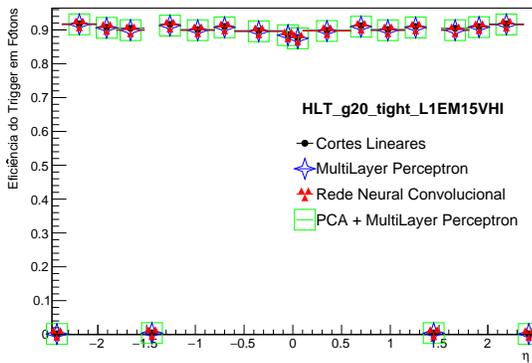
Para avaliar o impacto do uso do NeuralRinger no sistema de seleção *online* de fótons, foi efetuada a correção de empilhamento em todos os modelos selecionados para cada ponto do plano  $\eta \times E_T$  e, em seguida, os dados de fótons e jatos foram propagados em todos os modelos. Então foi medida a

eficiência para a classe de sinal e a capacidade de rejeição nas amostras de jatos hadrônicos, por faixa de  $E_T$ , posição da partícula  $\eta$  e o empilhamento da amostra. Essas medidas foram também avaliadas para os diferentes em dois pontos de operação do HLT: *tight* e *loose*. Nesses pontos de operação foram considerados fótons a partir de 20 GeV de energia transversa em que o nível L1 estimou pelo menos 15 GeV de energia associada ao *cluster* associado a partícula.

A Fig. 9 mostra a eficiência do algoritmo NeuralRinger com as diferentes arquiteturas propostas, medidas sobre a classe de sinal, em que  $\epsilon = P_D$ , considerando a aprovação dos fótons em toda a cadeia de algoritmos do HLT em função de  $E_T$  e da coordenada  $\eta$  da partícula. Quando substitui-se a técnica baseada em cortes lineares pelos modelos neurais explorados nesse trabalho, não há mudança na aceitação de fótons pelo sistema de seleção de eventos do ATLAS, conforme esperado. Manter a mesma eficiência do HLT é de suma importância pois não é desejável que haja prejuízo na quantidade de fótons detectados para diversos valores de energia e de coordenada da partícula.



(a)

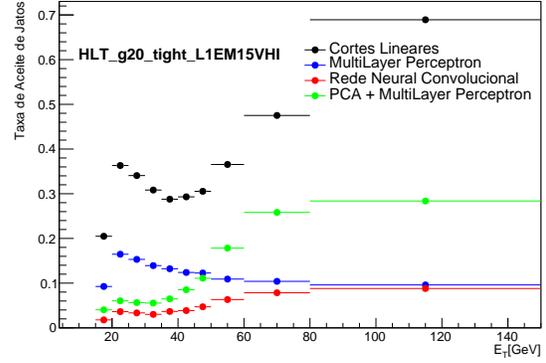


(b)

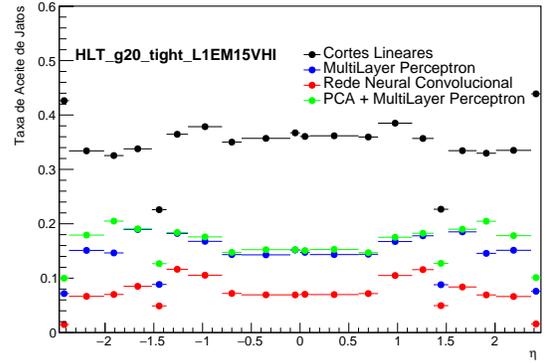
Figura 9: Análise de eficiência do HLT medida sobre a classe de sinal com relação a (a) energia e (b) coordenada da partícula, considerando o critério *Tight*.

Já a Fig. 10 mostra a taxa de aceitação de jatos hadrônicos no *trigger* de fótons. Observa-se, em consonância com a

Tabela III, que os modelos neurais apresentam uma menor aceitação de jatos hadrônicos quando comparado ao método baseado em cortes lineares, indicando que para todas as regiões definidas no plano  $E_T \times \eta$  o NeuralRinger consegue eliminar falsos fótons das cadeias de processamento.



(a)



(b)

Figura 10: Análise de eficiência do HLT medida sobre a classe de jatos com relação a (a) energia e (b) coordenada da partícula, considerando o critério *Tight*.

Dentre os modelos neurais baseados na assinatura em anéis, o modelo convolucional foi o que apresentou a menor taxa de aceitação de jatos para toda a faixa de  $E_T$  e  $\eta$ . Nota-se também que o NeuralRinger operando com o pré-processamento por PCA apresenta uma performance superior ao modelo neural sem pré-processamento para  $E_T < 50$  GeV. Já na região de altas energias, o modelo com apenas 8 neurônios na camada oculta aceita uma quantidade de jatos hadrônicos menor do que o modelo com pré-processamento por PCA.

## V. CONCLUSÕES

O experimento ATLAS é o maior do LHC, contribuindo significativamente para diversas descobertas científicas. Neste experimento, diversas técnicas são aplicadas para a rápida identificação de partículas. Dentre elas, o algoritmo NeuralRinger, que faz uso de redes neurais artificiais, mostra-se uma interessante abordagem nesse contexto. A adaptação desta

técnica para a detecção rápida de fótons exibe potencial na aplicação do experimento, uma vez que reduz a ocorrência de falsos positivos entre as etapas do HLT e na geração dos arquivos para posterior análise *offline*. Dessa forma, para a próxima etapa de atualizações do LHC, espera-se que o NeuralRinger de fótons opere como técnica padrão nas cadeias de processamento deste tipo de partícula. A abordagem baseada em redes convolucionais apresenta maior potencial de utilização, com a maior redução de aceitação de falsos fótons no sistema de seleção *online* do ATLAS, suscitando investigações de desempenho do modelo no ambiente computacional do ATLAS, comparando com os modelos MultiLayer Perceptron.

#### AGRADECIMENTOS

Os autores agradecem a FAPESB, CNPq, FAPEMIG, FAPERJ e RENAFAP pelo apoio financeiro e à colaboração ATLAS pelas contribuições técnicas ao trabalho. Agradecemos também ao IFBA *campus* Vitória da Conquista. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

#### REFERÊNCIAS

- [1] K. Albertsson, P. Alton, D. Anderson, and et al, “Machine learning in high energy physics community white paper,” *Journal of Physics: Conference Series*, vol. 1085, p. 022008, sep 2018.
- [2] A. R. Jimenez, J. E. García Navarro, and M. M. Llácer, “Convolutional Neural Networks for event classification,” *PoS*, vol. LHCP2021, p. 264, 2021.
- [3] W.-B. He, Y.-G. Ma, L.-G. Pang, H. Song, and K. Zhou, “High energy nuclear physics meets Machine Learning,” 3 2023.
- [4] M. Rossi, “Deep learning applications to particle physics: from monte carlo simulation acceleration to protodune reconstruction,” 2023.
- [5] C. Shimmin, P. Sadowski, P. Baldi, E. Weik, D. Whiteson, E. Goul, and A. Søgaard, “Decorrelated jet substructure tagging using adversarial neural networks,” *Physical Review D*, vol. 96, 03 2017.
- [6] A. Ghosh, B. Nachman, and D. Whiteson, “Uncertainty-aware machine learning for high energy physics,” *Phys. Rev. D*, vol. 104, p. 056026, Sep 2021.
- [7] A. Radovic, M. Williams, D. Rousseau, M. Kagan, D. Bonacorsi, A. Himmel, A. Aurisano, K. Terao, and T. Wongjirad, “Machine learning at the energy and intensity frontiers of particle physics,” *Nature*, vol. 560, 08 2018.
- [8] P. Baldi, P. Sadowski, and D. Whiteson, “Searching for exotic particles in high-energy physics with deep learning,” *Nature communications*, vol. 5, p. 4308, 07 2014.
- [9] L. Evans and P. Bryant, “LHC Machine,” *Journal of Instrumentation*, vol. 3, pp. S08001–S08001, aug 2008.
- [10] D. J. Griffiths, *Introduction to elementary particles; 2nd rev. version*. Physics textbook, New York, NY: Wiley, 2008.
- [11] ATLAS Collaboration, “Observation of a new particle in the search for the standard model Higgs boson with the ATLAS detector at the LHC,” *Physics Letters B*, vol. 716, no. 1, pp. 1 – 29, 2012.
- [12] G. Aad, B. Abbott, *et al.*, “Evidence for higgs boson decays to a low-mass dilepton system and a photon in pp collisions at  $\sqrt{s} = 13$  TeV with the atlas detector,” *Physics Letters B*, vol. 819, p. 136412, 2021.
- [13] J. Seixas, L. Caloba, M. Souza, A. Braga, and A. Rodrigues, “Neural second-level trigger system based on calorimetry,” *Computer Physics Communications*, vol. 95, no. 2, pp. 143–157, 1996.
- [14] ATLAS Collaboration, “The ATLAS experiment at the CERN Large Hadron Collider,” *Journal of Instrumentation*, S08003 (2008), 01 2008.
- [15] R. Wigmans, *Calorimetry: Energy Measurement in Particle Physics*. International Series of Monographs on Physics, OUP Oxford, 2017.
- [16] ATLAS Collaboration, “Technical Design Report for the Phase-II Upgrade of the ATLAS TDAQ System,” Tech. Rep. CERN-LHCC-2017-020. ATLAS-TDR-029, CERN, Geneva, Sep 2017.
- [17] G. Aad, Abbott, *et al.*, “Performance of electron and photon triggers in ATLAS during LHC Run 2,” *Eur. Phys. J. C*, vol. 80, p. 47. 56 p, Sep 2019.
- [18] A. Ruiz-Martinez and A. Collaboration, “The Run-2 ATLAS Trigger System,” tech. rep., CERN, Geneva, Feb 2016.
- [19] S. S. Haykin, *Neural networks and learning machines*. Upper Saddle River, NJ: Pearson Education, third ed., 2009.
- [20] J. V. da Fonseca Pinto and the ATLAS Collaboration, “An ensemble of neural networks for online filtering implemented in the ATLAS trigger system,” *Journal of Physics: Conference Series*, vol. 1162, p. 012039, jan 2019.
- [21] W. Spolidoro Freund, “An Ensemble of Neural Networks for Online Electron Filtering at the ATLAS Experiment,” *J. Phys. Conf. Ser.*, vol. 1525, no. 1, p. 012076, 2020.
- [22] I. T. Jolliffe and J. Cadima, “Principal component analysis: a review and recent developments,” *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 374, no. 2065, p. 20150202, 2016.
- [23] S. Kiranyaz, T. Ince, R. Hamila, and M. Gabbouj, “Convolutional neural networks for patient-specific ecg classification,” in *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 2608–2611, 2015.
- [24] M. M. Taye, “Theoretical understanding of convolutional neural network: Concepts, architectures, applications, future directions,” *Computation*, vol. 11, no. 3, 2023.
- [25] R. C. Torres, D. E. F. de Lima, E. F. de Simas Filho, and J. M. de Seixas, “Neural online filtering based on preprocessed calorimeter data,” in *2009 IEEE Nuclear Science Symposium Conference Record (NSS/MIC)*, pp. 530–536, 2009.
- [26] E. F. SIMAS FILHO, J. M. de Seixas, and L. P. Calôba, “Modified post-nonlinear ica model for online neural discrimination,” *Neurocomputing*, vol. 73, no. 16, pp. 2820–2828, 2010. 10th Brazilian Symposium on Neural Networks (SBRN2008).
- [27] D. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *International Conference on Learning Representations*, 12 2014.