

Conjunto de Redes Neurais Artificiais para Detecção Online de Fótons de Altas Energias

J. L. Marin¹, E. F. de Simas Filho¹, E. E. P. de Souza¹,
B. S.M. Peralva², J. V. F. Pinto³, M. V. de Araújo³, J. M. de Seixas³

¹Laboratório de Sistemas Digitais, PPGEE/UFBA, ²PPGMVC/UERJ,

³ Laboratório de Processamento de Sinais, COPPE/POLI, UFRJ

¹Salvador, ²Nova Friburgo, ³Rio de Janeiro, Brasil

{juan.lieber, eduardo.simas, edmar.egidio}@ufba.br

bernardo.peralva@uerj.br

{jodafons, micael.verissimo, seixas}@lps.ufrj.br

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 adaptação desta técnica, que opera identificando elétrons, para a detecção rápida de fótons. Os resultados com dados simulados mostram a eficiência do método proposto no ambiente do experimento ATLAS.

Index Terms—Redes Neurais, NeuralRinger, Física de Altas Energias, Identificação de partículas

I. INTRODUÇÃO

Um dos maiores motores da humanidade é a eterna busca pelo conhecimento. A composição do universo, bem como sua origem, é até hoje objeto de grande interesse da comunidade científica. O estudo de partículas atômicas e subatômicas tem sido estudada através de colisores de partículas de alta energia [1]. O LHC (do inglês, *Large Hadron Collider*), construído no CERN (Centro Europeu para Pesquisa Nuclear), é o maior colisor de partículas em atividade, consistindo em um percurso aproximadamente circular de 27 quilômetros. Construído a 100 metros abaixo da superfície na fronteira franco-suíça, o LHC opera acelerando feixes de prótons, com velocidade próxima a da luz, colocando-os em colisão a cada 25 ns, alcançando uma energia de 13 TeV. Com isso, é possível aumentar a probabilidade de ocorrência de partículas raras, que auxiliam em um melhor entendimento na composição do universo [2]. Por conta disso, um alto volume de dados é gerado por evento, cerca de 52 TB/s, sendo necessário um sistema de filtragem de eventos, reduzindo os dados apenas com os eventos de interesse. No experimento ATLAS (do inglês, *A Toroidal LHC Apparatus*) [3], o sistema de filtragem é dividido em dois níveis em cascata, a fim de reduzir a latência entre as etapas de processamento. Esse sistema é também responsável por filtrar os eventos de interesse, dentro da grande massa de dados que é gerada durante as colisões, que são definidos por canais físicos extremamente raros.

Com essa alta taxa de produção de colisões ocorre o problema do empilhamento de sinais [4], que degrada o desempenho dos diversos métodos de identificação de partículas. Em especial, os fótons são de grande interesse do experimento, sendo a primeira observação do bóson de Higgs feita através da identificação de um par de fótons [5]. Recentemente, um novo decaimento deste mesmo bóson foi observado, sendo uma das partículas resultantes um fóton [6]. Usualmente, o ruído de fundo associado aos fótons é composto por jatos hadrônicos que podem falsear a assinatura de fótons.

O uso de técnicas de aprendizado de máquina vem se tornando uma constante na solução de diversos problemas de engenharia e instrumentação científica, principalmente em cenários onde há uma grande quantidade de dados e deseja-se encontrar um evento raro que possua características singulares. As redes neurais artificiais se mostram uma poderosa ferramenta na solução desse tipo de problema, fazendo uso de algoritmos de otimização e diferentes arquitetura de modelos [7]. O trabalho desenvolvido em [8] mostra a evolução do uso de redes neurais artificiais em experimentos de física de altas energias. Em [9] uma rede neural adversarial é usada para reduzir as incertezas sistemáticas na identificação de jatos hadrônicos. Já em [10], o uso de aprendizado profundo em redes neurais é utilizado para a busca de partículas exóticas em física de altas energias. O algoritmo NeuralRinger [11], que usa um modelo neural MLP (do inglês, *Multi Layer Perceptron*), foi desenvolvido para a discriminação elétron/jato no experimento ATLAS, no complexo de aceleração LHC. Este algoritmo, descrito detalhadamente na seção II-B, utiliza a informação de energia dos canais de leitura do calorímetro para montar anéis concêntricos e alimentar uma rede neural para performar a discriminação. Desde 2017, é a técnica padrão de detecção *online* de elétrons no ATLAS, para energias superiores a 15 GeV¹ [12].

Nesse contexto, o objetivo desse trabalho é adaptar a técnica NeuralRinger para a seleção rápida de fótons, fazendo uso do

¹A unidade padrão de energia em física de altas energias é o elétron-volt (eV). Essa unidade é definida como a quantidade de energia cinética para ganhar por um elétron quando submetido a uma diferença de potencial de 1V no vácuo

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 [3]) foi um dos responsáveis, em 2012, pela descoberta do bóson de Higgs [5], 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) [13]. 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 fornecer 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 η e ϕ as principais.²




Figura 1: Experimento ATLAS e seus diversos subsistemas (adaptado de [3])

O ATLAS, através do 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 [14].

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 [12]. Os eventos de interesse

²O 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 , ϕ) são usadas no plano transversal, com ϕ sendo o ângulo azimutal em torno do eixo z. A pseudo-rapidez é definida em termos do ângulo polar θ como $\eta \equiv -\ln[\tan(\theta/2)]$.

do experimento ATLAS (*trigger*) passam por um sistema de seleção que é dividido em dois níveis [15]. 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 [12], [15]. A Fig. 2 ilustra o HLT para as cadeias responsáveis por identificação de fótons.

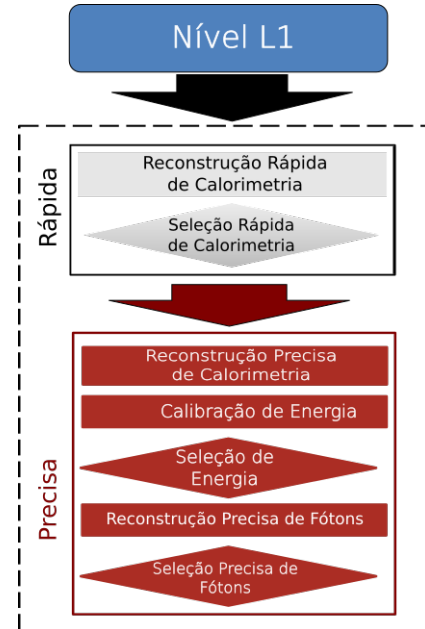


Figura 2: Sistema de seleção de eventos em cadeias de fótons no experimento ATLAS (adaptada de [12])

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 [12].

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 [12]. 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* sinaliza que aquela partícula não é um fóton. Entretanto, há o cenário em que uma partícula é rejeitada pelo critério *tight* e aprovada pelo *loose*. Essa situação é usada quando deseja-se gerar uma alta estatística na busca de eventos raros.

B. Algoritmo NeuralRinger

O algoritmo NeuralRinger foi originalmente proposto em [11], 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).

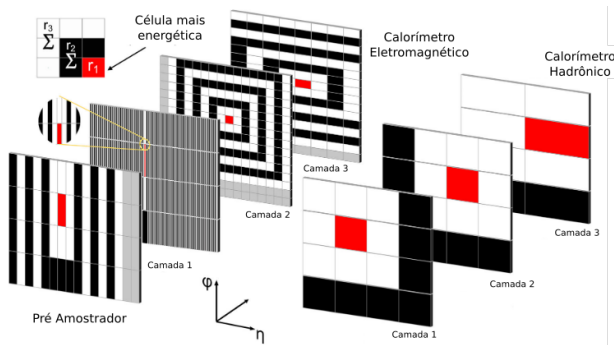


Figura 3: Construção dos anéis em cada camada do sistema de calorimetria (extraído de [12])

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 [7]. 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, η , do sistema de calorimetria [16], [17]. 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 [13], esse trabalho propõe a adaptação do algoritmo NeuralRinger para a identificação de fótons no experimento ATLAS.

III. MÉTODO

A primeira etapa realizada para o desenvolvimento deste trabalho consistiu em coletar as assinaturas de fótons e jatos hadrônicos. Esses dados foram coletados a partir de dados simulados pela colaboração ATLAS, considerando a verdade desta associada a cada candidato, seguindo-se para a separação destes no plano $E_T \times |\eta|$. Com os dados agrupados neste plano, procedeu-se ao treinamento dos modelos neurais, seguindo para a seleção do melhor modelo através do processo de validação cruzada. Uma vez obtido o melhor modelo para operar, procede-se com o procedimento de correção do limiar de decisão por valores de empilhamento. A fim de avaliar a performance do método proposto, a eficiência na identificação de fótons é contabilizada emulando o sistema de seleção de eventos *online* do ATLAS.

A adaptação do NeuralRinger para identificação rápida de fótons segue uma metodologia similar à desenvolvida para o caso de elétrons. O conjunto de dados utilizado para treinamento e teste dos modelos neurais consiste em fótons isolados para a classe de sinal e qualquer outra partícula para a classe de jatos. Esses dados são advindos de simulação de Monte Carlo, onde são simuladas colisões com decaimentos que resultam em fótons e jatos hadrônicos, colhendo a informação de energia para cerca de 200 mil canais de leitura. Os dados foram separados, no plano $\eta \times E_T$, em 25 regiões definidas 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]

A estrutura do modelo adotada foi a MLP, de maneira similar ao realizado para o caso de elétrons. Os modelos 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. Visando obter um modelo de menor complexidade possível, devido às restrições de tempo imposta pelo regime de colisões do LHC, a quantidade de neurônios da camada escondida foi variada de 2 a 5.

Para avaliar o desempenho do modelo, utiliza-se o índice soma-produto [18], [19]:

$$SP = \sqrt{\frac{P_D(1 - P_F) + (1 - P_D)P_F}{2}} \quad (1)$$

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	5
Função custo (<i>loss</i>)	<i>Mean Square Error</i> (MSE)
Parada	SP_{max}
Otimizador	Adam [20]
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 σ 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 $\eta \times E_T$.

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

Como resultado da seleção dos sinais através da verdade da simulação e consequente separação dos dados no plano $\eta \times E_T$, obteve-se a quantidade de candidatos a fóton e a jato em cada uma das regiões, mostrado na Fig. 5.

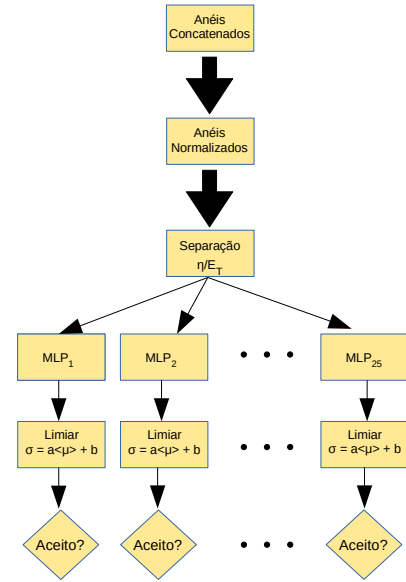


Figura 4: Diagrama ilustrativo da operação do conjunto de redes neurais com correção de empilhamento.

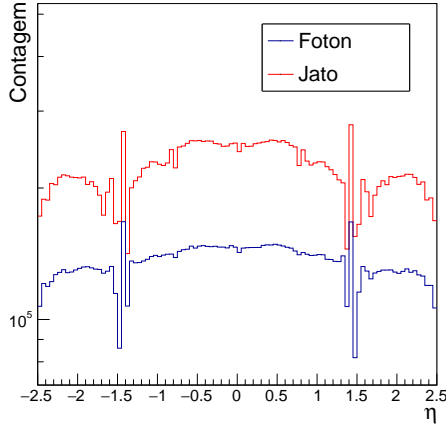
Estadística disponível de fóton/jato

E_T	0: 15->20 [GeV]	1: 20->30 [GeV]	2: 30->40 [GeV]	3: 40->50 [GeV]	4: 50->100000 [GeV]
4: 2.37->2.50	f: 15328 j: 303375	f: 20874 j: 317697	f: 24438 j: 151205	f: 27064 j: 72070	f: 144706 j: 72088
3: 1.54->2.37	f: 109202 j: 2257068	f: 139161 j: 2367100	f: 184213 j: 1109731	f: 184407 j: 518850	f: 969941 j: 505414
2: 1.37->1.54	f: 19440 j: 410499	f: 25974 j: 453386	f: 40707 j: 219728	f: 45605 j: 102531	f: 174407 j: 102198
1: 0.80->1.37	f: 76160 j: 1725472	f: 104684 j: 1767962	f: 127603 j: 778466	f: 134628 j: 351064	f: 694101 j: 347076
0: 0.00->0.80	f: 117166 j: 2776105	f: 145389 j: 2827188	f: 191923 j: 1255151	f: 189824 j: 563416	f: 987678 j: 551373

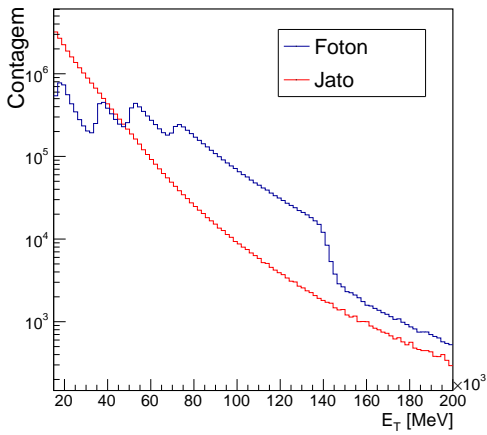
Figura 5: Quantidade de fótons e jatos para as diferentes regiões de operação do NeuralRinger.

Já a Fig. 6 mostra a distribuição estatística dos fótons e jatos com relação a energia e a posição η do sistema de coordenadas. Nota-se, na Fig. 6a em que a região $|\eta| \approx 1,4$ existe uma queda na contagem de partículas. Isso se deve ao fato de que, nessa região, a instrumentação do calorímetro eletromagnético possui uma resolução menor do que as demais regiões. Isso ocorre devido a passagem de cabos e a limitações na montagem do calorímetro. Já a Fig. 6b mostra que a quantidade de fótons supera a de jatos. Isso é devido ao fato de que, em energias elevadas, aumenta-se a relação sinal-ruído. As ondulações presentes no histograma de fótons são devidas ao uso de quatro conjunto de dados distintos para extrair os sinais associados a essa partícula. Cada um deles possui uma especificação mínima de energia (17,35,50 e 70 GeV) e é onde se concentra a maior parte dos sinais, gerando assim um pico na contagem em torno desses valores.

A Fig. 7 mostra o perfil dos sinais coletados para fótons e jatos. Observa-se que nos anéis finais (camadas hadrônicas) a energia dos jatos é, em média, superior a de fótons. Já nos



(a)



(b)

Figura 6: Histogramas dos fótons e jatos com relação a (a): posição. (b): energia.

primeiros anéis, nota-se que a energia dos fótons é superior a dos jatos. Essa característica gerada pelo procedimento de montagem dos anéis confere alto poder discriminante entre as classes exploradas nesse trabalho.

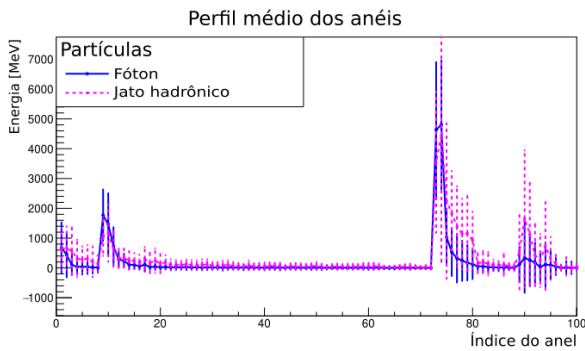




Figura 7: Perfil médio do vetor de anéis para fótons e jatos hadrônicos.

A Fig. 8 mostra a avaliação do resultado do treinamento de um modelo de 2 neurônios na camada oculta para uma única região de operação do NeuralRinger. Na Fig. 8a é mostrada a evolução do MSE durante a fase de treinamento e a fase de teste. Nota-se que ambas as curvas, vermelha e azul, possuem o mesmo comportamento, indicando que não há nenhum tipo de sobre-ajuste durante a etapa de treinamento.

A linha vertical preta indica a época em que se obteve o máximo índice SP , este mostrado na Fig. 8b. Como mencionado na Tabela III, o treinamento tenta ainda por 25 épocas encontrar um novo SP_{max} . Nesse caso, após a época 26 não foi possível encontrar e, portanto, esta foi a melhor época selecionada durante o treinamento. É válido ressaltar que comportamento similar foi observado nas demais regiões de operação e para os modelos com mais neurônios na camada oculta.



(a)



(b)

Figura 8: (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 $20 < E_T < 30$ GeV. (b): Evolução do índice SP para a mesma região de operação e mesmo modelo.

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

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*.

	P_D [%]	P_F [%]
Referência	94,24	25,88
MLP 2 Neurônios	$94,24 \pm 0,00$	$13,46 \pm 0,06$
MLP 3 Neurônios	$94,24 \pm 0,00$	$12,94 \pm 0,03$
MLP 4 Neurônios	$94,24 \pm 0,00$	$13,04 \pm 0,04$
MLP 5 Neurônios	$94,24 \pm 0,00$	$12,84 \pm 0,06$

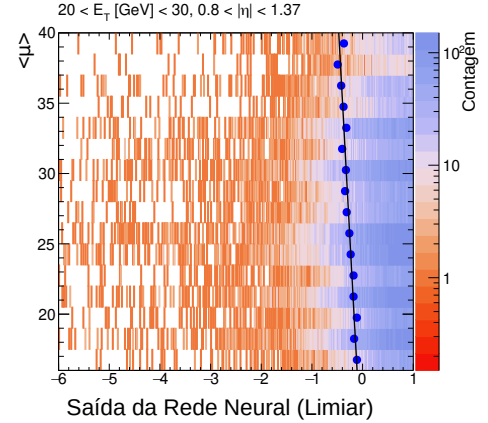
Em geral, os modelos reduzem em aproximadamente 45% a probabilidade de falso alarme com relação ao atual método de seleção. Nota-se também que, quando comparado com o método de referência, o NeuralRinger reduz drasticamente a taxa de falso alarme, mantendo a mesma probabilidade de detecção, ou seja, sem prejuízo na seleção de fótons verdadeiros. Observa-se também que, ao aumentar a quantidade de neurônios da camada oculta, não há uma redução significativa na taxa de falso alarme. Por essa razão, o modelo com o menor número de neurônios da camada oculta é escolhido, uma vez que apresenta a menor complexidade computacional, fator crucial para ambientes com alta taxa de eventos. Uma das razões para tanto se dá pelo alto poder discriminativo associado a montagem dos anéis para fótons e jatos.

A correção por empilhamento é mostrada na Fig. 9. Nos gráficos mostrados nesta, é destacado o ajuste da reta por valores de empilhamento, bem como a concentração de candidatos a fótons e jatos, mostrados nas Fig. 9a e 9b. Os pontos (em azul escuro) são posicionados para manter o mesmo P_D para todas as faixas de empilhamento. Nesse caso, o 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. 9a, que a maior quantidade de sinais está à direita da reta ajustada pelos pontos, indicando que a maioria dos sinais foram corretamente classificados pelo modelo. De maneira similar, observa-se na Fig. 9b que a maioria das partículas que compõe os jatos estão à esquerda da mesma reta, indicando que estes também foram corretamente classificados pelo NeuralRinger.


A fim de avaliar o impacto da substituição da atual técnica de seleção rápida de fótons pelo NeuralRinger, algumas cadeias de seleção comparando ambos os métodos foram emuladas, considerando todo o HLT. As emulações foram feitas sobre os dados de fótons e de jatos, para avaliar eficiência e redução de falso alarme. O resultado dessa emulação, considerando a classe de sinal, é mostrado na Fig. 10. As emulações foram feitas considerando diferentes tipos de seleção. O corte em energia é indicado pelo valor seguinte à letra g (g20, por exemplo, seleciona fótons a partir de 20 GeV). O critério de pureza da amostra (*tight*, *medium* ou *loose*) é indicado ao lado do corte em energia. Uma cadeia denominada, por exemplo, *HLT_g20_tight* seleciona fótons a partir de 20 GeV que foram aprovados pelo critério *tight* do sistema HLT;

Observa-se que a eficiência do HLT foi mantida para os três pontos de operação do *trigger* para toda a faixa de energia. A Fig. 11 mostra também a eficiência medida com relação ao empilhamento da amostra não foi alterada. Já a Fig. 12 mostra que a eficiência é mantida também para quase todas as faixas de η , com exceção da região próxima do final do detector $|\eta| \approx 2.5$. Nessa região, como pode-se observar, nenhum fóton é aprovado pelo critério *tight*, indicando que essa região é problemática para identificação desse tipo de partícula. No ATLAS, a manutenção dos níveis de eficiência de todo o sistema de seleção de eventos é de suma importância.

A eficiência do método contabilizada em jatos é mostrada nas Fig. 13, 14, 15 e 16. A Fig. 13 mostra a aceitação de falsos



(a)



(b)

Figura 9: Correção por empilhamento considerando as distribuições de(a): fótons (b): jatos




Figura 10: Análise de eficiência do HLT medida sobre a classe de sinal com relação a energia, considerando os critérios *Tight*, *Medium* e *Loose*

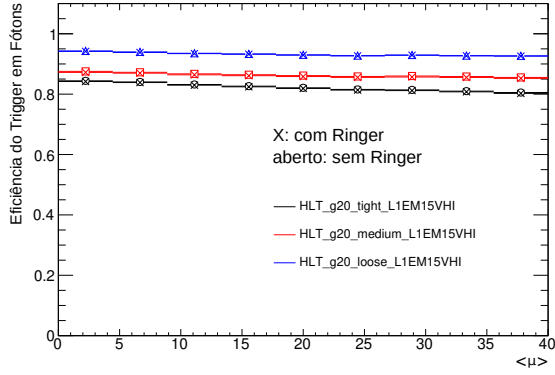


Figura 11: Análise de eficiência do HLT medida sobre a classe de sinal com relação ao empilhamento, considerando os critérios *Tight*, *Medium* e *Loose*




Figura 12: Análise de eficiência do HLT medida sobre a classe de sinal com relação a coordenada η , considerando os critérios *Tight*, *Medium* e *Loose*

fótons por faixas de energia. Observa-se que, para todos os pontos de operação, o Neural Ringer rejeita uma quantidade maior de jatos quando comparado a estratégia de seleção baseada em cortes lineares. Na Fig. 14 nota-se o mesmo fato por faixas de empilhamento de sinais. Devido ao processo de correção por empilhamento, nota-se que as curvas associadas ao NeuralRinger apresentam comportamento quase constante. Já na Fig. 15 observa-se também que o NeuralRinger rejeita uma maior quantidade de jatos por valores de η . Nota-se também uma queda drástica em $\eta \approx 1.5$ em virtudes dos fatores já mencionados. Por sua vez, a Fig. 16 mostra a taxa de aceitação de falsos fótons contabilizada ao final de todo o sistema de filtragem *online* de eventos. Nela, nota-se uma ligeira redução do falso alarme quando comparado com o atual método de seleção de fótons no experimento ATLAS.

Nota-se ainda os critérios *tight*, *medium* e *loose* apresentam a mesma eficiência nas Fig. 13, 14 e 15. Isso se dá pelo fato de, atualmente, os cortes nas variáveis de calorimetria são os

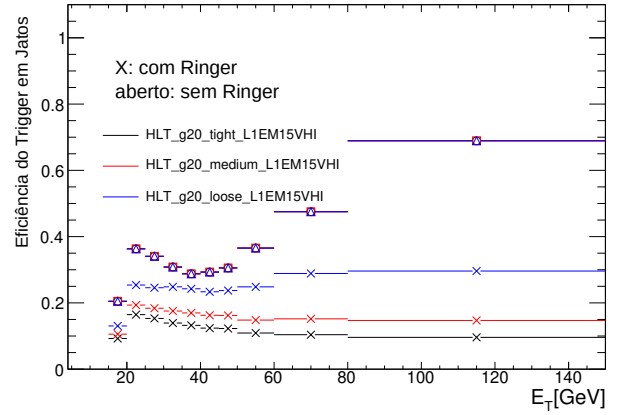


Figura 13: Análise de eficiência da etapa Rápida medida sobre os jatos com relação energia, considerando os critérios *Tight*, *Medium* e *Loose*

mesmos para os três critérios. A consequência da redução da taxa de aceitação de falsos fótons, quando o NeuralRinger é utilizado na etapa Rápida, é a redução no custo computacional atribuído à etapa Precisa, que é crítico dado o regime de operação de alta taxa de colisões do LHC.

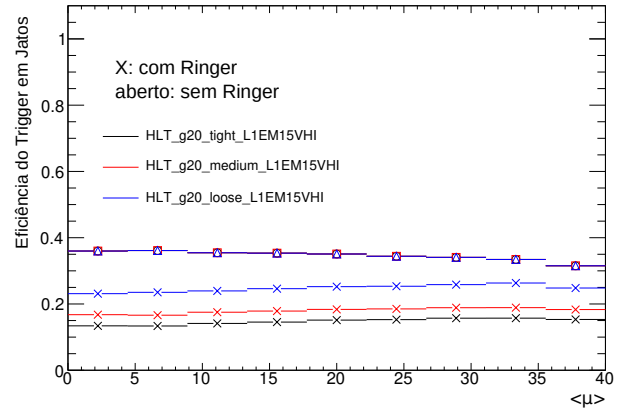


Figura 14: Análise de eficiência da etapa Rápida medida sobre jatos com relação ao empilhamento, considerando os critérios *Tight*, *Medium* e *Loose*

Já na Fig. 16 os três critérios apresentam desempenhos distintos, uma vez que essa medida é feita em todo o sistema de *trigger*, incluindo a etapa Precisa. Nessa análise, nota-se a redução. Deve-se destacar que a redução é significativa, haja vista a alta taxa de eventos. Dessa forma, a frequência de com que os eventos são salvos para análise *offline* é reduzida, poupando os requisitos de armazenamento e facilitando a busca pelos raros eventos de interesse.

As análises mostradas aqui evidenciam que a técnica NeuralRinger aplicada para fótons mantém a eficiência no sistema de seleção *online* de eventos e reduz a aceitação de

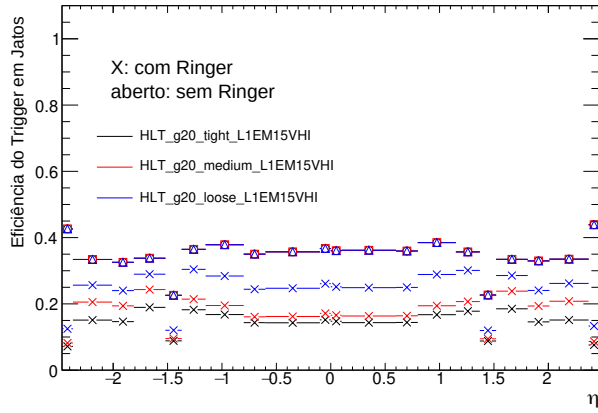


Figura 15: Análise de eficiência da etapa Rápida medida sobre os jatos com relação a coordenada η , considerando os critérios *Tight*, *Medium* e *Loose*




Figura 16: Análise de eficiência do HLT medida sobre os jatos com relação a energia, considerando os critérios *Tight*, *Medium* e *Loose*

jatos quando comparada com a técnica atual do experimento ATLAS. Dessa forma, a técnica poupa custo computacional das etapas posteriores à etapa rápida e diminui a escrita em disco ao final do processamento dos eventos.

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 Neural-Ringer, que faz uso de redes neurais artificiais, mostra-se uma interessante abordagem nesse contexto. A adaptação desta técnica para a detecção rápida de fótons exhibe 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.

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] D. J. Griffiths, *Introduction to elementary particles; 2nd rev. version*. Physics textbook, New York, NY: Wiley, 2008.
- [2] L. Evans and P. Bryant, "LHC machine," *Journal of Instrumentation*, vol. 3, pp. S08001–S08001, aug 2008.
- [3] ATLAS Collaboration, "The ATLAS experiment at the CERN Large Hadron Collider," *Journal of Instrumentation*, S08003 (2008), 01 2008.
- [4] I. De Lotto and D. Dotti, "Pile-up effects in time measurements," *Nuclear Instruments and Methods*, vol. 39, no. 2, pp. 281 – 292, 1966.
- [5] 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.
- [6] 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.
- [7] S. S. Haykin, *Neural networks and learning machines*. Upper Saddle River, NJ: Pearson Education, third ed., 2009.
- [8] 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.
- [9] C. Shimmín, 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.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] R. Wigmans, *Calorimetry: Energy Measurement in Particle Physics*. International series of monographs on physics, Clarendon Press, 2017.
- [14] 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.
- [15] A. Ruiz-Martinez and A. Collaboration, "The Run-2 ATLAS Trigger System," tech. rep., CERN, Geneva, Feb 2016.
- [16] 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.
- [17] 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.
- [18] 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.
- [19] E. F. Simas Filho, J. M. de Seixas, and L. P. Calóba, "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).
- [20] D. Kingma and J. Ba, "Adam: A method for stochastic optimization," *International Conference on Learning Representations*, 12 2014.