

# DESENVOLVIMENTO DE ALGORITMOS COMPUTACIONAIS PARA IDENTIFICAÇÃO DE ELÉTRONS PARA O EXPERIMENTO ATLAS

David de Melo Souza<sup>1</sup>  
Candida A. D. Meneguim<sup>2</sup>  
Fernando M. V. Xavier<sup>3</sup>  
Rafael Antunes Nóbrega<sup>4</sup>

## RESUMO

O experimento ATLAS no CERN, localizado na Suíça, é um detector capaz de identificar partículas provenientes da colisão de feixes de prótons produzidas pelo LHC. Este detector conta com sistemas de seleção de eventos que identificam as partículas de decaimento relevantes para as pesquisas realizadas pela Colaboração ATLAS. Um dos algoritmos mais relevantes destes sistemas é responsável pela identificação de elétrons. O presente trabalho apresenta dois algoritmos de discriminação, um linear, baseado no Modelo Linear Generalizado, e outro não-linear, baseado em Redes Neurais Artificiais, implementados na UFJF. Dados de simulação de Monte Carlo do experimento são utilizados para avaliação dos dois algoritmos a partir de uma comparação com o algoritmo atualmente empregado pelo experimento, conhecido como eGamma.

**Palavras-chave:** ATLAS. Calorímetros. Identificação elétron/jato.

## 1. INTRODUÇÃO

O CERN (do francês *Conseil Européen pour la Recherche Nucléaire*) é um dos principais laboratórios de colaboração internacional, composto por inúmeros países (CERN, 2012). Dentro de seu âmbito, inúmeros experimentos físicos são realizados. A busca por novos conhecimentos levou à construção do acelerador de partículas LHC (do inglês *Large Hadron Collider*) (Evans, 2008), com o objetivo de comprovar experimentalmente mecanismos e teorias desenvolvidas na área de física de partículas. O LHC pode colidir pacotes de prótons com até 14 TeV de energia de centro de massa.

---

1 Bolsista do Programa PIBIC/CNPq da UFJF.

2 Mestrando colaborador da Universidade Federal de Juiz de Fora.

3 Doutorando colaborador da Universidade Federal de Juiz de Fora.

4 Professor Orientador da Faculdade de Engenharia E - UFJF. Endereço Profissional do Professor Orientador: Universidade Federal de Juiz de Fora, Rua José Lourenço Kelmer, s/n - São Pedro 36036-900 - Juiz de Fora - MG - Brasil, Campus Universitário - Faculdade de Engenharia - Departamento de Circuitos Elétricos, sala 4274/E08.

Em especial, o LHC é composto por um túnel circular, com aproximadamente 27 km de extensão. Os pacotes de prótons circulam pelo acelerador até atingirem a energia cinética desejada, colidindo então contra prótons que foram aceleradas no sentido contrário. Um dos principais detectores do LHC é o ATLAS (do inglês *A Toroidal LHC ApparatuS*). Este detector, de uso geral, é capaz de detectar inúmeras partículas. O ATLAS é dividido em quatro principais seções: o detector de traços, utilizado para medir o percurso que partículas carregadas fazem até chegarem aos calorímetros; os calorímetros eletromagnético e hadrônico, empregados para medir, respectivamente, a energia depositada por partículas eletromagnéticas leves e por partículas hadrônicas; e as câmaras de múon, capazes de detectar a passagem de múons. A Figura 1 mostra uma ilustração do detector ATLAS e seus subdetectores.

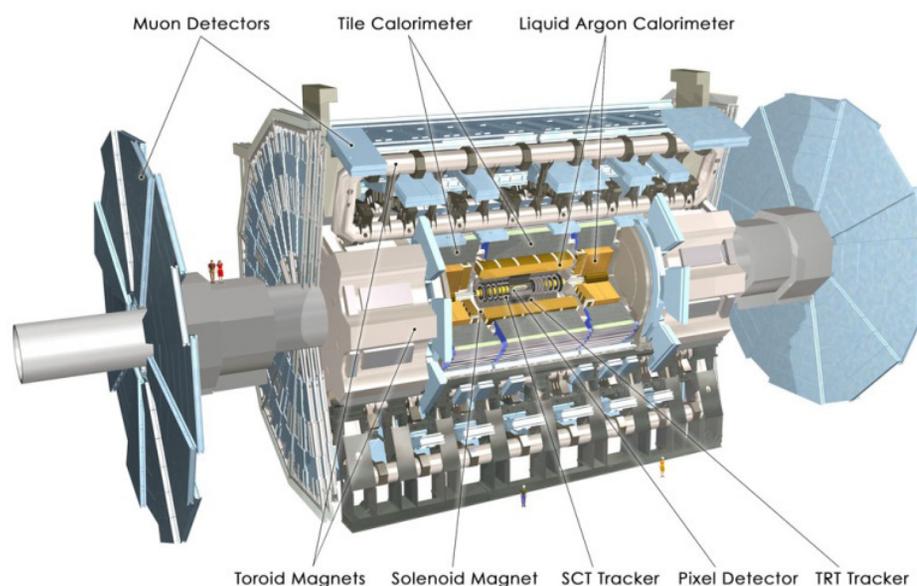


Fig. 1 - O detector ATLAS e seus detectores (ATLAS Collaboration, 2010).

Um dos objetivos do LHC é a comprovação da partícula conhecida como bóson de Higgs, prevista no Modelo Padrão (Cheng, 2006). Esta partícula explicaria o mecanismo no qual as partículas adquirem massa. Porém, por ser uma partícula extremamente energética, o Higgs tem um curtíssimo período de vida, o que impossibilita sua observação direta. Partículas que têm energias elevadas decaem rapidamente em outras partículas com menor energia, mais estáveis e, por sua vez, observáveis. A reconstrução da energia e da trajetória dessas partículas mais estáveis pode levar a descoberta do bóson de Higgs. Porém, estes eventos de interesse do LHC são muito raros, demandando alta luminosidade e longo tempo de aquisição. Por operar a elevadas taxas, levando em conta que a taxa de colisão entre grupos (*bunches*) de prótons é de 40 MHz, os sistemas de aquisição de dados dos detectores, e em especial do ATLAS, devem ser cuidadosamente projetados. Cada evento carrega, aproximadamente, 1,5 MB de dados de informação, gerando um fluxo de dados da ordem de 60 TB por segundo. O armazenamento de toda a informação fornecida pelo detector para posterior análise é impossível. Ademais, os eventos de interesse para o experimento ocorrem raramente, como mencionado acima. Desta maneira, um sistema de filtragem *online* (conhecido também como sistema de *trigger*) torna-se indispensável ao experimento, o que, no ATLAS, é realizado por três níveis em cascata, de forma a reduzir a taxa de eventos gradualmente. Uma vez aceito pelo terceiro nível, o evento é então armazenado para futura análise (*offline*). Nesta etapa utiliza-se, em geral, algoritmos mais eficientes e complexos, uma vez que não há compromisso com requisitos de tempo.

O trabalho descrito neste documento se concentra na identificação de elétrons; a assinatura de maior frequência do bóson de Higgs. No caso, utiliza-se apenas a informação de calorimetria do detector. A identificação de elétrons é dificultada pelo elevado ruído de fundo do experimento, representado aqui por jatos. Neste trabalho são utilizados dois algoritmos: um baseado em uma classificação linear e outro em uma classificação não-linear, este último baseado em Rede Neural Artificial (RNA) (Haykin S., 2008). Testes foram realizados com o intuito de promover uma comparação entre os algoritmos no problema de separação entre elétrons e jatos para compreender a importância da não-linearidade na classificação desses eventos.

## 2. METODOLOGIA

Primeiramente é necessário entender a importância do sistema de filtragem do ATLAS e alguns conceitos essenciais na obtenção dos dados para este tipo de análise, logo após encontraremos algumas alternativas para desenvolver dois classificadores para identificação do elétron e do jato.

### 2.1 SISTEMA DE FILTRAGEM DO ATLAS

O sistema de filtragem do ATLAS deve ser capaz de separar, de forma eficiente e rápida, a física de interesse (decaimentos do bóson de Higgs, por exemplo) da massa de dados já conhecida, que funciona como ruído de fundo do experimento. Para isto, foi concebido um sistema de filtragem (ATLAS *Trigger and Data Acquisition Collaboration*, 2000) dividido em três níveis (Figura 2).

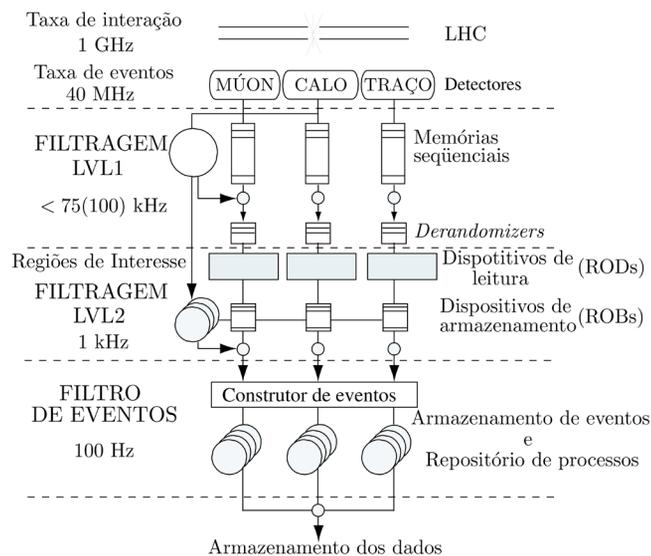


Fig. 2 - Esquema do sistema de filtragem do detector ATLAS (ATLAS *Collaboration*, 2010).

O primeiro nível de *trigger*, que realiza a seleção *online* dos eventos, possui um tempo de latência máxima de  $2\mu\text{s}$  e a maior taxa de filtragem de eventos. Assim, seu processamento é feito todo em hardware de alta velocidade, basicamente com FPGA (do inglês *Field Programmable Gate Array*), utilizando somente informação de câmaras rápidas de múons e de calorimetria com granularidade menos fina, obtida pela soma de células de deposição de energia. Este nível é responsável, também, por selecionar as regiões do calorímetro onde houve deposição significativa de energia, as chamadas

Regiões de Interesse (RoI - do inglês *Regions of Interest*) (Berge, 2007), e passá-las ao segundo nível de *trigger*. O segundo nível irá, então, processar somente os eventos selecionados pelo primeiro nível, já separados em RoI. Os eventos rejeitados pelo primeiro nível são definitivamente descartados. Neste segundo nível, utiliza-se a granularidade plena do ATLAS, de modo a refinar a decisão do primeiro nível. Como a taxa de eventos é menor no segundo nível (100 kHz), seu tempo de latência é de 10 ms, sendo sua implementação em software. O terceiro nível possui uma latência maior (aproximadamente 1 s), esperando-se que a taxa de gravação de eventos em mídia permanente não passe de 100 Hz. Os eventos salvos são geralmente usados em análises mais detalhadas e com menor preocupação com os requisitos de tempo.

## 2.2 EXTRAÇÃO DAS CARACTERÍSTICAS: PROCESSO DE ANELAMENTO

Observando as RoI de elétrons e jatos típicos do segundo nível de *trigger*, nota-se que as sutis diferenças entre os dois padrões de deposição de energia se encontram no espalhamento da deposição de energia e nas relações dos picos energéticos. Com base nessas diferenças entre elétrons e jatos, foi desenvolvido um algoritmo para extração da informação de calorimetria baseado na construção de anéis concêntricos (Torres, 2010), onde a célula de maior energia é o anel central. A informação referente a este anel é a energia armazenada na célula. Os anéis posteriores contêm a soma da energia das células adjacentes exteriores ao anel anterior.

Este processo irá se repetir até que uma região pré-determinada seja completamente preenchida. O processo de anelamento é realizado para todas as camadas dos calorímetros hadrônicos e eletromagnéticos. A Tabela I exibe o número de anéis extraídos para cada camada, totalizando 100 anéis. Estes anéis são usados como características para a identificação elétron/jato.

Tab. I - Quantidade de anéis por camada dos calorímetros.

	Camadas eletromagnéticas				Camadas hadrônicas		
	OS	1a	2a	3a	1a	2a	3a
Nº de Anéis	8	64	8	8	4	4	4

## 2.3 CLASSIFICAÇÃO DOS EVENTOS

Os eventos utilizados neste trabalho são provenientes de simulações de Monte Carlo produzidas pela Colaboração ATLAS. Como sinal, foram gerados elétrons isolados com energias entre 7 GeV e 80 GeV, e como ruído, jatos que possuem ao menos uma componente eletromagnética, que podem ser classificados erroneamente como elétrons. A colaboração ATLAS utiliza hoje um algoritmo chamado de eGamma (ATLAS *Collaboration*, 2010) desenvolvido para a identificação de elétrons utilizando apenas os detectores de calorimetria. Os resultados que mostraremos nesse documento usam como referência a saída do eGamma. Este algoritmo permite selecionar três níveis de cortes para a classificação de elétrons: *Loose*: com este nível espera-se uma maior taxa de erros de classificação de elétrons, ou seja, que um maior número de jatos seja classificado erroneamente como elétron, porém o número de elétrons classificados como jato é minimizado; *Tight*: neste nível, espera-se que um número maior de elétrons seja classificado erroneamente como jatos, porém o número de jatos classificados como elétrons é minimizado, fazendo com que a seleção de elétrons seja menos contaminada com eventos falsos; e *Medium*: que tenta conciliar ambas as características. Quando os dados são aprovados por quaisquer dos cortes, entende-se que ele é classificado como elétron, logo, a expressão “jatos aprovados” significa que

jatos foram classificados erroneamente como elétrons. Analogamente, “elétrons reprovados” significa elétrons classificados erroneamente como jatos.

Neste trabalho, foi utilizado como jatos, o conjunto de eventos reprovado por todos os critérios, *Loose*, *Medium* e *Tight* (000), dando um total de 571.336 eventos, e como elétrons, o conjunto de eventos aprovados pelos critérios *Medium* e *Tight*, somando um total de 77.280 eventos.

Para o caso da RNA, esses dados foram separados em três grupos padrões (Haykin S., 2008):

- Treinamento: 50% para atualizar os pesos sinápticos da rede de modo a minimizar a função custo que nesta rede é o Erro Médio Quadrático;
- Teste: 25%, utilizados para garantir boa generalização da rede;
- Validação: 25%, utilizados para testar o desempenho.

Para o classificador linear, os dados de Treinamento e Teste (da RNA) foram utilizados para calcular os pesos do classificador garantindo assim que os mesmos dados fossem utilizados, tanto na parte de cálculo dos parâmetros como na parte de medida de desempenho, pelos dois classificadores.

Além dos conjuntos que foram utilizados para o treinamento dos classificadores, os outros conjuntos formados pelos cortes feitos pelo sistema de filtragem na seleção de dados foram também classificados pelos dois métodos.

Esses conjuntos para jatos são:

- Aprovados pelo critério *Loose* (001), no total de 72.811 eventos;
- Aprovados pelo critério *Medium* (011) no total de 9.750 eventos;
- Aprovados pelo critério *Tight* (111) no total de 1.131 eventos.

E para os elétrons:

- Reprovados por todos os critérios (000) no total de 5.964 eventos;
- Aprovados pelo critério *Loose* (001) no total de 9.576 eventos.

A técnica de pré-processamento PCA (**Principal Component Analysis**) foi utilizada com o intuito de analisar a correlação entre os anéis. Foi possível perceber que se utilizarmos os 15 anéis com maior variância, tanto para elétron como para jato, a soma das variâncias dos anéis seria aproximadamente igual à soma das variâncias das componentes principais como mostra a Figura 3 para elétrons e a Figura 4 para jatos. Note que o uso do pré-processamento é justificado apenas se a análise das primeiras componentes for necessária ou suficiente. Vale ressaltar que a aplicação da PCA se justifica principalmente para o caso de seleção de eventos *online*.

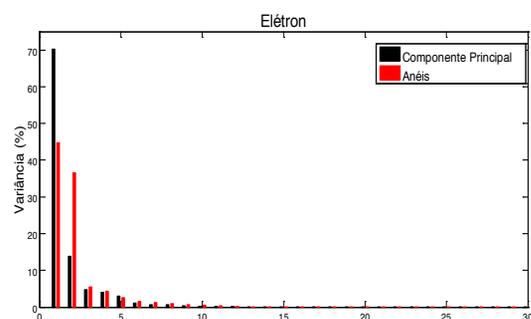


Fig. 3 - Comparação entre anéis sem pré-processamento e com PCA para elétrons.

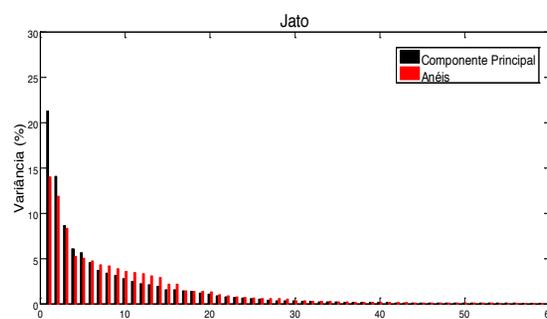


Fig. 4 - Comparação entre anéis sem pré-processamento e com PCA para jatos.

### 2.3.1 CLASSIFICADOR LINEAR

Baseado no processo de Bernoulli (Peebles, 1987) que envolve experimentos para os quais apenas duas saídas são possíveis, representadas no espaço amostral por  $\{0, 1\}$ , temos que:  $p(y=1) = h_\theta(x)$  e  $p(y=0) = 1-h_\theta(x)$ . Onde  $h_\theta(x)$  é a média  $\phi$  da distribuição de Bernoulli e representa a probabilidade que, dado  $x$ ,  $y$  seja igual à classe  $\{1\}$ . Essas duas relações podem ser consideradas em uma única equação, dada por:

$$p(y|x; \theta) = h_\theta(x)^y (1-h_\theta(x))^{1-y}$$

Logo,  $p(y|x; \theta)$  representa a probabilidade de  $y$  dado  $x$  parametrizado por  $\theta$ . Note que a função  $p(y|x; \theta)$  pode ser escrita em sua forma exponencial:

$$p(y|x; \theta) = \exp \left\{ y \ln \left( \frac{h_\theta(x)}{1-h_\theta(x)} \right) + \ln(1-h_\theta(x)) \right\}$$

Formulando a distribuição de Bernoulli como uma distribuição da família exponencial, temos que o parâmetro natural da equação exponencial  $p(y|x; \theta)$  é dado por  $\eta = \ln[h_\theta(x)/(1-h_\theta(x))]$ ; Logo, se  $y|x; \theta \sim \text{Bernoulli}(\phi)$ , então  $\phi = 1/(1+e^{-\eta})$  e  $E[y|x; \theta] = \phi$ . Baseando-se no Modelo Linear Generalizado (MLG) (Nelder, 1972),  $\eta$  é representado por uma combinação linear entre as características do evento e os seus pesos de forma que  $\eta = \theta^T X = \sum_{k=0}^N \theta_k x_k$ , sendo que  $x_0=1$ . Assim encontramos a nossa hipótese  $h_\theta(x)$ :

$$h_\theta(x) = \frac{1}{1+e^{-\eta}}$$

Assumindo que os dados,  $x_k^i$  e  $y_k^i$  (os  $i$ 's se referem às várias medidas e os  $k$ 's às várias características do evento), empregados para achar os parâmetros  $\theta_k$ , sejam gerados independentemente, podemos escrever a equação de verossimilhança dos parâmetros  $L(\theta)$  como:

$$L(\theta) = p(\vec{y} | X; \theta) = \prod_{i=1}^m (h_\theta(x^i))^{y^i} (1-h_\theta(x^i))^{1-y^i}$$

Temos então que: maximizar  $L(\theta)$  é o mesmo que minimizar a derivada de  $\ell(\theta) = \ln\{L(\theta)\}$ , o que nos leva a seguinte equação:

$$-\frac{\partial}{\partial \theta_k} \ell(\theta) = (y - h_\theta(x)) x_k$$

Podemos usar então o algoritmo LMS (do inglês *Least Mean Square*) para encontrar os parâmetros  $\theta_k$  que levam à máxima verossimilhança.

Usando todos os 77.280 dados (sem normalização) disponíveis para achar os parâmetros  $\theta_k$ , definimos completamente a nossa função  $h_\theta(x)$ . Como parâmetro de avaliação do desempenho desta fase de treinamento usou-se o produto SP, dado por:

$$SP = 100 \times \sqrt{P_e \times P_j \times \left( \frac{P_e + P_j}{2} \right)}$$

onde  $P_e$  e  $P_j$  são as probabilidades de detecção de elétrons e jatos.

O SP encontrado para o classificador linear foi de 99,22 e nesta análise (linear) tem apenas o caráter comparativo (entre os métodos), visto que o critério de parada utilizado para este classificador foi o erro médio quadrático.

### 2.3.2 CLASSIFICADOR NEURAL

A Rede Neural Artificial é composta de um perceptron multi-camadas feed-forward contendo 10 neurônios na sua única camada escondida, sua camada de saída é composta por um único neurônio e a camada de entrada recebe os 100 anéis. Os alvos utilizados foram +1 para o sinal (elétrons) e -1 para o ruído (jato). Todos os neurônios utilizam função de ativação hiperbólica.

Foi observado (Torres, 2010) que a rede neural apresentou melhores resultados quando o produto SP foi utilizado como critério de parada, em comparação com o MSE (do inglês *Mean Squared Error*). Enquanto o critério de parada por MSE visa encontrar o ponto onde a saída da rede neural fica mais parecida possível com o alvo especificado, o SP procura o ponto onde a distinção máxima entre as classes é obtida, sendo esse critério mais apropriado para redes neurais destinadas à reconhecimento de padrões.

Para a rede neural utilizada optou-se por não fazer a normalização dos dados, pois apresentou valores de SP e de eficiência do conjunto de teste ligeiramente melhores que quando normalizados.

Como o conjunto dos jatos possui muito mais eventos que o conjunto dos elétrons, foram criados subconjuntos dos jatos para que cada época contivesse um número igual de elétrons e jatos, evitando assim que a rede neural se especialize na classe de jatos. A cada rodada, somente metade do subconjunto de jatos é substituída por novos eventos, impedindo que um conjunto seja muito diferente do anterior, o que prejudicaria o treinamento da rede. Esse processo se mantém até que todo o conjunto de dados passe pela rede, completando 14 épocas no total. O critério de parada é introduzido à rede depois que todos os subconjuntos de jatos tenham passado pela primeira vez na rede. A partir deste ponto, se o produto SP do conjunto de teste tiver variação menor que 0,15 por 14 épocas seguidas, a rede encerra o treinamento, pois a estabilização dos pesos foi atingida. A rede salva é aquela que apresenta o maior valor de SP para o conjunto de teste. O resultado encontrado pela a melhor Rede Neural Artificial pode ser dado em termos de produto SP, igual a 99,6571.

### 2.4 EFICIÊNCIA DOS CLASSIFICADORES

A fim de quantificar este estudo definimos eficiência como a porcentagem de eventos classificados corretamente em relação ao número total de eventos, da seguinte forma:  $Eficiência = (Hit / All) * 100\%$ , onde *Hit* representa os eventos classificados corretamente e *All* representa todos os eventos classificados de cada respectivo conjunto. Por fim encontramos as seguintes eficiências para os classificadores:

Tab. II - Eficiência dos classificadores para cada conjunto.

<b>Classificador Linear</b>	<b>Rede Neural</b>
<b>Eficiências dos conjuntos de Elétrons:</b>	<b>Eficiências dos conjuntos de Elétrons:</b>
Conjunto de validação = 99.43%	Conjunto de validação = 99.76%
Conjunto 001 = 88.04%	Conjunto 001 = 91.04%
Conjunto 000 = 77.59%	Conjunto 000 = 79.02%
<b>Eficiências dos conjuntos de Jatos:</b>	<b>Eficiências dos conjuntos de Jatos:</b>
Conjunto de validação = 99.22%	Conjunto de validação = 99.48%
Conjunto 001 = 93.08%	Conjunto 001 = 94.84%
Conjunto 011 = 94.88%	Conjunto 011 = 95.73%
Conjunto 111 = 86.47%	Conjunto 111 = 89.57%

Nesta seção percebemos a concordância entre os métodos e ainda verificamos o quanto os classificadores têm coerência com o algoritmo da colaboração, pois os eventos selecionados pelos critérios mais exigentes (pelo eGamma) são classificados mais facilmente e como ponto positivo desta análise verificamos que os eventos classificados erroneamente (pelo eGamma) obtiveram eficiências relativamente altas.

## 2.5 HISTOGRAMA DOS CLASSIFICADORES

### CLASSIFICADOR LINEAR

Os resultados de todos os conjuntos são apresentados nas Figuras 5 e 6:

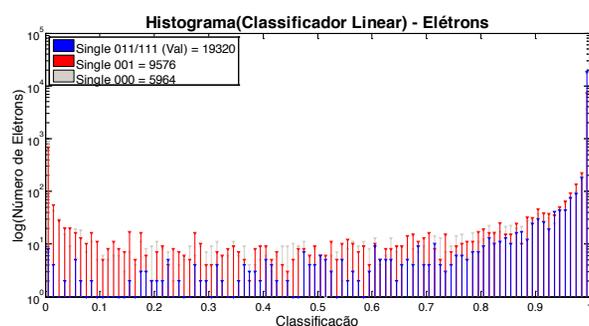


Fig. 5 - Histograma para elétrons.

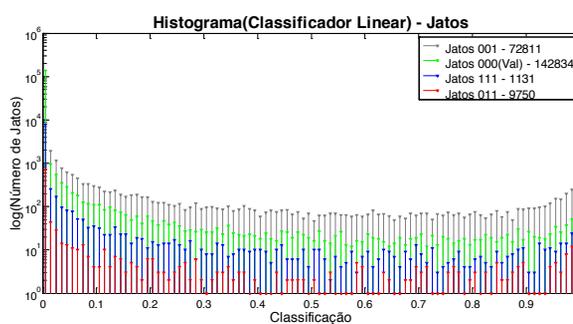


Fig. 6 - Histograma para Jatos.

### CLASSIFICADOR NEURAL

Os resultados de todos os conjuntos são apresentados nas Figuras 7 e 8 abaixo:

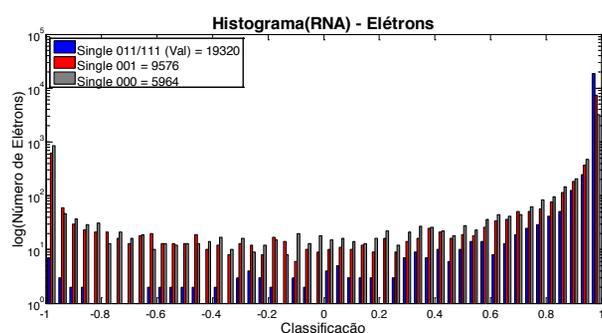


Fig. 7 - Histograma para elétrons.

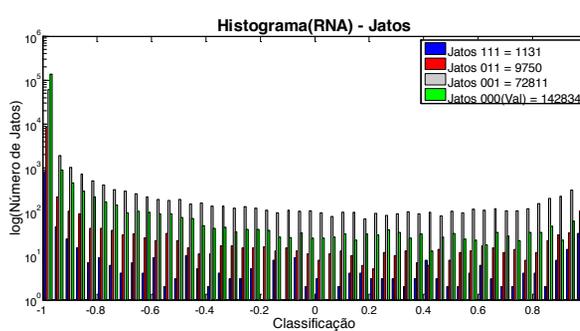


Fig. 8. -Histograma para jatos.

Nos quatro histogramas anteriores percebemos a disposição dos eventos classificados corretamente e erroneamente para cada conjunto, ao atentarmos para a escala logarítmica no eixo Y percebemos o quão eficientes são os dois métodos em foco.

## 2.6 COMPARAÇÕES ENTRE OS DOIS ALGORITMOS

Os histogramas a seguir (Figuras 9 e 10) apresentam os resultados dos conjuntos de validação, tanto para a Rede Neural quanto para o Classificador Linear.

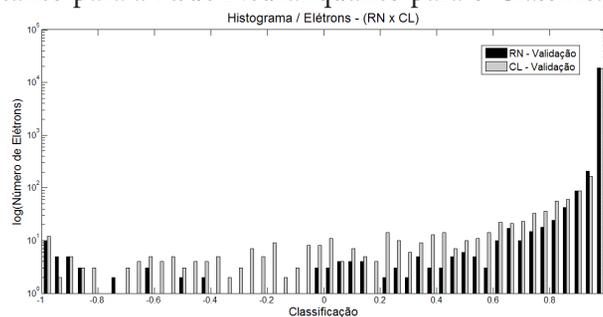


Fig. 9 - Histograma de comparação para o conjunto de validação dos elétrons.

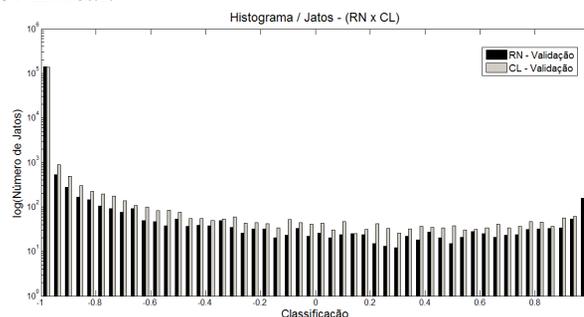


Fig. 10 - Histograma de comparação para o conjunto de validação dos jatos.

Ao observarmos os histogramas percebemos como o perfil de deposição das partículas nos diferentes calorímetros se traduz nos métodos empregados, o perfil de deposição do elétron é mais concentrado do que a do jato tornando seu subespaço n-dimensional mais bem definido, diminuindo sua região de confusão.

### 3. CONCLUSÃO

Este artigo apresentou a comparação entre dois métodos de classificação que nos possibilitam fazer a identificação de elétrons e jatos, um linear e outro não linear, aplicados aos dados de Monte Carlo gerados pelo experimento ATLAS com o intuito de classificar elétrons e jatos que atingem os detectores de calorimetria.

Foram feitas comparações entre as eficiências dos dois classificadores baseadas em cada um dos critérios (*medium*, *loose* e *tight*) utilizados pelo algoritmo eGamma. Nota-se que as classificações, referenciadas no eGamma, obtiveram uma eficiência alta, o que demonstra com clareza a tendência dos dois algoritmos a classificar corretamente os eventos validados pelo eGamma. Podemos traduzir de uma forma quantitativa as afirmações ao analisarmos as eficiências do conjunto de elétrons classificados pelos dois métodos. No Classificador Linear o conjunto de validação obteve uma eficiência de 99.43%, na Rede Neural essa eficiência chega a 99.76%, ou seja, existe uma concordância entre os resultados do eGamma e os dois métodos em relação ao conjunto de elétrons. Análogo a esses resultados são os obtidos para o conjunto de validação dos jatos, onde o Classificador Linear conseguiu uma eficiência de 99.22% e a Rede Neural obteve 99.48%.

A escolha entre a utilização dos métodos depende da necessidade da aplicação e a natureza dos dados, tendo em vista que uma implementação do Classificador Linear requer um menor esforço computacional, necessitando, porém, de uma quantidade suficiente de eventos para treinamento. Já o Classificador Neural consegue uma eficiência melhor, porém demanda um maior esforço computacional.

## DEVELOPMENT OF COMPUTER ALGORITHMS FOR IDENTIFICATION OF ELECTRONS FOR THE ATLAS EXPERIMENT

### ABSTRACT

The ATLAS experiment at CERN, located in Switzerland, is a detector capable of detecting particles coming from the proton-proton collisions produced by the LHC. This detector counts on a Trigger System to select the events related to the physics of interest. Monte Carlo simulation data are employed in the present work to evaluate and to compare two discriminative algorithms, one using a linear method, based on the Generalized Linear Model, and other using a non-linear Artificial Neural Network method.

**Keywords:** ATLAS. Calorimeters. Electron/Jet identification

### 4. REFERÊNCIAS

ATLAS Collaboration (2010) Performance of the electron and photon trigger in p-p collisions at a centre of mass energy of 900 GeV Tech. Rep. ATLAS-CONF-2010-022 CERN.

ATLAS Collaboration (2008) **Journal of Instrumentation** 3 1.

BERGE D., AIELLI G., ANDREI V. et al. (2007) **Nucl. Instrum. Methods Phys. Res. A** 581 476

CERN, European Center for Nuclear Research. [www.cern.ch](http://www.cern.ch), acessado em 10 de março de 2012.

CHENG, T.P., LI L.F. (2006). Gauge theory of elementary particle physics. Oxford University Press.

EVANS L et al. (2008) **Journal of Instrumentation** 1.

HAYKIN S. (2008) Neural Networks and Learning Machines (Prentice Hall).

NELDER, J.; WEDDERBURN, R. (1972). “Generalized Linear Models”. **Journal of the Royal Statistical Society. Series A (General)** (Blackwell Publishing) 135 (3): 370–384.

PEEBLES, P. Z. Jr. (1987) Probability, Random Variables, and Random Signal Principles. 2ª ed.: McGraw-Hill.

TORRES, R. C. (2010) Sistema Online de Filtragem em um Ambiente com Alta Taxa de Eventos e Fina Granularidade, Rio de Janeiro, UFRJ/COPPE, 2010.