

# Otimização do Segundo Nível de Trigger do ATLAS Baseado em Calorimetria

A. dos Anjos, R.C. Torres, T.C. Xavier, B.C. Ferreira, J.M. Seixas

(1) Signal Processing Laboratory/COPPE/Federal University of Rio de Janeiro, Ilha do Fundão, Rio de Janeiro, RJ, Brazil

D.O. Damazio

(2) Brookhaven National Laboratory, New York, USA

(Received)

This paper presents an optimization of the electron/jet discriminator system operating at ATLAS/LVL2, in CERN. The Regions of Interests were mapped in 14 variables, representing the energy deposited through the calorimeter's layers, the geometry of the electric shower and its energy peaks. Those variable are fed into a feed forward neural network in two ways: all 14 variables were pre-processed with a Principal Components Analysis before feeding the neural network, decreasing the data dimensionality, and using only the variables used in the hypothesis algorithm, but replacing it by a feedforward neural network. The use of neural networks increased the detection of electron by a factor of 6%, for a same rate of false alarm. Some ideas for increasing the speed of the actual algorithm were also made.

## I. INTRODUÇÃO

O LHC (Large Hadron Collider) colisionará partículas com elevada energia no centro de massa, através de um tubo circular com 26,7 km de circunferência dotado de poderosos imãs para aceleração das partículas. Cada colisão constitui um evento a ser analisado através de detectores acoplados ao LHC. O ATLAS (A Toroidal LHC ApparatuS), visto na Figura 1, é um dos detectores do LHC [1]. Ele é composto por diferentes sistemas de detecção:

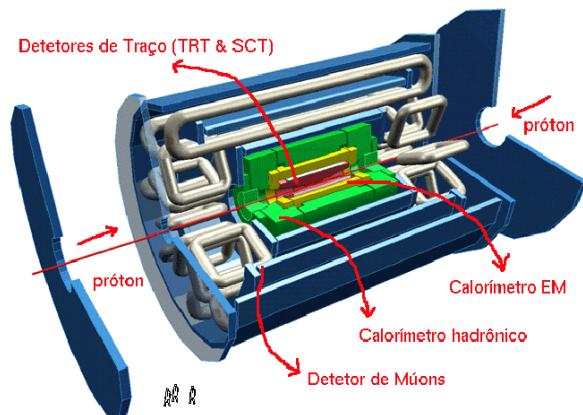


Figura 1: O ATLAS, de [1]

- Câmera de Arrasto - primeiro detector, localizado na região mais interna e altamente segmentado. A informação oferecida é uma imagem das trajetórias descritas pelas partículas.
- Calorímetros Hadronico e Eletromagnético - são capazes de medir a energia depositada pela partícula incidente. Permite a identificação de partículas.
- Câmara de Múons - é a parte mais afastada do centro e tem como objetivo a detecção de mísulas.

Um volume enorme de informação é gerado a cada colisão no LHC. Por outro lado, os eventos de possível interesse ocorrem com um período que varia de algumas horas a até dias de operação. Como cada evento carrega aproximadamente 1 MByte de informação, e espera-se uma taxa de 40 MHz de eventos sendo gerados, o fluxo de dados será da ordem de 40 TBytes por segundo, impossibilitando o armazenamento completo desses eventos para análise offline. Desta maneira, um sistema de filtragem online torna-se indispensável para o experimento. O sistema de filtragem deverá identificar eventos de interesse, para poder localizá-los na massa de eventos com física ordinária (ruído de fundo para o LHC).

Este trabalho tem como objetivo propor um classificador baseado em redes neurais artificiais, no canal elétron/jato, que otimize o atual algoritmo de classificação de partículas do segundo nível de Trigger que trabalha somente com informação de calorimetria, o T2Calo. Aliado ao uso de redes neurais artificiais, propõe-se técnicas de pré-processamento estatístico de forma a diminuir a dimensão dos dados de entrada da rede, tal como análise de componentes principais.

## II. O SISTEMA DE CALORIMETRIA

O sistema de coordenadas do detector ATLAS não é o sistema polar. É um sistema adequado ao formato cilíndrico dos detectores dispostos ao redor do ponto de impacto, ou seja, um sistema que acompanha a direção dos feixes de partículas provenientes da colisão. As coordenadas empregadas são  $\eta$ ,  $\phi$  e  $z$ . A variável  $\phi$  representa a rotação em torno do eixo de colisão  $z$ , e  $\eta$ , a chamada pseudo-rapidez, representa a direção de projeção das partículas, após a colisão.

O calorímetro e.m. do ATLAS [2] é dividido em 3 camadas com diferentes granularidades, sendo a segunda camada a mais profunda. Além disso, a seção e.m. é dividida em duas partes: o barril e a tampa. O barril e as duas tampas completam totalmente o espaço ao redor da colisão

até um valor de  $\eta = 3,2$ . O calorímetro eletromagnético tem, também, um pré-irradiador, que funciona praticamente como um calorímetro muito fino, com a função de recuperar a informação perdida no material morto da seção e.m. (fios, encapamentos, etc.).

A granularidade (resolução do detector no plano  $\eta \times \phi$ ) da seção e.m. é constante em relação à rotação (eixo  $\phi$ ), mas variável quanto ao eixo  $\eta$ . Nas três camadas, como no pré-irradiador, as granularidades e o tamanho das células de detecção são variáveis (Tabela 1).

Os calorímetros hadrônicos do ATLAS [3, 4] são formados pelo TileCal, ou calorímetro de telhas, e a Tampa Hadronica. O TileCal é posicionado logo depois do calorímetro eletromagnético, abrangendo as porções do barril ( $0 < |\eta| < 1,0$ ) e sua extensão ( $0,8 < |\eta| < 1,7$ ) da seção hadrônica dos calorímetros. Assim como a seção e.m., esta seção também possui granularidade variável, como visto na Tabela 2.

Camada	Peça	$\eta_{\text{início}}$	$\eta_{\text{fim}}$	$\Delta\eta \times \Delta\phi$	$N_\eta \times N_\phi$
<i>Pre-sampler</i>	Barril	0	1,5	$0,025 \times 0,1$	$4 \times 1$
	Tampa	1,5	1,8	$0,025 \times 0,1$	$4 \times 1$
Camada 1	Barril	0	1,4	$0,003125 \times 1$	$32 \times 1$
		1,4	1,475	$0,025 \times 0,025$	$4 \times 4$
	Tampa	1,375	1,5	$0,025 \times 0,1$	$1 \times 4$
		1,5	1,8	$0,003125 \times 0,1$	$32 \times 1$
		1,8	2,0	$0,004167 \times 0,1$	$24 \times 1$
		2,0	2,4	$0,00625 \times 0,1$	$16 \times 1$
		2,4	2,5	$0,025 \times 0,1$	$4 \times 1$
		2,5	3,2	$0,1 \times 0,1$	$1 \times 1$
Camada 2	Barril	0	1,4	$0,025 \times 0,025$	$4 \times 4$
		1,4	1,475	$0,075 \times 0,025$	$1 \times 4$
	Tampa	1,375	2,5	$0,025 \times 0,025$	$4 \times 4$
		2,5	3,2	$0,1 \times 0,1$	$1 \times 1$

Tabela 1: Granularidades do Calorímetro e.m.

Camada	Peça	$\eta_{\text{início}}$	$\eta_{\text{fim}}$	$\Delta\eta \times \Delta\phi$	$N_\eta \times N_\phi$
Camadas 1 e 2	Barril (TileCal)	0	1,0	$0,1 \times 0,1$	$2 \times 2$
	Barril Ext. (TileCal)	0,8	1,7	$0,1 \times 0,1$	$2 \times 2$
	Tampa (LAr)	1,5	2,5	$0,1 \times 0,1$	$2 \times 2$
		2,5	3,2	$0,2 \times 0,2$	$1 \times 1$
Camada 3	Barril (TileCal)	0	1,0	$0,2 \times 0,1$	$1 \times 2$
	Barril Ext. (TileCal)	0,8	1,7	$0,2 \times 0,1$	$1 \times 2$
	Tampa (LAr)	1,5	2,5	$0,1 \times 0,1$	$2 \times 2$
		2,5	3,2	$0,2 \times 0,2$	$1 \times 1$

Tabela 2: Granularidades e Dimensões do Calorímetro hadrônico.

O sistema de filtragem do ATLAS é concebido em três níveis (Figura 2), cada um com suas características definidas. Partindo de uma taxa de eventos de 40 MHz, a taxa de eventos armazenados precisa ser reduzida, ao final do processo de seleção, para aproximadamente 100 Hz para armazenamento em base de dados e posterior análise offline.

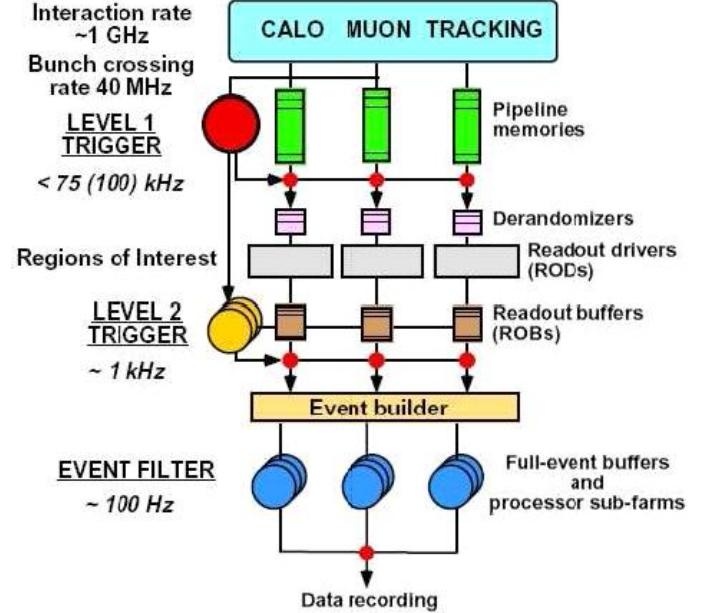


Figura 2: Sistema de Filtragem (Trigger) do ATLAS, de [1]

### III. SISTEMA DE FILTRAGEM DO ATLAS

O primeiro nível de trigger do ATLAS [5] realiza a seleção inicial dos eventos, sendo baseado na informação obtida com granularidade reduzida (baixa resolução) gerada por um subconjunto de detectores (calorimetria e detecção rápida de muôns). A granularidade neste nível é reduzida, uma vez que o tempo para a tomada de decisão neste nível é tão curto que torna-se necessário a redução da quantidade de informação a ser processada, para aumentar a velocidade de processamento. Este nível, então, descarta eventos com características bem distintas dos canais de interesse desejados. A taxa máxima de saída do primeiro nível de filtragem está limitada em 75 kHz (podendo ser expandida para 100 kHz).

É importante que se mantenha o tempo de latência (tempo para formar e distribuir a decisão do filtro) no valor mais baixo possível. Durante este tempo, a informação de todos os canais do detector precisa ser retida em memórias do tipo pipeline. Estas memórias estão geralmente contidas em circuitos integrados, posicionadas próximas ou junto ao detector, freqüentemente em regiões inacessíveis e imersas em ambientes de forte radiação. A latência do primeiro nível, medida do instante de uma colisão próton-próton até a decisão do primeiro nível estar disponível para o nível seguinte, deve

ser menor que  $2,5 \mu\text{s}$ . De forma a atender esta exigência, o primeiro nível de trigger está sendo implementado em hardware de baixa programabilidade na tecnologia FPGAs (Field Programmable Gate Array). O tempo de latência desejado para este nível de trigger foi, então, estipulado para  $2 \mu\text{s}$ , deixando-se  $500 \text{ ns}$  de margem de segurança.

De forma a reduzir o volume de tráfego de dados para o segundo nível, e, consequentemente, aumentar a banda passante entre estes dois níveis, o primeiro nível já marca as regiões de interesse (Region of Interest - RoIs), que correspondem a regiões do detector onde houve efetivamente a incidência de algum evento, e que foi aceito pelo primeiro nível, de tal maneira que o segundo nível observará somente estas regiões de interesse, e não toda a área do detector.

O segundo nível de trigger realiza o estágio seguinte do processo de filtragem, após a execução do primeiro nível. Este segundo nível, por sua vez, usa as regiões de interesse (RoIs) marcadas pelo primeiro nível para refinar a decisão do mesmo, validando a etiquetagem (resultado da classificação do primeiro nível) de cada ROI através da utilização da informação completa (resolução total dos detectores) de cada ROI. Todo este nível foi desenvolvido utilizando, o máximo possível, tecnologias padronizadas (comerciais), visando fácil reposição de material e implementação simplificada. Todos os processadores são de uso geral (tipo PC), e praticamente todas as comunicações entre estes dispositivos são feitas através de switchs Gigabit Ethernet, devido à velocidade, confiabilidade e padronização do protocolo. Todas as aplicações também estão desenvolvidas utilizando técnicas de orientação a objetos e totalmente implementadas em C++.

Para o segundo nível, então, foi definido um tempo de latência de, aproximadamente, 10 ms, onde a taxa de eventos que devem trafegar deste para o terceiro nível é da ordem de 1 kHz. Para ilustrar, na Figura 3 são mostradas RoIs típicas da segunda camada da seção e.m., para um elétron e um jato que passaram pelo primeiro nível, com diferenças sutis na deposição de energia.

O terceiro nível é o mais completo de todos. Dotado de uma latência maior (aproximadamente 1s), sua decisão é tomada baseando-se na informação de todos os subdetectores. Sua implementação também é feita em software com processadores normais (tipo PC), reduzindo o tráfego de dados entre ele e as mídias permanentes (onde as informações serão gravadas para posterior análise offline) para 100Hz.

#### IV. ALGORITMO T2CALO

A linha base de desenvolvimento na discriminação de chuveiros eletromagnéticos no segundo nível, com base em calorimetria, é o algoritmo T2Calo [6]. O primeiro passo do T2Calo é refinar a posição da ROI fornecida pelo primeiro nível a partir da célula com maior energia na segunda camada

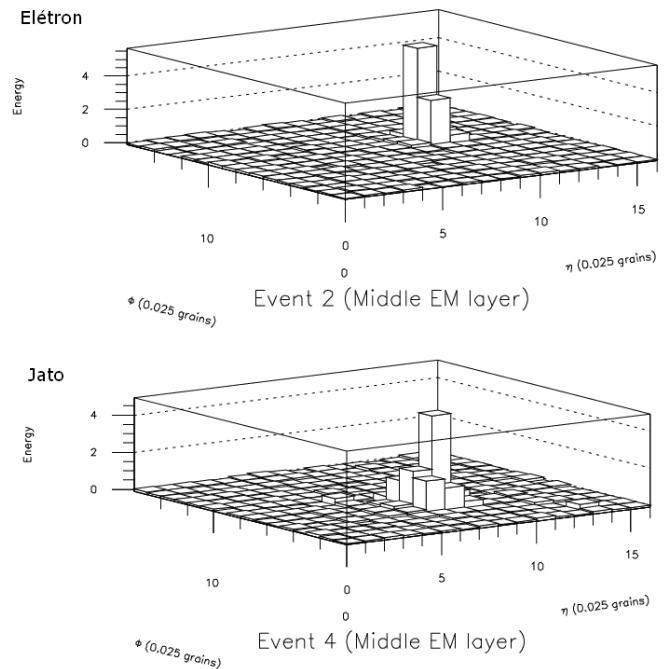


Figura 3: Duas RoIs típicas da segunda camada e.m..

do calorímetro eletromagnético (por ser a que mais absorve energia do evento). Esta nova posição ( $\eta_1; \phi_1$ ) é, então, refinada novamente calculando-se a posição ponderada de energia ( $\eta_c; \phi_c$ ) em uma janela de  $3x7$  células (em  $\eta \times \phi$ ), centralizadas em ( $\eta_1; \phi_1$ ). Em seguida, as seguintes variáveis são calculadas para realizar a identificação de elétrons:

$R_{shape} = E_{3x7}/E_{7x7}$ . Este valor é obtido da terceira camada eletromagnética. Entende-se por  $E_{n \times m}$  a energia depositada em uma janela de área ( $n \times m$ ), centrada em ( $\eta_c; \phi_c$ ). Esta variável leva em consideração o fato de que a maior parte da energia de chuveiros eletromagnéticos é depositada na segunda camada do calorímetro e.m. e representa o grau de espalhamento do chuveiro. Objetos e.m. apresentam chuveiros colimados, com pouca dispersão de energia.

$R_{\eta}^{strip} = (E_1 - E_2)/(E_1 + E_2)$ . Este valor é obtido da primeira camada eletromagnética, a partir de uma janela de  $\Delta\eta \times \Delta\phi = 0,125 \times 0,2$ , centrada em ( $\eta_c; \phi_c$ ).  $E_1$  e  $E_2$  são, respectivamente, as energias da primeira e segunda célula de maior energia. Objetos e.m. têm picos altamente energéticos.

$E_t$ . A energia transversa depositada no calorímetro eletromagnético é calculada em uma janela de  $3 \times 7$  células, centrada em ( $\eta_c; \phi_c$ ).

$E_t^{had}$ . É a energia que vaza para o calorímetro hadrônico, calculada em uma janela de tamanho  $\Delta\eta \times \Delta\phi = 0,2 \times 0,2$ , centrada em ( $\eta_c; \phi_c$ )

De posse destas variáveis, objetos e.m. podem ser discriminados na massa de jatos através de cortes, que tentam maximizar a eficiência de detecção em detrimento de uma pequena taxa de falso alarme. Tais cortes levam em conta as características de chuveiros eletromagnéticos: feixe de deposição bem colimado, pico único e altamente energético, maior interação da partícula com a seção e.m. do calorímetro e pouca energia na seção hadrônica. Idealmente, as variáveis  $R_{shape}$  e  $R_{\eta}^{strip}$  têm valor unitário. Alguns valores típicos destas variáveis para elétrons são mostrados abaixo.

- $R_{shape} \geq 0,90$
- $R_{\eta}^{strip} > 0,75$
- $E_t = 25,5 \times 10^3$
- $E_t^{had} = 2,2 \times 10^3$

A grande vantagem deste algoritmo reside na sua velocidade de execução, visto que, após o pré-processamento da informação da ROI, são necessários, no máximo, quatro análises condicionais para a aceitação / rejeição do evento. Testes mostraram uma eficiência de classificação de elétrons de 90,38%, para uma probabilidade de falso alarme de 15,71%.

## V. REDE NEURAL

O segundo nível de filtragem do experimento ATLAS pode utilizar redes neurais artificiais [7] (RNAs) em muitas de suas tarefas, como durante a fase de classificação de objetos locais. Eis algumas das características mais importantes destacadas para este nível:

**Robustez** - Em ambientes extremamente agressivos (sujeitos a falhas e radioatividade), como é o caso, RNAs podem manter um excelente desempenho, mesmo quando parte dos dados (canais de aquisição) de entrada ou neurônios são perdidos.

**Generalização** - RNAs podem extrair a informação relevante escondida sob uma grande quantidade de ruído. Os objetos a serem identificados têm, invariavelmente, essa característica.

**Identificação de novos fenômenos** - RNAs podem detectar a ocorrência de novos objetos de forma bastante eficaz. Isto é extremamente importante em ambientes que podem revelar resultados inesperados (nova física).

**Simples implementação** - Uma RNA pode ser implementada em hardware ou sistemas programáveis. Embora seja mais rápida se implementada em hardware dedicado, essa opção é inevitavelmente cara e pouco flexível.

Neste trabalho são propostas duas abordagens utilizando rede neural (ver Figura 4). Na primeira, troca-se o algoritmo de hipótese (o sistema condicional de cortes das quatro variáveis do T2Calo) por uma RNA. Na Segunda, utiliza-se toda a informação extraída pelo T2Calo da ROI - embora sejam quatro variáveis utilizadas no algoritmo de hipótese, existem outras 14 complementares que são extraídas e calculadas - como entrada da RNA, após um pré-processamento estatístico.

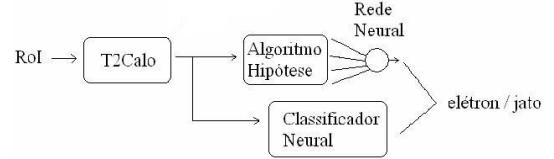


Figura 4: Esquema das implementações propostas com Redes Neurais Artificiais

## VI. T2CALO NEURAL

Uma massa de dados foi simulada para as colisões do LHC a serem lidas pelo ATLAS. Os dados brutos de simulação (que possuem a informação da colisão como um todo) foram emulados através do software de emulação do ATLAS, o Athena [8], passando por uma simulação de todo o sistema de filtragem, até o início do terceiro nível. Como resultado, aproximadamente 21.000 ROIs de elétrons e 7.000 de jatos passaram os cortes do primeiro nível e representam os dados simulados do segundo nível, com os quais este trabalho foi realizado.

O treinamento da rede neural artificial, para ambas as abordagens, foi feito dividindo-se a base de dados em duas partes, uma para o treinamento propriamente dito, e outra para o teste de generalização de sua resposta, sendo este utilizado tanto para o critério de parada, quanto para a validação da rede. Para tratar a diferença significativa entre o número de eventos de elétrons e jatos, o conjunto de dados foi replicado para que a estatística de elétrons não mascarasse a de jatos.

Na fase de treinamento foi utilizado o algoritmo de treinamento supervisionado *Resilient Backpropagation* [9]. A topologia escolhida para a rede neural artificial foi do tipo *Feedforward* com uma camada de neurônios escondida e um único neurônio na camada de saída, pois a resposta deve ser binária: ou temos um elétron ou um jato. O número de neurônios na camada escondida da rede foi variado de dois até o número máximo de variáveis de entrada, para a segunda abordagem, e fixado em quatro para a primeira abordagem. As fases do treinamento foram repetidas dez vezes, para cada topologia, para avaliarmos a flutuação estatística na eficiência de detecção, devido à inicialização na fase de treinamento.

A fim de diminuir a dimensão do espaço da entrada, para a segunda abordagem, utilizou-se uma análise de componentes principais (PCA) [10]. O espaço foi, então, diminuído de 14 para 12 variáveis, pois 12 componentes principais já armazenavam praticamente 100% da energia do sistema.

A Figura de mérito do projeto do discriminador escolhida foi o produto SP [7], pois ele relaciona as eficiências de detecção de ambas as classes, de forma que o valor de uma não mascare o valor da outra. É descrito pela fórmula abaixo:

$$SP = (\rho_1 * \rho_2) * (\rho_1 + \rho_2)$$

$$0 \leq SP \leq 2$$

onde  $\rho_1$  e  $\rho_2$  são as eficiências de detecção de jatos e elétrons.

O produto SP é usado na escolha da topologia da rede. Assim, uma análise da topologia contra o produto SP é mostrada na Figura 5, onde as barras de erro e o ponto médio são calculados da variação estatística proporcionada pelos diversos treinamentos efetuados para cada topologia.

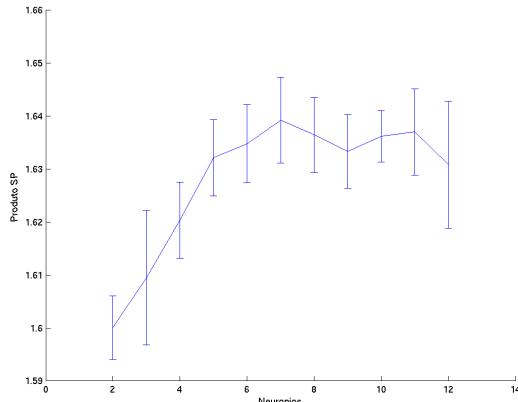


Figura 5: Produto SP em função do número de neurônios da rede neural para a segunda abordagem (vide texto).

A Figura 6 mostra a relação entre eficiência na detecção de elétrons contra a taxa de falso alarme, compondo a curva ROC (Receiver Operating Curve) de detecção. Tal curva é obtida variando o patamar de discriminação das distribuições da saída da rede classificadora para as duas classes (elétron e jato).

Podemos notar que a abordagem neural conseguiu melhor resultado: fixando-se um nível de falso alarme igual ao algoritmo clássico do T2Calo (15.71%) a eficiência de detecção da abordagem neural se mostrou melhor em cerca 5 pontos percentuais, atingindo 97,50% de eficiência de detecção para a primeira abordagem, contra 96,20% de eficiência de detecção

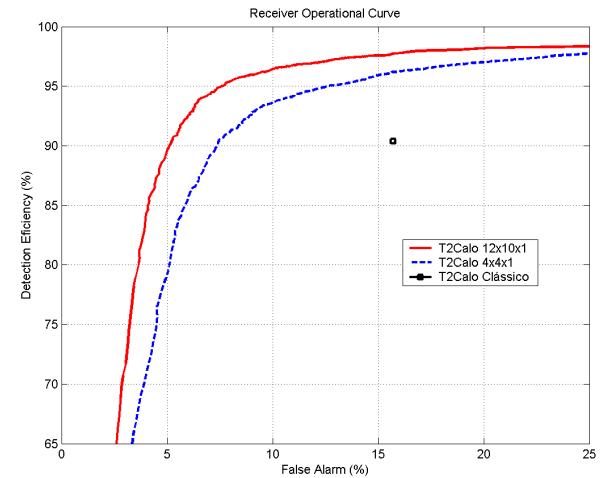


Figura 6: Curva ROC para as duas abordagens e o ponto de operação do algoritmo de hipótese.

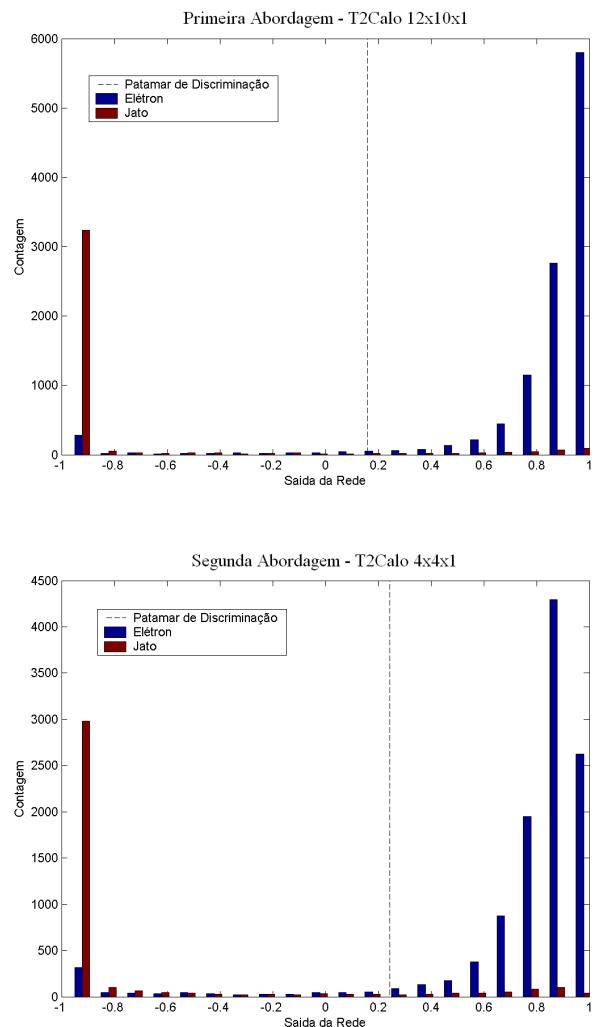


Figura 7: Histograma da resposta da rede neural para as duas abordagens, O primeiro

para a segunda abordagem. Os histogramas da Figura 7 mostram a saídas das redes para as duas abordagens, evidenciando que os elétrons são mais estreitados em torno de 1 na primeira abordagem do que na segunda, e os jatos para -1.

Como a granularidade do calorímetro é variável na direção de  $\eta$ , foi feito um estudo sobre a uniformidade da detecção. A Figura 8 mostra os resultados das duas abordagens neurais e do T2Calo clássico para diferentes valores de  $\eta$ . Há uma equivalência entre os métodos neurais no que diz respeito à eficiência de detecção, mas o mesmo não acontece para o falso alarme, onde a primeira abordagem mostra níveis bem menores de falso alarme em relação aos outros dois métodos. Já nas regiões laterais, os três métodos se alternam quanto à eficiência de detecção, mas a primeira abordagem continua apresentando menores índices de falso alarme.

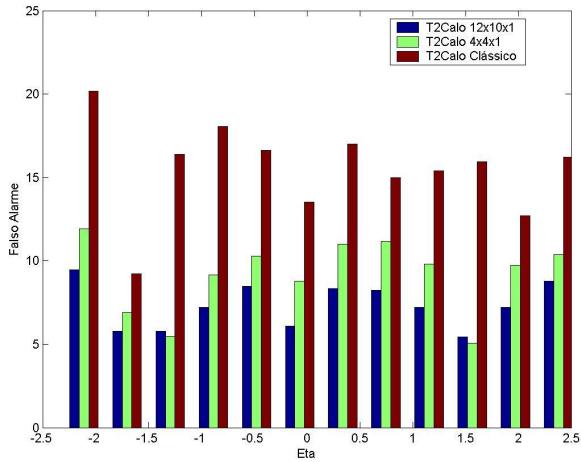
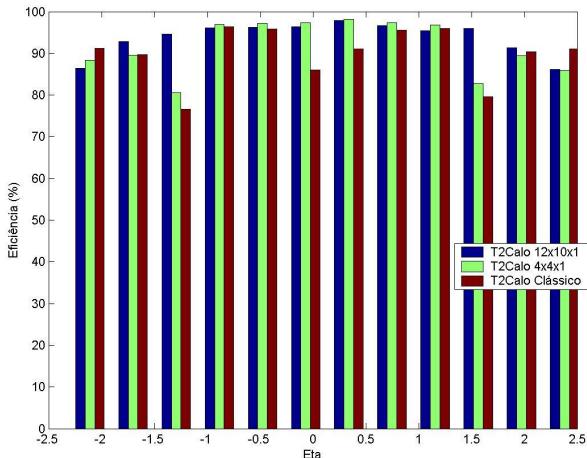


Figura 8: Eficiência de detecção e falso alarme de jatos em  $\eta$ .

Podemos entender a queda na eficiência de detecção de elétrons e aumento do falso alarme de jatos nos valores ex-

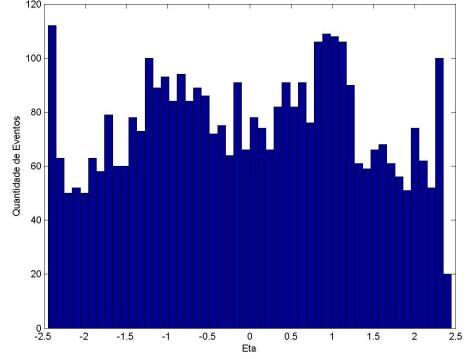
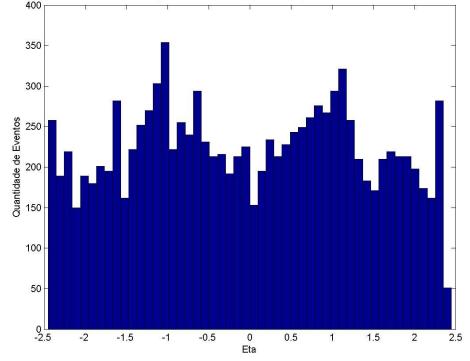
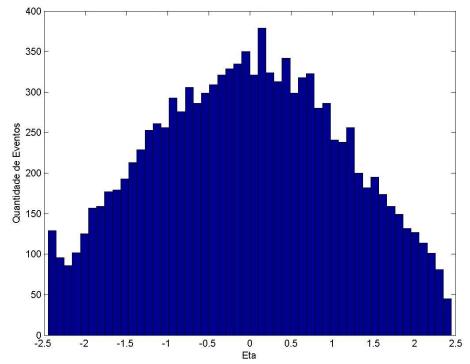
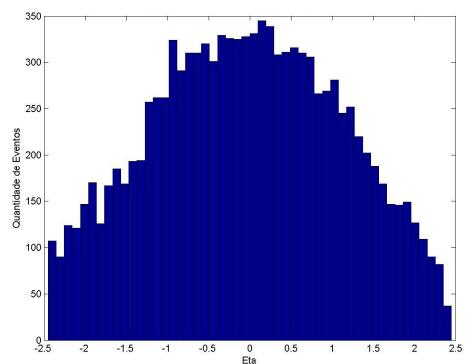


Figura 9: Contagem dos conjuntos de treino e teste de elétrons e jatos em  $\eta$ .

tremos de  $\eta$  pela baixa estatística nessas regiões, tanto a informação estatística para a RNA, quanto a especialista para o T2Calo. Uma contagem dos eventos do conjunto de treino e teste, em relação à coordenada  $\eta$ , é mostrada na Figura 9, tanto para elétron quanto para jato. A contagem de elétrons mostra uma queda no número de eventos nos extremos de  $\eta$ . Isso, agregado ao fato da menor resolução do detector nessas regiões, pode explicar a queda da eficiência de elétrons. Já para jatos, os eventos são mais bem distribuídos, explicando também a distribuição mais uniforme do falso alarme de jatos em  $\eta$ .

A Figura 10 analisa a discordância / concordância dos dois discriminadores neurais baseados na informação provida pelo T2Calo. A resposta das duas redes varia entre  $-1$  e  $1$ , para jatos e elétrons respectivamente, onde quanto mais próxima estiver destes valores, maior a confiança da rede em sua decisão. As linhas escuras contínuas representam os patamares de discriminação determinados pela maximização do produto SP para o grupo de validação de cada discriminador.

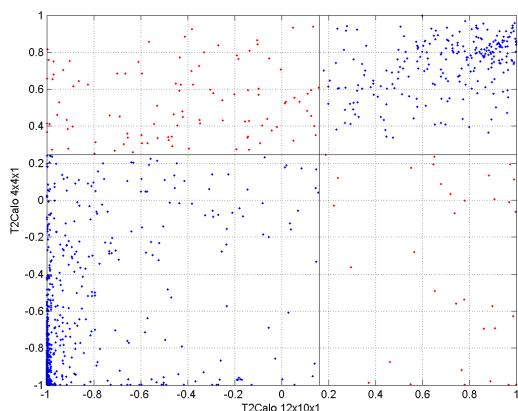
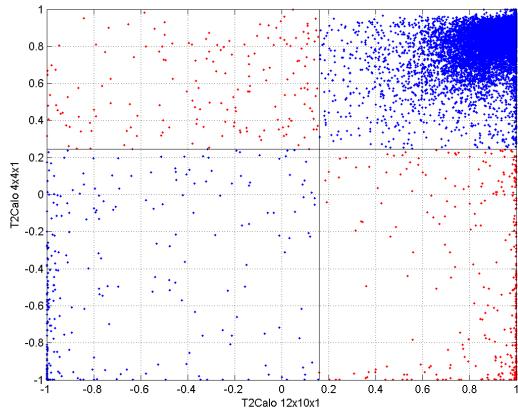


Figura 10: Figura de concordância das duas abordagens neurais para elétrons e jatos.

Os pontos em azul indicam os eventos que os dois discriminadores tiveram a mesma decisão, seja acertando, seja errando. Já os pontos em vermelho indicam eventos onde os discriminadores discordam, classificaram o evento de maneira diferente. Essa discordância ficou mais óbvia na classificação de jatos, onde os eventos que estão acima do patamar do T2Calo 12x10x1 (primeira abordagem) formam uma região muito menos densa que sua análoga, acima do patamar do T2Calo 4x4x1 (segunda abordagem).

## VII. OTIMIZAÇÃO DE VELOCIDADE DO ALGORITMO

Junto ao esforço em otimizar a eficiência de detecção de elétrons e jatos no segundo nível de Trigger, a velocidade do algoritmo também deve ser aumentada. Como visto, as especificações do segundo nível de filtragem limitam, o tempo de latência deste nível em  $10\text{ ms}$ . Desta maneira, o sistema de discriminação operando nesse nível deve manter as informações provenientes do nível acima por até  $10\text{ ms}$ , antes que informação adicional seja passada.

Um alto custo computacional do algoritmo está na aquisição dos dados brutos das RODs (Read Out Drivers) [6], dispositivos que armazenam as informações das células das RoIs marcadas pelo primeiro nível, para as células do TileCal. Dentro de uma ROD existem duas FeBs, fragmentos em forma de lista que armazenam os dados, e, em cada FeB, temos 128 canais com as informações de cada célula.

A Figura 11 ilustra um caso típico na distribuição das células, Trigger Towers (TT) e FeBs de uma ROI marcada pelo primeiro nível. Trigger Tower é um conjunto de células de diferentes camadas do calorímetro, distribuídas radialmente em relação ao eixo de colisão do detector (Figura 12).

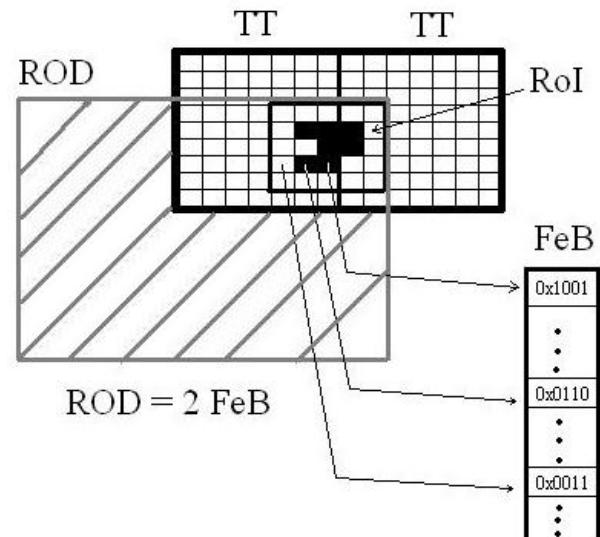


Figura 11: Ilustração de um caso típico na relação entre ROD e ROI

A busca por informações das células é feita seqüencialmente, obrigando o algoritmo de extração de dados a varrer um número muito grande e desnecessário de células, a cada aquisição de uma ROI.

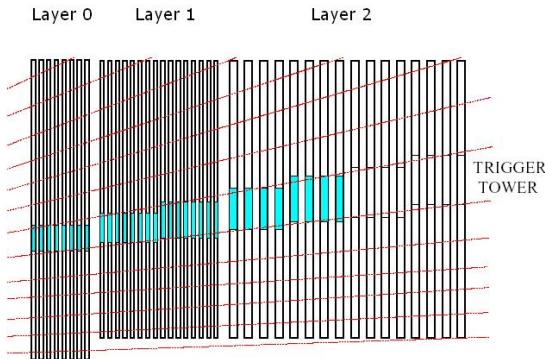


Figura 12: Ilustração de uma Trigger Tower, de [1]

Uma solução para esta questão é fazer uso dos identificadores de FeBs e seus canais, TTs e RODs para criar uma tabela que ligue todos os dispositivos. Assim, a partir da posição em  $\eta$  e  $\phi$  da célula poderíamos descobrir em qual TT ela se encontra e, consequentemente, todos os outros dispositivos associados à extração de suas características. A montagem desta tabela, ou indexamento, tem também um custo computacional muito alto, uma vez que todas as células do TileCal deveriam ser mapeadas. Porém, esse mapeamento será feito na inicialização do algoritmo e não é considerado tempo de execução.

Nesse trabalho só foi feita uma análise de uma possível solução para o problema em questão, não sendo apresentado nenhum resultado.

### VIII. CONCLUSÕES

Os resultados apresentados nesse trabalho mostram que a aplicação de redes neurais artificiais como classificadores de partículas pode ser uma abordagem vantajosa no que diz respeito à eficiência de detecção para o segundo nível de trigger do ATLAS. Esses classificadores tiveram um desempenho melhor até mesmo em posições de  $\eta$  onde a estatística é baixa.

A aplicação de análise de componentes principais, mesmo que pouco explorada, pode ser um caminho para diminuir ainda mais a dimensão do espaço de dados de entrada da rede aumentando a velocidade do algoritmo.

Outros efeitos que não foram levados em conta nesse trabalho também serão abordados, como o efeito de pile-up, onde há superposição de informação.

### IX. AGRADECIMENTOS

Agradecemos ao apoio financeiro do CNPq e FAPERJ (Brasil), e CERN (Suiça). Também agradecemos aos nossos colegas da colaboração pelo conjunto de dados e pelas discussões frutíferas ao longo do desenvolvimento deste trabalho.

- 
- [1] CERN, "The ATLAS Project", <http://atlas.ch>, acessado em janeiro 2005.
  - [2] ATLAS Group, *ATLAS Liquid Argon Calorimeter Technical Design Report*, Relatório, CERN, dezembro 1996.
  - [3] ATLAS Group, *ATLAS Tile Calorimeter - Technical Design Report*, Relatório, CERN, dezembro 1996.
  - [4] WIGMANS, R., "Advances in Hadron Calorimetry", *Submitted to the Annual Review of Nuclear and Particle Science*, 1991.
  - [5] ATLAS Collaboration, *Trigger Performance Technical Progress Report*, Report, CERN, 1999.
  - [6] ATLAS Collaboration, *ATLAS DAq, EF, LVL2 and DCS Technical Progress Report*, Report, CERN, 1998.
  - [7] HAYKIN, S., *Neural Networks: A comprehensive foundation*. Prentice Hall, 1999.
  - [8] ATLAS Collaboration, *ATLAS Computing Technical Design Report*, Report, CERN, 2005.
  - [9] TREES, H. V., *Detection, Estimation and Modulation*. John Wiley & Sons, 1966.
  - [10] JOLLIFFE, I. T., *Principal Component Analysis*, Springer-Verlag, 2002.