

Discriminação Neural de Elétrons no Segundo Nível de Trigger do ATLAS

A. dos Anjos, R. C. Torres, B. C. Ferreira, T. C. Xavier, and J. M. de Seixas
 Laboratório de Processamento de Sinais/COPPE/EP/Universidade Federal do Rio de Janeiro,
 Caixa Postal 68564 - Cidade Universitária, Rio de Janeiro, RJ, 21945-970, Brazil

This paper presents an electron/jet discriminator system for operating at the Second Level Trigger of ATLAS. The system processes calorimetry data and organizes the regions of interest in the calorimeter in the form of concentric ring sums of energy deposition, so that both signal compaction and high performance can be achieved. The ring information is fed into a feed forward neural discriminator. This implementation resulted on a 97% electron detection efficiency for a false alarm of 3%. The full discrimination chain could still be executed in less than $500\mu\text{s}$.

I. INTRODUÇÃO

O experimento ATLAS [1], no CERN, irá observar os produtos das interações próton-próton de alta luminosidade ($10^{34}\text{ cm}^{-2}\text{s}^{-1}$) do colisionador LHC a procura de uma nova física de interesse, sendo o bóson de Higgs a principal busca do experimento. O detector possui um formato cilíndrico e é formado por subdetectores especializados, que são (da parte mais interna para a mais externa): o detector interno, que identifica a trajetória das partículas carregadas; os calorímetros (eletromagnético e hadrônico), que medem a energia e a câmara de múons, que observa essas partículas que interagem pouco com os subdetectores anteriores. A partir dessa composição, o ATLAS é capaz de identificar as principais propriedades dos decaimentos das partículas geradas em cada colisão.

No LHC, pacotes de prótons irão colidir na frequência de 40 MHz. Mas, para a luminosidade projetada para o experimento, serão produzidas cerca de 23 colisões próton-próton inelásticas na mesma frequência, gerando uma taxa de aproximadamente 1 GHz. Com o interesse de reduzir a alta taxa de eventos, foi desenvolvido, para o experimento ATLAS, um sistema de filtragem (*trigger*) *online* [2] composto por três níveis conectados em cascata, com complexidade e tempo de processamento crescentes. O primeiro nível de filtragem (LVL1), usará a informação proveniente dos calorímetros e da câmara de múons para reduzir a taxa inicial de eventos para não menos que 75 kHz (esse valor poderá atingir o limite de 100 kHz). Para alcançar tal objetivo, o LVL1 será implementado em *hardware*. O LVL1 também identificará as áreas do detector onde houve maior deposição de energia, chamadas de Regiões de Interesse (RoIs).

As RoIs definidas pelo LVL1 são usadas pelo segundo nível de filtragem (LVL2) [4]. O LVL2 usará toda a fina granularidade do detector para reduzir a taxa de eventos, recebida pelo primeiro nível, para 1 kHz. Para efetuar essa tarefa, contará com uma rede de capacidade equivalente a 1000 CPUs de 4 GHz, que irão processar algoritmos de busca especializados com intuito de encontrar elementos que representem um física de interesse. Finalmente, os eventos aprovados pelo LVL2 serão apresentados ao terceiro nível, chamado de Filtro de Eventos (EF). Este nível de filtragem

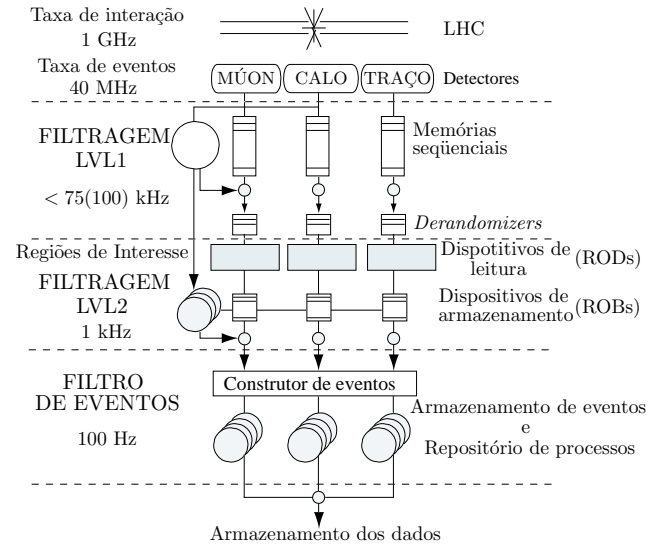


FIG. 1: Sistema de Filtragem de Eventos do ATLAS (figura retirada de [3]).

trabalhará no mesmo ambiente do LVL2 e irá refinar ainda mais a seleção feita, identificando os 100 eventos (taxa de 100 Hz) que serão gravados em mídia permanente. Para isso, o EF irá reconstruir o evento a partir da informação de todos os subdetectores. Os níveis do sistema de filtragem de eventos do ATLAS podem ser vistos na Figura 1.

A. A seleção elétron/jato

Quando um evento de um candidato a elétron (com momento elevado) é identificado pelo LVL1, o LVL2 usa toda a granularidade do detector a fim de confirmar se este objeto é ou não um elétron. O algoritmo que vem sendo a base de desenvolvimento do LVL2 para operar sobre a informação dos calorímetros e que tem como objetivo identificar elétrons é chamado de T2Calo [2]. Este é responsável por extrair quatro quantidades altamente discriminantes a partir de uma dada região de interesse indicada pelo LVL1. Essas quantidades são então entregues à um algoritmo de hipótese, que realiza cortes, sendo capaz de distinguir objetos melhor que o LVL1.

Os elétrons de momento elevado representam uma das principais assinaturas do bóson de Higgs, por isso, são objetos de extrema importância para o ATLAS. Esses elétrons são contaminados por jatos de partículas, pois o primeiro nível não consegue diferenciá-los com a informação limitada que possui. É esperado que para cada 25 mil objetos definidos como elétrons pelo LVL1, somente 1 seja realmente um elétron.

II. A DETECÇÃO ELÉTRON/JATO NEURAL

Redes neurais [5] vêm produzindo resultados bem satisfatórios em experimentos de física de altas energias [6, 7]. Esta técnica é muito robusta, de fácil manutenção e resulta numa separação melhor quando a aplicação se dá em um espaço de entrada de elevada dimensão (como encontrado na calorimetria do ATLAS).

Atualmente, os algoritmos de processamento utilizados são divididos em duas etapas. A primeira é responsável pela extração das características de uma entrada com dimensão elevada em um conjunto reduzido de variáveis altamente discriminantes. Após esta primeira etapa, as variáveis que exprimem as características da entrada são processadas por um algoritmo de hipótese que irá decidir sobre a natureza do objeto analisado.

O T2Calo é um exemplo de algoritmo de extração de características. Redes neurais podem ser implementadas após esse algoritmo para alcançar uma eficiência de discriminação maior que o conjunto de cortes utilizados atualmente. Outra abordagem, discutida nesse trabalho, é a substituição do algoritmo de extração de características.

A. Pré-processamento topológico em anéis

Ao observarmos a forma que objetos interagem com o calorímetro, é possível pensar em um algoritmo que melhor preserve as características das regiões de interesse [8]. A Figura 2 mostra a interação de um elétron típico com as diversas camadas do calorímetro. No lado esquerdo da figura, vemos a deposição no calorímetro eletromagnético e no da direita observamos as camadas do calorímetro hadrônico. Em média, cada RoI consiste em um conjunto de 1300 células espalhadas em diferentes camadas do calorímetro.

A elevada dimensão do espaço de entrada requer a utilização de uma compactação eficiente. Neste trabalho, propõe-se uma compactação em anéis, que será adaptada às condições de granularidade variante da configuração dos calorímetros do ATLAS e irá aproveitar a topologia da deposição energética dos objetos que interagem com o calorímetro. Os anéis de cada camada são extraídos localizando-se a célula de maior deposição de energia na camada e somando-se o valor das células concêntricas a este ponto. A Figura 3 ilustra como extrair os anéis de algumas

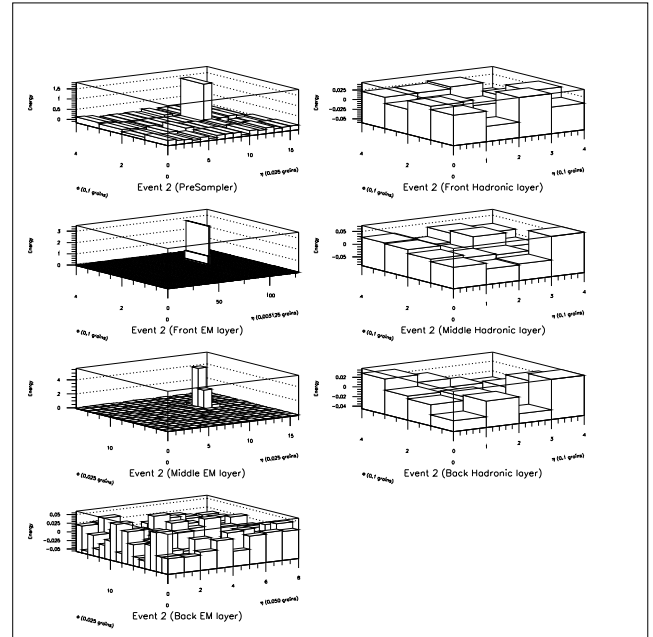


FIG. 2: Deposição de energia, de um elétron típico, nos calorímetros.

camadas dos calorímetros do ATLAS. Considerando-se as células em todas as 7 camadas, teremos um total de 100 anéis para cada RoI identificada pelo LVL1.

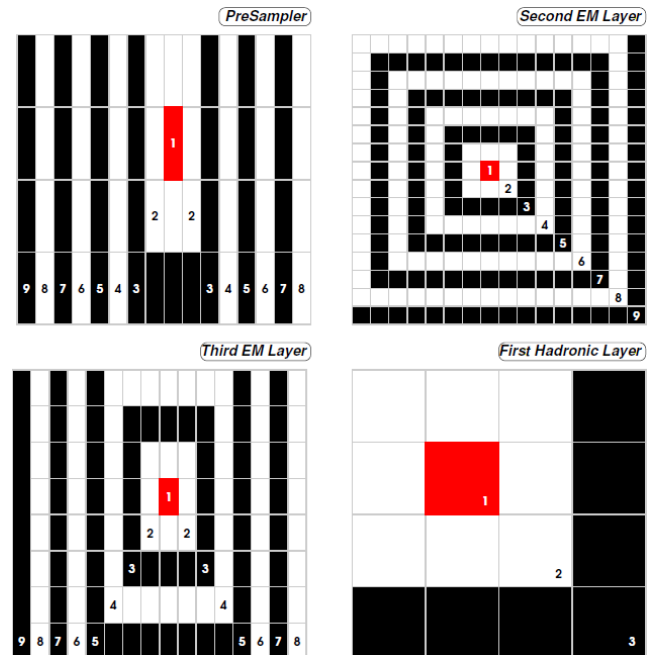


FIG. 3: A extração dos anéis em uma RoI nos calorímetros do ATLAS.

As somas energéticas em anéis são normalizadas da seguinte forma: para cada camada, calcula-se a soma da energia de cada célula e divide-se o valor da energia do

primeiro anel por esta soma. A energia do segundo anel é dividida pelo valor da soma menos a energia do primeiro anel. A energia do terceiro anel, pela soma da energia total menos a energia do primeiro e segundo anéis, e assim sucessivamente, até que o número de anéis se esgote. É possível observar que, os valores energéticos nos últimos anéis de cada camada, aqueles que possuem a razão sinal-ruído menor, terão o menor fator de normalização (a maior amplificação). Para que isso não ocorra, se a energia de um anel estiver abaixo de um dado limite a normalização é feita por uma constante.

O conjunto de anéis normalizados são entregues a uma rede neural *feedforward* (“back-propagation”) com 100 entradas, 5 neurônios na camada escondida e um único neurônio de saída.

III. RESULTADOS

Para representar a classe de elétrons, foi utilizado um conjunto de 22 mil elétrons, provenientes de simulações de elétrons simples e de decaimentos de $H \rightarrow ZZ \rightarrow 4e^-$ e $H \rightarrow ZZ \rightarrow 2e^- + 2\mu$. Aproximadamente 7 mil jatos, gerados a partir de simulações de di-jet, foram usados. Esses jatos foram previamente aprovados por uma simulação do LVL1, em sua configuração real de operação. Esses dados foram transformados em anéis e normalizados. Metade do conjunto de dados foi usado para treinar o sistema baseado em redes neurais e a outra metade para testar a performance do discriminador neural.

Com o intuito de comparar a eficiência dos dois métodos de extração de características (T2Calo e anéis), os mesmos dados citados anteriormente foram processados pelo algoritmo T2Calo. A saída do T2Calo foi normalizada, retirando-se a média e dividindo-se pelo desvio padrão.

A Figura 4 compara os resultados, a partir das curvas ROC (*Receiver Operating Curve*) [9], entre várias técnicas de discriminação em conjunto com o pré-processamento em anéis e com o pré-processamento usando as variáveis T2Calo. Observamos que o sistema que possui a menor compactação apresenta o melhor resultado, produzindo uma frequência de falso-alarme 8 vezes menor que o algoritmo T2Calo (para uma mesma eficiência de 92 %). Essa figura também mostra os resultados para a saída do algoritmo T2Calo para um sistema usando: discriminador de Fisher, análises de componentes principais [5] e redes neurais [10].

A Figura 5 mostra a performance de tempo para o discriminador baseado em redes neurais que utiliza o pré-processamento em anéis. Observamos nessa figura uma série de distribuições acumulativas para o tempo de cada uma das etapas de processamento: geração dos anéis, normalização, discriminação neural e o tempo total. O código em C++ foi compilado usando o GCC, com o *flag* de otimização ligado e executado em um processador Pentium-IV com 512 MB de memória RAM e *clock* de 2.4 GHz. Com o tempo de processamento médio em torno de $450\mu s$, concluímos que

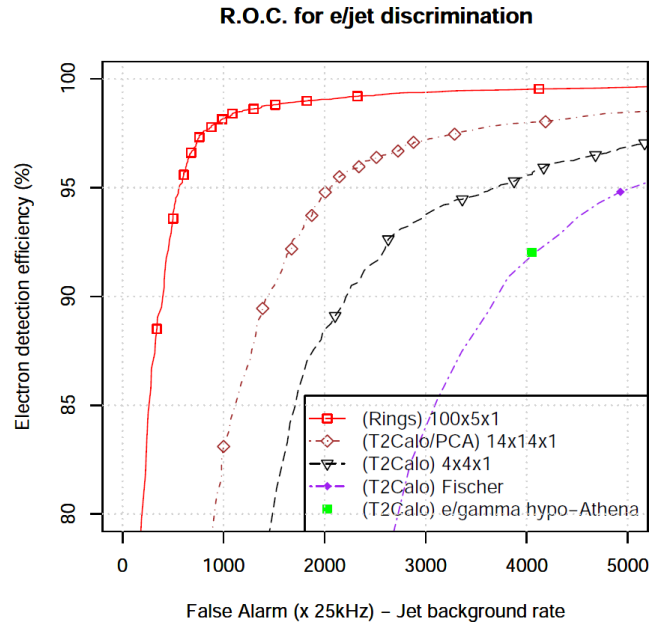


FIG. 4: Curvas ROC para várias técnicas de discriminação usando o pré-processamento em anéis e as quantidades extraídas pelo T2Calo.

este sistema se torna adequado para o LVL2, já que o tempo de processamento disponível para todo o LVL2 é de 10ms.

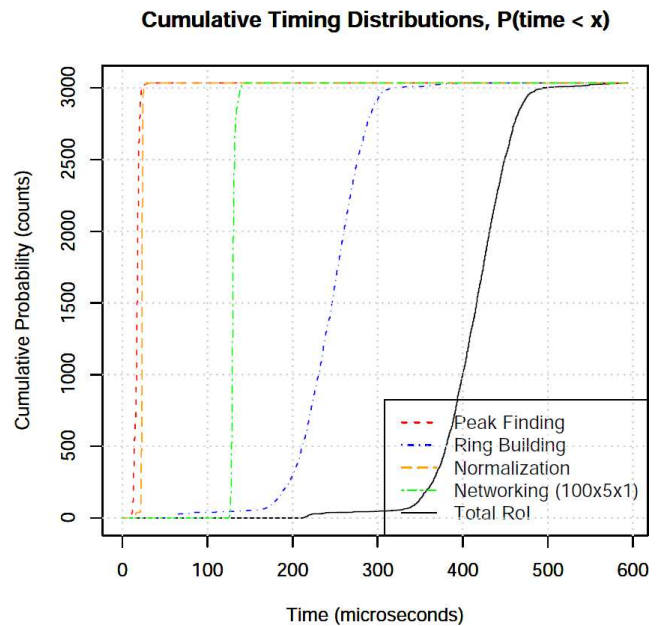


FIG. 5: Distribuição acumulativa do tempo de execução das etapas do sistema neural baseado no pré-processamento em anéis.

IV. RELEVÂNCIA DOS DADOS

Ao identificar a relevância dos dados, pode-se compactar mais ainda a dimensionalidade dos sinais originais de entradas

ou, até mesmo, manter a informação redundante, de forma a garantir a robustez do discriminador.

Para identificar a informação relevante, observamos a resposta do classificador neural em termos da sua sensibilidade à informação contida em cada anel. Para tal, a componente que representa um dado anel é substituída pela sua média e calculando-se a variação da saída da rede para esta substituição no vetor de entrada em relação a saída original, de acordo com a seguinte equação:

$$R_i = \frac{1}{N} \sum_{j=1}^N [\text{saída}(\vec{x}_j) - \text{saída}(\vec{x}_j|_{x_{j,i}=\bar{x}_i})]^2$$

Com o valor de relevância de cada anel calculado, podemos otimizar o sistema a partir da supressão dos anéis menos relevantes. Dessa forma, podemos reduzir a dimensão do conjunto de anéis tornando a etapa de formação de anéis mais rápida. É esperado que a robustez do classificador seja suficientemente grande, de forma a não diminuir a eficiência do sistema quando se retira informação irrelevante. Eventualmente, podemos ainda eliminar informação potencialmente ruidosa (irrelevante) e, com isso, obter um aumento na eficiência de classificação.

A Figura 6 adiciona à Figura 4 discriminadores neurais, baseados no pré-processamento em anéis, que foram treinados a partir da supressão dos anéis menos relevantes. A performance de tempo de processamento mostra que, para um sistema com 53 anéis de entrada, o tempo médio de processamento é de cerca de $300\mu s$ e sua eficiência de detecção se mantém, praticamente, inalterada.

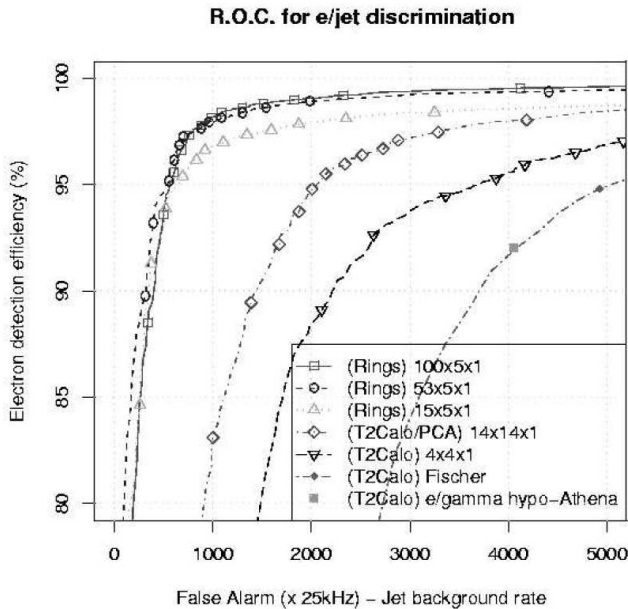


FIG. 6: Eficiência com a supressão de anéis menos relevantes.

V. IMPLEMENTAÇÃO DO ALGORITMO EM DSP

Computadores pessoais, apesar da facilidade encontrada na programação e da velocidade de processamento, são mais caros e possuem uma demanda de potência muito elevada. FPGAs (Field Programmable Gate Array) são rápidas e compactas, mas tornam a programação e a manutenção de programas complexos bem mais difícil. Em aplicações do processamento digital de sinais, existem operações que são utilizadas com muita frequência, como multiplicação, acumulação etc. Para algoritmos que utilizam essas operações, vem se tornando cada vez mais popular o uso de DSPs (Digital Signal Processors). Esses dispositivos exploram as características do processamento digital de sinais para alcançar elevadas taxas de execução em poucos ciclos.

O sistema de discriminação neural baseado nas somas energéticas em anéis foi implementado usando um DSP [11] de 32 bits e ponto flutuante. Este DSP possui 100 MHz de *clock*, memória interna de 4 MB. Para a implementação do discriminador neural elétron/jato baseado em 100 anéis, o tempo de execução obtido foi de $4.692 \pm 1.108 ms$ por RoI.

A Figura 7 mostra a distribuição acumulativa do tempo de execução das etapas do sistema neural baseado no pré-processamento em anéis para a implementação no DSP. Podemos observar que a etapa de formação dos anéis sozinha representa o gasto de tempo de processamento total do sistema, devido a necessidade de etapas condicionais no código. Já a etapa de discriminação, pode aproveitar as características do DSP e em média foi realizada em $10.429 \pm 0.465\mu s$ enquanto um processador Pentium-IV de 2.8 GHz executa a mesma etapa em, aproximadamente, $125\mu s$. O tempo de execução pode ser reduzido ao se trocar o DSP utilizado por outro com a frequência maior.




FIG. 7: Distribuição acumulativa do tempo de execução das etapas do sistema neural baseado no pré-processamento em anéis para a implementação no DSP.

VI. CONCLUSÕES

Neste trabalho, apresentamos um sistema de discriminação para o problema de classificação elétron/jato do segundo nível de trigger do detector ATLAS, baseado em um mapeamento topológico e redes neurais. Este sistema apresenta uma eficiência de detecção 8 vezes melhor, ao compararmos com o algoritmo que é a base de desenvolvimento no ATLAS, e um tempo de processamento pequeno ($450\mu s$), levando em consideração os requisitos do experimento. A compactação do vetor de entradas pode ser efetuada observando-se a relevância de cada uma das entradas para o classificador, permitindo o controle da robustez e do tempo de processamento. A partir da supressão de metade dos anéis, melhora o tempo de processamento em 35% sem apresentar impacto significativo na eficiência de classificação.

A implementação do mesmo algoritmo em um processador digital de sinais (DSP) de 100 MHz foi realizada, mostrando-se como uma alternativa barata e de fácil manutenção. Foi mostrado que essa implementação foi capaz de efetuar muito bem a etapa de hipótese do sistema apresentado.

Agradecimentos

Agradecemos ao apoio dado pelo CNPq, FAPERJ (Brasil) e CERN (Suíça) ao projeto. Também agradecemos aos nossos colegas da colaboração Trigger/DAQ por disponibilizar o conjunto de dados e pelas discussões frutíferas ao longo do desenvolvimento deste trabalho.

-
- [1] ATLAS Collaboration, *Atlas: Technical Proposal for a General-Purpose pp Experiment at the Large Hadron Collider at CERN*, CERN-LHCC-94-43 (1994).
- [2] Atlas Trigger and Data Acquisition Collaboration, *ATLAS High-Level Triggers, DAQ and DCS Technical Design Report*, CERN-LHCC-2000-017 (2003).
- [3] A. G. Mello, *Processamento Digital de Imagens para um Detector de Partículas de Alta Energia e Elevada Taxa de Eventos*, Ph.D. thesis, COPPE/UFRJ (2006).
- [4] A. dos Anjos et al., *The Second Level Trigger of the ATLAS Experiment at CERN's LHC*, IEEE Transactions on Nuclear Sciences **51**, p.909 (2004).
- [5] S. Haykin, *Neural Networks. A Comprehensive Foundation* (Prentice Hall, 1999), 2nd ed.
- [6] C. Kiesling et al., *New Computing Techniques in Physics Research III* (1994).
- [7] C. Lindsey, B. Denby and T. Lindblad, *Artificial neural networks in high energy physics*, URL <http://neuralnets.web.cern.ch/NeuralNets/nwInHep.html>.
- [8] J. M. de Seixas et al., *Neural Second Level Trigger System Based On Calorimetry*, Computer Physics Communications **85**, p.143 (1996).
- [9] H. Trees, *Detection, Estimation and Modulation* (John Wiley & Sons, 1966).
- [10] R. C. Torres et al., *Neural Triggering System Operating in High Resolution Calorimetry Information*, Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment **559**, p.134 (2006).
- [11] Analog Devices, *ADSP-21xx Processor*, URL <http://www.analog.com/processors/processors/ADSP/>.