

Otimização do Sistema Neural de Seleção Online de Eventos num Detector de Partículas através do Processamento Estatístico de Sinais

Edmar E. P. Souza, Eduardo F. Simas Filho, P. C. M. A. Farias

Laboratório de Sistemas Digitais - PPGEE

Universidade Federal da Bahia

edmar.egidio.purcino.de.souza@cern.ch, {eduardo.simas, paulo.farias}@ufba.br

José M. Seixas

Laboratório de Processamento de Sinais

Universidade Federal do Rio de Janeiro

seixas@lps.ufjr.br

Abstract—The ATLAS is the largest particle detector of the LHC (Large Hadron Collider). Considering the different ATLAS subsystems, the calorimeter comprises more than 100,000 sensors and is responsible for measuring the energy of the incoming particles. Electron detection is very important to the experiment as these particles are directly related to interesting physical signatures. The identification of electrons heavily relies on calorimeter information, and the background noise, composed of hadronic jets, may occur with frequencies up to 10^5 times higher than the physics of interest, making the identification process a difficult task. In previous studies it has been proposed an alternative electron detection algorithm (Neural Ringer), in which the energy profile measured at the calorimeter is formatted into concentric rings and these signals are used to feed an artificial neural network classifier. This work proposes the use of statistical signal processing techniques added to the Neural Ringer chain, aiming at extracting more discriminant features from the preprocessed calorimeter information. Through the proposed technique it is possible to both, increase the efficiency of Neural Ringer discriminator and reduce the amount of stored information in 60%. Results with simulated data are used to show the benefits of the proposed method.

I. INTRODUÇÃO

O LHC (*Large Hadron Collider*) [1] é o maior e mais potente acelerador de partículas já construído. Possui um percurso circular de 27 km de extensão e conta com a participação de cientistas de mais de 36 países. O ATLAS é um dos detectores de partículas do LHC e seu principal objetivo é identificar as características fundamentais da matéria [2]. O detector, conforme mostrado na Figura 1, possui um formato cilíndrico e é composto por sub-detectores especializados, que são: o detector de traço, que identifica a trajetória das partículas carregadas eletricamente; os calorímetros eletromagnético [3] e hadrônico [4], que medem a energia, e a câmara de múons, que detecta estas partículas (os múons) que possuem interação não relevante com os sub-detectores anteriores. O ATLAS recebe o produto das colisões de feixes de prótons do LHC que ocorrem numa taxa de até 40 MHz. Para esta frequência de colisões, o detector gera uma taxa de dados de aproximadamente 60 TB/s, sendo que a maior parte representa ruído de fundo para a identificação das propriedades físicas ainda não observadas experimentalmente. Para reduzir a alta taxa de eventos compostos na sua maioria por assinaturas de processos físicos já conhecidos, e portanto não relevantes para o experimento, foi desenvolvido um sistema de filtragem (*trigger*) *online*,

composto por três níveis sequenciais, com complexidade e tempo de processamento crescentes [5].




Fig. 1. Representação gráfica do detector ATLAS e seus sub-sistemas.

Conforme indicado na Figura 2, o primeiro nível (L1) usa a informação dos calorímetros e da câmara de múons e reduz a taxa inicial de eventos para 75 kHz. Este nível tem sérias restrições quanto ao tempo de processamento com latência máxima de 2,5 μ s, recebendo a total taxa de eventos do LHC como entrada. O L1 é implementado em *hardware* e identifica as regiões do detector onde possivelmente ocorreram eventos relevantes, locais chamados de Regiões de Interesse (*Regions of Interest* - RoIs).

Os dados provenientes das RoIs são utilizados pelo nível 2 de filtragem (L2), no qual é utilizada toda a granularidade do detector, com o objetivo de reduzir a taxa de eventos para 1 kHz. Para esta tarefa, o L2 é implementado em *software* e executado com forte processamento distribuído a fim de aumentar a detecção da física de interesse e de respeitar as limitações do tempo de processamento. Neste nível, o tempo máximo para tomada de decisão é 40 ms, e estão disponíveis informações do detector de trajetórias, das câmaras de múons, assim como a total resolução dos calorímetros.

O ultimo estágio de filtragem *online*, o Filtro de Eventos (*Event Filter* - EF), também implementado em *software*, recebe os eventos aprovados pelo L2 e refina ainda mais a seleção realizada pela etapa anterior. O EF têm latência de até quatro segundos para tomada de decisão, assim a taxa de eventos

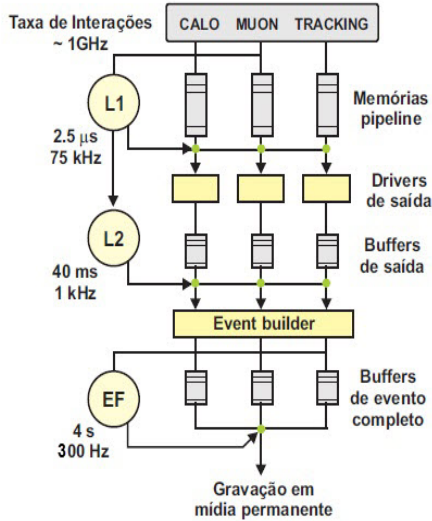


Fig. 2. Esquema do *trigger online* do ATLAS em três níveis de processamento sequenciais.

é reduzida para até 300Hz, que serão gravados em mídia permanente para posterior análise *offline* [5].

Neste trabalho, é proposto um discriminador para realizar a detecção de partículas eletromagnéticas (elétrons e fótons) no segundo nível de filtragem *online* de eventos do detector ATLAS. Com o objetivo de obter, ao mesmo tempo, alta eficiência, rapidez na tomada de decisão e redução na quantidade de informação armazenada, foi realizada a combinação de um pré-processamento estatístico dos sinais com discriminadores neurais. Este trabalho está sendo desenvolvido por pesquisadores brasileiros, que participam da colaboração do detector ATLAS.

II. DETECÇÃO DE ELÉTRONS NO ATLAS

Os elétrons estão envolvidos em diversos decaimentos raros de interesse para o experimento, como por exemplo o bóson de Higgs, partícula à qual os físicos atribuem a capacidade do fornecimento da massa. Recentemente foi detectado pelo ATLAS uma partícula com características semelhantes ao bóson de Higgs, dando início a uma era de novas descobertas.

A detecção de elétrons baseia-se no perfil de deposição de energia medido no sistema de calorimetria. São considerados aspectos como a distribuição transversal do chuveiro de partículas produzido e o vazamento para camadas hadrônicas. Os jatos hadrônicos são amplamente produzidos nas colisões (em taxas até 10^5 vezes maiores que os elétrons) e possuem um perfil de deposição de energia que pode ser semelhante ao do elétron, tornando complicado o processo de identificação. Os problemas abordados como a alta taxa de eventos, a raridade de ocorrência da física de interesse, e a intensa contaminação por ruído de fundo no canal de detecção reforçam a necessidade de implementação de algoritmos de identificação eficientes. Estas rotinas devem trabalhar dentro das janelas de tempo permitidas para a operação no *trigger*, facilitar a identificação de novas propriedades físicas e otimizar a armazenagem dos dados.

A. O Discriminador Neural Ringer

No trabalho [6] foi proposto um sistema de identificação de partículas alternativo ao discriminador padrão que opera no L2 do detector. O *Neural Ringer* efetua um pré-processamento topológico da informação de cada camada do calorímetro, localizando primeiramente a célula de maior deposição energética na camada e somando o valor das células localizadas em “anéis” concêntricos a este ponto. Neste procedimento é obtido um total de 100 anéis para cada RoI selecionada pelo L1 (ver Tabela 1), considerando uma RoI de tamanho fixo. Conforme a Figura 3, o anelamento aproveita a topologia de deposição de energia das partículas, adaptando as condições de granularidade de cada camada do calorímetro. Após o anelamento, o conjunto de anéis é utilizado para alimentar um classificador baseado numa rede neural artificial (RNA) *feedforward* [7] com duas camadas e um único neurônio na saída. Utilizando o *Neural Ringer*, foram obtidos melhores índices de classificação em relação ao discriminador padrão do detector, que realiza cortes lineares em algumas variáveis estimadas a partir do perfil de deposição de energia.

Tabela 1. Número de anéis por camada.

Camadas	PS	E1	E2	E3	H0	H1	H2
Anéis	08	64	08	08	4	4	4

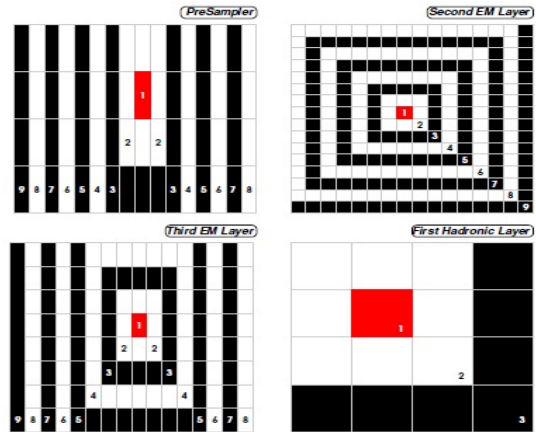


Fig. 3. Representação da formação dos anéis no calorímetro.

III. PRÉ-PROCESSAMENTO AO DISCRIMINADOR NEURAL RINGER

Este trabalho propõe a adição de uma etapa na cadeia do *Neural Ringer* onde será aplicado um pré-processamento estatístico aos sinais formatados em anéis, antes da classificação. O objetivo é permitir que características mais discriminantes sejam evidenciadas (eliminando a redundância e o ruído de medição), antes de serem apresentados ao classificador neural, de forma a aumentar a eficiência de classificação. Pretende-se também realizar a compactação da informação para otimizar os recursos necessários para o armazenamento dos dados produzidos pelo discriminador. A seguir serão descritas, de modo resumido, as técnicas de pré-processamento estatístico de sinais adicionadas na cadeia do *Neural Ringer*.

A. Análise de Componentes Principais

A Análise de Componentes Principais (*Principal Components Analysis* - PCA) [8] é uma técnica estatística, cujo objetivo é encontrar uma transformação linear tal que os sinais projetados sejam não-correlacionados e grande parcela da energia (variância) esteja concentrada num pequeno número de componentes.

Considerando-se um vetor $x = [x_1, \dots, x_n]^T$ aleatório com n elementos e assumindo-se que ele tenha média zero), A projeção z_i de x na direção de v_i definida por:

$$z_i = v_i^T x = \sum_{k=1}^N v_{ki} x_k \quad (1)$$

Na transformação por PCA, os componentes extraídos z_i ($i = 1, \dots, N$) devem ser ortogonais e ordenados de forma crescente pela variância das projeções. Deste modo, v_1 pode ser encontrado pela maximização de:

$$J_i^{PCA}(v_1) = E\{z_i^2\} = E\{(v_1^T x)^2\} = v_1^T C_x v_1 \quad (2)$$

onde C_x é a matriz de covariância de \mathbf{x} .

A maximização da equação anterior pode ser encontrada a partir da determinação dos autovetores e_1, e_2, \dots, e_n da matriz C_x . O ordenamento dos autovetores é, tal que, os autovalores que associados satisfazem $d_1 > d_2 > \dots > d_N$, assim $v_i = e_i$, tornando a decomposição por autovalores da matriz C_x equivalente a PCA de \mathbf{x} . A PCA, portanto consiste em uma mudança de base, em que os primeiros k componentes contém a maior quantidade de variação do conjunto de dados. Em aplicações de compactação, a parcela contendo a menor variância é descartada, mantendo assim os componentes com maior nível de energia.

B. Análise de Componentes Independentes

A análise de componentes independentes (*Independent Components Analysis* - ICA) [9] busca uma transformação onde os componentes na saída são mutuamente independentes estatisticamente. Esta técnica, a partir dos sinais observados (\mathbf{x}), estima as fontes de sinais independentes (\mathbf{s}) que produziram as assinaturas medidas. Na ICA, considera-se que um sinal multidimensional $x(t) = [x_1(t), \dots, x_N(t)]^T$ observado (ou medido) é gerado a partir da combinação linear das fontes independentes $s(t) = [s_1(t), \dots, s_N(t)]^T$:

$$\mathbf{x} = \mathbf{A}\mathbf{s}, \quad (3)$$

onde \mathbf{A} é a matriz de mistura. O objetivo final da ICA é encontrar uma aproximação \mathbf{y} das fontes independentes \mathbf{s} , utilizando apenas os sinais observados \mathbf{x} .

$$\mathbf{y} = \mathbf{W}\mathbf{x}, \quad (4)$$

sendo \mathbf{W} a matriz de separação. Se $\mathbf{W} = \mathbf{A}^{-1}$, $\mathbf{y} = \mathbf{s}$ e o problema foi completamente solucionado [9].

A ICA vem sendo aplicada na solução de diversos problemas na área de processamento de sinais, como cancelamento de ruído, telecomunicações e engenharia biomédica [10]. Diversos algoritmos foram propostos na literatura para a estimação dos componentes independentes. Neste trabalho foi utilizado o FastICA [9], por apresentar boa precisão e rapidez, mesmo em problemas com alta dimensionalidade.

IV. METODOLOGIA

A adição da etapa de pré-processamento ao discriminador *Neural Ringer* foi realizada com a aplicação da PCA e em seguida da ICA aos sinais formatados em anéis (concatenados num único vetor totalizando 100 anéis). A informação pré processada foi utilizada para alimentar a RNA (ver Figura 4).



Fig. 4. Adição da etapa de Pré-processamento ao *Neural Ringer*.

Neste trabalho, foi utilizado um conjunto de dados simulados por técnicas de Monte Carlo. Neste conjunto, a classe de elétrons possui aproximadamente 30.000 assinaturas provenientes do decaimento do bóson Z ($Z \rightarrow e^+e^-$). A classe de jatos hadrônicos possui aproximadamente 80.000 assinaturas. Nesta mesma base de dados, foram realizados dois cortes em energia, que selecionaram respectivamente as assinaturas com energia transversa (E_T) acima de 10GeV (e10) e assinaturas com E_T maior que 22 GeV (e22), sendo o conjunto e22 um sub-conjunto dos dados e10. As Figuras 5 e 6 mostram a distribuição em energia dos conjuntos e10 e e22.




Fig. 5. Distribuição de energia das RoIs das simulações de Monte Carlo considerando as assinaturas e10 (a) e e22(b).

O conjunto de dados e10 simula uma configuração pouco restritiva para o primeiro nível de filtragem e, para isso, foi realizado um corte mais livre em energia, contendo informações de partículas com baixa E_T e alto nível de ruído (espera-se uma alta energia transversa para as partículas envolvidas no decaimento de um bóson Z em dois elétrons). O conjunto e22 simula um corte mais severo no primeiro nível, sendo selecionados eventos com mais alta E_T . Deste modo, nesta base de dados encontram-se jatos hadrônicos com perfil de energia bastante semelhante ao perfil de elétrons, dificultando a decisão dos sistemas de classificação.

Uma etapa de normalização dos dados foi realizada antes da aplicação as técnicas de pré-processamento citadas anteriormente. A normalização aplicada foi pela energia total, realizando a divisão da energia de cada anel (E_{ai}) pela energia total do evento, conforme a equação a seguir:

$$E_{Ni} = E_{ai} / \sum_{i=1}^{100} E_{ai} \quad (5)$$

Para avaliação de desempenho do discriminador foram utilizadas a curva ROC [11] e o índice SP, conforme definido na Equação 6:

$$SP = \sqrt{\left(\frac{1}{2}\right) \times (E_{f_e} + E_{f_j}) \times \sqrt{E_{f_e} \times E_{f_j}}}, \quad (6)$$

onde $E_{f_e} = PD$ (probabilidade de detecção de elétrons) e $E_{f_j} = 1 - PF$ (probabilidade de classificar um jato hadrônico incorretamente) são as eficiências obtidas, respectivamente, para elétrons e jatos.

O treinamento da rede neural foi realizado com os dados pré-processados, aplicando o método de validação cruzada, que é utilizado para estimar a flutuação estatística do conjunto de sinais no desempenho dos classificadores. O método realiza primeiramente a divisão de todo o conjunto de dados em N subgrupos (este processo é realizado de forma aleatória). Em seguida, é definido um número de sorteios (neste caso foram 10 sorteios) e também são selecionados os conjuntos de treino, teste e validado de cada subgrupo. Na sequência é treinado um discriminador neural para cada sorteio, utilizando os subgrupos definidos anteriormente [12]. O processo de validação cruzada é exemplificado na Figura 6.




Fig. 6. Representação do processo de validação cruzada usado no treinamento do classificador neural.

A rede neural utilizada possui duas camadas e um único neurônio na camada de saída. O algoritmo de treinamento usado foi o *Resilient Backpropagation - (RPROP)* [13], e a função de ativação utilizada em todas as redes foi a tangente hiperbólica. Para a determinação do número ótimo de neurônios da camada oculta foi realizado um estudo de avaliação do índice SP e das probabilidades de detecção (PD) e falso alarme (PF) associadas a quantidade de neurônios, conforme indicado nas Figuras 7 e 8. A configuração que obteve melhores resultados ocorreu com o uso de 18 neurônios na camada oculta, onde os parâmetros Max SP e PD apresentaram os melhores resultados em função da minimização da PF nas simulações.




Fig. 7. Curva de variação do máximo SP (%) em função do número de neurônios da camada oculta.

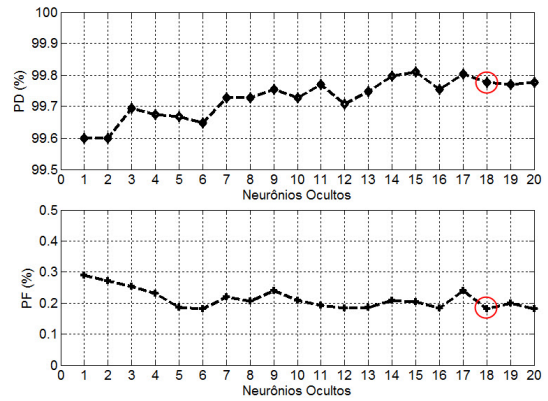


Fig. 8. Curvas de variação da PD(%) e PF(%) em função do número de neurônios da camada oculta

V. RESULTADOS

Conforme abordado, foi utilizada a técnica PCA a fim de realizar uma compactação eficiente e para cada nível de compactação foi aplicado a ICA para extrair as características mais relevantes dos dados. A Figura 9 mostra a curva de carga da energia armazenada em função do número de componentes retidos através da aplicação da PCA. Nas Figuras 10 e 11 são mostradas as variações do índice SP também em função do número de componentes retidos, para os conjuntos e10 e e22 respectivamente. Com esta análise é observado que para o conjunto e10, com o uso de 40 componentes (equivalendo a 99% da energia) é obtido o máximo índice SP das análises realizadas. Para o conjunto e22 o máximo índice SP é encontrado utilizando 50 componentes, representando também a 99% da energia.




Fig. 9. Curva de carga da compactação por PCA aplicada ao conjunto de dados e10.

O corte em 99% da energia total das amostras utilizadas com a técnica PCA/ICA, forneceu um decréscimo na probabilidade de falso alarme, bem como um considerável aumento no índice SP em relação aos demais métodos estudados. A Tabela 2 mostra os valores do índice SP e as probabilidades de detecção e de falso alarme associadas a cada sistema classificador.

A Figura 12 mostra as curvas ROC dos classificadores *Neural Ringer* [14] e do discriminador neural com a adição do pré-processamento por PCA/ICA, ambos sobre os dados do conjunto e10. Observa-se que a eficiência do método proposto




Fig. 10. Curva de variação do Max SP em função do número de componentes retidos na compactação por PCA no conjunto e10.




Fig. 11. Curva de variação do Max SP em função do número de componentes retidos na compactação por PCA no conjunto e22.

é superior ao *Neural Ringer* para baixos e altos valores de PF. Na Figura 13, são mostradas as curvas ROC do *Neural Ringer* e do classificador neural com pré-processamento aos dados do conjunto e22. Neste caso é possível observar que a eficiência da aplicação do pré-processamento aumenta consideravelmente em relação ao *Neural Ringer* para baixos índices de PF. A partir de aproximadamente 0.4% de Falso Alarme o *Neural Ringer* apresenta valores discretamente melhores.

Tabela 2. Comparação dos métodos aplicados no conjunto de dados e10 e e22.

Discriminadores	Max SP(%)	PD(%)	PF(%)
E10 - Ringer	99.69 +/-0.4	99.75	0.38
E10 - Ringer + ICA	99.80 +/-0.2	99.75	0.17
E22- Ringer	99.67 +/-0.5	99.73	0.41
E22- Ringer + ICA	99.69 +/-0.3	99.73	0.34

Análise por Camadas

Com o objetivo de avaliar a contribuição de cada camada do calorímetro, para a eficiência de classificação, foram aplicadas as técnicas de pré-processamento camada a camada do sistema de calorimetria, conforme proposto em [15]. A Figura 14 mostra a eficiência de discriminação (medida pelo índice SP) quando a classificação realizada por camada do calorímetro. Nota-se que a aplicação da PCA/ICA, sem compactação, eleva a eficiência de classificação.




Fig. 12. Curva ROC dos classificadores estudados sob as assinaturas e10.




Fig. 13. Curva ROC dos classificadores estudados sob as assinaturas e22.

Observa-se que as informações das camadas E1, E2 e H0 produzem maior eficiência. Mais especificamente, utilizando somente a camada E1, é possível obter um valor do SP próximo ao do *Neural Ringer*. Assim foi treinado um classificador neural utilizando como entrada apenas os sinais destas três camadas concatenados num único vetor realizando, assim, uma compactação por relevância de discriminação das camadas (redução de 100 para 76 anéis). Adicionando ainda a etapa de pré-processamento por PCA/ICA e considerando uma retenção de 99% da energia contida nestas camadas selecionadas, foram obtidos apenas 25 componentes, caracterizando uma compactação de 75% em relação aos 100 anéis originais.

A Tabela 3 mostra os valores de PD, PF e o número de componentes armazenados, obtidos com o *Neural Ringer* e os discriminadores neurais com pré-processamento utilizando todos os anéis e usando somente os anéis das camadas mais relevantes. Observa-se que a utilização somente das camadas E1,E2 e H0 como entrada provoca um discreto aumento na probabilidade de falso alarme, como também um leve decréscimo no índice SP em relação ao *Neural Ringer*. No entanto, o decréscimo da eficiência foi relativamente baixo, aproximadamente 0.2% de incremento na probabilidade de Falso Alarme para o mesmo valor de PD - 99,75%. Pode-se observar também que, através da metodologia proposta possível reduzir consideravelmente a quantidade de informação




Fig. 14. Resultados do índice SP obtidos por camada do calorímetro

armazenada, o que é muito importante para a aplicação. A Figura 15 apresenta os resultados em função das curvas ROC.

Tabela 3. Comparação do método aplicado nos dados e10.

Discriminadores	Max SP(%)	PD(%)	PF(%)	Comp.
Ringer	99.69 +/-0.4	99.75	0.38	100
ICA/PCA	99.80 +/-0.2	99.75	0.17	40
ICA/PCA _(E1,E2,H0)	99.66 +/-0.2	99.75	0.58	25




Fig. 15. Curvas ROC das análises dos discriminadores Ringer, Ringer + ICA/PCA e a análise com pré-processamento sob as camadas mais relevantes.

VI. CONCLUSÕES

A seleção *online* de eventos em experimentos de física de altas energias é um problema que requer sistemas de discriminação que combinem alta eficiência e rapidez na execução. Considerando especificamente o detector ATLAS, foi observado que a adição da etapa de pré-processamento estatístico, no processo de identificação de elétrons eleva a eficiência de classificação do *Neural Ringer*, na análise de ambos os conjuntos e10 e e22. A aplicação da PCA em conjunto com a ICA apresentou melhores resultados nas análises sob o índice SP, e também produziu aumento da probabilidade de detecção e diminuição da probabilidade de falso alarme. Considerando a compactação associada ao uso da PCA/ICA,

obteve-se elevação da eficiência utilizando apenas 40 % da informação do conjunto e10 e 50 % no caso do conjunto e22 (redução dos 100 anéis para 40 e 50 componentes nos conjuntos e10 e e22 respectivamente), conservando 99% da energia. O estudo da compactação por relevância das camadas do calorímetro também apresentou resultados interessantes, pois embora a eficiência de classificação tenha permanecido próxima ao *Neural Ringer* sem pré-processamento, o tempo de processamento do sistema e a quantidade de informação armazenada são ambos reduzidos. Neste caso, a discriminação é realizada utilizando apenas 25 % da informação original. A diminuição na taxa de falso alarme dos resultados obtidos com as técnicas propostas, poderá reduzir consideravelmente o armazenamento de eventos incorretos, considerando a altíssima taxa de eventos produzidos neste ambiente.

AGRADECIMENTOS

Os autores agradecem ao apoio financeiro do CNPq, FINEP, CAPES, RENAFEA, CERN e União Européia. e também à colaboração do detector ATLAS pelos dados simulados e por discussões e sugestões sobre o trabalho.

REFERENCES

- [1] EVANS, L., BRYANT, P., LHC Machine, Journal of Instrumentation, v. 3, n. S08001, pp. 1158, 2008.
- [2] ATLAS COLLABORATION, ATLAS Experiment at CERN Large Hadron Collider, Journal of Instrumentation, v. 3, n. S08003, pp. 1407, 2008.
- [3] KOLETSSOU I., "The ATLAS liquid argon calorimeter at the LHC". Nuc. Inst. and Methods in Physics Research A, v. 628, pp 351-354, 2011.
- [4] HERNANDEZ Y., "The ATLAS Tile Calorimeter performance at LHC, Nuc. Inst. and Methods In Physics Research A - <http://dx.doi.org/10.1016/j.nima.2012.11.069i>, 2013.
- [5] WIEDENMAN W., ZHOU N., NEGRI A., HAUSER R., WHITESON D., "The operational performance of the ATLAS trigger and data acquisition system and its possible evolution. Proc. of the Int. Conf. on Computing in High Energy and Nuclear Physics (CHEP), 2012.
- [6] DOS ANJOS, A., TORRES, R., SEIXAS, J., "Neural triggering system operating on high resolution calorimetry information", Nuc. Inst. and Methods in Physics Research A, v. 559, n. 1, pp. 134138, 2006.
- [7] HAYKIN, S., Neural Networks and Learning Machines. 3rd ed. Prentice Hall: Nova Jersey, Estados Unidos, 2008.
- [8] JOLLIFFE, I. T., Principal Component Analysis. 2nd ed. Springer: Nova York, Estados Unidos, 2002.
- [9] HYVARINEN, A., KARHUNEN, J., OJA, E., Independent Component Analysis. Wiley: Nova York, Estados Unidos, 2001.
- [10] ESCUDERO, J., HORNERO, R., ABASOLO, D., et al., "Artifact removal in magneto-encephalogram background activity with independent component analysis", IEEE Transactions on Biomedical Engineering, v. 54, n. 11, pp. 1965-1973, 2007.
- [11] H. L. VAN TREES, "Detection, Estimation, and Modulation Theory", v. 1, 2009-11-04, 2001.
- [12] SIMAS FILHO, E.F, SEIXAS J., CALOBA, L.P., ATLAS Second-Level Electron/Jet Neural Discriminator based on Nonlinear Independent Components. Proceedings of Science, v. ACAT10, p. 1-7, 2010.
- [13] RIEDMILLER, M., BRAUN, H., "A direct adaptive method for faster backpropagation learning, the RPROP algorithm". In: Proc. of Int. Conf. on Neural Networks, pp. 586-591, São Francisco, Estados Unidos, 1993.
- [14] T. CIODARO, D. DEVA, D. DAMAZIO E J.M DE SEIXAS, "Online particle detection with Neural Networks based on topological calorimetry information", Journal of Physics: Conf. Series, v. 368, pp. 1-11, 2012.
- [15] SIMAS FILHO, E.F, SEIXAS J., CALOBA, L.P., Combinação de Classificadores Neurais Segmentados com Pré-processamento por Análise de Componentes Independentes para um Sistema Online de Filtragem. In: Congresso Brasileiro de Redes Neurais e Inteligência Computacional, p. 1-5, Ouro Preto-MG, 2009.