

DISCRIMINAÇÃO NEURAL DE PARTÍCULAS PARA UM DETECTOR SUBMETIDO A UMA ALTA TAXA DE EVENTOS

Thiago Ciodaro Xavier¹, José Manoel de Seixas¹, André Rabello dos Anjos²

¹Laboratório de Processamento de Sinais (LPS), Escola Politécnica/COPPE, UFRJ

¹E-mails: {xavier,seixas}@lps.ufrj.br

²Universidade de Wisconsin.

²E-mail: Andre.Dos.Anjos@cern.ch

Resumo – Esse artigo mostra os resultados da aplicação de redes neurais no desenvolvimento do sistema de filtragem *online* do detector ATLAS, um dos principais detectores que estarão posicionados ao redor do ponto de colisão do colisionador de partículas de última geração, o LHC (*Large Hadron Collider*). As Regiões de Interesse do calorímetro (medidor de energia) do ATLAS são mapeadas em 100 anéis concêntricos de deposição de energia, os quais alimentam a rede neural classificadora, que identifica elétrons (sinal de interesse) e rejeita o sinal de jatos (ruído de fundo). Como pré-processamento dos sinais, utiliza-se um mapeamento de relevância e a análise de componentes principais (PCA) objetivando uma compactação eficiente da informação. Deste modo, aumenta-se a velocidade de processamento e, eventualmente, a eficiência de detecção, com diminuição da taxa de falso alarme.

Palavra Chave – ATLAS, Física de altas energias, Compactação de sinais, Filtragem *online*, Classificadores, Redes Neurais.

Introdução

O CERN (do francês *Conseil Européen pour la Recherche Nucléaire*) é um dos principais laboratórios de colaboração internacional, composto por inúmeros países [1]. 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*), que busca comprovar experimentalmente mecanismos e teorias em física de partículas [2].

O LHC é um acelerador de partículas que irá colidir pacotes de prótons com até 14 TeV de energia no centro de massa. No caso do LHC, um túnel circular, com aproximadamente 27 km de extensão, conduz as partículas, que são submetidas a campos eletromagnéticos produzidos por poderosos ímãs ao longo deste túnel [2]. Essas partículas circulam pelo acelerador até atingirem a energia cinética desejada onde, então, são feitas colidir contra partículas que foram aceleradas no sentido contrário. Cada colisão constitui um evento a ser analisado através de detectores posicionados em torno dos pontos de colisão. A Figura 1 mostra o LHC e a posição de seus detectores.

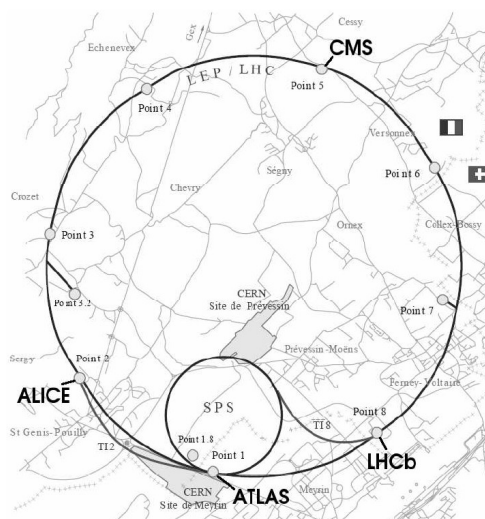


Figura 1: Vista aérea do LHC e seus detectores.

Um dos principais detectores do LHC é o ATLAS (do inglês *A Toroidal LHC ApparatuS*) [3]. Este detector, de uso geral, é capaz de detectar inúmeras partículas. Para alcançar tal detecção, o

ATLAS é dividido em 4 principais seções: o detector de traços, capaz de observar o percurso que as partículas fizeram desde a colisão até sua completa absorção; os calorímetros eletromagnético e hadrônico, capazes de medir, respectivamente, a energia depositada por partículas eletromagnéticas leves e partículas mais pesadas (hádrons); e as câmaras de múon, capazes de detectar a passagem de múons (partículas raramente observadas pelos subdetectores anteriores). A Figura 2 mostra uma ilustração dos detector ATLAS e seus subdetectores.




Figura 2: O detector ATLAS e seus subdetectores.

Um dos objetivos do LHC (e do ATLAS) é a comprovação da partícula conhecida como bóson de Higgs, prevista no modelo padrão [4]. 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 energia menor, mais estáveis e, por sua vez, observáveis. A observação dessas partículas mais estáveis leva ao bóson de Higgs. Porém, estes eventos de interesse do LHC são muito raros, demandando dias de operação a elevada taxa, no caso, em torno de 40 MHz.

Por operar a elevadas taxas, 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 [5]. O armazenamento de toda a informação fornecida pelo detector para posterior análise *offline* é impossível. Ademais, os eventos de interesse para o experimento ocorrem raramente, como mencionado acima. Desta maneira, um sistema de filtragem *online* 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 [6].

Esse trabalho 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 no ambiente HLT (do inglês *High Level Trigger*), que engloba os dois níveis superiores de filtragem. A identificação de elétrons é dificultada pelo elevado ruído de fundo do experimento, no caso, representado por jatos [5]. O compacto discriminador neural proposto neste trabalho atuará no segundo nível de filtragem do ATLAS, com acesso à granularidade plena dos calorímetros e a sua centena milhares de canais de leitura.

1 O sistema de calorimetria do ATLAS

O sistema de calorimetria do ATLAS é composto pelos calorímetros eletromagnético (e.m.) e hadrônico (Figura 3). O calorímetro eletromagnético, ou LArg [7] (do inglês *Liquid Argon Calorimeter*), 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. O calorímetro e.m. tem, também, um pré-irradiador (em inglês, *pre-sampler*), 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...).

Os calorímetros hadrônicos do ATLAS são formados pelo TileCal (do inglês *Tile Calorimeter*), e a Tampa Hadrônica [8]. O TileCal é posicionado logo atrás do LArg, abrangendo as porções do barril e sua extensão. Assim como a seção e.m., a seção hadrônica também possui granularidade variável.




Figura 3: Detalhes da calorimetria do LArg (a) e do TileCal (b).

Os dois calorímetros são dispostos ao redor do ponto de impacto e, por isso, têm o formato cilíndrico. O sistema de coordenadas do ATLAS, então, acompanha a direção dos feixes de partículas provenientes da colisão. As coordenadas empregadas são η , ϕ e z , representando, respectivamente, a direção do feixe de partículas após a colisão (também chamada de pseudo-rapidez) [9] e a rotação em torno do eixo de colisão z .

2 O 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, partículas cujas características ainda devem ser melhor estudadas...) da massa de dados já conhecida, que funciona como ruído de fundo do experimento. Para isto, foi concebido o Sistema de *Trigger* [5], dividido em três níveis (Figura 4). É importante que se mantenha o tempo de latência (tempo para formar e distribuir a decisão do filtro) no valor mais baixo possível para cada nível de operação, de modo a se adequar à elevada taxa de eventos do LHC. Durante esse tempo, a informação de todos os canais do detector precisa ser retida em memórias do tipo *pipeline* [6].

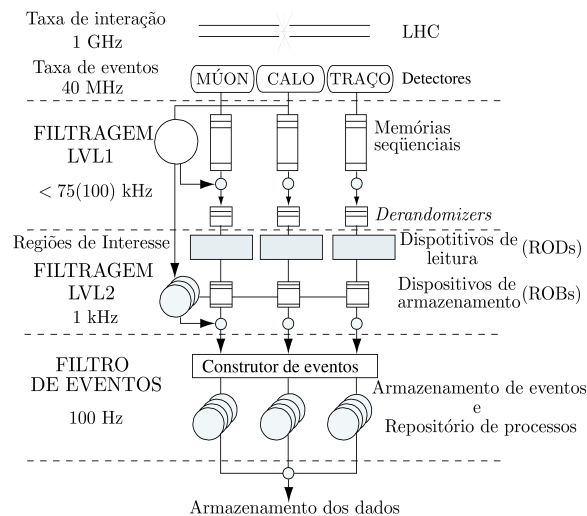


Figura 4: Esquema do sistema de filtragem do detector ATLAS.

O primeiro nível de *Trigger*, que realiza a seleção inicial, possui um tempo de latência máxima de

2 μ 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 [10], 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*), e passá-las ao segundo nível.

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* [11].

A operação do segundo nível de filtragem é dividida em duas etapas [11]. Na primeira, extraem-se as características essenciais para a análise da RoI, visando uma compactação efetiva da dimensão original do espaço de dados (a RoI é composta, tipicamente, por cerca de 1.000 células de calorimetria). Na segunda etapa, um algoritmo de hipóteses é aplicado sobre essas características extraídas para realizar a classificação dos subprodutos das colisões.

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. A seleção final é, então, feita *offline*.

2.1 O ambiente ATHENA

O ambiente de desenvolvimento ATHENA [12] foi concebido para fornecer um ambiente de emulação do sistema de filtragem, permitindo uma eficiente elaboração de seus algoritmos.

O objetivo do ATHENA é disponibilizar ferramentas que facilitem a escrita e análise de programas para os sistemas *online* e *offline* do ATLAS. Este ambiente possui ferramentas para realizar simulações de uma colisão próton-próton e simulação da resposta dos detectores a estas colisões, a partir de modelos precisos e em contínuo desenvolvimento dos detectores. Dessa forma, é possível realizar o desenvolvimento de todo o sistema de filtragem do segundo e terceiro níveis.

Como o experimento irá começar sua operação ao final de 2008, os eventos são simulados através de complexos algoritmos. Os dados simulados são reconstruídos dentro do ATHENA e os algoritmos de filtragem podem, enfim, ser testados, de acordos com recursos especificamente requisitados.

Neste trabalho foi utilizado um conjunto de dados com aproximadamente 2.400 RoI de calorimetria referentes a elétrons e 800 a jatos. Os dados já foram emulados pelo ATHENA e consistem em eventos que seriam aceitos pelo primeiro nível de filtragem, representando uma situação próxima à realidade de operação no segundo nível de *Trigger*.

3 Algoritmo de extração de características

O algoritmo de referência no segundo nível de filtragem do ATLAS, com base em calorimetria, é o algoritmo T2Calo [13]. Observando as RoI de elétrons e jatos típicos do segundo nível de *Trigger* (Figura 5), 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. São essas características que o T2Calo procura extrair através de suas variáveis discriminantes.

No final, o T2Calo calcula 4 variáveis altamente discriminantes, que são obtidas através de janelas no plano η e ϕ , ao redor da célula mais energética, no centro do feixe. Posteriormente, elas são apresentadas a um Algoritmo de Hipóteses que, através de cortes lineares sobre as variáveis extraídas, vistas a partir de correlações bi-dimensionais e incorporando o conhecimento especialista em calorimetria, irá etiquetar o evento como elétron ou jato.

4 Anelador neural

Assim como o algoritmo do T2Calo extrai as características de deposição de energia das RoI através de janelas (*cluster*) de células, numa área em η e ϕ , a proposta do anelador neural (*neuralringer*) é fazer o mapeamento das RoI através de anéis concêntricos de deposição de energia e utilizar redes neurais artificiais como Algoritmo de Hipóteses [14]. Estudos anteriores mostraram que o anelador neural consegue atingir resultados superiores aos resultados alcançados pelo T2Calo [14], com aproximadamente 96% dos elétrons que chegam no segundo nível detectados corretamente, enquanto uma taxa de, aproximadamente, 20kHz de jatos são eliminados.

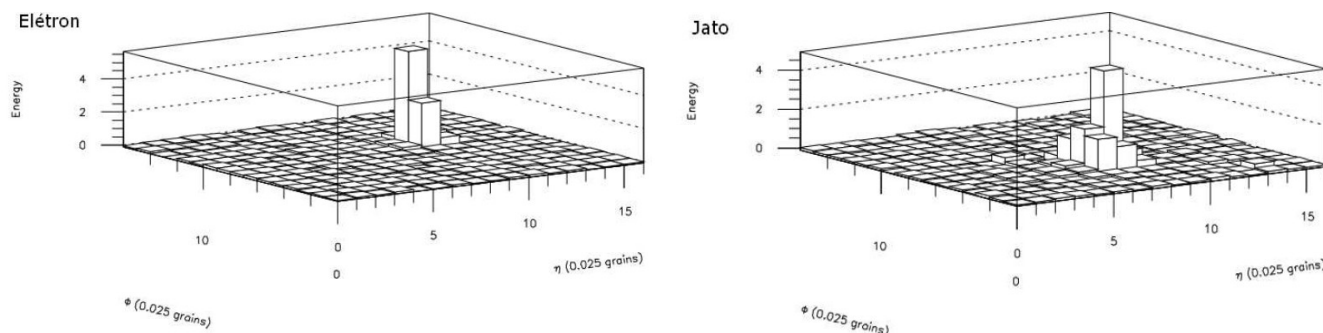


Figura 5: RoI típicas para um elétron e um jato aceitos pelo primeiro nível de filtragem, para a segunda camada e.m..

O mapeamento em anéis é feito de forma abstrata, uma vez que a granularidade de certas camadas do calorímetro impede a visualização de anéis. A Figura 6 mostra um conjunto de anéis para algumas camadas do calorímetro. Uma vez encontrada a célula mais energética da camada, os anéis são criados de forma concêntrica, somando-se a energia das células que formam o anel. Esse tipo de mapeamento também tenta extrair as características de espalhamento e relação de energia entre as camadas do calorímetro. Eventualmente, podem ser criados anéis incompletos.



Figura 6: Exemplo da topologia dos anéis para algumas camadas dos calorímetros do ATLAS.

A normalização em energia utilizada foi a do tipo seqüencial. Para cada camada, calcula-se a energia total depositada e divide-se o valor da energia do primeiro anel por essa energia. A energia do segundo anel é dividida pela diferença entre a energia total da camada e a energia do primeiro anel, e assim sucessivamente até que o número de anéis se esgote. Entretanto, os valores energéticos nos últimos anéis de cada camada, aqueles nos quais a relação sinal ruído é a menor, terão o menor fator de normalização e, portanto, a maior amplificação. Isto é prejudicial ao desempenho de qualquer discriminador, uma vez que beneficiará canais ruidosos. A solução é limitar a variação do fator de normalização por camada. A Tabela 1 exemplifica a execução do algoritmo.

Anel	Normalização	Soma em Anel
1	E (total da camada)	E_1
2	$E - E_1$	E_2
...
N	$E - E_1 - \dots - E_{N-1}$	E_N

Tabela 1: Normalização do tipo seqüencial para os anéis e suas energias (E_i)

Como pode-se especificar a região em η e ϕ dos anéis de cada camada, de forma a se adaptar à diferente granularidade de cada uma, a Tabela 2 mostra a quantidade de anéis utilizada para cada camada do calorímetro, totalizando 100 anéis.

Os dados de simulação que foram utilizados nesse artigo foram divididos em 2 grupos, treino e teste, sendo o grupo de teste também utilizado na validação do treinamento. Para lidar com a significativa diferença no número de eventos e evitar uma eventual tendência no treinamento, as RoI de jatos foram replicadas no conjunto de treino. O algoritmo de treinamento supervisionado utilizado para o treinamento da rede foi o *Resilient Backpropagation* [15].

	Camadas eletromagnéticas			Camadas hadrônicas			
	<i>Pre-sampler</i>	1 ^a	2 ^a	3 ^a	1 ^a	2 ^a	3 ^a
Número de Anéis	8	64	8	8	4	4	4

Tabela 2: Quantidade de anéis por camada dos calorímetros.

A figura de mérito escolhida para a discriminação entre elétrons e jatos foi o produto SP [14], que relaciona as probabilidades de detecção de elétrons e jatos de acordo com a fórmula:

$$SP = (p_e p_j) / (p_e + p_j)$$

Onde p_e indica a probabilidade de detecção de elétrons e p_j a probabilidade de detecção de jatos. O produto SP foi escolhido uma vez que, na discriminação do segundo nível de *Trigger*, deseja-se que a eficiência de detecção seja elevada, mas que o falso alarme seja o mais baixo possível. O produto SP torna essa relação eficiência de detecção/falso alarme homogênea. Inspeccionando a fórmula do produto SP, pode-se ver que ele assume valores entre 0 e 2.

Foram treinadas redes MLP (*Multi Layer Perceptron*) [16] com diversas topologias (2 a 15 neurônios na única camada escondida) e 1 neurônio na camada de saída, tendo havido 5 inicializações para cada tentativa de treinamento. A função tangente hiperbólica foi usada como a função de ativação dos neurônios, seja na camada escondida, seja na camada de saída. As variáveis de entrada são esferizadas (média nula e variância unitária) de acordo com o conjunto de treinamento. O treinamento foi feito por bateladas, onde o critério de parada utilizado foi o produto SP.

5 Compactação da informação

A fim de diminuir a dimensão do espaço de entrada original e aumentar a velocidade de processamento, com o aumento eventual da eficiência do classificador, aplicou-se um mapeamento de relevância e a análise de componentes principais.

5.1 Relevância

O estudo de relevância da entrada mostra quais são as variáveis mais importantes à discriminação [14]. Assim, as demais variáveis podem, a critério do projetista, ser descartadas do processamento.

A relevância se baseia no quanto o classificador desenvolvido altera seu desempenho quando se modificam estatisticamente os valores de uma dada variável explicativa. Para avaliar a relevância de cada componente, além de se utilizar a sua forma original, baseada na variação média quadrática da saída da rede, podemos utilizar a variação produzida no produto SP. Assim, temos:

$$R_{MSE_{x_i}} = \frac{1}{N} \sum_{j=1}^N [O(\vec{x}_j) - O(\vec{x}_j|_{x_i=\bar{x}_i})]^2$$

$$R_{SP_{x_i}} = SP(X) - SP(X|_{x_i=\bar{x}_i})$$

Onde R_{x_i} é a relevância da i -ésima componente, $O(\vec{x})$ é a resposta neural ao estímulo \vec{x} , \bar{x}_i representa o valor médio do componente \bar{x}_i do estímulo \vec{x} e X representa o conjunto dos N eventos de entrada da rede neural. As variáveis que produzem a maior flutuação na saída do discriminador ou as maiores diferenças no produto SP serão ditas relevantes.

A Figura 7 mostra a relevância dos 100 anéis calculada por MSE e SP. A linha vertical destacada em cada figura é o patamar de relevância, onde anéis com relevância maior do que este valor (uma ordem de grandeza abaixo da variável de maior relevância) são considerados relevantes. Já as linhas horizontais destacadas marcam a passagem de uma camada do calorímetro para a outra, de forma crescente (*pre-sampler* e.m., 1ª camada e.m....até a 3ª camada hadrônica). De acordo com a sua relevância, o número de anéis selecionados seria: MSE treino, 15 anéis; MSE teste, 19 anéis; SP treino, 23 anéis; SP teste, 35 anéis. Pode-se notar, pelo estudo de relevância por SP, que alguns anéis com valores negativos de relevância podem ser considerados variáveis confundidoras estatisticamente [17], uma vez que o produto SP aumenta quando eles são substituídos pela sua média. Note-se, entretanto, que a maior parte dos anéis relevantes independe do método de relevância utilizado.




Figura 7: Relevância dos anéis pelos métodos MSE (a) e pelo SP (b), para o conjunto de treino e teste.

5.2 Análise de componentes principais

A análise de componentes principais (PCA – do inglês *Principal Component Analysis*) é uma técnica estatística que descorrelaciona a informação contida numa base de dados através de uma mudança de base [18]. Os componentes que formam esta nova base são chamados de componentes principais e podem ser ordenados de acordo com sua energia (variância). Dependendo do valor de sua energia, podemos simplesmente descartar um componente minoritário, acarretando uma perda

controlada da informação.

A Figura 8a mostra a curva de carga para os componentes extraídos. O eixo vertical mostra o percentual de energia acumulado conforme a energia de cada componente é somada. Pode-se ver que com 40 componentes temos 95% de energia acumulada. Já a Figura 8b mostra a relevância por SP dos componentes principais (a relevância por MSE mostrou resultado semelhante). Nota-se que somente um componente é considerado relevante.

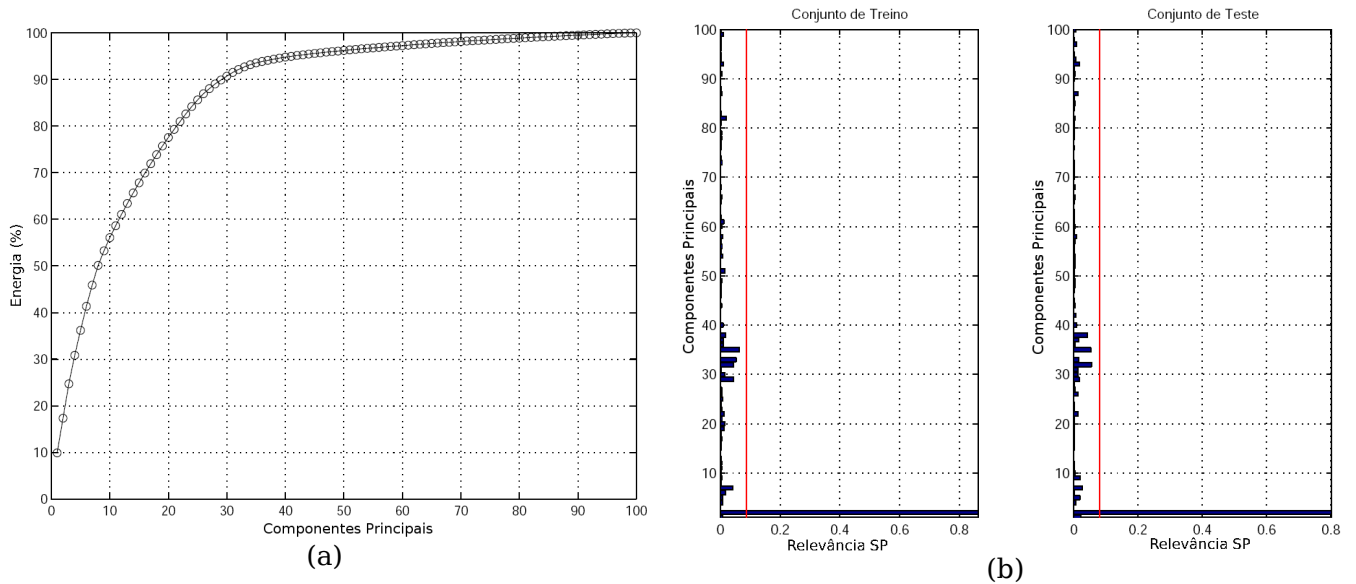


Figura 8: Seleção dos componentes principais por energia (a) e relevância SP (b).

A Figura 9 mostra o histograma das projeções, neste componente principal mais relevante de elétrons e jatos do conjunto de treino (o conjunto de teste mostrou resultado semelhante). Nota-se que o componente é bem seletivo. A Figura 9 mostra, também, a contribuição dos anéis originais para este componente principal. As linhas verticais mostram a passagem de uma camada para a outra do calorímetro, indo do calorímetro e.m. para o hadrônico.

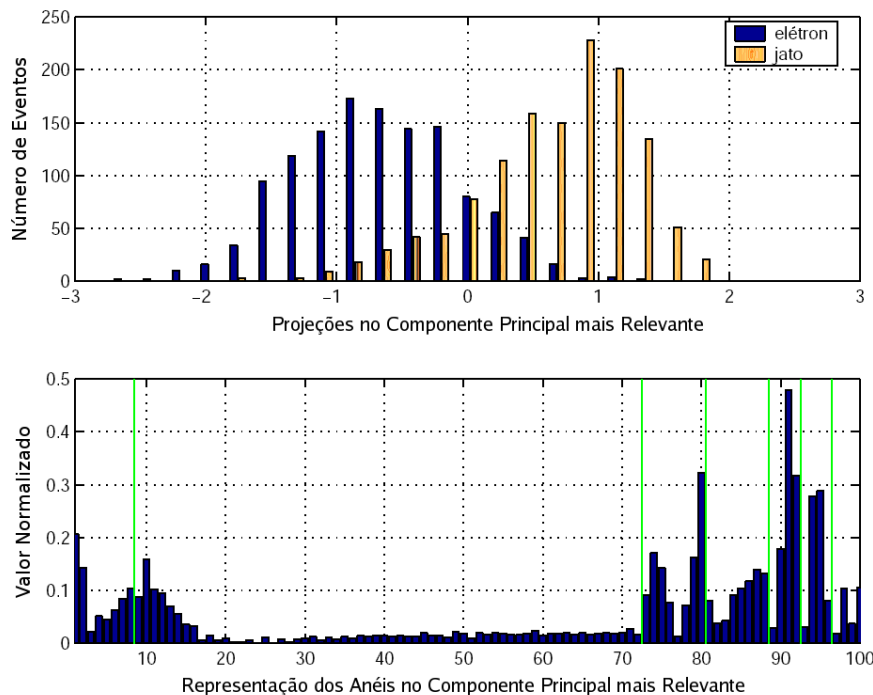


Figura 9: Histograma e representação no espaço de anéis original do componente principal mais relevante.

Nesta aplicação, na qual o detector é segmentado, pode-se utilizar uma extração de componentes principais de forma segmentada [19]. Como o calorímetro é dividido em camadas de deposição de energia, os componentes principais podem, então, ser extraídos por camadas. A seleção de componentes pode se dar pela curva de carga ou pela relevância destes para o discriminador neural.

A Figura 10 mostra as curvas de carga de algumas camadas do calorímetro eletromagnético e do hadrônico, enquanto que a Figura 11 mostra a seleção por relevância dos componentes principais extraídos de forma segmentada.




Figura 10: Curva de carga para algumas camadas dos calorímetros e.m. (a), e o hadrônico (b).

Para os componentes principais extraídos de forma segmentada, as curvas de carga mostraram uma compactação de aproximadamente 30%. Dos 100 componentes, a seleção por energia, levando em conta entre 90% e 95% de energia acumulada para cada camada, mantém 71 componentes. Entretanto, a relevância por MSE e SP desses componentes principais mostrou que apenas 10 a 15 componentes podem ser mantidos.

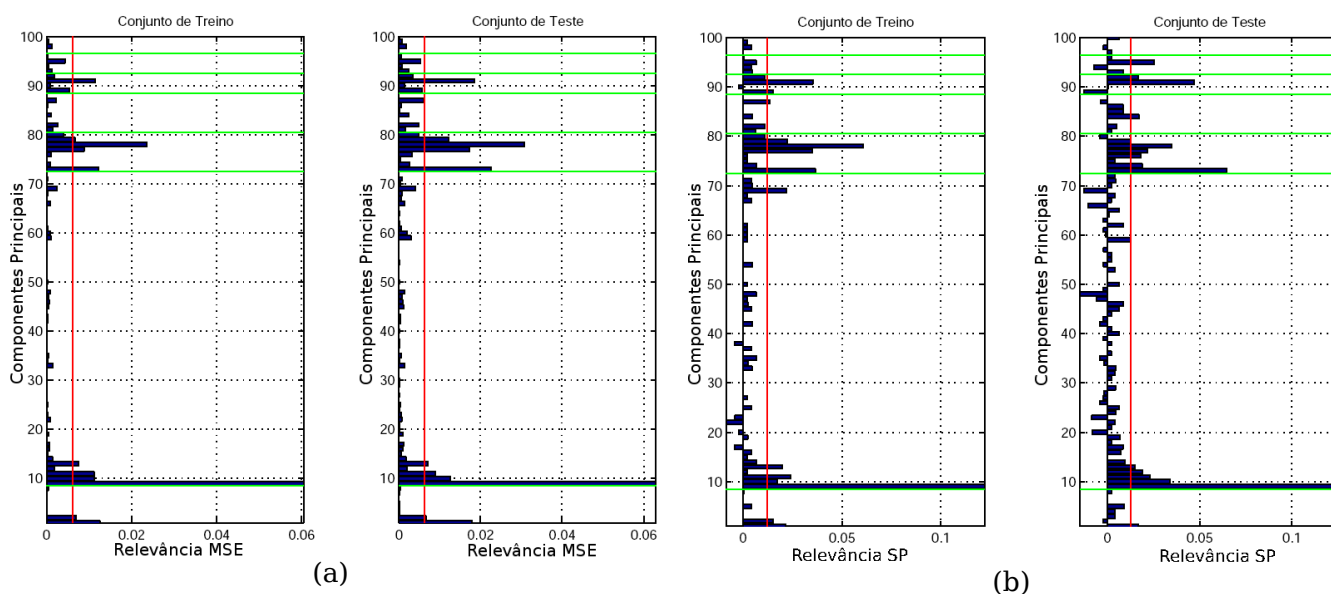


Figura 11: Seleção dos componentes principais extraídos de forma segmentada por relevância MSE (a) e SP (b).

6 Resultados de classificação

Feitas todas as análises quanto à compactação, diversas redes neurais foram treinadas, seguindo o método descrito na seção 4. As redes são comparadas através da curva ROC (do inglês *Receiver Operating Characteristics*) [16] de cada uma e pelo produto SP alcançado. A curva ROC relaciona a eficiência de detecção (para elétrons) com o falso alarme correspondente (jatos detectados erroneamente como elétrons). Conforme andamos na curva ROC, o produto SP é variado.

A Figura 12 mostra as curvas ROC das redes neurais treinadas compactando-se a informação por relevância. Note-se que, se fixarmos um nível de 10% de falso alarme, todas as redes mostram resultados semelhantes, com, aproximadamente, 95% de eficiência de detecção. Porém, se fixarmos em 5% o falso alarme, os cortes por relevância MSE apresentam uma eficiência de detecção levemente maior, com respeito àqueles adotados por relevância SP, mas a performance é cerca de 10 pontos percentuais melhor do que a alcançada com o uso da informação completa (100 anéis).

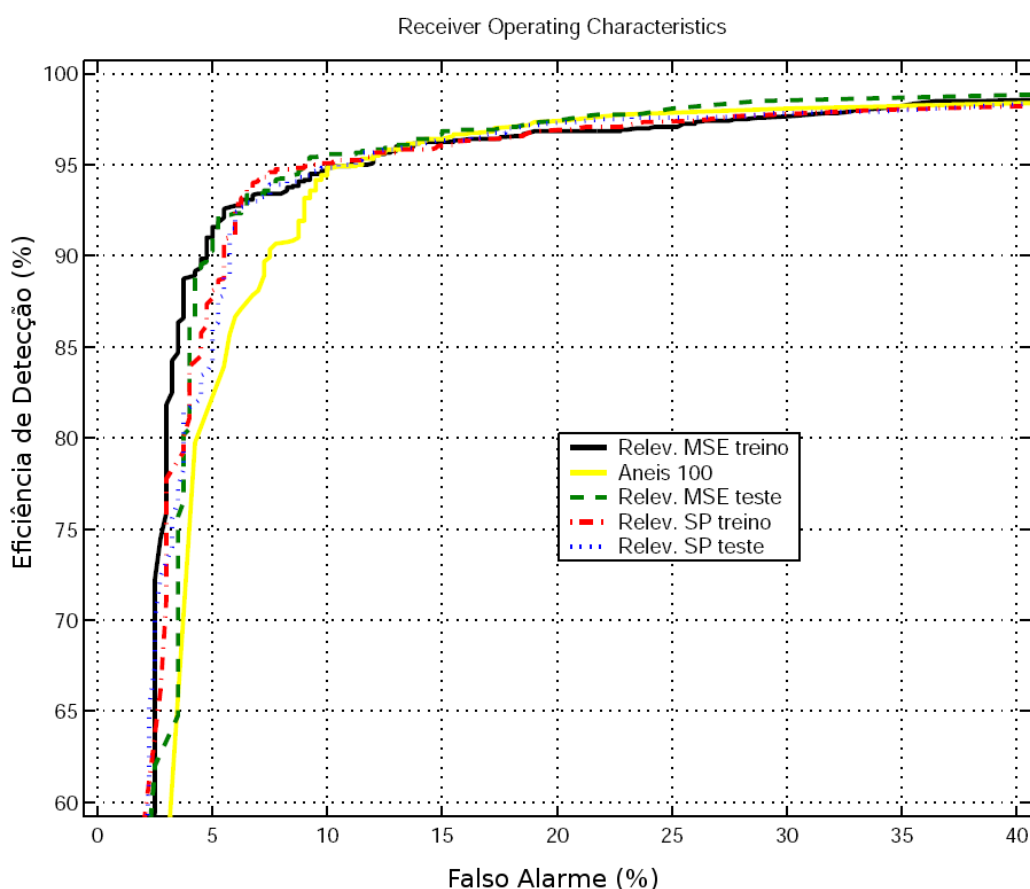


Figura 12: Curvas ROC dos discriminadores com anéis selecionados por relevância.

Para as análises com PCA segmentada e não segmentada, as respectivas ROC se encontram na Figura 13. Os classificadores neurais adotando cortes por relevância do conjunto de treino e teste, por MSE e SP, tiveram desempenho similares e estão representadas somente pela curva ROC referente à seleção de componentes pelo conjunto de treino. Pode-se ver que o componente mais relevante da PCA não segmentada consegue resultados inferiores, porém significativos por se tratar de apenas um único componente. Se fixarmos também um nível de falso alarme em 5%, o discriminador com corte por PCA segmentada e relevância por SP consegue uma eficiência de detecção entre 2,5 e 15 pontos percentuais melhor que os outros métodos. Já se fixarmos em 10% de falso alarme, os discriminadores têm praticamente a mesma eficiência de detecção.

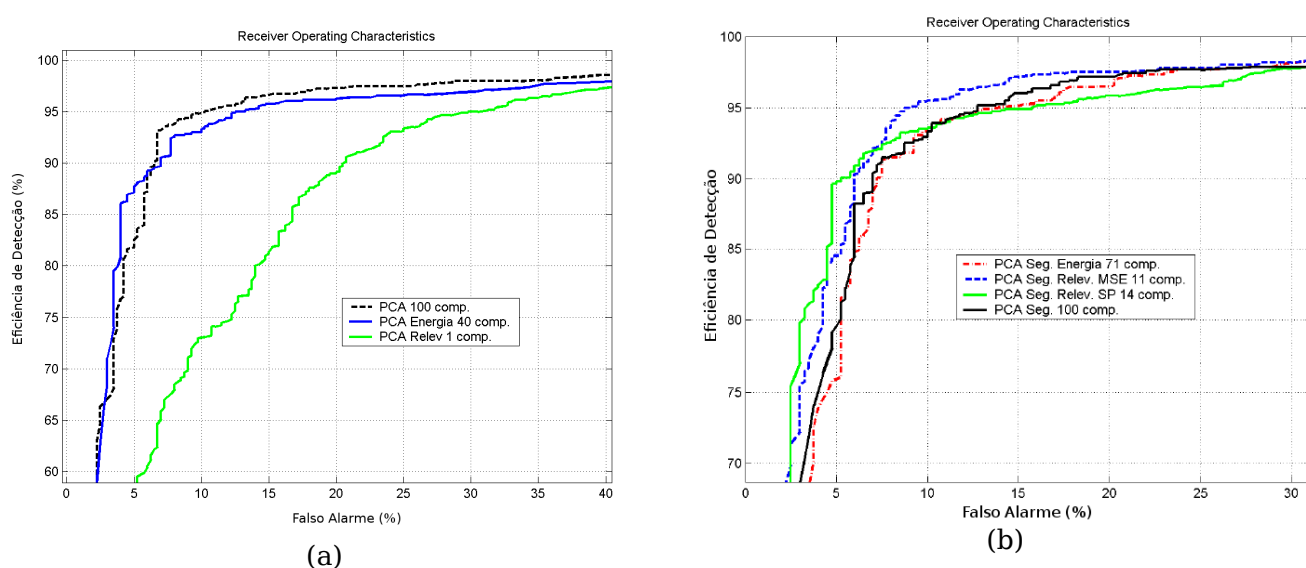


Figura 13: Curvas ROC dos discriminadores utilizando compactação por PCA não segmentada (a) e segmentada (b).

Assim, considerando o nível fixo de 5% de falso alarme e levando em conta o número de variáveis de entrada de cada análise, a Figura 14 mostra as curvas ROC para os melhores discriminadores, nas abordagens por relevância e por PCA. Já a Tabela 3 mostra o SP para um nível fixo de 5% de falso alarme, o SP máximo alcançado por cada discriminador e a arquitetura de cada discriminador (nós na camada de entrada, número de neurônios na camada escondida e na camada de saída).




Figura 14: Curvas ROC dos melhores discriminadores, com os tipos de compactação empregados.

	100 Anéis	PCA Seg. Relev. SP	Relev. MSE treino	Relev. MSE teste
SP - 5%	1,410	1,577	1,623	1,612
SP - máximo	1,578	1,591	1,629	1,612
Arquitetura/ FLOPS	100:2:1	14:7:1	15:4:1	19:2:1

Tabela 3: Produtos SP dos melhores discriminadores, considerando um falso alarme de 5%, o SP máximo alcançado pelo discriminador e a arquitetura utilizada (nós da camada de entrada, número de neurônios das camadas escondida e de saída).

7 Conclusão

Os discriminadores neurais desenvolvidos neste trabalho mostraram desempenho elevado na classificação de partículas, mesmo considerando – se o ambiente inóspito do LHC. O mapeamento das Regiões de Interesse em anéis concêntricos de deposição de energia não só compacta eficientemente a dimensão do espaço original de dados, como também extrai características (físicas) importantes sobre as partículas que atravessaram o calorímetro.

As técnicas posteriores de compactação, seja por relevância, seja por análise de componentes principais, além de diminuírem a dimensão dos dados de entrada da rede neural, também proporcionaram uma maior eficiência na discriminação de elétrons e jatos. A relevância dos componentes principais extraídos de forma não segmentada mostrou que podem haver variáveis confundidoras. Um estudo futuro é a retirada de forma exclusiva destes componentes. A retirada ou inclusão de variáveis, variando – se a dimensão original da informação, é um compromisso entre o tempo de processamento e a eficiência desejada para o discriminador. Fica a critério do projetista a decisão.

É importante ressaltar que o detector permanecerá em operação por 10 anos. Durante esse tempo, o cenário de operação poderá sofrer grandes mudanças, assim como os objetivos físicos do experimento. É de grande importância que os discriminadores do ATLAS tenham mecanismos simples para a adaptação a essas novas especificações. Neste aspecto, a compactação da informação aqui proposta sobre o algoritmo de anelamento neural contribui na adaptação do sistema de filtragem a diferentes cenários de operação.

Agradecimentos

Agradecemos ao apoio de instituições brasileiras de incentivo à pesquisa, CNPq e FAPERJ, e ao CERN (Suíça). Em especial, agradecemos aos colegas da colaboração T/DAQ pela disponibilização dos dados usados neste trabalho e pelas discussões frutíferas ao longo do seu desenvolvimento.

Referências Bibliográficas

- [1] CERN, European Center for Nuclear Research. www.cern.ch, acessado em janeiro de 2008.
- [2] K. Schindl, LHC Request and Overview, *Workshop on LHC performance*, março, 2003, Chamonix, França.
- [3] ATLAS, A Toroidal LHC ApparatuS. www.cern.ch/atlas, acessado em janeiro de 2008.
- [4] D. Halliday, R. Resnick e J. Walker, *Fundamentals of Physics*, John Wiley, 1996.
- [5] R. Goncalo, et al., Overview of the High-Level Trigger Electron and Photon Selection for the ATLAS Experiment at the LHC, *IEEE Nuclear Science Symposium*, p.167-172, San Juan, Porto Rico, outubro, 2005.
- [6] ATLAS Trigger and Data Acquisition Collaboration, ATLAS High-Level Triggers, DAQ and DCS Technical Design Report, *Technical Report*, CERN, 2000.
- [7] M. Lefebvre, An Overview of the ATLAS Liquid Argon Calorimetry and the ATLAS Electromagnetic Calorimeters, *7th International Conference on Calorimetry in High-energy Physics*, p.337-344, novembro, 1997, Tucson, EUA.
- [8] G. Schlager, The status and performance of the ATLAS hadronic tile calorimeter, *Nuclear Instruments and Methods in Physics Research, Section A*, v. 581, p.393-396, outubro, 2007, Viena, Áustria.
- [9] B. Nicquevert et al., The ATLAS coordinate system, *Technical Report*, CERN, 1996.
- [10] J. Garvey et al., The ATLAS Level-1 Calorimeter Trigger Architecture, *IEEE Transactions on Nuclear Science*, v. 51, p. 356-360, 2004.
- [11] M. Abolins, S. Armstrong, J.T. Baines, The second level trigger of the ATLAS experiment at CERN's LHC, *Nuclear Science, IEEE Transactions on*, v. 51, p. 909-914, junho, 2004.
- [12] The ATLAS Project, Athena User Guide and Tutorial, CERN, agosto de 2001.
- [13] The PESA Core Algorithms Group, Algorithms for the ATLAS high-level trigger, CERN, junho de 2003.
- [14] A. dos Anjos, R.C. Torres, J.M. de Seixas, B.C. Ferreira e T.C. Xavier, Neural Triggering System Operating in High Resolution Calorimetry Information, *Nuclear Instruments and Methods in Physics Research Section A*, v. 559, p. 134-138, abril de 2006.
- [15] M. Riedmiller e H. Braun, A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm, *Proceedings of the IEEE International Conference on Neural Networks*, v. 1, p. 586-591, IEEE, 1993.
- [16] S. Haykin, *Neural Networks. A Comprehensive Foundation*, Prentice-Hall, Inc., ed. 2, 1999.
- [17] E. M. do Nascimento, *Redes Neurais Artificiais: Uma Aplicação no Estudo da Poluição Atmosférica e seus feitos Adversos à Saúde*, *Tese de mestrado*, PEP/COPPE, UFRJ, 2006.
- [18] I.T. Jolliffe, *Principal Component Analysis*, Springer-Verlag, 2002
- [19] J. M. de Seixas, H. P. Lima Júnior. A Segmented Principal Component Analysis Applied to Calorimetry Information at ATLAS. *Nuclear Instruments and Methods in Physics Research Section A*, v. 559, p. 129-133, 2006.
- [20] H. Van Trees. *Detection, Estimation and Modulation*, John Wiley & Sons, 1966.