

## Um Discriminador de Partículas de Altas-Energias Baseado em um Calorímetro Projetivo

D.O.Damazio, J.M. Seixas

damazio@lacc.ufrj.br, seixas@lps.ufrj.br

COPPE/EE/UFRJ, CP 68504, Rio de Janeiro 21945-970, Brazil

### Abstract

*Neural processing is applied to a particle discriminator problem in a high-energy experimental physics environment. Using the energy deposition profile for incoming particles provided by an energy measurement detector with high granularity (a calorimeter), a two-layered neural network discriminator is trained on experimental data to identify electrons, pions and muons. During the training phase, the neural network discriminator is able to identify impurities in the original data sample, and classical physics methods do validate such outsider identification. After removing these impurities from the data sample, the neural network was retrained and was able to identify electrons, pions and muons with efficiencies of 100%, 99% and 100%, respectively. The discriminator may be implemented on fast digital signal processor technology for on-line operation.*

### 1 Introdução

De forma a pesquisar a estrutura da matéria, físicos, informáticos e engenheiros vêm trabalhando em diversos projetos de colisionadores de partículas de altas energias. Entre estes projetos está o LHC - Large Hadron Collider, que está sendo desenvolvido no CERN, Laboratório Europeu para a Física de Partículas. Este projeto, que deve entrar em funcionamento em 2005, consiste de um grande acelerador de partículas, que produz a colisão entre nuvens de prótons ( $\sim 10^{11}$  prótons em cada nuvem) a cada 25 nanossegundos. Complexos detectores são posicionados ao redor dos pontos de colisão, visando recolher informações sobre os subprodutos gerados pelas colisões. Um destes detectores é o ATLAS, um aparato de formato toroidal formado por várias camadas de detectores [1].

Uma informação fundamental a ser obtida no ambiente do LHC é a energia das partículas incidentes. Visando realizar esta medida, o ATLAS possui os calorímetros eletromagnético e hadrônico. Os calorímetros são detectores que medem, com grande precisão, a energia das partículas que neles penetram [2]. Eles são capazes de fornecer uma informação detalhada sobre a deposição de energia de uma dada partícula, a partir da absorção total desta energia em sua estrutura e pela amostragem, através de um número elevado de canais de leitura, do sinal de energia que está sendo absorvido. Os calorímetros são,




Figura 1: Barril e as extensões do barril.

então, detectores tipicamente segmentados e de elevada granularidade.

Para que a performance do calorímetro seja otimizada, temos calorímetros especializados na detecção de partículas eletromagnéticas (elétrons, por exemplo), bem como calorímetros especializados em partículas hadrônicas (prótons, píons, por exemplo). No LHC, a medição precisa das interações hadrônicas é importante e, para isto, o calorímetro hadrônico deverá fornecer uma informação de alta qualidade.

Além da medição detalhada do perfil de energia, os calorímetros podem também fornecer informações preciosas sobre o tipo de partícula que com eles interagem, uma vez que tal perfil de energia é dependente da classe a que a partícula incidente pertence. Assim, as informações providas de um calorímetro podem discriminar elétrons de píons, por exemplo [3]. Também, devido à rápida resposta que caracteriza os calorímetros, estes podem ser utilizados em sistemas *online* de validação de eventos físicos, os chamados sistemas de *trigger* [4]. Em experimentos de alta taxa de eventos, como é o caso do LHC, os sistemas de *trigger* são essenciais para a eliminação do enorme ruído de fundo que mascara os eventos de interesse para o experimento.

Este artigo descreve o projeto de um discriminador neural de partículas para uma fatia do calorímetro hadrônico a ser utilizado no LHC. Este calorímetro *Extended Barrel Tilecal* se encontra na extensão da parte central cilíndrica (conhecida como barril, e formada por 64 módulos) do detector hadrônico do ATLAS, o Tilecal




Figura 2: Um módulo do calorímetro hadrônico com o sistema óptico de leitura em destaque.

(veja a Figura 1). Dois conjuntos de módulos formam as extensões do barril aqui referidas, tendo cada uma 64 módulos. Formado por camadas de ferro, entre as quais se colocam telhas de material cintilante, o Tilecal, tanto na sua área do barril, quanto na sua área estendida, tem mostrado um excelente desempenho em testes experimentais em feixe de partículas realizados no CERN[5, 6]. A utilização das redes neurais nesta aplicação apresenta uma dupla finalidade:

1. discriminação entre diferentes tipos de partículas, incluindo elétrons, píons e múons, para diferentes níveis de energia;
2. identificação de contaminação no feixe experimental de partículas; tipicamente, múons no feixe de píons e píons e múons no feixe de elétrons. Esta contaminação que se apresenta apesar da alta qualidade do feixe de partículas utilizado tende a deteriorar artificialmente a performance de discriminação.

Na próxima seção descreveremos as características próprias do calorímetro em estudo, bem como alguns detalhes sobre a configuração experimental adotada para a aquisição dos dados, e as evidências de contaminação dos feixes experimentais de partículas. Na Seção 3, analisaremos a estrutura da rede neural utilizada bem como os resultados obtidos, tanto na determinação de contaminação, bem como na eficiência de discriminação alcançada quando descartamos os eventos de contaminação. Por último apresentamos as conclusões do trabalho.

## 2 O Calorímetro

O calorímetro *Extended Barrel* (EB), vem sendo desenvolvido para complementar as informações da parte central do calorímetro Tilecal. Este tipo de calorímetro é constituído de camadas de material pesado, no caso ferro, que serve de barreira para as partículas que interagem com o calorímetro, fazendo com que a energia destas partículas seja completamente absorvida no seu interior. Desta forma, quando a partícula penetra no calorímetro,

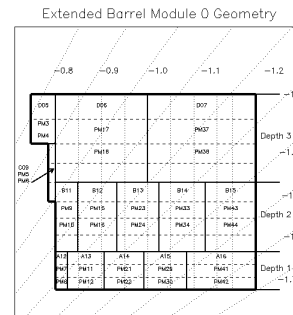


Figura 3: Células da extensão do barril.

ela sofre um processo de decaimento, o qual resulta na produção de outras partículas de menor energia. Isto vai ocorrendo até que a energia da partícula incidente seja totalmente absorvida na estrutura do calorímetro. Este processo forma uma cascata de partículas no interior do calorímetro, a qual é característica específica de cada classe de partículas que atinge o detector.

Para se obter uma amostragem da energia que está sendo despositada no calorímetro, entre as camadas de material pesado são dispostas telhas de material cintilante, as quais emitem luz quando são excitadas pela passagem das partículas durante a produção de uma dada cascata. O sinal de luz assim gerado é transportado por meio de fibras ópticas que se encontram acopladas às telhas em duas das suas laterais (veja a Figura 2). Por fim, o sinal luminoso é convertido em sinal elétrico através de um detector de luz, um tubo fotomultiplicador [5]. Tais sinais elétricos apresentam uma informação de carga proporcional à energia original da partícula incidente, a qual é lida por meio de um sistema de conversão analógica-digital de carga.

Para que se tenha acesso aos detalhes intrínsecos de cada cascata produzida no interior do Tilecal, este calorímetro se encontra segmentado em células de leitura. Na Figura 3, pode-se observar como estão dispostas estas células no calorímetro. Temos no sentido longitudinal 3 camadas de células compostas de 5 células na primeira camada, 6 na segunda e 3 na terceira. Como cada uma destas células produz dois canais de leitura (através das fibras ópticas acopladas em suas laterais), um total de 28 canais de leitura são gerados.

A Figura 4 nos mostra o arranjo experimental utilizado para a coleta dos dados que iremos utilizar. Foram construídos dois módulos representantes desta técnica, produzindo-se, então, um total de 56 sinais de energia para cada evento registrado. Estes módulos são vistos na parte central do arranjo mostrada na figura 4.

Como estes dois módulos são relativamente estreitos, parte da cascata gerada pela interação da partícula com o detector tende a escapar do detector, simplesmente pela ausência de matéria. Este efeito é conhecido como vazamento de energia. Para compensar este vazamento, foram




Figura 4: Montagem do Experimento.

dispostos cinco módulos de um protótipo anterior deste tipo de calorímetro a volta dos dois módulos do *Extended Barrel*, dois acima e três abaixo. Cada um destes módulos possui quatro camadas longitudinais com cinco células radiais cada uma, com a mesma dupla leitura que caracteriza o protótipo EB. Assim, estes 5 módulos fornecem 200 sinais adicionais por evento.

Os dados brutos adquiridos pelo sistema de aquisição de dados devem sofrer uma análise *offline* para remover eventos considerados inválidos. Os cortes que são tipicamente realizados nesta análise são feitos de forma clássica, através de histogramas de variáveis produzidas por detectores auxiliares (contadores de cintilação e câmaras de fios com alta resolução de posição) que se encontram na linha de feixe. Assim, rejeitam-se eventos referentes a raios cósmicos e eventos para os quais o ponto de impacto no detector se encontra fora de limites toleráveis. Tipicamente, o feixe de partículas tem 4 milímetros de dispersão e este é o valor máximo de dispersão admitida para os eventos a serem registrados. Esta limpeza *offline* dos dados experimentais tipicamente reduz em 30 a 40% o volume de dados adquirido.

No caso das partículas estudadas neste trabalho (elétrons, píons e múons) há uma natural produção de múons nos feixes experimentais de píons e de elétrons. Entretanto, esta contaminação é facilmente eliminada (pelo menos para valores de energia do feixe superiores a 80 GeV), pois os múons depositam muito pouca energia nos calorímetros, ao contrário dos píons e elétrons. Desta forma, eventos que tenham depositado pouca energia no detector são rejeitados por serem associados com múons. Adicionalmente, para o feixe de elétrons, além da contaminação por múons, ainda existe uma contaminação relativamente elevada por píons. Como a nossa aplicação baseada em redes neurais compreende uma fase de treino supervisionado, esta contaminação representa um grau de dificuldade a mais para o projeto do classificador neural. Veremos, entretanto, que o sistema neural consegue observar a presença desta contaminação, deslocando ligei-




Figura 5: Saídas da rede neural para o conjunto contaminado por impurezas no feixe de partículas.

ramente o valor alvo desejado para píons em direção ao valor alvo desejado para elétrons. Podemos então parar o procedimento de treino, retirar a contaminação assim encontrada, e reiniciar a fase de treino do discriminador de partículas com base no novo conjunto de treino, agora refinado.

### 3 O Discriminador Neural

O discriminador neural foi gerado através do uso do pacote de rotinas JetNet-2.0 [7]. A rede foi estruturada com 256 nós de entrada (total dos canais de leitura do arranjo experimental), 20 nós na camada intermediária e 3 nós na camada de saída. Cada nó da camada de saída foi associado a uma classe de partículas. O método utilizado para o treinamento supervisionado foi o *backpropagation*, usando-se a tangente hiperbólica como função de ativação. Os alvos foram estipulados como sendo 1 para o nó correspondente a classe da partícula e -1 para os outros dois nós. Assim, por exemplo, o neurônio de saída assinalado para a classe dos elétrons recebe como alvo 1 e os relativos a píons e múons recebem como alvo -1, quando estiver sendo treinada a rede com um evento de elétron. A decisão sobre a classe de uma dada partícula que esteja sendo apresentada à rede neural é obtida através da identificação do nó de saída com maior probabilidade, o que define a classe vencedora.

Os dados experimentais que compõem os conjuntos de treinamento e teste cobrem a faixa de 20 a 100 GeV. Conforme anteriormente mencionado, sabe-se que há contaminação de píons e múons (maior nos feixes de menor energia) no feixe de elétrons e múons no feixe de píons. Por outro lado, eventos especificamente de múons também são coletados para análise.

Durante a fase de treino para estes dados experimentais (metade do total, com o restante compondo o conjun-




Figura 6: Correlação entre as saídas de elétrons e píons para um conjunto de elétrons contaminado.

to de teste), a eficiência de acerto para elétrons estaciona em torno dos 73%, enquanto que os valores alvo para píons não são atingidos nem na saída de elétrons nem na de píons.

A Figura 5 nos permite visualizar o que ocorre na fase de treinamento. Nesta figura, podemos ver cada uma das saídas da rede neural, sendo que a primeira coluna está associada ao nó que identifica elétrons, a seguinte píons e a última múons. Os histogramas de cada coluna mostram as saídas da rede para cada conjunto de dados. Assim, temos elétrons na primeira linha desta matriz de histogramas, píons na segunda e múons na terceira linha. Desta forma, o primeiro quadro no alto a esquerda apresenta o histograma da saída de elétrons para o conjunto de elétrons, o segundo ao seu lado apresenta a saída de píons para o mesmo conjunto de elétrons, e assim por diante. Podemos ver que a distribuição no conjunto de elétrons para as saídas tanto de elétrons como de píons apresenta uma estrutura bimodal. Temos na saída de elétrons uma grande quantidade de eventos com valores próximos ao seu valor alvo 1 (ou seja, considerados por esta saída como sendo elétrons) e uma certa quantidade de eventos com valores próximos a -1 (ou seja, sendo rejeitados como elétrons). Por outro lado, na saída associada aos píons temos uma situação simetricamente oposta, muitos eventos tendo valores próximos de -1 (sendo rejeitados como píons por esta saída) e alguns eventos próximos de seu valor alvo 1 (sendo considerados píons portanto). Podemos também observar que a saída de elétrons e a de píons para o conjunto de píons (segunda linha) não atinge os valores alvo de -1 para a saída de elétrons e de 1 para a de píons, conforme se desejaria.

A Figura 6 mostra a correlação entre a saída de elétrons e a de píons para o conjunto original de elétrons. Podemos ver que os eventos que são firmemente rejeitados como elétrons pela saída de elétrons são aqueles plenamente aceitos como píons pela saída de píons. Podemos então, baseados nesta figura, definir um ponto de corte a partir do qual consideraremos os eventos como sendo píons que estão contaminando o conjunto de elétrons. No caso específico do conjunto desta figura, po-

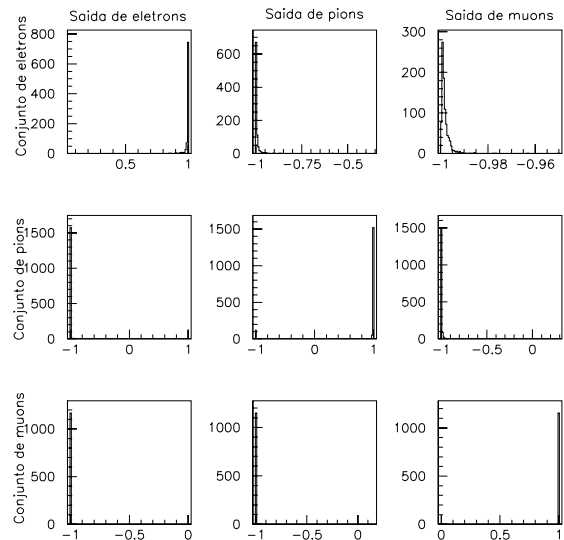


Figura 7: Saídas da rede neural para os dados descontaminados.

demos considerar como elétrons todos os eventos que levaram a saída de elétrons a valores maiores do que 0,2 e, ao mesmo tempo, a saída de píons da rede a valores menores do que 0,1, considerando todo o resto como contaminação. Note-se que a saída de múons não é sensível a esta contaminação.

Definido o corte que valida os eventos, podemos retirar de nossa amostra experimental os eventos que foram falsamente considerados como elétrons e efetuar o retraining da rede neural. Ao fim do treinamento, obtém-se uma eficiência de classificação de 100% para elétrons, 99% para píons e 100% para múons, no caso de estarmos lidando com feixes de partículas de 100 GeV de energia. Podemos ver na Figura 7 o resultado final obtido. Nesta figura podemos ver que apenas os histogramas dispostos na diagonal principal da figura têm eventos com valores em torno de 1, enquanto que todos os demais apresentam eventos próximos do valor -1, indicando a situação de classificação desejada, onde apenas o neurônio relativo a classe do evento que está sendo apresentado à entrada do discriminador é ativado.

Podemos verificar o acerto na identificação de impurezas feita pela rede neural através do conhecimento de certas características físicas da deposição de energia para as diferentes partículas no calorímetro. Este é o método usado classicamente para a identificação destas impurezas. Um fato que pode ser explorado é a percentagem de energia depositada na primeira camada do calorímetro hadrônico [2]. Normalmente, elétrons depositam a maior parte de sua energia na primeira camada, ao contrário dos píons que tendem a depositar uma maior fração de sua energia nas camadas adiante. A Figura 8 mostra a percentagem de deposição de energia nesta primeira camada do detector contra a saída de elétrons da nossa rede neural, quando se considera os eventos originais de elétrons. Vemos então claramente, que eventos que depo-




Figura 8: Correlação da saída de elétrons com a fração da energia depositada na primeira camada do detector (método clássico), para eventos do conjunto original de elétrons.

Energia	Contaminação
20 GeV	8%
50 GeV	20%
80 GeV	26%
100 GeV	27%

Tabela 1: Níveis de contaminação para diferentes níveis de energias do feixe.

sitaram muita energia (mais de 19%) na primeira camada foram declarados elétrons pela saída de elétrons (que, pela correlação da Figura 6, sabemos que são eventos rejeitados pela saída de píons) pois obtiveram valores maiores do que 0,2 nesta saída de elétrons. Enquanto os restantes, que depositaram uma pequena parcela de sua energia na primeira camada, foram rejeitados como elétrons (e consequentemente aceitos como píons, como demonstra a Figura 6) pela rede neural. A estrutura bimodal da figura por si só já esclarece que temos dois conjuntos de dados assumidos erroneamente a princípio como parte de um mesmo conjunto.

Uma vez que temos uma rede já treinada em conjuntos de treinamento livres de impurezas, podemos avaliar se esta rede é capaz de generalizar o seu comportamento para identificar as impurezas que antes contaminavam o conjunto de elétrons. A Figura 9 mostra o desempenho da rede para os conjuntos originais de dados, evidenciando a sua capacidade de identificar a contaminação. Há, na saída de elétrons, um conjunto maior de eventos em valores bem próximos de 1, que é o nosso conjunto de elétrons. Temos também um outro pico menor que o anterior e que se encontra bastante próximo de -1, que é o conjunto de píons que contamina o nosso conjunto original de elétrons. Estas afirmativas têm perfeita correlação com os resultados obtidos para píons. Desta forma, além do método clássico para eliminação de impurezas, temos também agora, um método neural eficiente na eliminação de impurezas e confirmação deste resultado.

Estes procedimentos foram realizados para vários

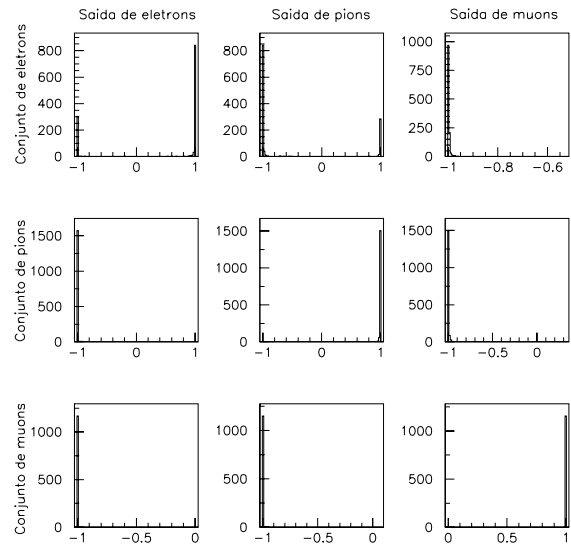


Figura 9: Saídas da rede neural retreinada para os dados contaminados.

Energia	elétrons	píons	múons
20 GeV	100%	98%	100%
50 GeV	99%	99%	99%
80 GeV	100%	99%	100%
100 GeV	100%	99%	100%

Tabela 2: Eficiências obtidas nos conjuntos de teste após o retreino da rede neural com eventos livres de contaminação.

valores de energia do feixe de partículas, visando a obtenção de redes que pudessem cobrir as diferentes faixas de energia utilizadas experimentalmente. Na Tabela 1, indicamos os níveis de contaminação encontrados para os conjuntos de elétrons para cada energia. Verificamos que obtemos um aumento do nível de contaminação em maiores energias.

A Tabela 2 apresenta as eficiências de teste obtidas para elétrons, píons e múons após o retreino da rede neural para cada uma das energias consideradas. Pode-se notar o alto nível nas eficiências de discriminação obtidas do discriminador neural. É interessante chamar a atenção para os dados de 20 GeV. Os resultados obtidos para esta energia são similares aos demais de maior energia. Entretanto, nesta faixa de energia, os métodos clássicos começam a se tornar cada vez menos eficientes, já que as frações de energia depositadas para cada camada do detector vão se tornando cada vez menos distinguíveis para as diferentes partículas. As redes neurais, por seu turno, conseguem manter a sua elevada capacidade de discriminação das partículas de forma praticamente independente da energia do feixe incidente.

## 4 Conclusões

Discutimos neste trabalho o desenvolvimento de um método baseado na aplicação de redes neurais para se obter um classificador de partículas para um detector da física de altas energias, o calorímetro hadrônico de telhas cintilantes.

Apesar da contaminação inerente aos processos físicos que produzem o feixe experimental de partículas, as redes neurais conseguem identificar a contaminação dos dados durante a fase de treinamento. Após a purificação da amostra estatística com o método neural, o classificador neural é retreinado, atingindo eficiências médias de 100%, 99 % e 100% para elétrons, píons e múons, respectivamente. Mostramos também que a análise clássica baseada no processo físico de deposição de energia no calorímetro comprova os resultados da descontaminação obtida pelo método neural.

De modo a implementarmos um sistema online de discriminação, para rejeitar durante a aquisição de dados os eventos de contaminação e, assim, tornar mais eficiente a recolha dos dados experimentais, a tecnologia dos processadores digitais de sinais (DSPs - Digital Signal Processors) está sendo considerada. Uma vez que as redes neurais envolvem um número significativo de produtos internos, elas são facilmente implementáveis nesta tecnologia.

Para esta implementação o ADSP-21060 [8] vem sendo utilizado. Este DSP de 32 bits e ponto flutuante é capaz de realizar uma operação de produto interno em apenas um ciclo de relógio, ou seja, 25 nanosegundos. Estas características o tornam uma opção atraente para desenvolver um classificador capaz de operar de forma online na maioria das condições experimentais dos feixes de partículas em uso na área da física experimental de altas energias. Esta implementação se encontra em desenvolvimento.

## Agradecimentos

Agradecemos ao apoio dado a este trabalho pelo CNPq, FUJB e CAPES (Brasil) e pelo CERN (Suíça). Agradecemos também à colaboração internacional Tilecal, por ceder os conjuntos de dados experimentais utilizados neste trabalho e pelas discussões frutíferas nos tópicos deste trabalho.

## Referências

- [1] The Atlas Collaboration. Technical Proposal for a General-Purpose pp Experiment at the Large Hadron Collider at CERN. CERN/LHCC/94-43(1994).
- [2] R. Wigmans, Advances in Hadron Calorimetry. Rev.Nucl. Part.Sci.41 (1991) 133.

- [3] Electron-Pion Discrimination with a Scintillating Fiber Calorimeter. D. Acosta et al. **Nuclear Instruments and Methods**, A(302) pp 36-46 (1991).
- [4] Neural Second-Level Trigger System Based on Calorimetry. J.M. Seixas, L.P. Caloba, M.N. Souza, A.L. Braga and A.P. Rodrigues **Computer Physics Communications**, Volume. 95, pp 143-157 (1996).
- [5] F. Ariztizabal et al., Calorimeter with Longitudinal Tile Configuration. *Nuclear Instruments and Methods* A349, pp 384 (1994).
- [6] [http://atlasinfo.cern.ch/Atlas/SUB\\_DETECTORS/TILE/tilecal.html](http://atlasinfo.cern.ch/Atlas/SUB_DETECTORS/TILE/tilecal.html)
- [7] L. Lönnblad et al. *Comput. Phys. Commun.* **70** (1992) 167.
- [8] DSP/MSP Products Reference Manual. Analog Devices, Inc. (1995).