



Classificação automatizada via redes neurais de distribuições de "ângulo de arremesso" de partículas carregadas na magnetosfera terrestre: Aplicação para medidas in situ de satélites

RELATÓRIO FINAL DE PROJETO DE INICIAÇÃO CIENTÍFICA  
(PIBIC/INPE/CNPq)

José Matheus da Silva Rocha (USP, Bolsista PIBIC/CNPq)

E-mail: [josé.matheus.rocha@usp.br](mailto:josé.matheus.rocha@usp.br)

Vitor Moura Cardoso e Silva Souza (Divisão de Geofísica Espacial/INPE,  
Orientador)

E-mail: [vitor.souza@inpe.br](mailto:vitor.souza@inpe.br)



# Classificação automatizada via redes neurais de distribuições de "ângulo de arremesso" de partículas carregadas na magnetosfera terrestre: Aplicação para medidas in situ de satélites

Projeto de iniciação científica apresentado na SICINPE-2018 sob orientação de Vitor Moura Cardoso e Silva Souza atuante na Divisão de Geofísica Espacial, do Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, SP, Brasil.

## Lista de ilustrações

Figura 1: Representação simplificada das principais regiões da magnetosfera. ....	10
Figura 2: Representação bidimensional dos Cinturões de radiação Van Allen, suas subdivisões em interna e externa, na qual a cor dá uma ideia da quantidade de partículas por unidade de volume nas regiões dos cinturões Van Allen. Os eixos da figura estão em unidades de raios terrestres.....	10
Figura 3: Representação do Fluxo médio normalizado de elétrons pelo ângulo de arremesso para $L = 5$ mensurado no mês de Novembro de 2014. ....	12
Figura 4: Modelo de neurônio artificial.....	12
Figura 5: Gráfico da Função Limiar.....	13
Figura 6: Gráfico da Função Linear por partes.....	14
Figura 7: Gráfico da Função Sigmoide.....	15
Figura 8: Estrutura de uma rede neural simples e o sentido de propagação da informação na estrutura.....	16
Figura 9: Rede neural do tipo <i>feedforward</i> com múltiplas camadas. Representação do sentido de propagação do sinal de entrada e do sinal de retro-propagação.....	17
Figura 10: Rede cíclica sem camada intermediária.....	17
Figura 11: Rede cíclica com camada intermediária.....	18
Figura 12: Esquemática do processo de aprendizagem não supervisionada. ....	19
Figura 13: Fluxo médio de elétrons, com energia na faixa de 2.00 a 5.60 MeV, em função do parâmetro L (L-Shell) durante o mês de novembro de 2014 obtida pelo instrumento REPT a bordo da Van Allen Probe A. Nota-se a presença dos cinturões externo ( $3 < L < 6,5$ ) e interno ( $L < 2,5$ ). A barra de cores na lateral direita de cada um dos painéis representa a intensidade do fluxo.	21
Figura 14: Órbita da sonda Van Allen Probe A durante o 1º dia do mês de novembro de 2014. No painel a) temos a projeção da órbita no plano da eclíptica, o ponto vermelho representa a posição aproximada da sonda às 15:00 Universal Time (UT), sendo a parte clara da Terra (representada como um círculo centrado) o lado voltado para o Sol. No painel b) tem-se a projeção da órbita no plano perpendicular ao plano da eclíptica, sob um ponto de vista no qual o observador encontra-se entre o Sol e a Terra e olhando para a Terra. Essa vista nos mostra a inclinação do plano que contém a órbita da sonda em relação ao plano da eclíptica ( $Z_{GSE}=0$ ). O painel c) pode ser analisado com base no que foi comentado nos outros painéis. ....	22



Figura 15: Fluxo médio de elétrons, com energia na faixa de 2.00 a 5.60 MeV, em função do parâmetro L (L-Shell) durante o mês de Dezembro de 2014 obtida pelo instrumento REPT abordo da Van Allen Probe A.....	25
Figura 16: Classificação dos PAD de elétrons relativísticos para o mês de Dezembro de 2014.	26
Figura 17: Classificação dos dados da THEMIS medidos pelo instrumento SST no canal de 408 KeV para o mês de março de 2008. ....	29
Figura 18: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 3. ....	30
Figura 19: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 11 ....	30
Figura 20: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 17. ....	31
Figura 21: Classificação dos dados da THD medidos pelo instrumento SST no canal de 561.5 KeV para o mês de março de 2008.....	31
Figura 22: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 2. ....	32
Figura 23: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 3. ....	32
Figura 24: Classificação dos dados da THD medidos pelo instrumento SST no canal de 719.5KeV para o mês de março de 2008.....	33
Figura 25: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 1. ....	34
Figura 26: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 32. ....	34



## Lista de abreviaturas e siglas

SOM	Mapa Auto Organizado (do inglês Self-Organization Map).
REPT	Telescópio de Elétrons e Prótons relativísticos.
PAD	Distribuição de ângulo de arremesso (do inglês Pitch Angle Distribution).
RNA	Redes neurais artificiais.
TDAS	Software de análise de dados da THEMIS.
SST	Telescópio de estado sólido.



## Lista de símbolos

$V_A$	Velocidade Alfvén.
$B$	Magnitude do campo magnético.
$\mu_0$	Permeabilidade magnética do vácuo.
$\rho_m$	Densidade de massa do plasma.
$J$	Fluxo de elétrons.
$\alpha$	Ângulo de arremesso.
$w_{n,j}$	Peso sináptico do neurônio $j$ com relação à entrada $n$ .
$p_k$	$k$ -ésimo sinal de entrada.
$b_j$	Bias associado ao neurônio $j$ .
$\varphi(v_j)$	Função de ativação associado ao neurônio $j$ .
$a$	Parâmetro de ativação.
$n$	Número de interações.
$A_{k,j}(n)$	Função de amplitude.
$l_{k,j}$	Distância do neurônio $k$ vencedor a um neurônio $j$ da vizinhança.
$\sigma(n)$	Função de aprendizagem.

## Resumo

Este trabalho, iniciado em fevereiro de 2018, tem como objetivo a continuidade do trabalho de iniciação científica, em andamento desde junho de 2017, que consistiu em realizar uma classificação automatizada, via redes neurais, das chamadas distribuições de “ângulo de arremesso” (pitch angle) de partículas eletricamente carregadas no espaço próximo à Terra conhecido como magnetosfera terrestre. Nesse trabalho, dados coletados in situ do fluxo de elétrons relativísticos fornecidos pelo instrumento REPT (Relativistic Electron-Proton Telescope) a bordo dos satélites gêmeos Van Allen Probes da NASA, foram utilizados para análise das distribuições de ângulo de arremesso de uma região conhecida como cinturão externo de radiação Van Allen. O processo de classificação automatizada deu-se por meio da utilização de um pacote de rotinas de processamento de dados, embutido no software MATLAB, conhecido como Neural Network Toolbox. Uma rede neural do tipo Mapa Auto Organizado (Self-Organized Map – SOM) foi empregada, uma vez que a mesma possibilita organizar em pequenos grupos, ou classes, subconjuntos dos dados de entrada que possuam características similares. Como critério de seleção dos dados do REPT, examinou-se períodos nos quais ocorreram intensas variações (maiores que uma ordem de grandeza) nos fluxos de elétrons relativísticos nos cinturões de radiação Van Allen. Dentre os diversos períodos disponíveis que satisfaziam esse critério, escolheu-se o mês de Novembro de 2014 para treinar a rede neural e o mês de Dezembro de 2014 para ser analisado. A rede neural foi capaz de reconhecer os padrões de distribuição advindos da literatura, porém houve alguns problemas com o número de classes estipulados para rede, que ocasionou classes sem representação e algumas distribuições diferentes das convencionais para esse tipo de estudo. A continuidade desse projeto de iniciação científica está pautada na inserção dos dados da THEMIS (Time History of Events and Macroscale Interactions during Substorms) na rede neural artificial com intuito de obter uma classificação automatizada para esse conjunto de dados.



## Sumário

Resumo.....	13
Introdução .....	8
Fundamentação Teórica .....	9
Introdução à magnetosfera terrestre .....	9
Distribuição do ângulo de arremesso nos cinturões de Van Allen .....	11
Modelo de neurônio .....	12
Arquitetura da rede neural .....	15
Redes acíclicas.....	15
Redes cíclicas (recorrentes).....	17
Métodos de aprendizagem .....	18
Aprendizagem supervisionada .....	18
Aprendizagem não supervisionada (auto-organizada) .....	19
Metodologia.....	20
Obtenção de dados .....	20
Treinamento da rede.....	22
Implementação matemática do algoritmo de aprendizagem da SOM.....	23
Resultados.....	26
Prefácio de aplicação da SOM nos dados da THEMIS .....	28
Metodologia.....	28
Obtenção dos dados.....	28
Treinamento da rede.....	28
Resultados .....	29
Discussão e Conclusão .....	35
Agradecimentos .....	36
Referências.....	37

## Introdução

O desenvolvimento das redes neurais artificiais (RNAs) foi inspirado no comportamento de redes neurais biológicas, e na capacidade que o cérebro humano tem em organizar seus constituintes estruturais, os neurônios, para processar informações advindas do ambiente externo no reconhecimento de padrões e na tomada de decisões em função dos dados que foram processados. Uma rede neural é basicamente um processador composto por inúmeros dispositivos denominados neurônios, unidades básicas de processamento, operando em paralelo e interligados convenientemente em forma de uma rede. Essa arquitetura pode ser implementada através de dispositivos eletrônicos ou simulação por programas de computadores, conforme o capítulo 1 de (Haykin, 2001).

Um passo muito importante na efetivação de uma RNA é o seu *treinamento*, no qual a rede será capaz de distinguir/identificar características/padrões presentes nos tipos de dados que se pretende analisar. Simplificadamente apresenta-se à RNA subconjuntos dos dados de entrada (inputs) e atribuem-se a cada um dos elementos destes subconjuntos determinados pesos, chamados de pesos sinápticos em analogia às sinapses neuronais. O treinamento da rede consiste na modificação sistemática destes pesos sinápticos, através de um algoritmo de aprendizagem, para que a RNA atinja um objetivo previamente determinado. Existe também a possibilidade da RNA alterar sua topologia durante o processo de treinamento, procedimento similar ao que ocorre no cérebro humano quando neurônios morrem e novas conexões sinápticas são formadas. Outra característica importante das RNAs está relacionada ao método de aprendizagem, que pode ser feito essencialmente de duas formas: supervisionada, na qual se ajustam, iterativamente, os pesos sinápticos da RNA de tal modo que as saídas (outputs) da rede aproximem-se cada vez mais de resultados (targets) já conhecidos, e a não supervisionada, em que a rede adapta seus pesos sinápticos em tempo real conforme modificações do ambiente onde está sendo aplicada. Ao leitor interessado consultar o capítulo 2 de (Haykin, 2001).

O benefício imediato da aplicação de uma rede neural está na sua capacidade de generalização, isto é, a capacidade de fornecer dados de saída (output) para dados de entrada (inputs) que não estavam presentes durante a etapa de treinamento. Outro ponto positivo é a sua estrutura, que pode ser moldada de forma conveniente dependendo do tipo de aplicação, permitindo que as redes neurais artificiais sejam aplicadas na solução de diversos tipos de problemas, lineares e não lineares. O primeiro trabalho relevante para o campo de redes neurais foi escrito pelo psiquiatra e neuroanatomista Warren *McCulloch* em parceria com o matemático Walter *Pitts* em 1943, revelando a interdisciplinaridade dessa área. O modelo tinha como estrutura básica um conjunto de neurônios artificiais que seguia uma lei de processamento denominada “tudo ou nada”, algo similar ao processo que será utilizado nesse trabalho, conhecido como método de aprendizagem competitiva (Haykin, 2001).

O objetivo desse trabalho é o estudo e aplicação de uma rede neural conhecida como Mapa Auto-Organizado (*Self Organizing Map - SOM*), que utiliza um método de aprendizagem não supervisionada capaz de caracterizar padrões, de forma automatizada e com a mínima interferência do usuário, das chamadas distribuições de ângulo de arremesso de elétrons relativísticos aprisionados nos cinturões de radiação de Van Allen, e de elétrons sub-relativísticos presentes na magnetosfera interna. Os dados utilizados como parâmetros de entrada para a SOM serão fornecidos pelo instrumento Telescópio de Elétrons e Prótons Relativísticos (Relativistic Electron Proton Telescope-REPT) abordo dos satélites gêmeos Van Allen Probes da NASA bem como pelo instrumento Solid State Telescope (SST) abordo dos satélites que compõem a missão Time History of Events and Macroscale Interactions during Substorms (THEMIS).

## Fundamentação Teórica

### Introdução à magnetosfera terrestre

O vento solar é um fluxo de partículas carregadas (predominantemente núcleos de hélio ionizado, prótons e elétrons) expelidas pela atmosfera solar no meio interplanetário, que viaja a velocidades relativamente grandes comparadas a velocidade característica de um plasma ionizado, chamada velocidade de Alfvén<sup>1</sup>. Em média a velocidade de propagação do vento solar é muitas vezes maior que a velocidade de Alfvén (COSTA JUNIOR, 2011).

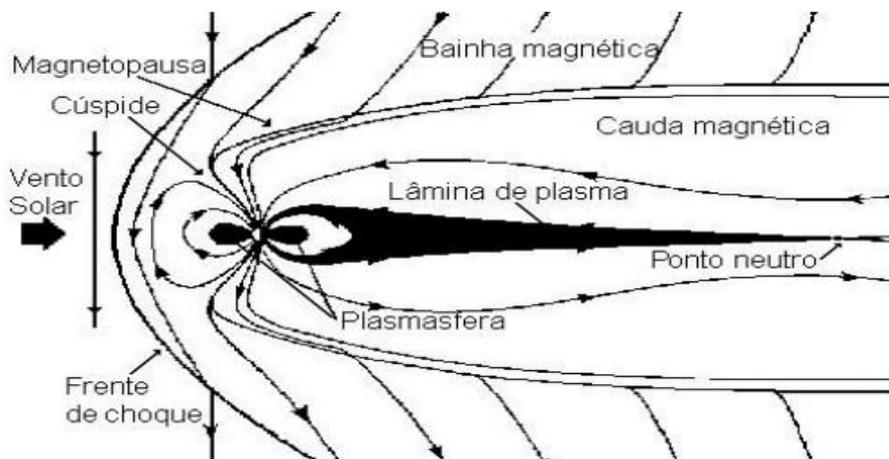
Quando estas partículas encontram um obstáculo, sendo ele magnetizado ou não, uma frente de choque é desenvolvida nas proximidades dessa região, aquecendo e desacelerando esse fluxo de partículas a velocidades inferiores a velocidade de Alfvén, sendo esse mecanismo fundamental para desviar a entrada dessas partículas no obstáculo. Essa frente de choque é formada entre a Terra e o Sol a uma distância que varia de 13 a 15 raios terrestres medidos a partir do “centro” da Terra. O fluxo de partículas que passa por essa frente de choque e continua se movendo em direção a Terra encontra a magnetopausa terrestre, que é definida como uma lâmina de corrente (KIVELSON, 1995) que separa o plasma quente de baixa densidade do interior da magnetopausa do plasma frio e denso da bainha magnética (SOUZA, 2017), região entre a frente de choque e a magnetopausa conforme Figura 1.

A magnetosfera terrestre pode ser definida como a região próxima a Terra, tendo como fronteira a magnetopausa, na qual o campo magnético terrestre é predominante sobre a dinâmica das partículas carregadas, sendo seu entendimento fundamental no estudo de uma miríade de processos físicos (KIVELSON, 1995). Dentre todo esse meio espacial denominado magnetosfera existe uma região nomeada como magnetosfera interior, que se estende de algumas centenas de quilômetros, medidos radialmente em relação à superfície da terra, até 7-8 raios terrestres em distância geocêntrica, ou seja, mensuradas em relação ao “centro” da Terra, na qual partículas com uma ampla variedade de energia coexistem. Partículas com baixa energia, alguns poucos elétrons-volt, originam-se de populações na ionosfera fria terrestre enquanto partículas com energia mais alta, na faixa de alguns keV, são originárias do vento solar. Para faixas de energias mais elevadas, da ordem de MeV, as partículas originam-se de raios cósmicos e prótons advindos do sol (SOUZA, 2017).

---

<sup>1</sup> A velocidade de Alfvén é expressa como  $V_A = \sqrt{\frac{B^2}{\mu_0 \rho_m}}$ , na qual **B** é a magnitude do campo magnético local,  $\mu_0$  é a permeabilidade magnética do vácuo e  $\rho_m$  a densidade de massa do plasma.

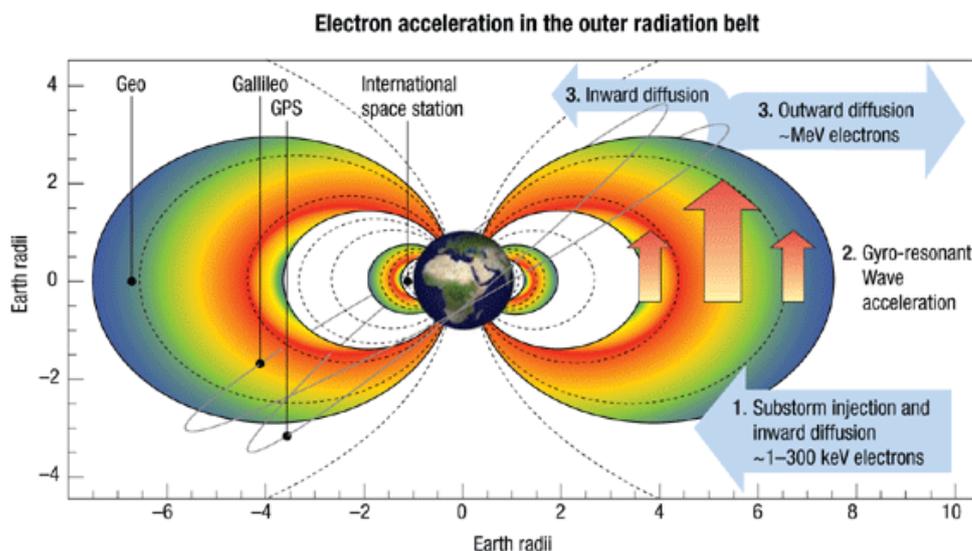
Figura 1: Representação simplificada das principais regiões da magnetosfera.



Fonte: COSTA JUNIOR, 2011.

Os cinturões de radiação Van Allen consistem em duas regiões em forma de toróide, localizados no espaço próximo à Terra, e que circundam o planeta. Essas regiões são formadas por partículas carregadas, elétrons e prótons em sua maioria, que oscilam em torno das linhas de campo magnético que conectam o hemisfério norte e sul. Os prótons são frequentemente encontrados na região que corresponde ao cinturão de Van Allen interno (em torno de 1 a 3 raios terrestres de distância radial da Terra), nessa mesma região pode ser encontrados elétrons de baixa energia (energia < 1 MeV). Os elétrons de maior energia são encontrados no cinturão de Van Allen externo (de 4 a 6 raios terrestres; J. F. Fennell et al., 2015). A Figura 2 ilustra de maneira simplificada os cinturões de radiação Van Allen.

Figura 2: Representação bidimensional dos Cinturões de radiação Van Allen, suas subdivisões em interna e externa, na qual a cor dá uma ideia da quantidade de partículas por unidade de volume nas regiões dos cinturões Van Allen. Os eixos da figura estão em unidades de raios terrestres.



Fonte: PAPAPOULOS, 2014.

## Distribuição do ângulo de arremesso nos cinturões de Van Allen

A distribuição do ângulo de arremesso (do inglês *pitch angle distribution* - PAD), ângulo entre o campo magnético local e o vetor velocidade da partícula, de partículas carregadas na magnetosfera nos dá uma noção da direção de propagação relativa ao campo magnético local, em um dado instante de tempo, para uma dada faixa de energia. Essas distribuições tem origem no gráfico de fluxo médio, dada uma faixa de energia, por ângulo de arremesso.

Existem três tipos de PAD amplamente conhecidos encontrados nos cinturões de radiação Van Allen, sendo cada um deles associado a mecanismos físicos diferentes. Nesse trabalho será utilizado o critério de (Gannon et al., 2007) na identificação dessas PADs nos dados da REPT A; a saber as distribuições são denominadas : 90°- peaked, butterfly e flattop.

Matematicamente pode-se definir a relação  $r$  entre os fluxos  $J$ , medidos em uma faixa de energia, nos ângulos de arremesso de 90°, e o fluxo médio em 45° e 135°, como sendo:

$$r = \frac{J^{\alpha=90^\circ}}{(J^{\alpha=45^\circ} + J^{\alpha=135^\circ})/2}, \quad \begin{cases} r < 0.9 & \text{Butterfly} \\ r > 1.1 & 90^\circ - \text{peaked} \\ 0.9 \leq r \leq 1.1 & \text{flattop} \end{cases}$$

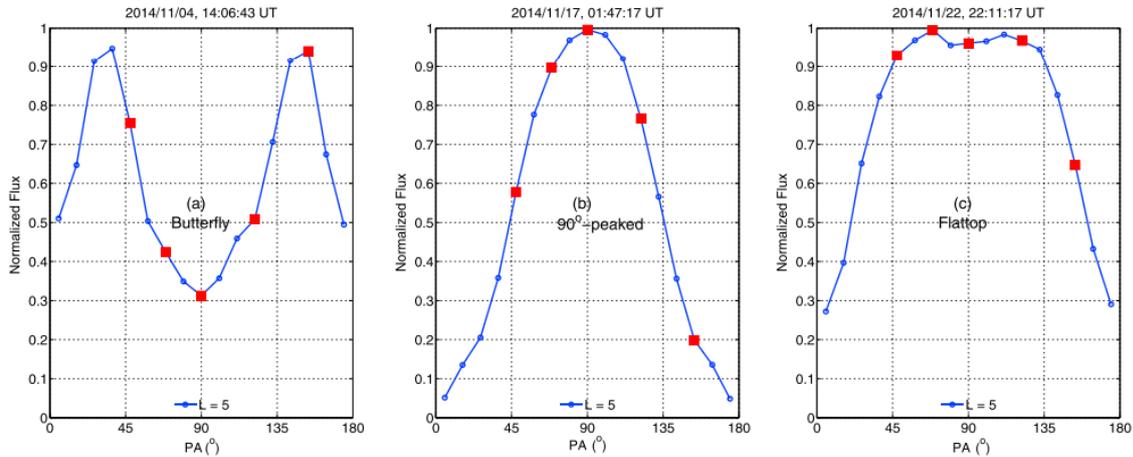
Se os instrumentos captassem a mesma quantidade de fluxo  $J$  para todos os ângulos de arremesso, o resultado da PAD seria uma linha horizontal, mas isso não ocorre na prática. Tem-se a ocorrência do 90°-peaked no caso em que o fluxo  $J$  é mais acentuado no ângulo de 90°, partículas fluindo perpendicularmente ao campo magnético onde está sendo feito as medidas, tal que para os demais ângulos o fluxo decresce suavemente, ou seja, tem-se um máximo local no ângulo de arremesso de 90°. E não menos relevante, a identificação dessa PAD, no espaço e no tempo, pode estar associado a interações onda-partícula e difusão radial interna ocorrendo no cinturão de radiação Van Allen (Gannon et al., 2007).

No caso da existência de um mínimo local a 90° e dois máximos locais em torno de 45° e 135° tem-se a PAD denominada Butterfly, que similar a 90°-peaked, está associada a dois mecanismos físicos, conhecidos como sombreamento do cinturão Van Allen pela magnetopausa (Kim et al., 2008) e *drift-shell splitting* (Sibeck et al., 1987).

O terceiro PAD conhecido, denominado flattop, nessa região é caracterizado pelo estabelecimento de um fluxo máximo entre os ângulos de 45° e 90°, e decréscimo suave para valores de ângulo de arremesso menor e maior respectivamente. Tal distribuição é relacionada com a dispersão das partículas por interação onda-partícula (Horne et al., 2003).

Na Figura 3 tem-se um exemplo dessas três distribuições de ângulo de arremesso para o mês de Novembro de 2014, utilizando o canal de 1.8 MeV de energia do REPT A. Os bins de PA destacados em vermelho nas distribuições representam os dados que serão utilizados como entrada para a rede neural.

Figura 3: Representação do Fluxo médio normalizado de elétrons pelo ângulo de arremesso para  $L = 5$  mensurado no mês de Novembro de 2014.

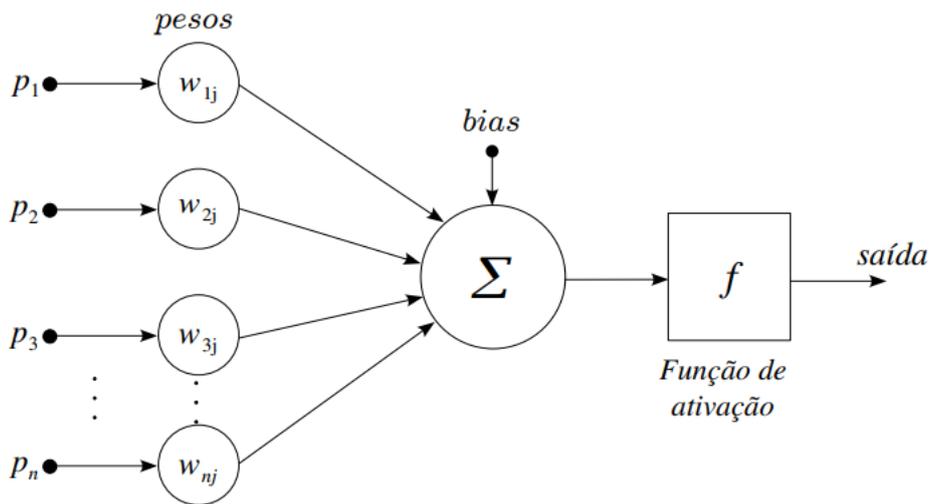


Fonte: Souza, 2016.

## Modelo de neurônio

O neurônio é a unidade básica de processamento de informação numa rede neural, sendo constituído por três elementos básicos: conjunto de sinapses (elos de conexão), um somador e uma função de ativação (Haykin, 2001).

Figura 4: Modelo de neurônio artificial



Fonte: Haykin, 2001.

1. Elos de conexão (Peso sináptico): Tem como função alterar o sinal de entrada multiplicando-o por um fator ajustável, na imagem acima o primeiro índice  $n$  dos pesos,  $w_{nj}$ , refere-se ao terminal de entrada, já o segundo, o índice  $j$ , ao neurônio em questão.
2. Somador: Soma os sinais de entrada que foram ponderados pelos seus respectivos pesos sinápticos. Semelhante a um combinador linear.

3. Função de ativação: Restringe a amplitude do sinal de saída (output) de um neurônio. Também denominada função restritiva, pois permite que o usuário normalize o sinal de saída em um intervalo que facilite análises posteriores.

O modelo neural também inclui o *bias*, que pode ser interpretado como uma característica interna de cada neurônio. O *bias* é aplicado externamente e tem como função aumentar ou diminuir o valor de entrada da função de ativação.

Em termos matemáticos o neurônio  $j$  pode ser descrito pelo seguinte par de equações:

$$u_j = \sum_{k=1}^n p_k w_{kj}$$

$$y_j = \varphi(u_j + b_j) \text{ ou } y_j = \varphi(v_j)$$

, tal que  $p_1, p_2, \dots, p_k$  são os sinais de entrada;  $w_{1j}, w_{2j}, \dots, w_{kj}$  os pesos sinápticos do neurônio  $j$  e  $b_j$  é o bias;  $\varphi(v_j)$  é a função de ativação e  $y_j$  o sinal de saída do neurônio.

### Tipos de funções de ativação

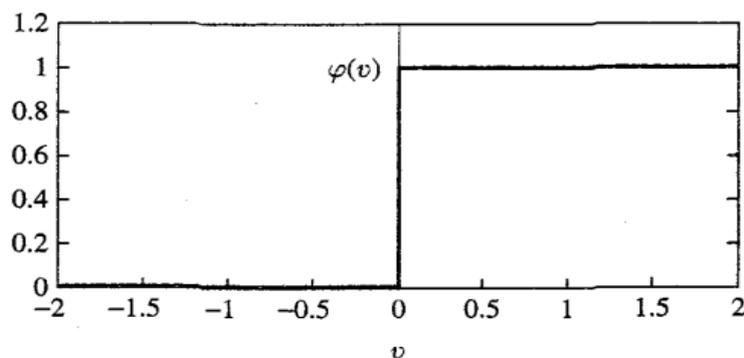
A função de ativação modela a forma como o neurônio responde aos sinais de entrada e gera o sinal de saída. Podemos caracterizar três tipos básicos de funções de ativação:

1. *Função Limiar (Heaviside)*: Possui a característica de emitir o valor 1 quando  $v \geq 0$  e 0 para valores diferentes. O neurônio que possui essa função de ativação é conhecido como modelo de *McCulloch-Pitts*, pois é caracterizado pela propriedade “tudo ou nada”.

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases}$$

Na qual  $\varphi(v)$  é a soma das bias com o somador.

Figura 5: Gráfico da Função Limiar

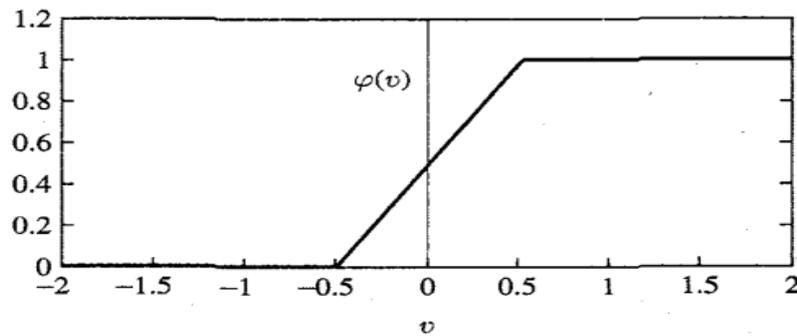


Fonte: Haykin, 2001.

2. *Função Linear por partes*: Podendo ser vista como uma aproximação de um amplificador não linear, essa função possui um fator de amplificação dentro da região linear.

$$\varphi(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & \frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases}$$

Figura 6: Gráfico da Função Linear por partes.



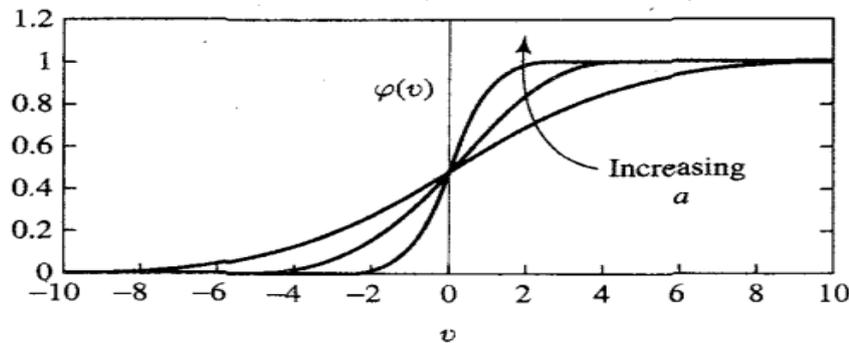
Fonte: Haykin, 2001.

3. *Função Sigmoide*: É uma função estritamente crescente que possui uma combinação de comportamento linear e não linear. Um exemplo é a função logística:

$$\varphi(v) = \frac{1}{1 + e^{-av}}$$

, na qual  $a$  é o parâmetro de inclinação.

Figura 7: Gráfico da Função Sigmoide.



Fonte: Haykin, 2001.

A característica que torna a função sigmoide como a forma mais utilizada em neurônios como função de ativação é que ela assume valores contínuos entre 0 e 1.

## Arquitetura da rede neural

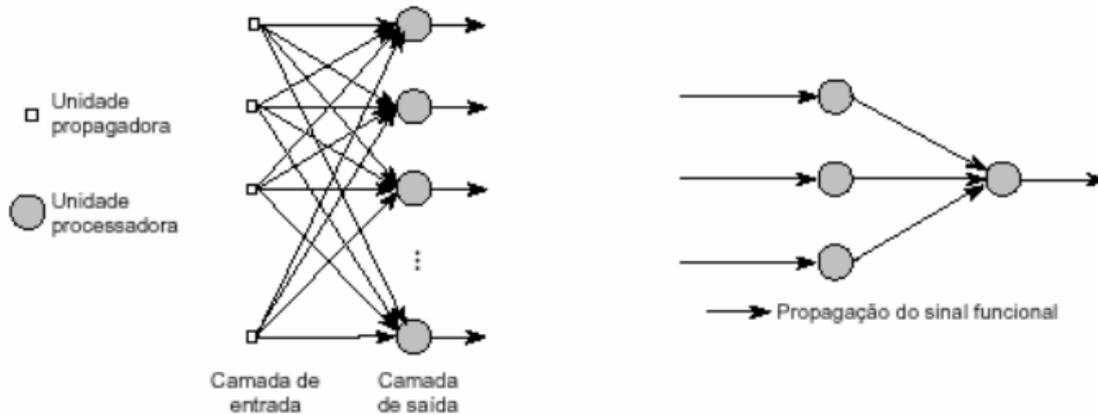
A arquitetura de uma rede neural artificial é basicamente a maneira como os neurônios estão dispostos na rede, como eles se interligam. Essa disposição está intimamente relacionada com o tipo de problema que será abordado e seu respectivo algoritmo de aprendizagem, como a rede ajusta os pesos sinápticos devidos os valores de entrada (input) e saída (output).

### Redes acíclicas

Disposição onde a propagação de sinais ocorre de maneira unidirecional, ou seja, os sinais são propagados apenas da entrada para a saída. Tal arranjo pode ser feito utilizando uma única camada de processamento de informação ou múltiplas camadas, de acordo com a natureza do problema a ser solucionado.

No caso mais simples de redes neurais, existe uma camada de neurônios de entrada cujas saídas repassam a informação sem processamento, sendo chamados assim propagadores puros, para os neurônios de saídas que ficam responsáveis por processar as informações. O número de neurônios na camada de entrada está relacionado ao número de variáveis de entrada (input) assim como o número de neurônios da camada de saída está relacionado ao número de variáveis de saída (output), que são as respostas que se espera da rede.

Figura 8: Estrutura de uma rede neural simples e o sentido de propagação da informação na estrutura.

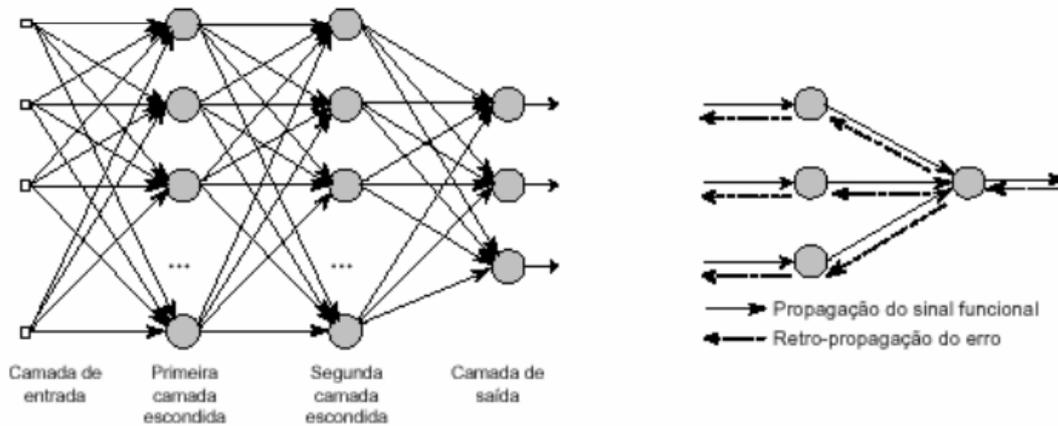


Fonte: MATSUNAGA, 2012.

Devido a sua simplicidade a rede neural de uma única camada resolve um número limitado de problemas.

Um segundo tipo de arquitetura se diferencia pela presença de uma ou mais camadas intermediárias (camadas com neurônios que processam a informação) entre a entrada e a saída da rede neural. O aumento de camadas possibilita a capacidade de resolução de problemas mais complexos, aumento computacional de processamento não linear e aumento da armazenagem de informação da rede. Nesse tipo de rede neural com múltiplas camadas é frequentemente utilizado um algoritmo de retro-propagação do erro (*error backpropagation*) na etapa de treinamento, em que o sinal de entrada é propagado da entrada para saída de forma direta (**feedforward**) e o sinal de erro é propagado no sentido contrário, ou seja, da saída para a entrada (propagação reversa).

Figura 9: Rede neural do tipo *feedforward* com múltiplas camadas. Representação do sentido de propagação do sinal de entrada e do sinal de retro-propagação.

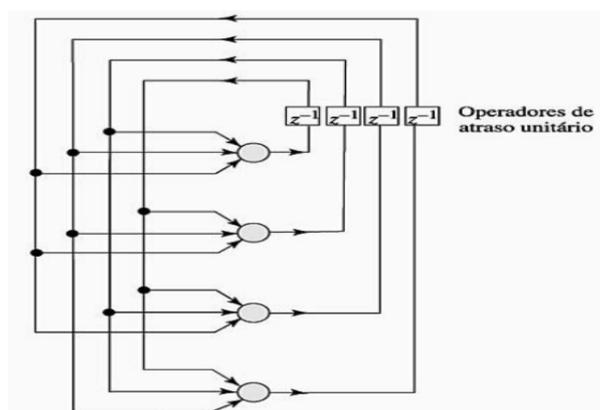


Fonte: MATSUNAGA, 2012.

### Redes cíclicas (recorrentes)

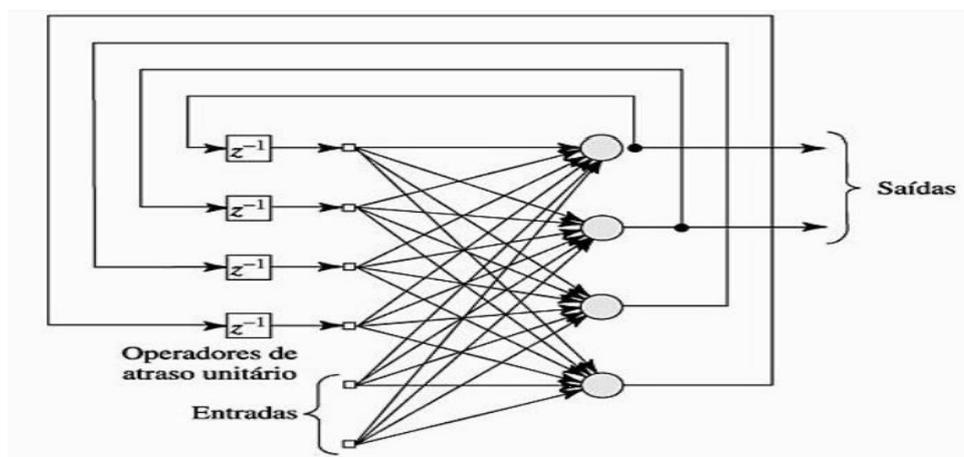
É um arranjo onde existem laços de realimentação, ou seja, a saída de um neurônio pode ser entrada dos neurônios adjacentes pertencentes a uma mesma camada. Nessa estrutura, similares à rede acíclica podem existir ou não camadas intermediárias.

Figura 10: Rede cíclica sem camada intermediária.



Fonte: Haykin, 2001.

Figura 11: Rede cíclica com camada intermediária.



Fonte: Haykin, 2001.

A presença de laços de realimentação, em ambas as estruturas acima, figuras 9 e 10, influencia diretamente na capacidade de aprendizagem da RNA, sendo que os elementos de atraso unitário  $z^{-1}$  implicam em um comportamento dinâmico não linear.

## Métodos de aprendizagem

Existe basicamente dois tipos de aprendizagem, um de forma supervisionada e outro de forma não supervisionada. Em ambos os casos o processo busca ajustar os pesos sinápticos, em alguns casos até a estrutura da rede, com base nas informações usadas no seu treinamento na busca de uma representação própria dos fenômenos por ela modelada.

### Aprendizagem supervisionada

Também conhecida como aprendizagem com um professor, utiliza-se um conjunto de dados que descreve o ambiente no qual a RNA estará inserida, na qual os parâmetros de entrada e suas respectivas saídas são conhecidos. O processo busca ajustar a rede para aproximar o conjunto de saída com base no conjunto de entrada e assim minimizar o erro, que é basicamente a diferença entre o output gerado pela rede e o respectivo valor conhecido do conjunto de dados. Uma vez que todo o conhecimento, conjunto de dados, é transferido para rede neural ela estará apta para lidar com o ambiente de operação de forma autônoma, ou seja, operar com dados de entrada para os quais os respectivos dados de saída são desconhecidos pelo supervisor da rede (professor).

Figura 12: Esquemática do processo de aprendizagem não supervisionada.



Fonte: Haykin, 2001.

### Aprendizagem não supervisionada (auto-organizada)

É embutida na RNA uma regra de aprendizagem que fornece condições suficientes para que a rede aperfeiçoe seus parâmetros livres, pesos sinápticos, estrutura e afins, permitindo assim um mapeamento em tempo real dos dados de entrada. Uma regra muito utilizada nesse tipo de aprendizagem é denominada aprendizagem competitiva (*competitive learning algorithm*) na qual os elementos básicos de saída, os neurônios, competem entre si para se tornar ativos.

## Metodologia

Neste trabalho será aplicada uma rede neural do tipo acíclica com aprendizagem não supervisionada denominada Mapa Auto Organizado (*Self Organizing Map –SOM*) baseada num algoritmo de aprendizagem competitiva (*competitive learning algorithm*), no qual os neurônios competem entre si para se tornar ativos. A rede neural terá 32 neurônios, sendo que os vetores de entrada são matrizes  $5 \times N$ , em que  $N$  é o número de amostras colhidas em  $N$  instantes de tempo. Para isso utilizar-se-á o pacote Neural Network Toolbox presente no software MATLAB (*MATrix LABoraty*).

## Obtenção de dados

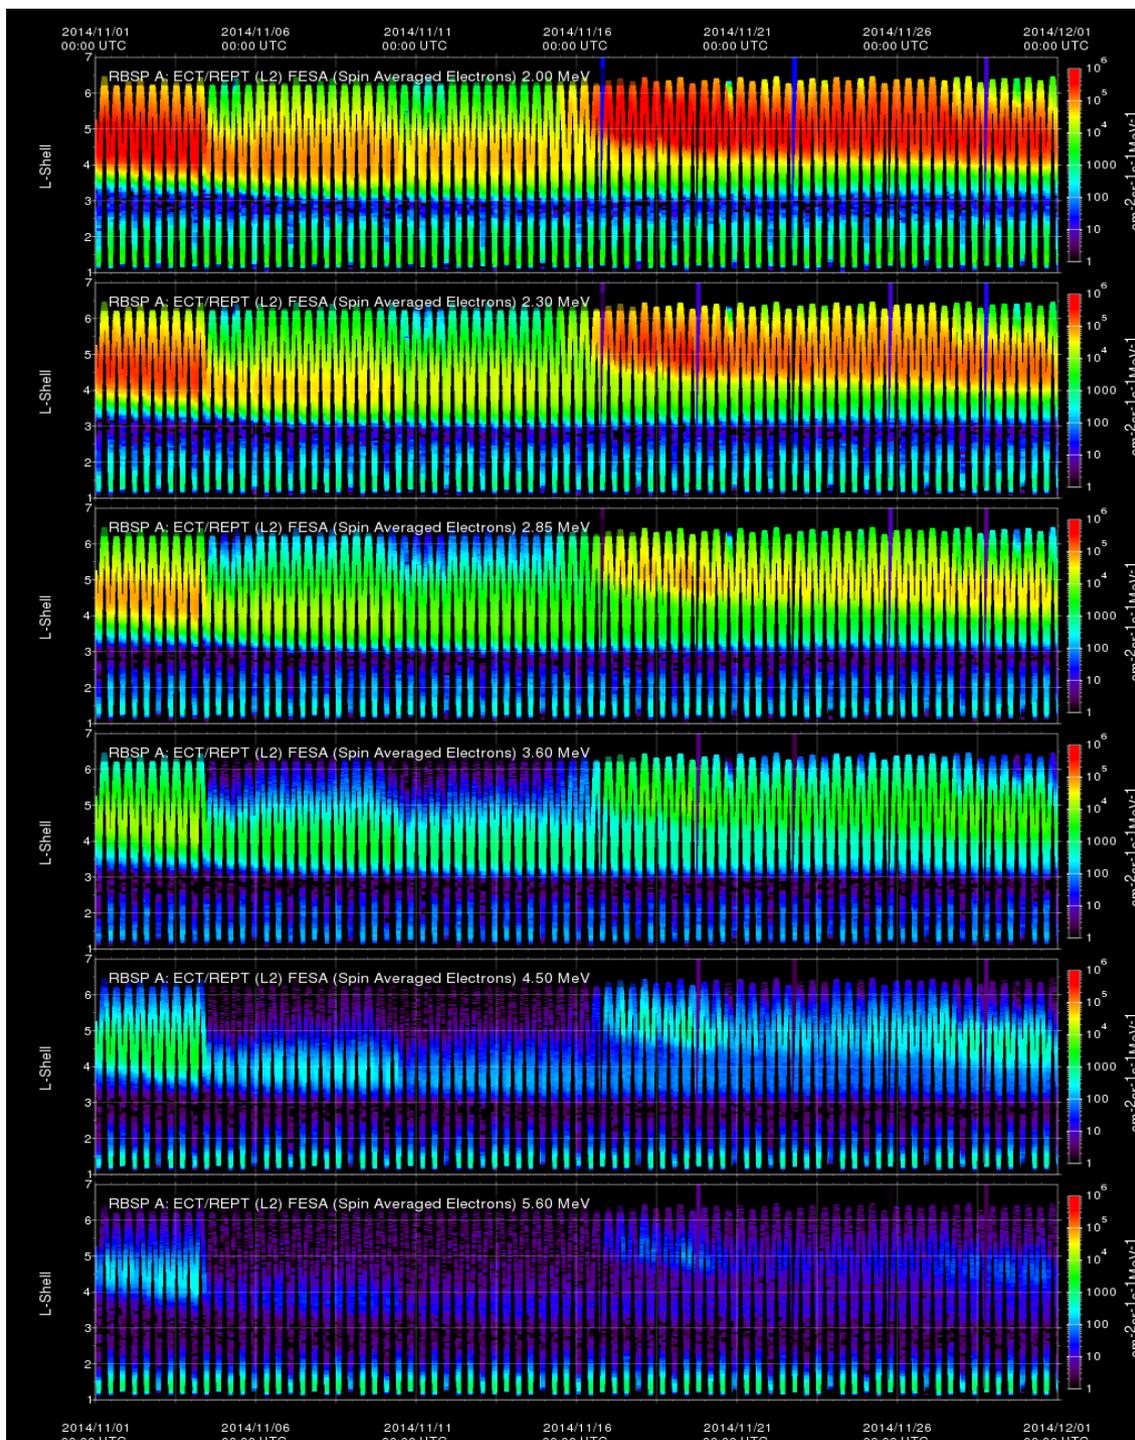
A primeira etapa é a preparação do conjunto de dados, ou seja, a obtenção dos dados de fluxo de elétrons relativísticos ( $>1$  MeV) medidos pelo instrumento Telescópio de Elétrons e Prótons Relativísticos (*Relativistic Electron Proton Telescope-REPT*, Baker et al, 2013) abordo das sondas Van Allen Probes (Mauk et al.,2013), numa região da magnetosfera da terra chamada cinturões de radiação Van Allen. Estes dados foram obtidos no site [https://www.rbsp-ect.lanl.gov/data\\_pub/rbspa/](https://www.rbsp-ect.lanl.gov/data_pub/rbspa/).

Buscar-se-á incluir períodos nos quais ocorreram intensas variações nos fluxos de elétrons relativísticos nessa região, no intuito de maximizar a quantidade de distribuição de ângulos de arremesso distintas que serão fornecidas para a rede. Essa preocupação na escolha do conjunto de dados é crucial para que a rede se torne capaz de distinguir as distribuições de ângulo de arremesso em outros conjuntos de dados, nos quais a rede neural artificial será aplicada. Outro parâmetro importante na seleção do período de análise é o tempo de processamento computacional da rede neural, uma vez que quanto maior for o conjunto de dados maior será o tempo de processamento necessário para a fase de treinamento. Para mais informações sobre a etapa de seleção de dados e da fase de treinamento de uma rede neural para análise de ângulo de arremesso de elétrons relativísticos nos cinturões de radiação Van Allen consultar as seções 4.3.1. e 4.3.2. da referência (SOUZA et al.,2017).

Com base no que foi exposto acima, escolheu-se o mês de Novembro de 2014 como período de análise, pois apresenta, conforme Figura 13 abaixo, uma variação significativa do fluxo médio de elétrons, no cinturão de radiação externo, possibilitando uma amostragem maior da distribuição dos ângulos de arremesso para ser analisado pela rede neural. Um sistema de coordenadas usual para esse tipo de análise envolve o parâmetro L-Shell como unidade de distância radial, que é basicamente uma projeção da distância radial no plano equatorial magnético. Para mais informações sobre esse sistema consultar McIlwain (1961).

Outro aspecto importante desse conjunto de dados foi o canal de energia escolhido, pois o instrumento REPT possui 12 canais de energia, a saber; 2.00, 2.30, 2.85, 3.60, 4.50, 5.60, 7.15, 8.80, 11.65, 15.35, 22.55 e 59.45 MeV. Dos canais mencionados escolheu-se o primeiro deles, que contém os fluxos de elétrons, por ângulo de arremesso, com 2 MeV de energia.

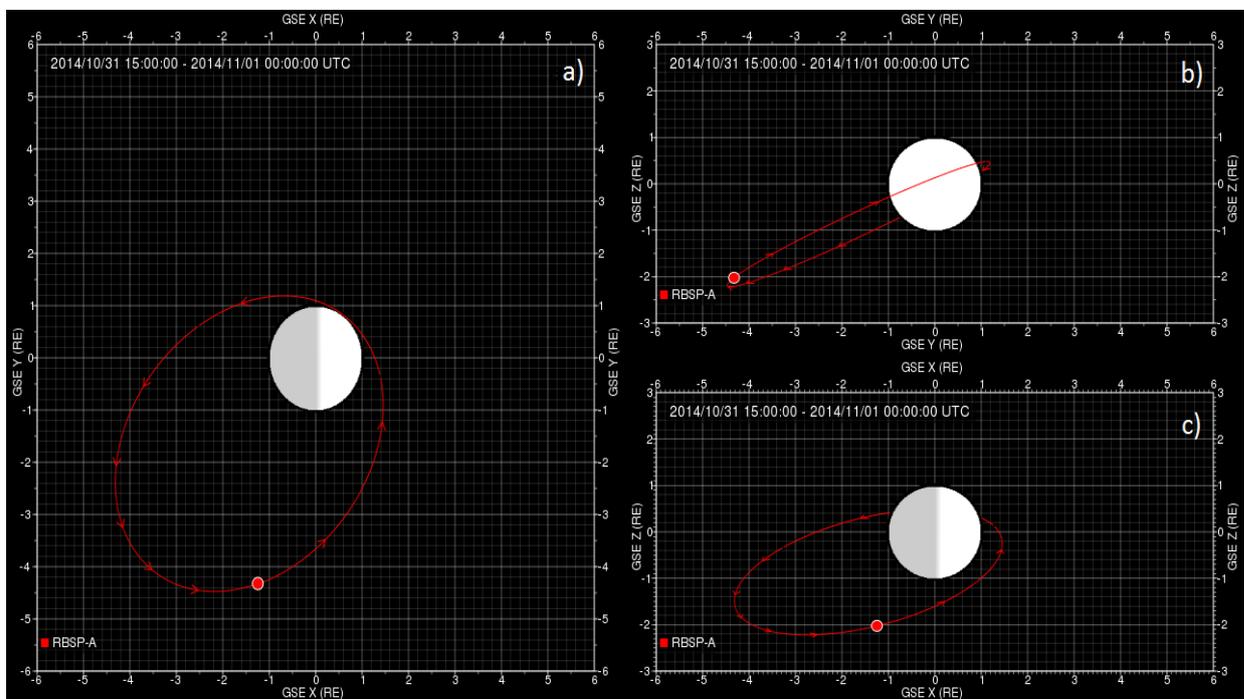
Figura 13: Fluxo médio de elétrons, com energia na faixa de 2.00 a 5.60 MeV, em função do parâmetro L (L-Shell) durante o mês de novembro de 2014 obtida pelo instrumento REPT a bordo da Van Allen Probe A. Nota-se a presença dos cinturões externo ( $3 < L < 6,5$ ) e interno ( $L < 2,5$ ). A barra de cores na lateral direita de cada um dos painéis representa a intensidade do fluxo.



Fonte: <http://rbspgateway.jhuapl.edu/rPlotTime?context>.

A sonda Van Allen Probe A possui uma órbita elíptica razoavelmente inclinada em relação ao plano da eclíptica, plano que contém a órbita da Terra em torno do Sol. Essa configuração de órbita (ver Figura 14) visa maximizar a obtenção dos dados, tanto de fluxo de energia quanto de outros parâmetros mensurados por essa sonda, no equador magnético da Terra (Mauk et al., 2013).

Figura 14: Órbita da sonda Van Allen Probe A durante o 1º dia do mês de novembro de 2014. No painel a) temos a projeção da órbita no plano da eclíptica, o ponto vermelho representa a posição aproximada da sonda as 15:00 Universal Time (UT), sendo a parte clara da Terra (representada como um círculo centrado) o lado voltado para o Sol. No painel b) tem-se a projeção da órbita no plano perpendicular ao plano da eclíptica, sob um ponto de vista no qual o observador encontra-se entre o Sol e a Terra e olhando para a Terra. Essa vista nos mostra a inclinação do plano que contém a órbita da sonda em relação ao plano da eclíptica ( $Z_{GSE}=0$ ). O painel c) pode ser analisado com base no que foi comentado nos outros painéis.



Fonte: <http://rbspgway.jhuapl.edu/ExtendedMissionOrbit>.

## Treinamento da rede

Na etapa de treinamento (aprendizagem), utilizou-se como dados de entrada as distribuições de ângulo de arremesso de elétrons de energia 2 MeV fornecidos pelo instrumento *REPT* a bordo da sonda Van Allen Probe A, para o mês de novembro de 2014.

Utilizaram-se dados de fluxo de elétrons relativísticos para 5 ângulos de arremesso, a saber: 47.65°, 68.82°, 90.00°, 121.76°, 153.53°. *A priori* poderíamos utilizar todas as 17 resoluções de ângulo de arremesso fornecidas pela sonda, que são elas; 5.29°, 15.88°, 26.47°, 37.06°, 47.65°, 58.24°, 68.82°, 79.41°, 90.00°, 100.59°, 111.18°, 121.76°, 132.35°, 142.94°, 153.53°, 164.12° e

174.71°, mas isso tornaria o processo demorado pois requisitaria mais neurônios de processamento. A escolha desses 5 ângulos justifica-se nos tipos de padrões de distribuição que espera-se obter nos cinturões de radiação Van Allen, ou seja, nas características das 3 PAD presentes nesse meio, conforme seção Distribuição do ângulo de arremesso nos cinturões de Van Allen. Esse número de ângulos de arremesso também justifica os 32 ( $2^5$ ) neurônios que compõem a rede, conforme mencionado na seção.

## Implementação matemática do algoritmo de aprendizagem da SOM

Numa rede neural artificial do tipo SOM cada neurônio está diretamente conectado com a camada de entrada de dados (input layer). Isso significa que dado um vetor de entrada  $\mathbf{x}^t$ , com dimensão D, extraído aleatoriamente de um conjunto com T vetores de entrada, ou seja,  $\mathbf{x}^t = (x_1^t, x_2^t, \dots, x_D^t)$  sendo  $t=1, 2, \dots, T$ . Cada neurônio  $\mathbf{k}$  tem um vetor peso  $\mathbf{w}_k$ , representativo do mesmo, com a mesma dimensão dos dados de entrada que se pretende analisar, em outras palavras  $\mathbf{k}$  pode ser escrito como  $\mathbf{w}_k = (w_{k1}, w_{k2}, \dots, w_{kD})$ . Os elementos  $w_{kj}$  do vetor de peso podem ser interpretados como a “importância” atribuída ao correspondente elemento do vetor de entrada  $x_j^t$  para a saída do neurônio  $\mathbf{k}$ .

As componentes dos vetores de peso da rede neural artificial são inicializados com valores entre 0 e 1, de forma aleatória. O processo de aprendizagem é um mecanismo na qual, em cada interação da rede com os vetores de entrada, modificam-se as componentes do vetor de peso, incrementando  $\Delta w_{kj}$  a cada valor  $w_{kj}$  de acordo com a regra de aprendizagem. No caso da aprendizagem competitiva, método de aprendizagem utilizada nesse trabalho, os neurônios competem entre si, dado um parâmetro de competição, para responderem a um subconjunto de dados de entrada. Em outras palavras, para cada instante de tempo  $\mathbf{n}$ , um vetor  $\mathbf{x}^t$  interage com um vetor de peso  $\mathbf{w}_i$  considerado “próximo” ao vetor de entrada. Nesse caso o que determina o grau de proximidade entre  $\mathbf{x}^t$  e um dado vetor de peso  $\mathbf{w}_i$  é a distância euclidiana  $d(\mathbf{x}^t, \mathbf{w}_i)$  entre eles.

$$d(\mathbf{x}^t, \mathbf{w}_i) = \left( \sum_{j=1}^D (x_j^t - w_{kj})^2 \right)^{\frac{1}{2}}$$

O neurônio  $\mathbf{k}$  na qual o vetor de peso  $\mathbf{w}_k$  é o mais próximo do vetor de entrada  $\mathbf{x}^t$  é chamado de neurônio vencedor, ou seja, a distância euclidiana é calculada para todos os vetores de peso da rede, dado um vetor de entrada qualquer, e o neurônio vencedor é aquele que apresenta a menor distância do dado de entrada. Esse neurônio define o centro de uma vizinhança, os neurônios mais próximos desse *neuron* dada uma topologia pré-definida, na qual as alterações devido o processo de aprendizagem também são sentidas, ou seja, a vizinhança nesse contexto também sofre alterações.

Essa vizinhança é descrita por uma função de amplitude  $A_{k,j}(n)$  em função do número de passos  $\mathbf{n}$ , instantes de tempo, dada por:

$$A_{k,j}(n) = \exp \left( - \left( \frac{l_{k,j}}{\sqrt{2}\sigma(n)} \right)^2 \right)$$

, na qual  $l_{k,j}$  é a distância do neurônio  $k$  vencedor ao um neurônio  $j$ , e  $\sigma(n)$  é uma função que mensura a participação dos neurônios da vizinhança no processo de aprendizado. Espera-se que essa influência da vizinhança decresça com o tempo, sendo assim essa função sigma é dada por uma exponencial decrescente:

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_0}\right)$$

, sendo  $\sigma_0$  a influência da vizinhança no começo da fase de treinamento, ou seja, em  $n = 0$ . E  $\tau_0$  é uma constante de tempo.

A cada tempo de interação  $n$ , o peso sináptico  $w_j(n)$  do neurônio  $j$ , que pertence à vizinhança topológica  $A_{k,j}(n)$ , do neurônio vencedor  $k$ , tem seu peso sináptico acrescido de um valor  $\Delta w_j(n)$  e o novo vetor peso em uma interação posterior  $w_j(n+1)$  é dado por:

$$w_j(n+1) = w_j(n) + \Delta w_j(n) \quad (1)$$

$$\Delta w_j(n) = \eta(n) A_{k,j}(n) (x^t - w_j(n)) \quad (2)$$

, na qual  $\eta(n)$  é a taxa de aprendizagem que possui a mesma forma funcional do parâmetro  $\sigma(n)$ .

Substituindo (2) em (1):

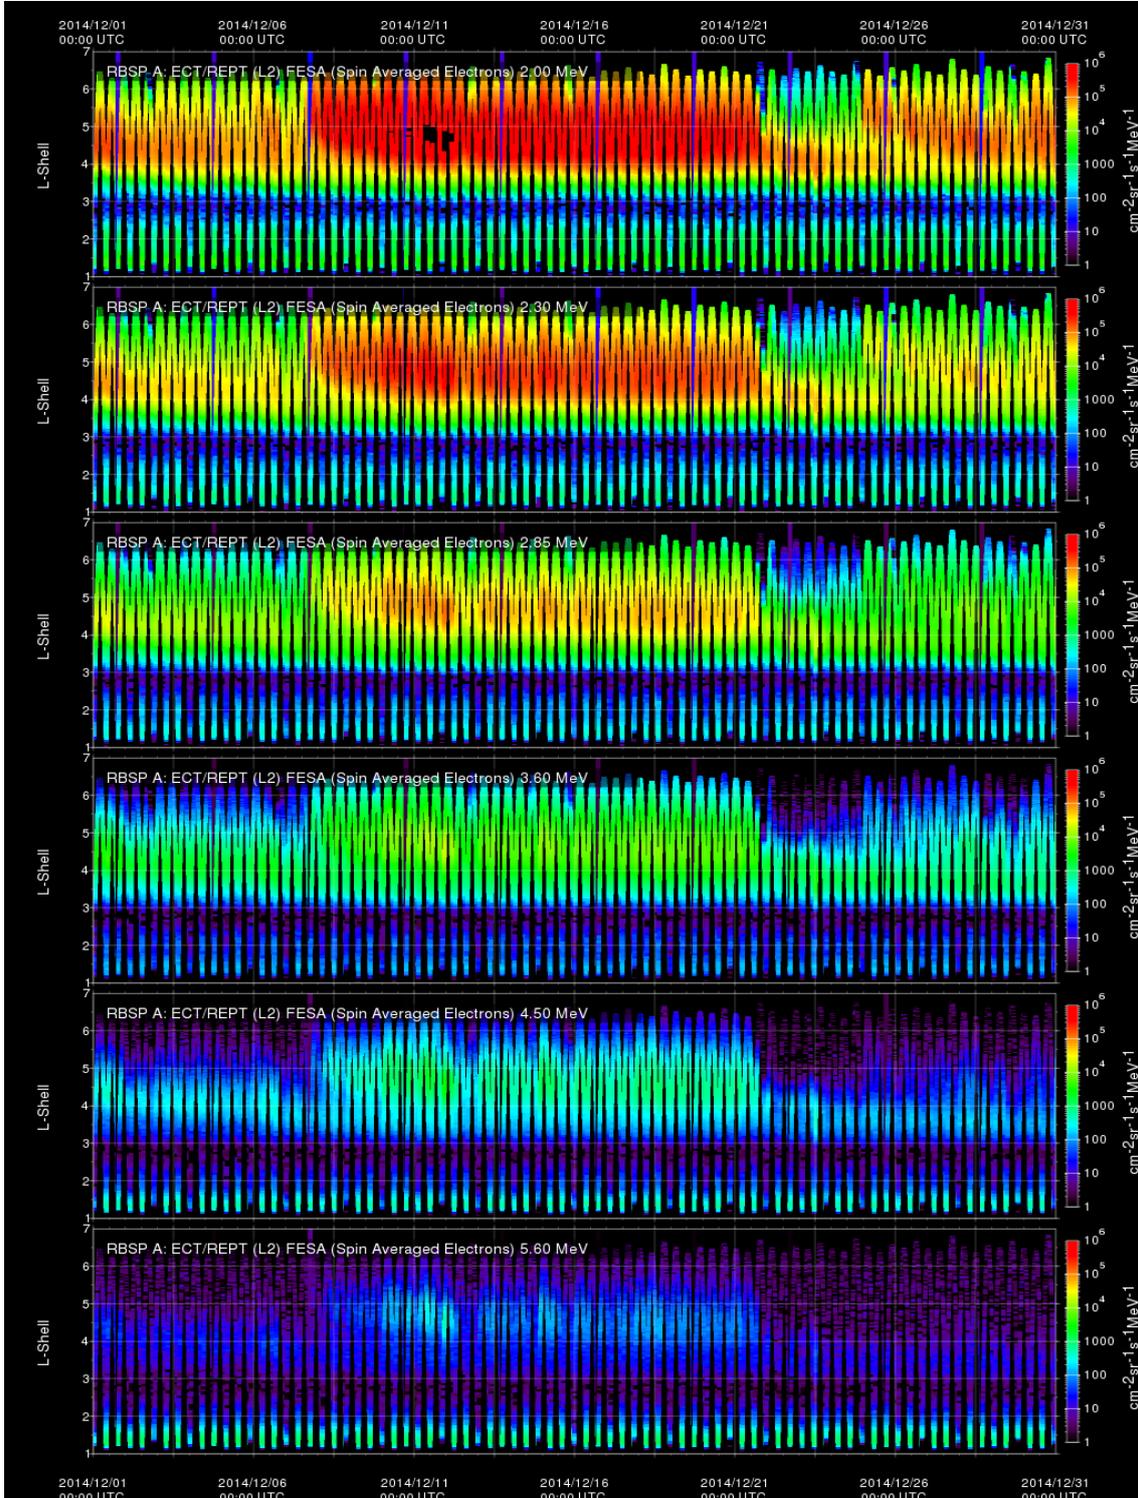
$$w_j(n+1) = [1 - \eta(n) A_{k,j}] w_j(n) + \eta(n) A_{k,j}(n) x^t \quad (3)$$

Pode-se concluir da Equação (3) que no limite em que  $n$  for muito grande, o valor do peso sináptico num instante de tempo  $n$  será o mesmo, em termos práticos, que o valor do peso sináptico no ponto  $n+1$ . Em outras palavras o segundo termo do lado direito da Equação (1) vai à zero. Para saber mais sobre o método de aprendizado da SOM consultar a seção 4.2.1 da referência (SOUZA et al., 2017).

De tudo que foi exposto nessa seção conclui-se que a aprendizagem da rede neural está intimamente relacionada com o número de informação, ou ludicamente, exemplos a qual ela será exposta na fase de treinamento. Esses exemplos são os conjuntos de dados utilizados nesse passo, e a quantidade de exemplos é terminada pelo parâmetro de tempo  $n$ , ou seja, de tal maneira que a condição analisada acima seja satisfeita. Pois uma vez que o valor de peso sináptico  $w_j$  de um neurônio  $j$  não se altera de uma interação  $n$  para  $n+1$ , esse neurônio está apto para caracterizar um padrão nos dados.

Após a fase de treinamento da SOM, será estabelecida 32 classes, note a relação da quantidade de classes com o número de neurônios que compõe a estrutura da rede. Uma vez feita a etapa de treinamento da SOM, pode-se usar a rede para classificar um conjunto de dados semelhante ao que ela foi exposta durante o aprendizado, e extrair dessas informações as 32 classes que foram pré-definidas. Nesse trabalho aplicaram-se os dados de fluxo de elétrons relativísticos medidos pelo REPT para o mês de Dezembro de 2014, ver Figura 15, na rede neural treinada.

Figura 15: Fluxo médio de elétrons, com energia na faixa de 2.00 a 5.60 MeV, em função do parâmetro L (L-Shell) durante o mês de Dezembro de 2014 obtida pelo instrumento REPT abordo da Van Allen Probe A.

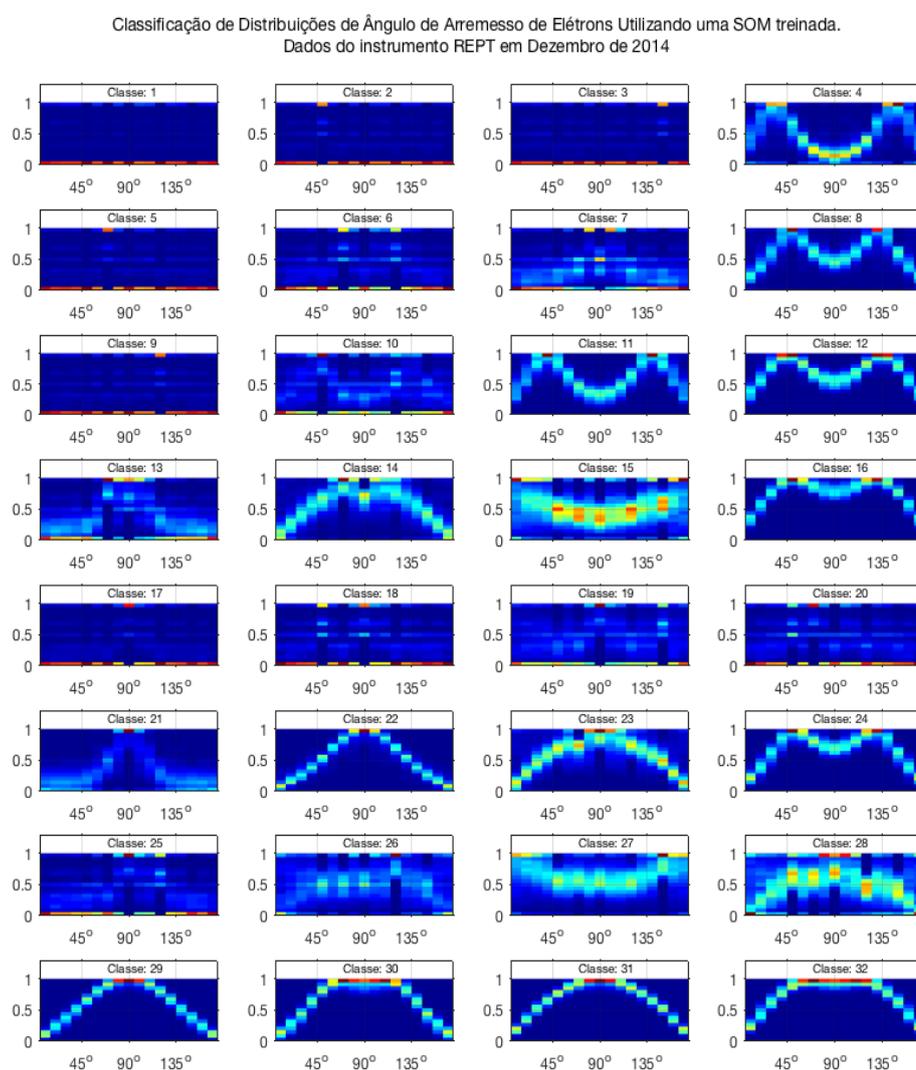


Fonte: <http://rbspgway.jhuapl.edu/rPlotTime?context>.

## Resultados

Conforme discutido na seção anterior, a SOM com 32 neurônios treinados via algoritmo de aprendizagem competitiva com o pacote de dados do mês de Novembro de 2014, foi utilizada para classificar de forma automática, dada as 32 classes pré-definidas, os dados de fluxo de elétrons relativísticos medidos pela REPT A no mês de Dezembro de 2014. A Figura 16 mostra o resultado da classificação dos dados feito pela rede.

Figura 16: Classificação dos PAD de elétrons relativísticos para o mês de Dezembro de 2014.



Fonte: O autor.

Da Figura 16 tem-se que a rede neural conseguiu classificar os 3 tipos de padrões de distribuição de ângulo de arremesso conhecidas da literatura, ver Distribuição do ângulo de arremesso nos cinturões de Van Allen, para a região do cinturão externo de Van Allen. A saber: a classe 4, 22 e 30 representam as distribuições Butterfly, 90°-peaked e Flattop respectivamente. Uma coisa sutil foi que a rede classificou como classe diferente variações da mesma distribuição, ou seja, utilizou classes diferentes para identificar o mesmo padrão global, como pode ser visto na distribuição Butterfly presente nas classes 4, 8, 12 e 16.

As 32 classes podem ser reduzidas as 3 distribuições presentes na literatura, mesclando as classes que representam o mesmo padrão global, reforçando assim sua veracidade. Dos problemas presentes nesse resultado deve-se destacar que algumas classes ficaram sem nenhuma representatividade, ver classe 1, 2, 3, 5, 6,7, 9, 10, 17, 18, 19, 20,25 na Figura 16, e outras como a classe 15, 26 e 27 apresentaram um comportamento diferente das distribuições previamente conhecidas para a região onde se fez essa análise. Ambos os problemas continuam sem resposta, cabendo no caso das distribuições diferentes um estudo para entender se as mesmas são superposições das 3 distribuições conhecidas ou se estão associadas a fenômenos físicos diferentes nos cinturões de radiação.

## **Prefácio de aplicação da SOM nos dados da THEMIS**

### **Metodologia**

Essa etapa está pautada na aplicação de uma rede neural do tipo Mapa Auto Organizado para caracterizar de forma automatizada dados de fluxo de elétrons nas três maiores faixas de energia (408KeV, 561.5KeV e 719.5KeV) do instrumento SST (Solid State Telescope) abordo da sonda THD (uma das 5 sondas que compõem a missão THEMIS, a saber: THA, THB, THC, THD e THE). A motivação da escolha dos 3 maiores canais de energia do instrumento SST é devido a maior proximidade, em relação aos demais canais da sonda, com o canal de energia já analisado pelo REPT de 2 MeV.

### **Obtenção dos dados**

A obtenção dos dados de fluxo foi feita através de um conjunto de rotinas da TDAS (THEMIS Data Analysis Software) com a utilização da linguagem de programação IDL. Escolheu-se o mês de fevereiro de 2008 para treinamento da SOM e o mês de março do mesmo ano para aplicação da rede neural treinada.

### **Treinamento da rede**

Treinou-se 3 redes do tipo SOM, uma para cada canal de energia mencionado anteriormente. Utilizou-se como dados de entrada as distribuições de ângulo de arremesso de elétrons fornecidos pelo instrumento SST abordo da sonda THD para o mês de fevereiro de 2008 nas 3 maiores faixas de energia fornecidas pela sonda. A escolha do mês de fevereiro de 2008 para treinar a SOM foi motivada pelo estudo de um fenômeno físico denominado dipolarização da magnetosfera terrestre abordada no artigo (Wang et al., 2014).

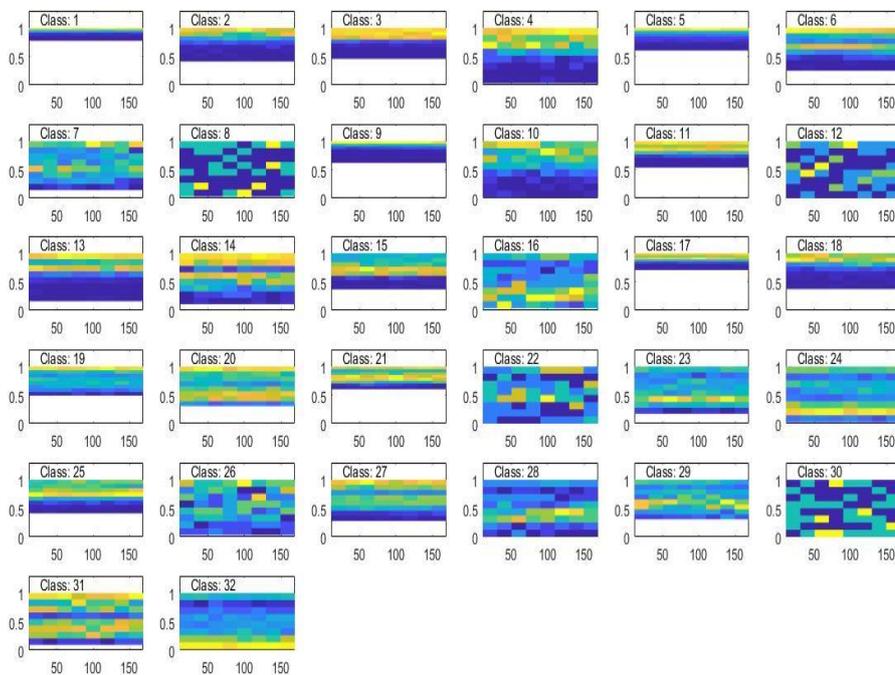
O instrumento SST possui 8 “bins” de ângulos de arremesso, a saber: 11.25°, 33.75°, 56.25°, 78.75°, 101.25°, 123.75°, 146.25° e 168.75°. Conforme discutido na seção Obtenção de dados para a REPT, escolher todos os ângulos tornaria o processamento dos dados mais demorado pois requisitaria mais neurônios.

Nessa etapa foram utilizadas os ângulos de arremesso de 33.75°, 56.25°, 78.75°, 146.25° e 168.75°, mantendo o padrão de 5 entradas da rede aplicada na REPT, uma para cada ângulo, com 2 neurônios associados para cada uma das entradas.

## Resultados

Para o canal de energia de 408 KeV o período de dados para treinamento variou de 2008-02-01/00:06:22 até 2008-02-14/10:42:12 UT. Com a rede neural treinada no canal de 408 KeV, aplicou-se a SOM para um conjunto de dados de fluxo de elétrons que variam do dia 2008-03-01/00:06:30 UT até 2008-03-08/08:30:54 UT. A Figura 17 a seguir mostra a classificação obtida pela rede.

Figura 17: Classificação dos dados da THEMIS medidos pelo instrumento SST no canal de 408 KeV para o mês de março de 2008.

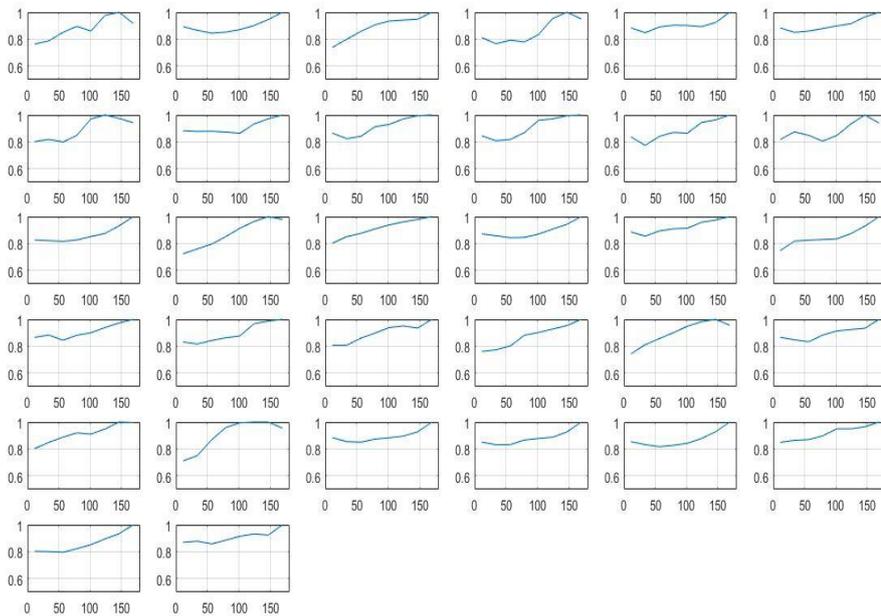


Fonte: O autor.

Deve-se levar em conta que a coloração nas classes da figura 1 está relacionada a frequência de ocorrência dos dados no conjunto, crescendo do azul escuro (baixa frequência) em direção ao amarelo escuro (elevada frequência). E que os eixos representam os ângulos de arremesso (0 a 180°) no eixo X e fluxo normalizado de elétrons no eixo Y. Da figura 1 tem-se que algumas classes possuem semelhança, por exemplo as classes 3, 11 e 17, com alta frequência para valores de fluxo normalizado perto de 1, e baixa frequência conforme os valores de fluxo vão diminuindo.

Para a classe 3 a rede agrupou 183 distribuições de ângulos de arremesso para o canal de 408 KeV do conjunto de dados no qual a rede foi aplicada, as características salientes desse conjunto podem ser ilustradas pela Figura 18 a seguir

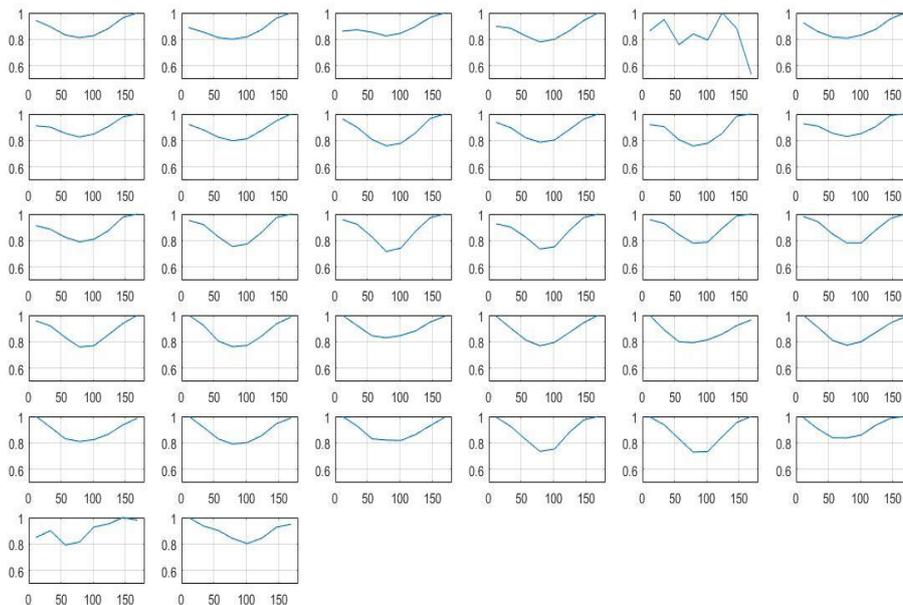
Figura 18: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 3.



Fonte: O autor.

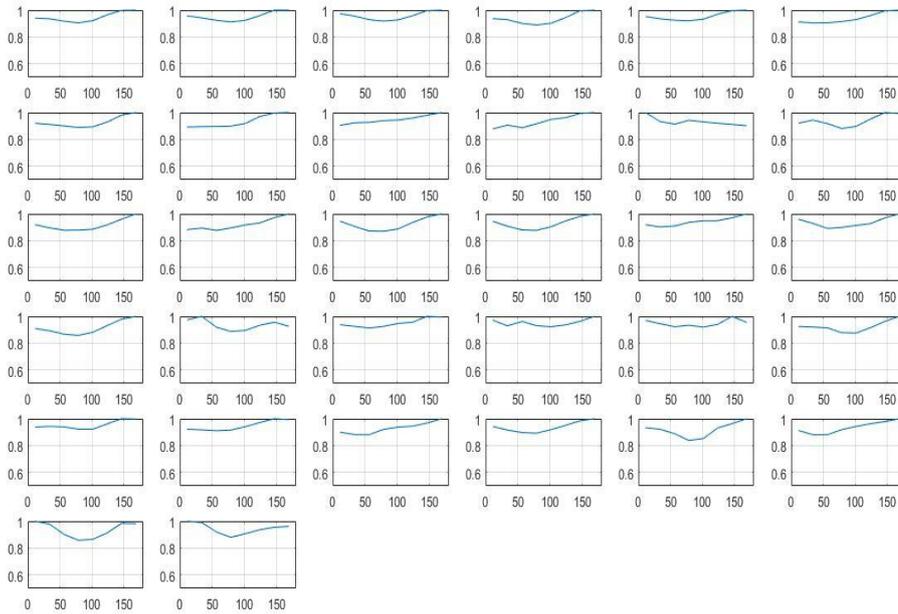
Para efeito de comparação a seguir tem-se as 32 primeiras distribuições de ângulo de arremesso do canal de 408 KeV para as classes 11 e 17, respectivamente.

Figura 19: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 11



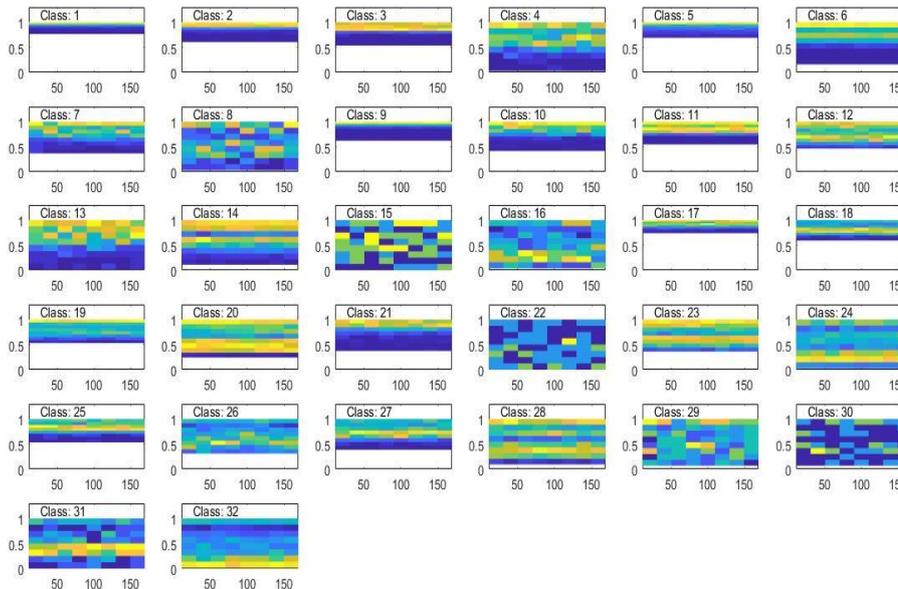
Fonte: O autor.

Figura 20: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 17.



Fonte: O autor.

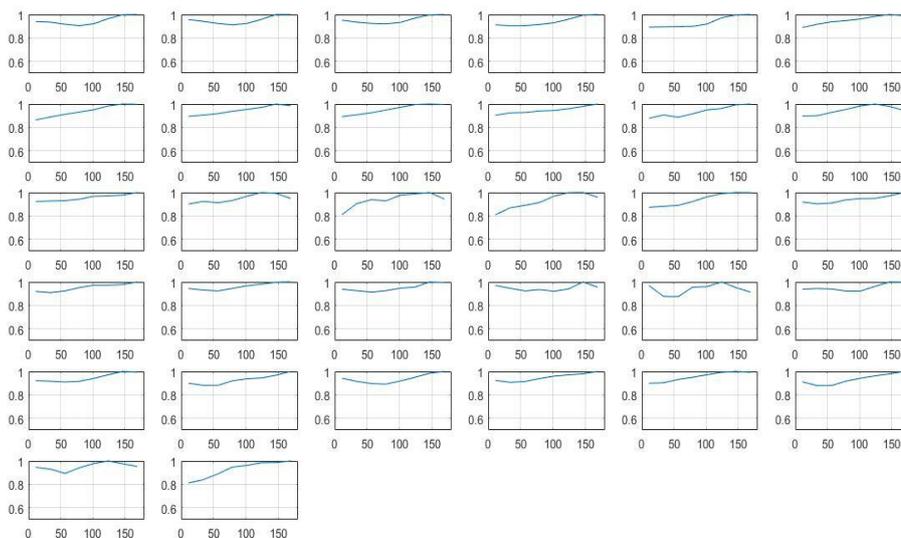
Figura 21: Classificação dos dados da THD medidos pelo instrumento SST no canal de 561.5 KeV para o mês de março de 2008.



Fonte: O autor.

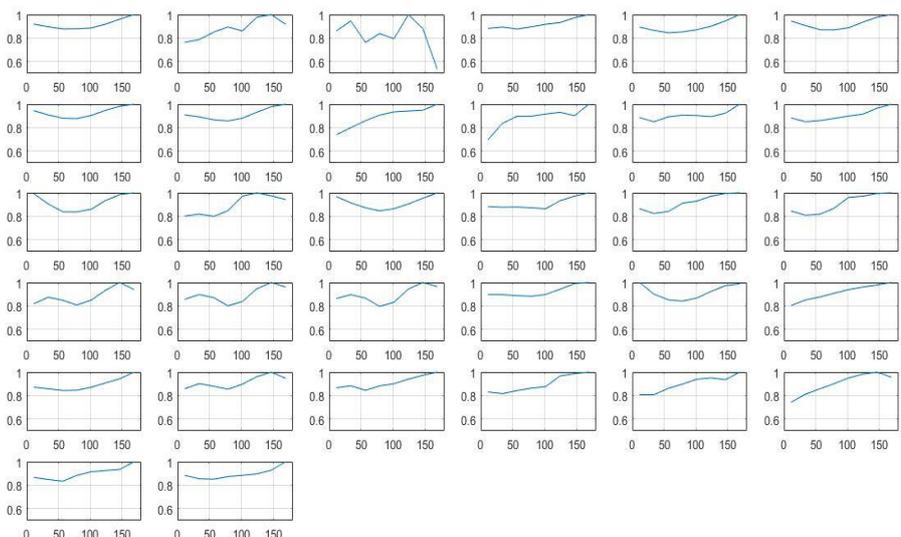
Para o canal de 506.5 KeV, treinou-se a rede neural com um conjunto de dados de fluxo de elétrons obtidos pela sonda THD que variam do dia 2008-02-01/00:06:22 UT até 2008-02-14/10:42:12 UT. Com a SOM treinada aplicou-se a mesma para um conjunto de dados que variam do dia 2008-03-01/00:06:30 UT até 2008-03-08/08:30:54 UT. A Figura 21 acima mostra a classificação obtida pela rede nesse canal de energia. Para efeito de comparação, qualitativa, a seguir tem-se duas figuras que representam as 32 primeiras distribuições das classes 2 e 3 que na Figura 21 aparentam semelhança visual.

Figura 22: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 2.



Fonte: O autor.

Figura 23: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 3.

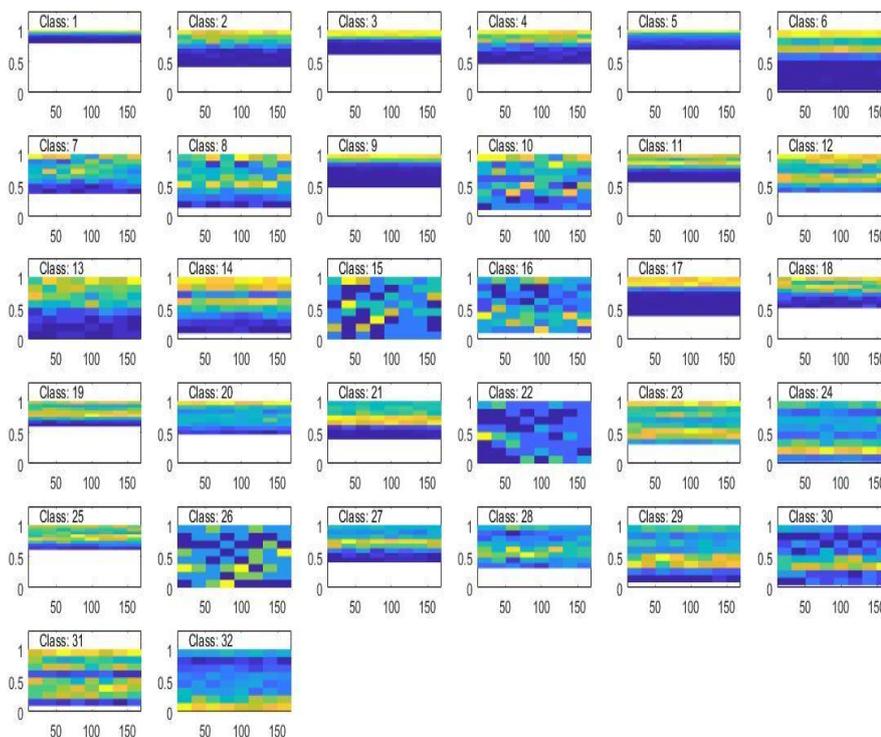


Fonte: O autor.

Pode-se observar diferenças sutis entre as duas classes evidenciadas pelas distribuições de ângulo de arremesso nas Figura 22 e Figura 23. Uma vez que o número de classes é elevado, dada as distribuições conhecidas na literatura, a rede diferencia/classifica as distribuições com base em pequenas nuances podendo separar em classes distintas variações de uma mesma distribuição.

Para o canal de 719.5 KeV, treinou-se a rede neural com um conjunto de dados de fluxo de elétrons obtidos pela sonda THD da THEMIS que variam do dia 2008-02-01/00:06:22 UT até 2008-02-10/08:42:06 UT. Com a SOM treinada aplicou-se a mesma para um conjunto de dados que variam do dia 2008-03-01/00:06:30 UT até 2008-03-08/08:30:54 UT. A Figura 24 a seguir mostra a classificação obtida pela rede nesse canal de energia.

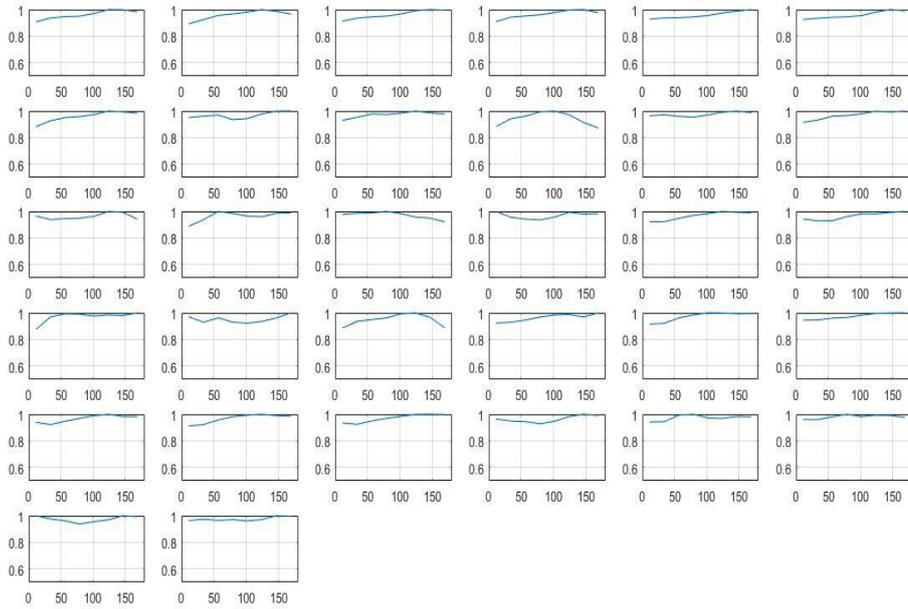
Figura 24: Classificação dos dados da THD medidos pelo instrumento SST no canal de 719.5KeV para o mês de março de 2008.



Fonte: O autor.

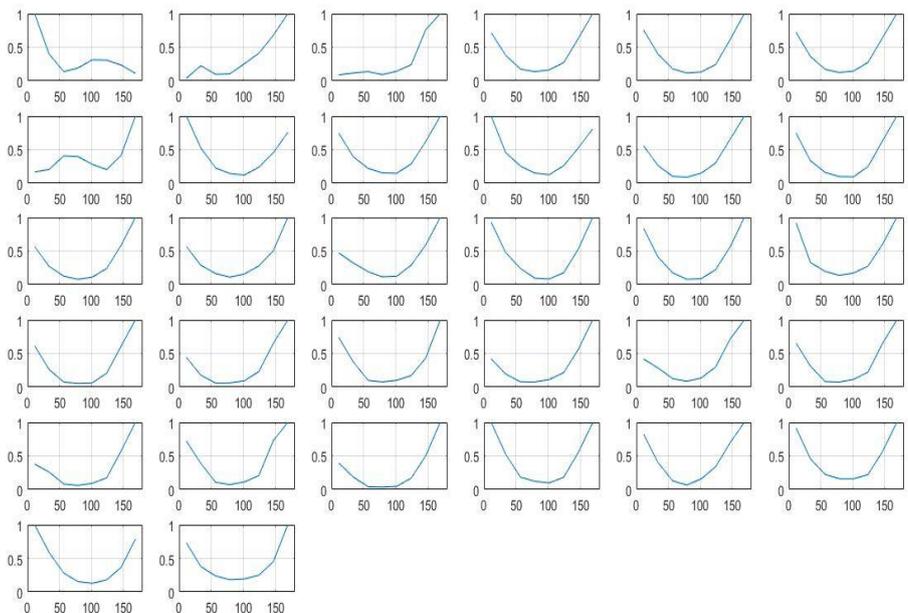
A comparação entre as classes visualmente semelhantes foi feita nos dois canais de energia anteriores, resultando em diferenças aparentes e nos dando uma ideia que de realmente a rede neural está agrupando distribuições de ângulo de arremesso de forma satisfatória. Nesse momento comparar-se-á classes visualmente distintas, como por exemplo as classes 1 e 32. Para a classe 1 tem-se um subconjunto de 749 distribuições de ângulo de arremesso caracterizadas como semelhantes, enquanto na classe 32 um subconjunto de 119 distribuições, as figuras a seguir representam as 32 primeiras distribuições para cada uma dessas classes, 1 e 32 respectivamente.

Figura 25: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 1.



Fonte: O autor.

Figura 26: Conjunto das primeiras 32 distribuições de ângulo de arremesso para classe 32.



Fonte: O autor.

## Discussão e Conclusão

O presente projeto de iniciação científica teve como objetivo iniciar o aluno de graduação no estudo das distribuições de ângulo de arremesso no cinturão externo de radiação Van Allen, e desenvolver competências como pesquisa acadêmica, utilização de software para análise de dados e processamento de dados.

Nesse trabalho dados coletados *in situ* fornecidos pelo REPT A foram utilizados para análise da distribuição de ângulo de arremesso de uma região conhecida como cinturão externo de radiação Van Allen, utilizou-se um software de processamento de dados, embutido no programa MATLAB, conhecido como Neural Network Toolbox para utilização de uma rede neural do tipo Mapa Auto Organizado-SOM. Os dados analisados pela rede neural correspondem ao mês de Dezembro de 2014.

A RNA foi capaz de reconhecer os padrões de distribuição advindos da literatura, porém houve alguns problemas com o número de classes estipulados para rede. Sendo assim algumas classes não ficaram representativas e outras apresentaram distribuições diferentes das convencionais para esse tipo de estudo.

Num segundo momento iniciou-se o estudo da aplicação da SOM para dados da sonda THD, do conjunto de sondas da missão THEMIS, visando classificar de forma automatizada as distribuições de ângulo de arremesso numa faixa de energia menor que a da REPT A. Novamente o software Neural Network Toolbox foi utilizado, em conjunto com o conjunto de rotinas TDAS responsável pelo fornecimento dos dados de fluxo de elétrons do instrumento SST abordo da sonda THD. Os dados analisados pela rede correspondem ao mês de Março de 2008 nos 3 canais de energia mencionados na seção Metodologia. A RNA conseguiu separar de forma satisfatória as distribuições de ângulo de arremesso distintas, pode-se destacar que a trigésima primeira PAD da Figura 20 tem o formato similar a nonagésima PAD da Figura 19, entretanto a RNA foi capaz de distinguir/classificar as distribuições em classes diferentes devido aos níveis distintos de fluxo normalizado em torno de ângulo de arremesso de  $90^\circ$ . Deve-se ressaltar que tais distribuições semelhantes podem estar associadas a fenômenos físicos distintos.

## **Agradecimentos**

Todos os integrantes do Gamma Junior Engenharia, em especial as integrantes do Grupo Snark por proporcionar inúmeras discussões produtivas sobre a implementação e aplicação das redes neurais artificiais.

Ao Instituto Nacional de Pesquisas Espaciais pela oportunidade de interação dos alunos de Engenharia Física da EEL-USP em trabalhos extracurriculares com os pesquisadores do instituto, mediada pela Gamma Junior Engenharia.

A pesquisadora Claudia Medeiros por simular partes fundamentais dos dados responsáveis pela geração dos padrões de distribuição do mês de Dezembro.

Ao CNPq pelo auxílio concedido durante o período de 01/02/2018 a 31/07/2018.

“Até logo e obrigado pelos peixes”.

## Referências

HAYKIN, Simon. **Redes Neurais: Princípios e prática**. 2. Ed. Porto Alegre: Bookman, 2001.

KIVELSON, Margaret G.; RUSSELL, Christopher T.. **Introduction to space physics**. New York: Cambridge University Press, 1995.

MATSUNAGA, Victoria Yukie. **Curso de redes neurais utilizando MATLAB**. Belém do Pará: 2012. Disponível em: <[https://paginas.uepa.br/engprod/index.php?option=com\\_rokdownloads&view=file&task=download&id=132:apostilaredesneurais](https://paginas.uepa.br/engprod/index.php?option=com_rokdownloads&view=file&task=download&id=132:apostilaredesneurais)>. Acesso em: 20 set. 2017.

Souza, V. M., et al. (2016), A neural network approach for identifying particle pitch angle distributions in Van Allen Probes data, *Space Weather*, 14, 275–284, doi:10.1002/2015SW001349.

SOUZA, V. M. et al. (2017), Classification of magnetospheric particle distributions via neural networks. In: E. CAMPOREALE; S. WING; J. JOHNSON. **Machine Learning techniques for Space Weather**.

PAPADOPOULOS, Leonidas; KILLIAN, Mike. **NASA's Van Allen Probes Detect Life-Protective Electron Barrier Inside Earth's Radiation Belts**. Disponível em: <<http://www.americaspace.com/2014/11/29/nasas-van-hallen-probes-detect-life-protective-electron-barrier-inside-the-earths-radiation-belts/>>. Acesso em: 26 set. 2017.

COSTA JUNIOR, E. et al. O vento solar e a atividade geomagnética. **Revista Brasileira de Ensino de Física**, Ouro Preto, Mg, Brasil, v. 4, n. 33, p.1-8, 22 nov. 2011.

McIlwain, C. E. (1961), Coordinates for mapping the distribution of magnetically trapped particles, *J. Geophys. Res.*, 66(11), 3681–3691, doi:[10.1029/JZ066i011p03681](https://doi.org/10.1029/JZ066i011p03681).

HORNE, Richard Bertram. Plasma astrophysics: Acceleration of killer electrons. **Nature Physics**, [s.l.], v. 3, n. 9, p.590-591, set. 2007. Springer Nature. <http://dx.doi.org/10.1038/nphys703>.

Gannon, J. L., X. Li, and D. Heynderickx (2007), Pitch angle distribution analysis of radiation belt electrons based on combined release and radiation effects satellite medium electrons A data, *J. Geophys. Res.*, 112, A05212, doi:10.1029/2005JA011565.

Horne, R. B., N. P. Meredith, R. M. Thorne, D. Heynderickx, R. H. A. Iles, and R. R. Anderson (2003), Evolution of energetic electron pitch angle distributions during storm time electron acceleration to megaelectronvolt energies, *J. Geophys. Res.*, 108(A1), 11–13, doi:10.1029/2001JA009165

Kim, K. C., D.-Y. Lee, H.-J. Kim, L. R. Lyons, E. S. Lee, M. K. Öztürk, and C. R. Choi (2008), Numerical calculations of relativistic electron drift loss effect, *J. Geophys. Res.*, 113, A09212, doi:10.1029/2007JA013011.

Sibeck, D. G., R. W. McEntire, A. T. Y. Lui, R. E. Lopez, and S. M. Krimigis (1987), Magnetic field drift shell splitting: Cause of unusual dayside particle pitch angle distributions during storms and substorms, *J. Geophys. Res.*, 92(A12), 13,485–13,497, doi:10.1029/JA092iA12p13485.

J. F. Fennell, S. G. Claudepierre, J. B. Blake, T. P. O'Brien, J. H. Clem- 730 mons, D. N. Baker, H. E. Spence, G. D. Reeves, Van allen probes show 36 that the inner radiation zone contains no mev electrons: Ect/mageis data, *Geophysical Research Letters* 42 (5) (2015) 1283–1289, 2014GL062874. doi:10.1002/2014GL062874.

Wang, K., C.-H. Lin, L.-Y. Wang, T. Hada, Y. Nishimura, D. L. Turner, and V. Angelopoulos (2014), Pitch angle distributions of electrons at dipolarization sites during geomagnetic activity: THEMIS observations, *J. Geophys. Res. Space Physics*, 119, 9747–9760, doi:10.1002/2014JA020176.