

Universidade do Vale do Paraíba
Instituto de Pesquisa e Desenvolvimento

ALESSANDRO GERSON MOURA IZZO DE OLIVEIRA

ESTUDO DA RELAÇÃO ENTRE O CAMPO MAGNÉTICO E A INTENSIDADE DE
RAIOS CÓSMICOS NO MEIO INTERPLANETÁRIO VIA REDES NEURAIS

São José dos Campos, SP

2013

Alessandro Gerson Moura Izzo de Oliveira

ESTUDO DA RELAÇÃO ENTRE O CAMPO MAGNÉTICO E A INTENSIDADE DE
RAIOS CÓSMICOS NO MEIO INTERPLANETÁRIO VIA REDES NEURAIAS

Dissertação de Mestrado apresentada ao Programa de Mestrado em Física e Astronomia, como complementação dos créditos necessários para obtenção do título de Mestre em Física e Astronomia.

Orientador: Prof. Dr. Marlos Rockenbach da Silva

São José dos Campos, SP

2013

O46c

Oliveira, Alessandro Gerson Moura Izzo de

Estudo da relação entre o campo magnético e a intensidade de raios cósmicos no meio interplanetário via redes neurais [dissertação] / Alessandro Gerson Moura Izzo de Oliveira; Orientador: Prof. Dr. Marlos Rockenbach da Silva. – São José dos Campos, SP, 2013.

1 CD-ROM; 107 p. ; 21cm

Dissertação (mestrado) - Universidade do Vale do Paraíba, Instituto de Pesquisa e Desenvolvimento. Programa de Pós-Graduação em Física e Astronomia.

Inclui referências

1. Física e Astronomia. 2. Raios cósmicos. 3. Redes neurais (Computação). 4. Ambientes aeroespaciais. I. Silva, Marlos Rockenbach da II. Universidade do Vale do Paraíba, Instituto de Pesquisa e Desenvolvimento. Programa de Pós-Graduação em Física e Astronomia. III. Título.

CDU: 52

Autorizo exclusivamente para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação, por processo fotocopiadoras ou transmissão eletrônica, desde que citada a fonte.



Alessandro Gerson Moura Izzo de Oliveira


Data: 20 de fevereiro de 2013.

ALESSANDRO GERSON MOURA IZZO DE OLIVEIRA

**“ESTUDO DA RELAÇÃO ENTRE O CAMPO MAGNÉTICO E A INTENSIDADE DE RAIOS
CÓSMICOS NO MEIO INTERPLANETÁRIO VIA REDES NEURAIS”**

Dissertação aprovada como requisito parcial à obtenção do grau de Mestre em Física e Astronomia, do Programa de Pós-Graduação em Física e Astronomia, do Instituto de Pesquisa e Desenvolvimento da Universidade do Vale do Paraíba, São José dos Campos, SP, pela seguinte banca examinadora:

Prof^ª. Dra. **ALESSANDRA ABE PACINI** (UNIVAP) - 

Prof. Dr. **MARLOS ROCKENBACH DA SILVA** (UNIVAP) - 

Prof. Dr. **OLI LUIZ DORS JUNIOR** (UNIVAP) - 

Prof. Dr. **EZEQUIEL ECHER** (INPE) - 

Prof^ª. Dra. Sandra Maria Fonseca da Costa

Diretor do IP&D – UniVap

São José dos Campos, 20 de fevereiro de 2013.

“Mas eu não quero me encontrar com gente louca”, observou Alice.

“Oh, não se pode evitar”, disse o gato, “todos são loucos por aqui. Eu sou louco. Você é louca.”

“Como sabe que eu sou louca?” indagou Alice.

“Você deve ser”, respondeu o gato, “ou então não teria vindo aqui...”

Lewis Carroll

*Dedico todo este trabalho,
a meus avós e minha sogra pelas saudades
que deixaram,
a minha esposa pela compreensão,
a minha mãe pelo apoio e confiança,
e ao meu pai pela estante de livros.*

AGRADECIMENTOS

Muitas pessoas contribuíram na realização deste trabalho cada uma a seu próprio modo, quero agora expressar meu mais profundo agradecimento a elas:

Aos membros da minha família que me encorajaram durante esse período de tantas dificuldades, em especial as minhas irmãs Angela Marcia e Aline Bruna e também ao meu sogro Romeu Panhoca pelas palavras de incentivo que sempre me fizeram acreditar em um futuro melhor.

Ao meu orientador Dr. Marlos Rockenbach Silva, pela enorme confiança que depositou na minha dedicação a este projeto. Também por ter sido tão paciente e solícito ao indicar a direção correta em todas as discussões que tivemos.

Aos amigos Kaylla Prado Araujo, Rafael Sampaio, Maira Amaral e Ricardo Parra Catarina pelas sugestões, correções e pela infinita paciência em me ouvir falar sobre raios cósmicos e redes neurais por horas a fio.

Aos colaboradores do grupo da Rede Global de Detectores de Múons, que disponibilizam os dados para acesso público na internet. Em especial ao Dr. Kazuoki Munakata PI da GMDN e ao Dr. Nelson Jorge Schuch e Dr. Alisson Dal Lago gerentes brasileiros da GMDN.

Aos responsáveis pela Universidade do Vale do Paraíba – UNIVAP, pelo suporte financeiro ao conceder a bolsa de estudos.

Finalmente meu muito obrigado a todos que colaboraram nesta jornada que foi muito longa, e que agora parece tão breve anunciando como serão as jornadas vindouras.

Resumo

No meio interplanetário, as relações entre os raios cósmicos e o campo magnético são significativamente importantes na compreensão do Clima Espacial, cuja ação sobre a Terra e seus habitantes é indiscutível e em alguns momentos inclusive ameaçadora. Todavia essas relações permanecem obscuras o bastante para não haver ainda um modelo matemático que as represente satisfatoriamente bem. No intuito de produzir indícios e evidências que auxiliem o desenvolvimento desses modelos, este projeto de pesquisa propõe aplicar um recurso computacional relativamente novo: os perceptrons de múltiplas camadas, modelo típico e amplamente estudado de rede neural, com a finalidade de simular a intensidade de raios cósmicos, determinada segundo o método de Rockenbach (2010), em função da relação intrínseca entre as componentes do Campo Magnético Interplanetário (*Interplanetary Magnetic Field* - IMF), no sistema de coordenadas GSE, em períodos de severa atividade do Clima Espacial causada pela ação de eventos de origem solar, em especial as ejeções de massa coronal interplanetárias (*Interplanetary Coronal Mass Ejection* - ICMEs). A capacidade do perceptron de reproduzir o perfil de variação de raios cósmicos durante um desses períodos tendo por base o que assimilou em uma outra época distinta, pode indicar o quão intensamente o perfil depende do IMF. Os resultados mostraram que simulações produzidas por perceptrons que contam com elementos de memória e retroalimentação são mais semelhantes aos eventos observados. Também se conclui que com o auxílio de novos instrumentos de análise as observações de solo podem fornecer dados de qualidade equiparável ou mesmo superior aos fornecidos pela tecnologia espacial.

Palavras chaves: raios cósmicos; redes neurais; ICME; perceptron; Clima Espacial.

Abstract

In the interplanetary environment, the relations between cosmic rays and magnetic field are significantly important for the understanding of space weather, whose action on the Earth and its inhabitants is undeniable and at times even threatening. These relationships remain obscure enough to not be a mathematical model to represent them well. In order to produce clues and evidences to assist the development of these models, this research project proposes to apply a relatively new technology resource: the multilayer perceptrons, a typical and widely studied model of neural network, with the purpose of simulate the intensity of rays cosmic, as calculated by Rockenbach (2010), as a function of the intrinsic relationship between the components of the IMF in GSE coordinate system, at times of severe space weather activity caused by the action event of solar origin, ICMEs in particular. The capacity of the perceptron to reproduce the profile of variation of cosmic rays during such period based on what it assimilated into another epoch of similar behavior may indicate how deeply the profile depends on the IMF. The results indicated that simulations produced by perceptrons that have memory and feedback are more similar to observed events. It is also concluded that, with the help of new tools of analysis, surface observations can provide data of quality equivalent or even superior to those provided by space born technology.

Keywords: cosmic rays; neural networks; ICME; perceptron; space weather.

LISTA DE ABREVIATURAS E SIGLAS

ACE	- <i>Advanced Composition Explorer</i> – Satélite de monitoramento do meio interplanetário
AU	- <i>Astronomical Unit</i> – Unidade Astrônômica ($1,5 \times 10^{11}$ m)
CIR	- <i>Corotating Interaction Region</i> – Região de Interação Corrotante.
CME	- <i>Coronal Mass Ejection</i> – Ejeção de Massa Coronal
Dst	- <i>Disturbance Storm Time</i> – Índice Geomagnético Dst
GCR	- <i>Galactic Cosmic Ray</i> – Raios cósmicos Galáticos
GEO	- Coordenadas Geográficas
GMDN	- <i>Global Muon Detector Network</i> – Rede Global de Detectores de Múons
GSE	- <i>Geocentric Solar Ecliptic</i> – Sistema de Coordenadas Solar-Eclíptico
GSM	- Geocentric Solar Magnetospheric Sistema de Coordenadas Solar-geomagnético
HCS	- <i>Heliospheric Current Sheet</i> - Lâmina de Corrente Heliosférica
ICME	- <i>Interplanetary Coronal Mass Ejection</i> – Ejeção de Massa Coronal Interplanetária
IMF	- <i>Interplanetary Magnetic Field</i> – Campo Magnético Interplanetário
MC	- Magnetic Cloud Nuvem Magnética
MLP	- <i>MultiLayer Perceptron</i> - Perceptron de Camadas Múltiplas
NARX	- <i>Nonlinear AutoRegressive model with eXogenous inputs</i> - Modelo Não-Linear e Autoregressivo com Entradas Exógenas
NARX-P	- rede NARX operando no modo Paralelo
NARX-SP	- rede NARX operando no modo Série-Paralelo
NN	- <i>Neural Network</i> - Rede Neural
SCR	- <i>Solar Cosmic Ray</i> - Raio Cósmico Solar
SEP	- <i>Solar Energetical Particle</i> - Partícula Energética Solar
SSC	- <i>Storm Sudden Comencement</i> – Início Súbito da Tempestade

LISTA DE FIGURAS

Figura 2.1 – Ilustração das partes componentes do Sol é algumas estruturas solares.....	19
Figura 2.2 – Representação esquemática da folha de corrente heliosférica..	24
Figura 2.3 – Modelo de Saia de Bailarina, representação 3D da heliosfera..	25
Figura 2.4 – Diagrama de Maunder e média mensal do número de manchas solares no mesmo período.....	27
Figura 2.5 – Diagrama comparativo do ciclo de atividade solar e da média mensal da contagem de raios cósmicos.....	28
Figura 2.6 – Estrutura da Magnetosfera Terrestre.....	30
Figura 2.8 – Ilustração da região de acoplamento entre o IMF e da magnetosfera terrestre.....	32
Figura 2.9 – Gráfico do índice DST indicando as fases de uma tempestade magnética.....	33
Figura 3.1 – Espectro de raios cósmicos superiores a 100 MeV.....	37
Figura 3.2 – Ilustração esquemática do processo causador da anisotropia solar Leste-Oeste.....	40
Figura 3.3 – Esquema da anisotropia Norte-Sul.....	41
Figura 3.4 – Gráfico da contagem de nêutrons durante um decréscimo de Forbush.....	42
Figura 3.5 – Esquema ilustrativo de uma ICME e da região de choque.....	43
Figura 3.6 – Chuveiro de Partículas.....	45
Figura 3.7 – (A) Esquema artístico de um detector de múons de duas camadas (B) Foto do detector de múons em São Martinho, RS.....	47
Figura 3.8 – Desvio percentual na contagem de muons dos canais verticais dos detectores que compõe a GMDN.....	48
Figura 3.9 – Linhas indicativas das direções assintóticas da rede global de detectores de múons.....	50
Figura 4.1 – Neurônio Biológico.....	57
Figura 4.2 – Grafo de um neurônio artificial.....	58

Figura 4.3 – Gráficos da função degrau, linear, logística e tangente hiperbólica.....	62
Figura 4.4 – (A) Grafo representativo de um perceptron de camada única. (B) Grafo de um perceptron de múltiplas camadas.....	63
Figura 4.5 – Representação de uma rede NARX no modo série paralelo.....	65
Figura 4.6 – Grafo representativo de uma rede NARX no modo paralelo.....	65
 Figura 5.1 – Gráfico demonstrando um falso resultado para o valor do coeficiente de correlação.....	 78
Figura 5.2 – Dados do meio interplanetário no período de 09 a 14 de abril de 2001.....	79
Figura 5.3 – Dados do meio interplanetário no período de 27 de outubro de 2003 a 01 de novembro de 2003.....	80
Figura 5.4 – Dados do meio interplanetário no período de 16 a 24 de novembro de 2003.....	81
Figura 5.5 – Dados do meio interplanetário no período de 12 a 18 de dezembro de 2003.....	82
Figura 5.6 – Redes treinadas com o evento de abril de 2001 simulando o evento de outubro de 2003.....	86
Figura 5.7 – Redes treinadas com o evento de abril de 2001 simulando o evento novembro de 2003.....	87
Figura 5.8 – Redes treinadas com o evento de abril de 2001 simulando o evento de dezembro de 2006.....	88
Figura 5.9 – Redes treinadas com o evento de outubro de 2003 simulando o evento de abril de 2001	89
Figura 5.10 – Redes treinadas com o evento de outubro de 2003 simulando o evento de novembro de 2003	90
Figura 5.11 – Redes treinadas com o evento de outubro de 2003 simulando o evento de dezembro de 2006	91
Figura 5.12 – Redes treinadas com o evento de novembro de 2003 simulando o evento de abril de 2001.....	92
Figura 5.13 – Redes treinadas com o evento de novembro de 2003 simulando o evento de outubro de 2003.....	93

Figura 5.14 – Redes treinadas com o evento de novembro de 2003 simulando o evento de dezembro de 2006.....	94
Figura 5.15 – Redes treinadas com o evento de dezembro de 2006 simulando o evento de abril de 2001	95
Figura 5.16 – Simulações de redes treinadas com o evento de dezembro de 2006 simulando o evento de outubro de 2003	96
Figura 5.6 – Simulações de redes treinadas com o evento de dezembro de 2006 simulando o evento de novembro de 2003	97
Figura 5.6 – Simulações da intensidade do IMF em dezembro de 2006	98

SUMÁRIO

1.INTRODUÇÃO.....	14
2. CLIMA ESPACIAL.....	17
2.1 O Sol como fonte energética do Geoespaço	18
2.2. Espaço Interplanetário e o Vento Solar.....	21
2.2.1. Distribuição Espacial.....	23
2.2.2. Variação Temporal.....	25
2.3. A Terra e o Campo Geomagnético.....	29
2.3.1. Tempestades Geomagnéticas.....	31
3. RAIOS CÓSMICOS.....	35
3.1. Origem dos Raios cósmicos.....	36
3.2. Modelagem de Raios cósmicos.....	37
3.3. Anisotropias Recorrentes.....	39
3.4. Decréscimo de Forbush.....	41
3.5. Rede Global de Detectores de Múons.....	44
3.6. Cálculo da Intensidade de Raios cósmicos.....	48
4. REDES NEURAIS.....	55
4.1. Neurônio.....	56
4.2. Arquitetura de Rede.....	62
4.3. Aprendizado.....	66
5. DADOS E CÁLCULOS	73
5.1. Tratamento de Dados	74
5.2. Características dos Eventos.....	78
5.2.1 Evento de Abril de 2001.....	79
5.2.2. Evento de Outubro de 2003.....	80
5.2.3. Evento de Novembro de 2003.....	81
5.2.4. Evento de Dezembro de 2003.....	82
5.3. Topologia das redes.....	83
5.4. Resultados.....	85

5.4.1. Redes Treinadas com o Evento de Abril de 2001.....	85
5.4.2. Redes Treinadas com o Evento de Outubro de 2003.....	88
5.4.3. Redes Treinadas com o Evento de Novembro de 2003.....	91
5.4.4. Redes Treinadas com o Evento de Dezembro de 2006.....	94
5.4.5 Simulações do IMF.....	97
 6. CONCLUSÕES	 99
 7. REFERÊNCIAS BIBLIOGRÁFICAS.....	 101

1. INTRODUÇÃO

O estudo das partículas que compõem os assim chamados raios cósmicos é muito significativo, pois já trouxe grandes contribuições para campos fundamentais da física (como a física de partículas). A análise das características dos raios cósmicos que chegam à Terra de fontes até mesmo de fora da galáxia, fornece informações sobre o Clima Espacial que por sua vez afeta de maneira direta e intensa o ambiente terrestre, especialmente em períodos de grande atividade solar.

Assim, desenvolver modelos matemáticos que reproduzam o comportamento destas partículas é uma tarefa muito meritória, mas também tem se mostrado bastante difícil, tantos são os fatores que as afetam. A fim de apoiar esta tarefa, o principal objetivo deste trabalho de pesquisa de mestrado é produzir evidências e indícios para o desenvolvimento destes modelos, usando redes neurais artificiais (*Neural Networks* - NN) como instrumento de busca e analisando as potencialidades das redes neurais como ferramenta computacional aplicada a pesquisas de fenômenos físicos. Obviamente, devido à abrangência da proposta é necessário limitar os elementos estudados para que o esforço de pesquisa se torne factível, deixando muitas possibilidades para trabalhos posteriores e/ou complementares.

Foi escolhida como objeto de estudo a relação entre raios cósmicos galácticos (*Galactic Cosmic Rays* - GCRs) e as ejeções de massa coronal interplanetárias (*Interplanetary Coronal Mass Ejection* - ICMEs), uma vez que a existência de uma relação é bem demonstrada pelo fenômeno dos decréscimos de Forbush. Os detalhes que permitiriam uma modelagem matemática de todas as características dessa relação ainda são obscuros ou mesmo desconhecidos, tornando-a perfeitamente adequada à proposta deste trabalho. Os valores horários da intensidade de GCRs e de suas componentes foram determinados pelas equações descritas em Okazaki(2008) e Rockenbach (2010) utilizando dados da rede global de detectores de múons (*Global Muons Detector Networks* - GMDN). As ICMEs, por sua vez podem ser estimadas pelo efeito que produz nas componentes do Campo Magnético Interplanetário (*Interplanetary Magnetic Field* - IMF), com medições feitas pelo satélite *Advanced Composition Explorer* – ACE que está localizado no ponto lagrangiano (L1) entre o Sol e a Terra.

Uma das principais funções das NNs é estabelecer soluções para problemas nos quais não se encontram modelos matemáticos suficientemente adequados. Uma rede neural é fundamentalmente um hardware ou software que simula o massivo processamento paralelo do sistema nervoso biológico, em uma escala muito menor (Haykin, 2001). Assim como uma rede neural biológica aprende com suas experiências, treina-se a NN com um conjunto inicial de dados de entrada e de dados de saída, supondo que haja uma relação de causalidade entre entradas e saídas. Durante o treinamento, a NN ajusta suas unidades de processamento de forma que, para um específico dado de entrada, sua resposta calculada se aproxime ao máximo possível do dado saída esperado. No entanto, há algumas desvantagens: a rede pode se ajustar para que seus resultados sejam os mais parecidos possíveis com o da relação matemática que liga os dados de entrada e saída, todavia não é capaz de determinar qual é essa relação. Além disso os conjuntos de dados de entrada e de saída devem satisfazer certas condições e ser preparados previamente para garantir um funcionamento otimizado da NN ao lidar com eles. A proposta deste trabalho é aplicar diferentes NNs que busquem discernir uma relação entre seleções diversas de dados do IMF e dos GCRs, assumindo que, o conjunto de dados de entrada e saída para o qual a rede produziu um melhor ajuste, é o conjunto que apresenta uma relação matemática mais significativa. A comparação dos resultados e da eficiência das NNs pode levar também a importantes evidências sobre a natureza desta relação.

Este trabalho está estruturado nos seguintes capítulos:

- **CAPÍTULO 2 – CLIMA ESPACIAL.** Neste capítulo, caracterizam-se as principais estruturas componentes do Clima Espacial, bem como seu principal agente: o Sol.
- **CAPÍTULO 3 – RAIOS CÓSMICOS.** Neste capítulo define-se de modo sucinto o conceito de raios cósmicos e seu comportamento no meio interplanetário, explana-se como podem ser detectados por meio da GMDN e discute-se como determinar a densidade de raios cósmicos e a intensidade da anisotropia com base nos dados dos detectores de múons.

- **CAPÍTULO 4 – REDES NEURAIS.** A função deste capítulo é explanar sobre as NNs e suas aplicações, também discute-se maneiras de aperfeiçoar a rede e de como preparar os dados para que a ela própria possa interpretá-los de modo otimizado.
- **CAPÍTULO 5 – DADOS E CÁLCULOS.** Nesta seção são apresentados os resultados das abordagens e testes, atentando para as indicações de direção de pesquisa, de instrumental matemático e dos critérios que devem nortear a dissertação.
- **CAPÍTULO 6 – CONCLUSÕES.** Nesta parte final são avaliadas as conclusões finais e expõem-se as propostas de complementação do trabalho.

2. CLIMA ESPACIAL

O Clima Espacial se refere as condições do Sol, do Vento Solar, da magnetosfera, ionosfera e termosfera que não só podem afetar a performance e a confiabilidade de sistemas tecnológicos espaciais ou terrestres, mas também oferecer riscos a saúde e a vida humana (Mavromichalaki et al, 2006). Desta forma, é bastante compreensível o motivo pelo qual pesquisas neste campo crescem em importância na mesma proporção em que cresce a dependência da humanidade por recursos tecnológicos. Os elementos que compõem e afetam o Clima Espacial também determinam a incidência de raios cósmicos sobre a superfície terrestre e, portanto a compreensão da matemática intrínseca da relação entre o fluxo de partículas cósmicas e o Clima Espacial permitirá estabelecer conclusões e previsões sobre um a partir do outro.

O ambiente do Clima Espacial pode ser dividido em três elementos principais: (1) O Sol, que é a principal fonte de energia do Clima Espacial liberada por meio de explosões solares (“flares”), partículas energéticas solares e ejeções de massa coronal além das emanações quiescentes como o Vento Solar. (2) O espaço interplanetário que, se no passado era visto como uma área onde simplesmente nada havia, predominando o perfeito vácuo, atualmente se entende que está preenchido pelo plasma¹ altamente condutor do Vento Solar no qual as linhas do campo magnético ficam “congeladas”. (3) A Terra, sua atmosfera superior e magnetosfera que, basicamente, são o alvo que têm que suportar toda a energia e materiais a ela direcionados. Há

Embora a interação Sol-Terra seja responsável por fenômenos como as inócuas auroras polares, ela também produz eventos que podem causar danos a tecnologia atual e, por conseguinte oferecer riscos as pessoas como as tempestades geomagnéticas. Tempestades geomagnéticas, quando muito intensas, podem causar a perda de sistemas de comunicação e navegação por várias horas e até mesmo severos blecautes. Apesar de todos os esforços de pesquisa empreendidos, a previsão do Clima Espacial permanece um desafio. A precisão e a confiabilidade

¹ O plasma é um gás de partículas carregadas, que consiste de um número igual de portadores de carga positiva e negativa. Ter, aproximadamente, o mesmo número de cargas com sinais diferentes no mesmo elemento de volume garante que o plasma se comporte como *quasineutro* no estado estacionário. (Baumjohann, W, Treumann, R. A., 1999)

das previsões, mesmo para eventos muito intensos de explosões solares e CMEs e suas consequências para Terra, permanecem ruins. Em parte, pelo fato de a física por trás destes eventos ainda não ter sido completamente entendida e em parte devido a limitações instrumentais.

2.1 O Sol como fonte energética do Geoespaço.

A astrofísica classifica o Sol como uma estrela de tamanho, temperatura e brilho médios, uma típica estrela que acabou de passar da meia idade. Popularmente foi apelidado de “astro-rei”. É interessante perceber que pela denominação escolhida sua importância jamais foi subestimada, mas que ao contrário várias culturas chegaram mesmo a adorá-lo, sendo que algumas ainda o adoram, considerando-o uma deidade. Apesar de todo o fascínio e curiosidade que despertou a seu respeito, apenas recentemente com o advento dos satélites e naves capazes de ir além da atmosfera terrestre, se pôde começar a estudar com maior minúcia a natureza do Sol; ainda assim muitas questões persistem sem respostas convincentes.

Graças a sua proximidade com a Terra, o Sol é a única estrela da qual se obteve uma quantidade tão significativa de informação, de tal forma que é bem aceito que ele teve sua origem a $4,5 \times 10^9$ anos que também é, aproximadamente, o tempo que resta antes que se torne uma gigante vermelha. Na presente data o Sol é basicamente composto por hidrogênio e hélio, mas também se encontram traços de elementos mais pesados tal como carbono, magnésio, cálcio, ferro, neônio, oxigênio, níquel, argônio e enxofre. Nele existe uma disputa entre as forças fundamentais da natureza: a atração da gravidade se opõe a força expansiva das reações nucleares mediadas pela ação da força eletromagnética. Sua estrutura interna pode ser resumida em três camadas principais, que podem ser vistas na Figura 2.1: o núcleo, a camada radiativa e a camada convectiva.

No centro, ocupando um quarto do raio solar², o **núcleo** tem uma temperatura em torno de $1,4 \times 10^7$ K (Rockenbach, 2010). De modo muito sucinto, nas condições de temperatura e pressão do núcleo do Sol, os núcleos atômicos (prótons fundamentalmente, dada a composição básica do Sol) e elétrons se movem em

² O raio solar equivale a aproximadamente $6,96 \times 10^8$ m. (Stix, 2004),

altíssimas velocidades pelo plasma, tão altas que quando uma colisão entre dois prótons ocorre, a interação coulombiana é superada e a força nuclear forte assume, unindo as partículas e criando o núcleo de um novo elemento, o hélio. Este é o processo de fusão nuclear, e é responsável por produzir uma quantidade enorme de energia.




Figura 2.1 - Ilustração artística das camadas do Sol e algumas estruturas solares.
Fonte: Modificado de http://msal.com/images/science_layers_of_sun.jpg (2012).

Após ser produzida no núcleo solar, essa energia passa a se mover em direção ao exterior do Sol, em um movimento que pode levar de 100 mil a um milhão de anos. Na **zona radiativa** essa energia, na forma de fótons, passa por sucessivos processos de absorção e remissão, fazendo que a temperatura baixe ao longo da camada. Há ainda, envolvendo a zona radiativa, uma camada com espessura de cerca de 1% do raio solar chamada **tacoclina** a partir da qual passa a haver fluxo de material. Supõe-se que é a súbita variação de velocidade nessa área, que por meio de um processo dinâmico, produz o campo magnético solar (Silva, 2006).

Acima da zona radiativa está a **zona convectiva** que se estende de 0,75 a aproximadamente 1 raio solar. Nela, a temperatura diminui o suficiente para que haja a produção de íons de hidrogênio, carbono, nitrogênio, oxigênio e ferro, que fazem com que a radiação deixe de ser o processo mais significativo no transporte da energia, dando lugar a convecção, assim o plasma das regiões inferiores e mais quentes dessa camada sobe em direção à superfície, enquanto o plasma mais frio próximo a superfície desce, dando origem a enormes células convectivas que podem ser observadas por meio dos grânulos vistos na fotosfera (Silva, 2006). É importante notar que, a circulação convectiva do plasma interfere no campo magnético desempenhando um papel importantíssimo para a compreensão dos flares e das manchas solares.

Sobre a zona convectiva encontra-se o que se considera como a atmosfera solar, cuja parte mais inferior é a **fotosfera**, responsável pela maior parte da radiação visível emitida. Por vezes, linhas de campo magnético irrompem nesta camada, produzindo o que se convencionou chamar de manchas solares. A concentração destes campos magnéticos intensificados criam regiões mais frias e escuras que foram percebidas a olho nu desde a antiguidade. Além da fotosfera está a **cromosfera**, melhor observada na faixa de radiação do H α . Nela também se forma um padrão convectivo por meio do qual jatos de material são expelidos na forma de estruturas denominadas espículas. Por fim, logo acima da cromosfera está a **coroa**, cuja parte mais interna pode ser vista como o fino halo ao redor do Sol, observado por ocasião de um eclipse solar total e é composta pelo material aprisionado pelo campo magnético do Sol (Silva, 2006). Material solar escapa continuamente do Sol, apesar da ação inibidora de sua intensa gravidade. Nas regiões onde as linhas de campo magnético são fechadas o material escapa mais lentamente do que nas regiões onde as linhas são consideradas abertas. O material que escapa é conhecido como **Vento Solar**.

O Sol, tal como a Terra, possui um movimento rotacional ao redor de seu eixo, porém sua constituição é fluida e seu período de rotação varia em função da latitude sendo que, a parte equatorial completa uma volta em um intervalo de tempo menor que as regiões próximas aos pólos. A interação entre a dinâmica e o eletromagnetismo do Sol, faz com que ele alterne entre períodos calmos e de

intensa atividade magnética em um ciclo médio de onze anos que culmina por inverter a polaridade do campo magnético global do Sol.

Em geral os eventos observáveis produzidos pelo Sol possuem grandezas físicas de magnitudes consideráveis, mas tendo em vista os efeitos exercidos sobre o Clima Espacial, três classes de eventos se destacam em importância, por transmitirem energia e/ou matéria ao espaço interplanetário e à Terra:

- **Explosões Solares (“Flares”):** Emissões repentinas de radiação com amplo espectro de frequência, que varia das ondas de rádio até os raios gama. Significantes ao clima espacial, pois são capazes de aquecer a atmosfera superior da Terra em poucos minutos, alterando sua densidade e modificando o arrasto de satélites que orbitam nessa área, o que faz com que decaiam pra órbitas mais baixas. (Schwenn, 2006)
- **Partículas Energéticas Solares (“Solar Energetic Particles” - SEPs):** Partículas aceleradas a velocidades quase relativísticas durante explosões solares, chegam à órbita terrestre em questão de minutos e representam um sério perigo tanto a astronautas em órbita quanto a instrumentos de satélites que não estejam sob a proteção do campo geomagnético (Rockenbach, 2010).
- **Ejeções de Massa Coronal (“Coronal Mass Ejections” - CMEs):** Intensas liberações de matéria solar na forma de gigantescas nuvens de gás ionizado, podem atingir a Terra no período de alguns dias e produzir, dentre vários efeitos, tempestades geomagnéticas e assim como os SEPs, fazem parte do meio material que permeia a região interplanetária.

2.2 Espaço Interplanetário e o Vento Solar

Se o Sol é a principal fonte energética do Clima Espacial, o espaço interplanetário é a região pela qual a energia deve se propagar para sustentar os fenômenos essenciais para determinação das condições climáticas. Essa região que, antes da década de 1950 era interpretada como uma imensidão vazia, hoje, sabe-se ser preenchida por um plasma de baixa densidade, que se expande da coroa solar para áreas muito além da Terra: o Vento Solar.

A tabela 2.1 sumariza algumas das propriedades físicas do plasma e do campo magnético do Vento Solar a distância de 1 unidade astronômica³ do Sol.

Tabela 2.1 – Propriedades físicas observadas do Vento Solar próximo a órbita da Terra .
Fonte: Kivelson e Russell (1995).

Densidade de Prótons	6,6 cm ⁻³
Densidade de Elétrons	7,1 cm ⁻³
Densidade de He ²⁺	0,25 cm ⁻³
Velocidade de Fluxo (quase radial)	450 Km.s ⁻¹
Temperatura Protônica	1,2×10 ⁵ K
Temperatura Eletrônica	1,4×10 ⁵ K
Campo Magnético (Indução)	7×10 ⁻⁹ T

A compreensão do sistema do Vento Solar é muito mais fundamentada em observações terrestres de longo termo do que em estruturas analítico-teóricas. Possivelmente, pois ainda há uma limitação na quantidade de dados obtidos nas proximidades do Sol. O mesmo não ocorre para informações provenientes das circunvizinhanças da Terra, que são muito abundantes. Há informações o suficiente para que sejam, até mesmo, disponibilizadas ao público pelos institutos de pesquisa.

Este é o caso das medições feitas pelos instrumentos a bordo do satélite ACE (disponíveis ao acesso público no endereço http://www.srl.caltech.edu/ACE/ASC/level2/lvl2DATA_MAG.html, acesso em 14 de Abril de 2012) que são parte dos dados utilizados nesta pesquisa e como o momento e a posição nos quais os dados foram obtidos podem afetar significativamente as conclusões deste trabalho, optou-se por dividir a revisão teórica do meio interplanetário em dois tópicos distintos: Primeiramente discutir-se-á a distribuição espacial do Vento Solar e do IMF pela região interplanetária para, em seguida, discutir a maneira pela qual tipicamente ocorre a variação temporal, tanto de longo quanto de curto termo, para estes dois elementos. Contudo, deve-se manter em mente que a distribuição espacial e a variação temporal estão profundamente interligadas e é impossível dissertar sobre uma sem que ao menos rápidas referências sobre a outra surjam.

³ A Unidade Astronômica ("Astronomical Unit" – AU) equivale a distância média entre o Sol e a órbita da Terra, ou seja, 1,5×10¹¹ m (Kivelson, Russell, 1995)

2.2.1 Distribuição Espacial do Meio Interplanetário

Ainda que se considere o profundo poço de potencial gravitacional produzido pela imensa massa solar, as altas temperaturas e a pressão de radiação fazem com que uma parcela do material solar atinja velocidades capazes de abandonar esse poço e produzir o Vento Solar. A geometria magnética do Sol varia severamente em função do tempo e o modelo vigente é mais bem compreendido quando analisado em períodos de baixa atividade solar. Em posições de baixa latitude, as linhas do campo magnético são mais comumente fechadas e com magnitude suficiente para, juntamente com a atração gravitacional, reter a maior parte do plasma em suas imediações fazendo com que o pouco material que escape fique com uma velocidade de fluxo relativamente baixa, formando o Vento Solar lento. Nas regiões próximas aos pólos, as linhas de campo se estendem para o exterior que podem ser consideradas abertas. O material nesta região pode fluir em uma velocidade superior para o meio interplanetário produzindo o Vento Solar rápido. De fato, em períodos em que a atividade solar é mínima, é possível perceber claramente as regiões do Sol onde as linhas estão abertas, pois são caracterizadas por uma região escurecida próxima ao polos conhecidas como *buracos coronais* (Longcope, 2005).

O Vento Solar constitui um tênue plasma constituído de íons e elétrons fluindo a partir do Sol (Schwenn, 2006) e por consequência direta da lei de Faraday o campo magnético interplanetário permanece congelado no plasma do Vento Solar sendo carregado, dobrado e torcido por ele. Como os hemisférios solares possuem polaridade magnética oposta, na região equatorial solar, surge uma corrente elétrica que divide o meio interplanetário em dois setores. Essa lâmina delimitadora é denominada *folha ou lâmina de corrente heliosférica* (“Heliospheric Current Sheet” - HCS) e é descrita por Schatten (1971) como uma “descontinuidade tangencial que separa dois plasmas com campo magnético antiparalelos”. Uma representação artística pode ser observada na Figura 2.2.




Figura 2.2 - Representação esquemática da folha ou lâmina de corrente heliosférica (HCS).
Fonte: Modificado de http://wind.nasa.gov/mfi/hcs/smith_cartoon.gif (2009)

O Sol rotaciona sobre seu eixo enquanto ejeta o Vento Solar no qual o IMF está congelado fazendo com que as linhas de campo assumam a forma de espirais arquimedianas denominadas *espirais de Parker* em homenagem a seu primeiro propositor. Outro fator a se considerar é de que o eixo magnético do Sol não está alinhado ao eixo de rotação, o que faz com que a lâmina de corrente heliosférica tenha um movimento de precessão. Ao traçar a geometria do meio interplanetário considerando todos os fatores anteriores, a HCS fica similar ao formato da saia de uma bailarina rodopiando, modelo primeiramente proposto por Alfvén (1977) e propriamente denominado como *modelo de saia de bailarina*.

O Vento Solar rápido comprime mais intensamente o Vento Solar lento conforme se afasta do Sol. Como consequência se formam estruturas, que em condições suficientemente estáveis, que corrotacionam com o Sol e portanto são chamadas de *regiões de interação corrotante* (“corotating interaction regions” – CIR) (Schwenn, 2006). Essas regiões produzem distúrbios geomagnéticos e também afetam a contagem de raios cósmicos no meio interplanetário (Rockenbach et al, 2004). Uma representação artística da geometria do meio interplanetário até a órbita terrestre, com destaque para o modelo de saia de bailarina e as CIRs pode ser visto na Figura 2.3.




Figura 2.3 - Modelo de saia de bailarina, esquema 3D do IMF e da HCS até as proximidades da órbita terrestre. Fonte: Schewenn 2006.

2.2.2 Variação Temporal

A descrição espacial apresentada no tópico anterior não é estática, mas ao contrário, muito dinâmica e variável. Embora as estruturas observadas nas regiões interplanetárias sejam recorrentes, suas características podem sofrer severas mudanças de um período para o outro, produzindo condições climáticas espaciais muito diversas. Como se pôde observar pela descrição espacial, os elementos do meio interplanetário e do IMF, bem como das condições que os influenciam, são oriundos do Sol, então é lógico assumir que a variação temporal destes também é extremamente dependente da variação temporal do Sol.

Alguns registros das atividades e estruturas solares têm milênios, mas registros científicos e detalhados, no rigor do termo, datam de apenas poucas centenas de anos e algumas extrapolações podem ser feitas com base em dados obtidos na própria Terra por meio de amostras do gelo polar, anéis de árvores e ^{14}C (Rigozzo; Nordemann, 1998). Atualmente a tecnologia enviada ao espaço permite que se obtenha uma quantidade muito maior de dados de alta precisão, já que são obtidos livres dos diversos elementos complicadores das medições terrestres. Dos eventos temporais de longo termo que acontecem no Sol, se destacam em significância para o meio interplanetário: o ciclo de atividade de 11 anos e o ciclo magnético de 22 anos.

De modo geral, o ciclo de atividade solar é definido por duas épocas distintas: o período solar calmo, quando a atividade está em seu **mínimo** com eventos como explosões solares e CMEs sendo raros e isolados com o perfil magnético global do Sol muito bem representado por um dipolo magnético. Este perfil, no entanto, evolui para outro período no qual a atividade solar é **máxima**, quando eventos de liberação de massa e energia são frequentes e o campo magnético solar tem uma aparência muito mais caótica (Babcock, 1961). As **manchas solares**, áreas onde o magnetismo local se torna forte o suficiente para criar uma região escura na brilhante fotosfera são excelentes indicadores do processo de passagem do período calmo para o período ativo tanto por sua contagem numérica quanto por sua posição latitudinal. No período calmo, as manchas são poucas e ocorrem preferencialmente próximas aos polos. Com o decorrer do tempo o número de manchas aumenta e elas convergem para áreas de menor latitude indicando a intensificação da atividade solar como descrito por Jones et al, 2010. Dados observacionais podem resultar em diagramas como mostrado na Figura 2.4, que ilustra o *diagrama de Maunder* (ou diagrama de borboleta) indicando a latitude das manchas no disco solar, e o diagrama do número de manchas no qual o início e fim de cada ciclo pode ser percebido claramente (na presente data vivencia-se o início do 24º ciclo solar).

A maneira pela qual o ciclo de atividade solar afeta o meio interplanetário é bastante evidente: durante épocas de mínimo, o Vento Solar apresenta características relativamente bem estáveis e regulares, quando eventos recorrentes são mais numerosos, enquanto um comportamento muito mais desordenado pode ser observado em épocas de máximo, quando eventos temporais de curto termo são mais frequentes e intensos.




Figura 2.4 - No gráfico superior, o diagrama de Maunder. No gráfico inferior, a média mensal do número de manchas solares no mesmo período. Fonte: Modificado de http://solarscience.msfc.nasa.gov/images/Zurich_Color_Small.jpg e <http://solarscience.msfc.nasa.gov/images/bfly.gif>. 14 de abril de 2012.

Sob estas condições, a contagem de raios cósmicos que atinge a Terra varia uma vez que eles são partículas eletricamente carregadas que atravessam o meio interplanetário permeado pelo plasma de que é composto o Vento Solar, e no qual o IMF está congelado. Dados observacionais demonstram que a contagem de raios cósmicos e o ciclo de atividade solar estão inversamente relacionados, de modo que o máximo de um ocorre quando o outro está em seu mínimo, o que pode ser visto na Figura 2.5, onde o gráfico do número de manchas solares está no painel superior e o gráfico das contagens de raios cósmicos galácticos no painel inferior.




Figura 2.5 - Diagrama comparativo do ciclo de atividade solar (acima) e da média mensal da contagem de raios cósmicos (abaixo), no qual a interferência do IMF sobre os raios cósmicos pode ser percebida. Modificado de: <http://neutronm.bartol.udel.edu/~pyle/modplotM.png>

Em períodos de pouca atividade, o campo magnético global do Sol tem um modelo de quase dipolo, porém esta configuração muda no decorrer do ciclo de 11 anos. De um ciclo de 11 anos para outro, o campo magnético solar tem sua polaridade invertida, formando um ciclo magnético do Sol que dura algo em torno de 22 anos, tempo necessário para que logo que estabelecido um modelo de dipolo o Sol retorne a ele (Babcock, 1961). As linhas do campo interplanetário separadas pela HCS acompanham essas alterações, mudando de orientação para acompanhar os hemisférios do Sol, o que também afeta a contagem de raios cósmicos de maneira perceptível. Observando a Figura 2.5, percebe-se que picos mais agudos se intercalam com picos mais chatos na contagem de raios cósmicos, situação explicada pelo modelo de deriva tridimensional estabelecido por Kóta e Jokipii (1983) o qual demonstra que a polaridade define a trajetória percorrida pelos raios cósmicos que assim são mais ou menos afetados pelas ondulações na HCS.

Outras estruturas liberadas pelo Sol para o meio interplanetário, tais como as ICMEs, também são responsáveis por alterações relevantes, mas sua ocorrência não tem uma periodicidade estabelecida entre eles, embora se saiba que ocorram

mais comumente em épocas de máximo solar. A maneira que estas estruturas afetam os raios cósmicos será discutida de forma detalhada no Capítulo 3.

2.3 A Terra e o Campo Geomagnético

A Terra se diferencia dos outros planetas conhecidos de muitos modos, mas dentre todas as suas singularidades, o fato dela suportar uma variedade enorme de formas de vida a torna realmente única. Uma combinação muito específica de condições ambientais tem que se sustentar para que não apenas os seres vivos existam, mas também possam evoluir para seres complexos capazes de modificar seu meio ambiente de forma inclusive consciente. Contudo, o ambiente terrestre não é autônomo, mas extremamente dependente de elementos e eventos que estão e ocorrem fora de seus limites, sendo que alguns desses agentes trazem consigo sérias ameaças à vida que permitem existir. Por isso é tão importante estudar, entender e monitorar as condições ambientais do *Geoespaço*, ou seja, o *Clima Espacial*.

Um dos elementos que permite a existência de vida, e que garante o bem estar da tecnologia humana é a condição do planeta de possuir um campo magnético global com perfil de *quasi* dipolo. A presença deste campo produz um campo magnético, que pode ser entendido como uma cavidade no Vento Solar formada pela interação deste e do IMF nele congelado com o campo magnético intrínseco ou da atmosfera superior ionizada de um corpo planetário (Pulkkinen, 2007).

No caso da Terra, predomina claramente a ação do campo magnético intrínseco que tem módulo de 50000 nT em regiões polares e cerca de 30000 nT para pequenas latitudes. No entanto a *corrente de anel*, que consiste tipicamente de íons aprisionados no campo magnético com energias que vão de algumas dezenas de keV até várias centenas de keV, também contribui na cavidade magnetosférica, principalmente em épocas de intensa atividade geomagnética.

O tamanho da cavidade depende de um delicado equilíbrio entre o Vento Solar, o plasma magnetosférico, o IMF e o campo geomagnético, de forma que a região onde este equilíbrio se estabelece é chamada *magnetopausa* (Russel, 2012). Em épocas de baixa atividade solar, na parte da magnetosfera voltada para o Sol, a magnetopausa está situada a aproximadamente 10 R_T da Terra (R_T equivale a um

raio terrestre, ou seja, cerca de 6370 km), mas pode ser empurrada até o interior da órbita geoestacionária ficando a $6,6 R_T$ em épocas de grande atividade. Do outro lado, na parte noturna, o Vento Solar deforma o campo de dipolo fazendo com que a cavidade assuma a forma de uma cauda de cometa, onde a magnetopausa está, em média, $30 R_T$ distante da Terra, com a cauda em si se estendendo por algumas centenas de R_T . Não obstante, a velocidade do Vento Solar é superior as velocidades características do plasma magnetosférico e assim uma frente de choque se forma na frente da magnetopausa, criando uma onda de choque chamada “*Bow Shock*” e uma bainha magnética (*magnetosheath*) entre esse choque e o campo geomagnético, que diminui o fluxo do Vento Solar. Uma representação dessas estruturas componentes da magnetosfera pode ser vista na Figura 2.6.

É importante entender que o Vento Solar é capaz de transferir energia para a magnetosfera através do processo de *reconexão magnética* que ocorre entre o campo magnético interplanetário e o campo geomagnético. A reconexão magnética acontece “quando dois campos magnéticos anti-paralelos se aproximam, havendo uma interconexão entre as linhas destes campos magnéticos” (Gonzalez et al, 1994). Se uma quantidade muito grande de energia passa do Vento Solar para a magnetosfera, devido a uma estrutura, como por exemplo uma ejeção de massa coronal interplanetária (ICME), a Terra fica sujeita a uma *tempestade geomagnética*.




Figura 2.6 - Estrutura da magnetosfera terrestre. Modificado de: <http://image.gsfc.nasa.gov/poetry/magnetism/magnetosphere3.gif>

2.3.1. Tempestades Geomagnéticas

Para discutir as tempestades geomagnéticas é conveniente adotar o sistema de coordenadas **GSM** (*Geocentric Solar Magnetospheric*), que consiste de um espaço tridimensional cartesiano no qual o eixo X tem a direção determinada pela reta que liga o Sol a Terra com sentido da Terra em direção ao Sol, o eixo Z é uma projeção do eixo dipolo magnético da Terra com o positivo apontando para o norte, por fim o eixo Y completa a regra da mão direita. O índice **Dst** (*Disturbance Storm Time*) mede a magnitude de uma tempestade geomagnética através do campo magnético produzido pela corrente de anel que é intensificada pela ação da tempestade. Como este campo tem orientação contrária à componente horizontal do campo geomagnético, a interação entre ambas causa um decréscimo no módulo da componente horizontal, e desta forma considera-se o índice Dst negativo. Também usar-se-á o mesmo sistema de classificação de tempestades geomagnéticas usado por Rockenbach (2010), indicado na Tabela 2.2.

As estruturas que o Sol produz em direção a Terra podem ou não ser *geofetivas*, isto é, capazes de gerar tempestades geomagnéticas. As principais condições para que isso ocorra foram estabelecidas por Gonzalez e Tsurutani (1987) que empiricamente determinaram a componente B_z do campo magnético interplanetário como o elemento mais importante na ocorrência de reconexão magnética, já que se percebeu que se esta componente for negativa, de acordo com o sistema de coordenadas GSM, e com magnitude suficientemente grande durante um intervalo de tempo maior que três horas, tempestades magnéticas intensas, ou seja, $Dst < -100$ nT, são observadas na Terra.

Tabela 2.2 – Classificação da Intensidade das Tempestades Geomagnéticas de acordo com o índice Dst. Fonte: Rockenbach (2010).

Tempestades Moderadas	$-50 \text{ nT} > Dst > -100 \text{ nT}$
Tempestades Intensas	$-100 \text{ nT} > Dst > -250 \text{ nT}$
Tempestades Super Intensas	$Dst < -250 \text{ nT}$

O modelo mais aceito para explicar o fenômeno demonstra que o fato do campo geomagnético estar orientado no sentido positivo de z e, portanto contrário a componente B_z do IMF, causa a reconexão magnética que permite a entrada de partículas do Vento Solar no campo magnético terrestre. Este processo é regido pelo

campo elétrico $\mathbf{E}$, oriundo da relação $\mathbf{E} = \mathbf{v} \times \mathbf{B}_s$, onde $\mathbf{v}$ é a velocidade do Vento Solar e $\mathbf{B}_s$ é a componente z negativa do campo magnético, que nas condições sugeridas, produz uma corrente elétrica de convecção orientada no sentido negativo do eixo y com intensidade superior a 5 mV/m (Gonzalez; Tsurutani, 1987). Para penetrar na magnetosfera da Terra as partículas do Vento Solar dependem da interação entre as linhas do IMF e do campo magnético da Terra que após estarem interconectadas no lado diurno, em uma primeira reconexão magnética, são arrastadas e deformadas pelo Vento Solar pois se encontram congeladas nele. Com isso, já no lado noturno, essas linhas se tornam novamente antiparalelas, o que ocasiona uma nova reconexão com a magnetosfera terrestre na qual, por fim, as partículas precipitam ao longo do campo geomagnético, produzindo as auroras polares e intensificando a corrente de anel dentre outros efeitos (Gonzalez et al., 1994). Uma representação esquemática do processo pode ser vista na Figura 2.7.




Figura 2.7 - Região de acoplamento entre o IMF e a magnetosfera terrestre. Modificado de Gonzalez e Tsurutani (1992).

Através da variação temporal do índice Dst é possível discernir as fases pelas quais passa uma tempestade geomagnética. A Figura 2.8 mostra o gráfico que

indica como o índice Dst varia durante a ocorrência de uma tempestade geomagnética ocorrida em 2001⁴.




Figura 2.8 – Gráfico do índice Dst mostrando as fases de uma tempestade geomagnética. A área I destacada no gráfico é referente a fase inicial da tempestade, a região II se refere a fase principal e por fim a região III se refere a a fase de recuperação da tempestade magnética.

Anunciando a tempestade, pode-se perceber um aumento no valor do índice causado pelo incremento da componente horizontal do campo magnético pressionado pela estrutura em colisão. Este momento está ilustrado na região I do gráfico, é a fase inicial da tempestade conhecida como *início súbito da tempestade* (*Storm Sudden Commencement – SSC*) e pode durar de alguns minutos até várias horas, todavia essa fase nem sempre está presente (Gonzalez et al., 1994). Segue-se uma abrupta queda no valor do índice, uma vez que, graças aos processos de reconexão magnética, há mais partículas na corrente de anel que, desta maneira, fica mais intensa e produz um campo magnético de polaridade oposta ao que previamente existia. Esta é a *fase principal* da tempestade, através dela obtemos a classificação do evento na tabela 2.1, costuma durar de meia hora até algumas horas e pode ser visualizada na região II do gráfico da Figura 2.8. Finalmente, as partículas excedentes começam lentamente a interagir com a atmosfera, e com a perda delas a corrente de anel diminui, bem como o campo magnético por ela produzido, inicia-se a *fase de recuperação* que pode ser observada na região III do

⁴ Dados obtidos de: http://wdc.kugi.kyoto-u.ac.jp/dst_final/200612/index.html. Acesso em: 01 de dezembro 2012.

gráfico. Sua duração se estende de algumas dezenas de horas até semanas, tempo para que o campo geomagnético retorne às condições anteriores a tempestade. Não é incomum que outra tempestade principie ainda nesse intervalo de tempo.

3. RAIOS CÓSMICOS

Raios cósmicos podem ser definidos, num sentido amplo, como partículas energéticas que chegam a Terra de qualquer lugar além da atmosfera e são fonte de radiação ionizante em toda superfície do planeta (Cronin, 1999). Sua intensidade medida na superfície da Terra varia com a latitude geomagnética, a altitude e o ciclo de atividade solar. O título de “raios” cósmicos é, no mínimo, capcioso uma vez que consiste principalmente partículas, porém interpretações mais abrangentes podem considerar raios gama e neutrinos também como raios cósmicos. Sua descoberta foi atribuída a Victor Hess, que em 1912 buscava entender as evidências de radiação dentro de uma câmara de íons vazia e muito bem isolada. Primeiro se acreditou que a radiação tinha origem terrestre, mas experimentos com um balões que afastavam a câmara várias centenas de metros acima do solo, demonstrou que a radiação era mesmo de origem extraterrestre, uma vez que o registros de radioatividade intensificavam-se ao invés de decair. (Cronin, 1999).

Para energias abaixo de uma centena de GeV sabe-se que os raios cósmicos são compostos principalmente de prótons (92%), partículas α (6%), núcleos pesados (1%), elétrons (1%) e raios γ (0,1%). Na faixa energética entre 10^{11} eV e 10^{13} eV, as quantidades relativas mudam para 50% de prótons, 25% partículas α , 13% pelo grupo constituído de carbono, oxigênio e nitrogênio e 13% de ferro. Acima destas energias, medidas diretas e indiretas começam a divergir e quanto maior o fluxo energético menor o fluxo de partículas tornando qualquer conclusão sobre a composição da componente primária muito difícil (Paganini, 2001). O estudo e a compreensão dos raios cósmicos são de grande relevância, encontrando aplicações como a datação com C^{14} utilizada por arqueólogos. A própria física das partículas tem sua origem ligada aos raios cósmicos, já que antes do advento dos aceleradores de partículas modernos o único modo de observar partículas tão energéticas era através da observação *in natura*. Na astrofísica são ainda mais importantes, pois trazem informações de sua fonte que pode estar tanto no sistema solar quanto em um ponto muito distante desta galáxia ou mesmo fora dela.

3.1. Origem dos raios cósmicos

Por se tratarem de partículas eletricamente carregadas, a trajetória dos raios cósmicos é dependente da interação eletromagnética que sofrem no meio interestelar desde sua origem até o momento de sua observação. Uma das maneiras de estabelecer a origem das partículas é analisar seu espectro de energia. Deduções podem ser feitas através de sua isotropia e constância. Paganini (2001) estabelece o fluxo diferencial destas partículas pela equação:

$$\frac{dN}{dE} \propto E^{-\gamma} \quad (3.1)$$

onde γ é a principal característica do espectro denominada índice espectral (Mursula; Usoskin, 2003). Na prática a Equação 3.1 implica que a contagem de partículas acima de uma dada energia decai por um fator de 100 para cada década na energia, ou seja, o fluxo de raios cósmicos é cerca de 1 por centímetro quadrado a cada segundo na faixa de 100 MeV, mas de apenas 1 a cada quilômetro quadrado por século na faixa de 10^{20} eV (Cronin, 1999).

A partir dessas considerações é possível concluir que a maior parte do espectro de raios cósmicos tem sua origem fora do sistema solar, sendo portanto chamados de raios cósmicos galácticos, uma vez que os corpos que preenchem os requisitos energéticos para produzi-los são estrelas de nêutrons e supernovas. Para energias abaixo de 10^9 eV começam a surgir os *raios cósmicos solares* (SCR – “*Solar Cosmic Rays*”), que como o nome indica tem sua origem no Sol. Contudo na faixa de espectro de energia da ordem de algumas centenas de MeV os SCR compõem a maior parte do fluxo de raios cósmico. A Figura 3.1 mostra que a maior parte do fluxo de raios cósmicos está acima de 1 GeV, o que faz dos GCRs os principais componentes dos raios cósmicos. A Figura 3.1 destaca dois pontos relevantes no espectro de raios cósmicos: o joelho e o tornozelo. Supõem-se que a mudança na inclinação no perfil do espectro de raios cósmicos percebida após o joelho e em seguida ao tornozelo deva-se a mudança no mecanismo de aceleração destes raios cósmicos.

Não obstante, desde a década de 1960 são observados raios cósmicos cuja energia chega a 10^{20} eV, valor que desafia até hoje explicações científicas. Como

base de comparação, deve se manter em mente que o acelerador Tevatron no Fermilab, um dos mais poderosos do mundo, consegue acelerar prótons até uma energia de 10^{12} eV (Cronin, 1999). Para justificar acelerações superiores de modo a obter energias acima de 10^{19} eV, a literatura começa a ficar especulativa e alguns autores chegam a postular explicações alternativas, como defeitos no tecido do espaço-tempo que ao liberar energia o faria na forma de partículas ultra energéticas (Bhattacharjee, Hill e Schramm, 1992).




Figura 3.1 - Espectro de raios cósmicos superiores a 100 MeV. Modificado de Cronin, 1999.

3.2. Modelagem de Raios cósmicos

A observação de raios cósmicos em detectores terrestres tem uma pobre relação com os dados que seriam obtidos se os detectores estivessem nos limites externos da heliosfera, pois o Vento Solar e o IMF discutidos no capítulo anterior interferem na dinâmica dos raios cósmicos. Para explicar o transporte de partículas de raios cósmicos na heliosfera, Parker (1965) sintetizou os quatro principais processos em uma equação que leva seu nome. Esta é dada por:

$$\frac{\partial f}{\partial t} = -\mathbf{V} \cdot \nabla f - \langle \mathbf{v}_D \rangle \cdot \nabla f + \nabla \cdot (k^{(S)} \cdot \nabla f) + \frac{1}{3} (\nabla \cdot \mathbf{V}) \times \frac{\partial f}{\partial \ln P} + J_{fonte} \quad (3.2)$$

sendo $f(\mathbf{r}, P, t)$ é a função de distribuição dos raios cósmicos onde $\mathbf{r}$ é a posição, t é o tempo e $P = pc/q$ é a rigidez magnética da partícula, na qual p é o momento da partícula, q é a carga elétrica e c é a velocidade da luz. $\mathbf{V}$ é a velocidade do Vento Solar. k é o tensor de difusão que pode ser separado em uma parte simétrica, $k^{(S)}$, e outra anti-simétrica, $k^{(A)}$. Temos que:

- $\frac{\partial f}{\partial t}$ indica a variação da função distribuição em relação ao tempo e para muitos modelos nos quais se considera as partículas em equilíbrio pode ser aproximado a zero;
- $-\mathbf{V} \cdot \nabla f$ está ligado ao processo convectivo que surge devido as irregularidades do campo magnético congelado no Vento Solar que produz um gradiente de partículas direcionado para fora da heliosfera (Jokipii, 1971);
- $\langle \mathbf{v}_D \rangle \cdot \nabla f$ relaciona-se com a deriva das partículas, tanto devido a curvatura quanto ao gradiente, do *campo magnético heliosférico (HMF – “Heliospheric Magnetic Field”)* de geometria geralmente aceita como esférica;
- O termo, $\nabla \cdot (k^{(S)} \cdot \nabla f)$, descreve a difusão das partículas entre as irregularidades espalhadas no HMF, e para as quais normalmente se adota uma propagação heliocêntrica. O tensor k de difusão pode ser formulado por:

$$k = \begin{pmatrix} k_{\parallel} & 0 & 0 \\ 0 & k_{\perp} & k_T \\ 0 & -k_T & k_{\perp} \end{pmatrix} = k^{(S)} + k^{(A)} \quad (3.3)$$

Nele a parte simétrica é composta pelas componentes paralela ($k_{\parallel}$) e perpendicular ($k_{\perp}$) ao HMF, enquanto a parte anti-simétrica (k_T) está ligada ao vetor de deriva efetiva pela equação:

$$\langle \mathbf{v}_D \rangle = \nabla \times k^{(A)} \cdot \frac{\mathbf{B}}{B} \quad (3.4)$$

- $\frac{\partial f}{\partial \ln P}$ expressa a expansão adiabática do Vento Solar a medida que se afasta do Sol;
- J_{fonte} apenas diz respeito a fonte dos raios cósmicos.

Normalmente a Equação 3.2 é resolvida de modo numérico partindo das suposições do espectro de raios cósmicos na periferia mais afastada da heliosfera e muito embora seja usual aceita-la com uma geometria esférica de raio da ordem de 100 AU, já se mostrou que sua forma não é tão regular (Langner; Potgieter, 2005).

3.3 Anisotropias Recorrentes

São as características anisotrópicas das partículas de raios cósmicos que fornecem as pistas que permitem elaborar uma base teórica. Além das modulações recorrentes, discutidas na sessão anterior, devido à variação temporal/espacial da heliosfera, também é importante conhecer os fluxos anisotrópicos que surgem na forma de modulações diurnas, tanto do tempo solar quanto do tempo sideral, além do *decréscimo de Forbush* que é de especial interesse a este trabalho, pois é o mais

relacionado com a súbita e intensa variação das componentes do IMF e a variação da intensidade de raios cósmicos detectados na Terra.

A *anisotropia solar diurna* surge do fluxo de partículas paralelo ao plano equatorial do Sol e pode ser decomposta em duas componentes: uma tangente a órbita da Terra denominada *Anisotropia Leste-Oeste* e outra perpendicular a órbita, mas paralela à direção formada pela linha Sol-Terra chamada *Anisotropia radial*. Como está esquematizado na Figura 3.2, a anisotropia Leste-Oeste surge em decorrência do fato dos raios cósmicos serem empurrados pelas linhas do IMF em espiral que age como uma grande roda de pás. Assim os raios cósmicos ganham uma velocidade de algumas centenas de quilômetros por segundo se tornando mais rápidos que a Terra ao longo de sua órbita e a intensidade de raios incidentes a 90° Leste da linha Sol-Terra é aumentada enquanto a intensidade a 90° Oeste diminui, fazendo com que anisotropia Leste-Oeste sempre esteja no auge às 18:00 horas do dia solar local (Pomerantz, 1976). A anisotropia radial se deve ao movimento de




Figura 3.2 - Ilustração esquemática do processo causador da anisotropia diurna solar Leste-Oeste. Modificado de Pomerantz, 1976.

convecção das partículas causado pelas irregularidades do IMF que estando congelado no Vento Solar tem uma expansão heliocêntrica. Também está relacionada com a inversão da polaridade magnética solar no decorrer de seu ciclo de onze anos.

A *anisotropia diurna sideral* é uma decorrência da interação do IMF com o gradiente radial da densidade de raios cósmicos. A densidade de raios cósmicos na periferia da heliosfera é maior que a densidade próxima ao centro, portanto a quantidade de partículas que chegam a Terra de áreas externas a órbita do planeta é sempre maior que a quantidade vinda de áreas internas a órbita. Por se tratarem de partículas eletricamente carregadas se movendo pelo IMF, estão sujeitas a força de Lorentz cuja direção é perpendicular ao plano da eclíptica terrestre. O sentido que a força adquire é determinado pelo produto vetorial entre a velocidade da partícula e o IMF e, portanto depende da orientação de ambos, mas a orientação do IMF se reverte a cada onze anos acompanhando o ciclo magnético solar. Assim em determinadas épocas o influxo de partículas no hemisfério norte é maior que no hemisfério sul, enquanto em outras se dá exatamente o inverso (Hall et al,1995). A Figura 3.3 apresenta uma representação esquemática da descrição acima.




Figura 3.3 - Esquema da anisotropia Norte-Sul, onde G_r representa o vetor gradiente de densidade de raios cósmicos. Modificado de Hall et al., 1995.

3.4 O Decréscimo de Forbush

Das anisotropias transitórias dois tipos de decréscimos na intensidade de raios cósmicos são muito comuns: decréscimos recorrentes, cujo início é gradual, tem um perfil quase simétrico e normalmente estão associados a CIRs da heliosfera, e os decréscimos não recorrentes que começam subitamente e causam um profundo mínimo na contagem de raios seguido de uma lenta fase de recuperação. O gráfico indicativo da contagem horária percentual de nêutrons registrada no Monitor de

Nêutrons de Moscou⁵ em dezembro de 2006, é ilustrado pela Figura 3.4. Não é incomum, mesmo na literatura especializada, que se use a denominação *decréscimo de Forbush* para designar qualquer decréscimo de curto termo, mas se aplicada de forma mais rigorosa, apenas os decréscimos não recorrentes são adequados a ela (Cane, 2000) e é com isso em mente que se usará a designação neste texto.




Figura 3.4 - Decréscimo de Forbush registrado pelo Monitor de Neutrons de Moscou para o período de 14 a 18 de Dezembro de 2006.

Para explicar o mecanismo deve-se revisitar o que foi visto no capítulo anterior para discutir as CMEs e suas contrapartidas interplanetárias as ICMEs. Eventos como as ejeções de massa coronal, definidos de modo geral por de uma ocasional ejeção de plasma solar magnetizado, que após a erupção é guiado pela liberação da energia transportada pela advecção de campos magnéticos durante a CME (Subramanian, 2012). A CME se expande e propaga dando origem ao que se convencionou chamar ejeção de massa coronal interplanetária (*“Interplanetary Coronal Mass Ejection”* – ICME). Os indicadores da ocorrência de uma ICME são: queda na temperatura de prótons do plasma, fluxo bidirecional de partículas e intensos campos magnéticos, contudo nem todos os indicadores estão presentes em cada ICME, e na verdade quase sempre eles não se sobrepõem muito bem. Eles podem ou não estar acompanhadas de *nuvens magnéticas* (*Magnetic Clouds* – MC) que são basicamente ICMEs com certas propriedades específicas que permitem

⁵ Dados disponíveis em: <http://cr0.izmiran.rssi.ru/mosc/main.htm>. Acesso em: 05 de maio de 2012.

caracteriza-las como uma estrutura magnética cilíndrica livre de forças (Subramanian, 2012).

A velocidade de uma ICME normalmente supera a do Vento Solar que está indo no contra fluxo, e com isso se cria uma região de choque frontal na qual o Vento Solar é comprimido e aquecido, como está representado na ilustração da Figura 3.5 na qual as barras verticais marcadas com a letra **S** mostram o momento da passagem da região de choque e o intervalo entre T_1 e T_2 indicam o início e o fim da passagem da ICME pela Terra. Existem, por consequência, três possíveis tipos de decréscimo relacionados a uma ICME: (1) aqueles devidos apenas a região de choque, (2) os que se devem apenas pela própria ICME, (3) e os causados pelas duas estruturas (Cane, 2000). Este último tipo é o mais comum, representando cerca de 80% dos decréscimos observados e pode ser identificado por uma variação de 2 etapas, a primeira causada pela região de choque e a segunda devida a ação da ICME em si (Cane, 2000).




Figura 3.5 - Configuração de uma ICME e região de choque. Modificado de Cane, 2000.

A ICME e a região de choque comprimem o plasma a sua frente. Assumindo que o campo magnético está congelado no interior no plasma, a intensidade do campo magnético tem seu valor aumentado nas vizinhanças da região de choque. Conforme o choque passa pela Terra age como um escudo para a população de raios cósmicos no ambiente, desde que estes não consigam se difundir através do campo magnético ampliado. Isso leva a uma queda na intensidade de raios cósmicos quando a Terra está no interior da região de choque, que se manifesta

como parte do decréscimo de Forbush. Na verdade essa é uma descrição idealizada pois o campo magnético tem uma componente ordenada, tanto quanto uma turbulenta. O que acontece é que os raios cósmicos se espalham através do emaranhado e turbulento campo magnético, mas este processo é inibido nas vizinhanças da região de choque que tem uma componente magnética ordenada mais forte. Assim é a inabilidade das partículas de raios cósmicos de se difundir eficientemente na frente de choque que causa o decréscimo de Forbush.

Há ainda, mais um elemento a se considerar: é possível interpretar uma ICME como um recipiente de baixa densidade magnética que se expande e propaga pelo espaço interplanetário. O intenso campo magnético relativamente ordenado serve como paredes desse recipiente ao inibir o processo de difusão das partículas energéticas dos arredores. Como a ICME foi originada nas circunvizinhanças do Sol, onde a densidade de raios cósmicos é muito baixa é possível entender a queda na detecção de raios cósmicos quando a Terra encontra-se no interior desse recipiente.

Como tanto a contribuição da região de choque quanto a da ICME se baseiam na inibição do processo de difusão por campos magnéticos ordenados é de se esperar que as partículas mais energéticas sofram menos a ação do decréscimo e que sua variação seja mais suave.

3.5. Rede Global de Detectores de Múons.

As partículas de raios cósmicos detectadas na superfície da Terra não são as mesmas que viajaram pelo espaço interplanetário. Quando penetram no ambiente terrestre as partículas de raios cósmicos colidem e interagem com a matéria que compõe a atmosfera. Após o choque inicial da partícula primária uma série de combinações e recombinações ocorrem gerando o que se convencionou chamar de *chuveiro de partículas* (chuveiro cósmico) ilustrado esquematicamente na Figura 3.6. Os raios cósmicos que incidem na atmosfera, vindos do meio interplanetário são conhecidos como primários, enquanto as partículas menos energéticas, subprodutos da colisão inicial são os raios cósmicos secundários.




Figura 3.6 – Chuveiro de Partículas: Representação esquemática da produção de partículas quando uma partícula cósmica penetra na atmosfera. É possível notar que a componente muônica é a mais diretamente relacionada ao raio cósmico primário. Modificado de Grieder (2001).

Das diversas partículas geradas pela interação dos raios cósmicos primários com a atmosfera, os múons são de especial interesse. Eles resultam do decaimento dos mésons $\pi^\pm$ descobertos por Lattes et al (1947) e são uma componente penetrante o suficiente para atingir o solo, somado ao fato de serem produzidos nas fases iniciais do chuveiro, retendo uma quantidade maior de informação sobre a direção da partícula primária que o produziu. Os múons são partículas da família dos

léptons, estando, portanto sujeitos a ação das interações eletromagnéticas e nucleares fraca. Possuem massa $m_0 = 106 \text{ MeV}/c^2$ e seu tempo de vida é $\tau_0 = 2,19 \mu\text{s}$, no entanto graças a dilatação temporal relativística, não só atingem o solo mas chegam também ao subsolo terrestre. (Paganini, 2001).

Em 1992, os observatórios de Nagoya no Japão e Hobart na Austrália deram início à rede de detecção de múons, cada um convenientemente situado em hemisférios diferentes do planeta. No hemisfério norte o detector do Japão conta com uma área de observação de 36 m^2 enquanto, do outro lado do equador o australiano conta com uma área de 9 m^2 . Ambos os observatórios são multidirecionais, ou seja, é possível captar partículas vindas de 30 direções diferentes. Em março de 2001 foi integrado a rede um pequeno protótipo detector com área de 4 m^2 , instalado no Observatório Espacial do Sul, localizado em São Martinho da Serra, RS. O detector de São Martinho sofreu uma ampliação em dezembro de 2005, sua área de observação passou a 28 m^2 . Em agosto de 2012, o detector de São Martinho passou por uma nova ampliação, passando a ter 32 m^2 de área de detecção. E em março de 2006 a rede foi concluída com a instalação de um detector de área equivalente ao detector de Hobart, na Universidade do Kuwait passando a receber dados sobre todos os quadrantes do globo terrestre, passando a ser chamada de Rede Global de Detectores de Múons (“Global Muon Detector Network” – GMDN).

Nos observatórios de São Martinho, Nagoya e Hobart são utilizados o mesmo modelo de detector diferindo apenas pela área que cobrem. O modelo é constituído de duas camadas de plástico cintilador separadas por uma distância vertical de $1,73 \text{ m}$ e com uma camada de chumbo de 5 cm de espessura entre elas para filtrar componentes “moles”, isto é, menos energéticas (Okazaki, 2008). Em cada camada há um conjunto de detectores unitários constituídos de uma base quadrada de plástico cintilador de 1 m de lado, sobre a qual existe um tubo fotomultiplicador de $12,7 \text{ cm}$ de diâmetro (Rockenbach, 2010). Como esquematizado na Figura 3.7(A), é possível deduzir a direção de incidência do múon ao verificar qual par de detectores unitários foi atingido por ele: O intervalo de tempo decorrido entre a colisão com a camada superior e a camada inferior é tão ínfimo que ambos os detectores cintilam simultaneamente, e ao registrar quais detectores cintilaram o ângulo entre eles indica a direção na qual o múon se movia.




Figura 3.7 - (A) Esquema artístico de um detector de múons de duas camadas. (B) Detector de Múons montado no Observatório Espacial do Sul em São Martinho, RS, Brasil. Modificado de Rockenbach, 2010.

O modelo de detector instalado no Kuwait difere muito do modelo acima descrito sendo do tipo *hodoscope*. Ele é formado por quatro camadas horizontais de 30 *tubos contadores proporcionais* (“*Proportional Counter Tubes*”- PCT) e cada tubo por sua vez é um cilindro com de 10 cm de diâmetro no qual há um anodo de tungstênio de 50 micron de espessura, ao longo do eixo de simetria longitudinal. As camadas estão dispostas em dois pares, o par superior está afastado uma distância vertical de 80 cm do par inferior. Os eixos dos PCT de cada camada são perpendiculares entre si, na primeira e terceira camada a partir de cima os eixos estão alinhados na direção leste-oeste, enquanto na segunda e quarta camadas estão alinhados com a direção norte-sul. Acima do detector há uma camada de 5 cm de chumbo para reduzir a interferência de componentes moles. A detecção se dá por um sistema no qual o registro ocorre quando um múon é detectado simultaneamente em todas as camadas e a direção pode ser determinada pela comparação do ponto onde atravessou o par de camadas superior com o ponto pelo qual atravessou o par de camadas inferior. Do modo que foi construído esse detector tem 529 canais direcionais, mas para que seus dados possam ser aproveitados em conjunto com GMDN, o número de canais é convertido para apenas 13, o que torna o detector do Kuwait equivalente ao de Hobart na Austrália.

Uma representação dos dados obtidos pela GMDN está ilustrada nos painéis da Figura 3.8 que mostram o gráfico do desvio da média anual registrado para os

canais verticais dos detectores de Nagoya, Hobart, São Martinho e o Kuwait a cada hora do mês de dezembro de 2006.




Figura 3.8 – Desvio horário da média anual da contagem de múons medido pelos canais verticais de cada detector da GMDN. No primeiro painel a partir do topo, o traço em preto mostra o desvio para o canal vertical do detector instalado em Nagoya. No segundo painel o traço azul indica o desvio calculado a partir dos dados do canal vertical do detector de Hobart. No painel seguinte, o traço vermelho mostra o desvio indicado pelo canal vertical do detector de São Martinho, RS. No painel mais inferior o desvio da contagem média anual como calculado a partir das medições do canal vertical do detector instalado no Kuwait,

Os dados da contagem de múons produzidos pela GMDN estão disponíveis ao público nos endereços eletrônicos: ftp://ftp.bartol.udel.edu/takao/muon_data/⁶, e <http://www.stelab.nagoya-u.ac.jp/ste-www1/div3/muon/muon1.html>⁷.

3.6 Cálculo da Intensidade de Raios cósmicos Galácticos

Nagashima et al (1972) indicam um tratamento aprimorado por Okazaki (2008) e Rockenbach (2010) pelo qual através dos dados da GMDN é possível estabelecer a relação entre a distribuição de partículas primárias no meio interplanetário e os múons detectados em superfície utilizando na tarefa uma série de *coeficientes de acoplamento*. A fim de determinar estes coeficientes é preciso conhecer a *direção*

⁶ Acesso em 01 de dezembro de 2012

⁷ Acesso em 01 de dezembro de 2012

assimptótica para cada direção de incidência possível dos múons observados pelos detectores.

Direção assimptótica de uma partícula primária é a direção da trajetória da partícula primária antes de sofrer a ação do campo geomagnético (Rockenbach, 2010). O múon é uma partícula particularmente adequada à tarefa, pois graças às características listadas anteriormente ele, aproximadamente, mantém a direção da partícula que o produziu. A Figura 3.9 ilustra as direções assimptóticas determinadas para os detectores da GMDN, utilizando a integração adaptativa de Runge-Kutta para tratar o problema do deslocamento das partículas dos raios cósmicos pelo campo geomagnético. As soluções de Runge-Kutta propiciam um método iterativo para resolver equações diferenciais. O método recebeu um renovado interesse após o advento dos computadores digitais, e desde então muitos pesquisadores têm contribuído para estender seus limites teóricos e desenvolver métodos particulares (Butcher, 2003). Na Figura 3.9 cada ponto marcado com um símbolo indica a direção assimptótica para partículas com rigidez média, P_m , de cada canal direcional que é calculada utilizando a função resposta dos múons na atmosfera. A linha que liga os símbolos mostra espalhamento das direções assimptóticas para partículas cuja rigidez está entre $P_{0,1}$ e $P_{0,9}$, limitando a energia central em 80% da resposta de energia de cada canal direcional. A figura também mostra a abrangência da GMDN que cobre todo céu, exceto por algumas lacunas sobre a América do Norte e o sul do Oceano Índico (Rockenbach, 2010).

A partir deste ponto passa-se a determinar o vetor anisotropia tridimensional dos GCRs. Nesta tarefa as componentes do vetor anisotropia são calculadas no sistema de coordenadas geográficas locais (GEO), isto é, *eixo-z* aponta para o norte geográfico, o *eixo-x* tem sua origem sobre a linha do equador, está contido no plano equatorial apontando para o zênite às 00:00 horas do horário local, o *eixo-y* completa o sistema de coordenadas e pode ser facilmente determinado pela regra da mão direita.




Figura 3.9 – REDE GLOBAL DE DETECÇÃO DE MÚONS (GMDN). Linhas indicando as direções assintóticas observadas pelos detectores que compõem a rede. Modificado de Okazaki, 2008.

Como calculado por Okazaki (2008) a anisotropia pode ser determinada ajustando a função $I_{i,j}^{aj}(t)$, dada por meio da relação:

$$I_{i,j}^{aj}(t) = I_{i,j}^0(t) + \xi_x^{GEO}(t)(c_{1i,j}^1 \cos \omega t_i - s_{1i,j}^1 \sin \omega t_i) + \xi_y^{GEO}(t)(s_{1i,j}^1 \cos \omega t_i - c_{1i,j}^1 \sin \omega t_i) + \xi_z^{GEO}(t)c_{1i,j}^0 \quad (3.5)$$

para a contagem horária observada $I_{i,j}^{obs}(t)$ de múons no horário universal no j-ésimo canal direcional do i-ésimo detector da GMDN (Okazaki, 2008). Nesta equação $\xi_x^{GEO}(t)$, $\xi_y^{GEO}(t)$ e $\xi_z^{GEO}(t)$ são os parâmetros de melhor ajuste que representam as três componentes da anisotropia; os coeficientes de acoplamento estão presentes na notação $c_{1i,j}^1$, $c_{1i,j}^1$ e $c_{1i,j}^1$ tendo sido calculados assumindo

que a rigidez independe da anisotropia; por fim t_i , indica o horário universal na localização do i -ésimo detector e $\omega = 2\pi/24$.

É importante perceber que o vetor da anisotropia aponta para uma direção a partir da qual o maior fluxo de GCRs é medido, ou seja, o vetor anisotropia é dirigido no sentido oposto ao vetor fluxo dos raios cósmicos galácticos. Entre as três componentes da anisotropia, $\xi_z^{GEO}(t)$, é que está relacionada à anisotropia norte-sul, enquanto $\xi_x^{GEO}(t)$ e $\xi_y^{GEO}(t)$ estão ligados à variação diurna. Agora, assumindo que:

$$I_{i,j}^0(t) = I'_0(t) + I''_0(t) \frac{P_{mi,j}}{P_{m1,1}} \quad (3.6)$$

onde $I'_0(t)$ e $I''_0(t)$ são os parâmetros de melhor ajuste e $P_{mi,j}$ e $P_{m1,1}$ são as rigidezes do j -ésimo canal do i -ésimo detector de múons e o canal vertical de Nagoya ($i=1, j=1$), respectivamente. A primeira parcela da soma indica a porção da densidade que é independente da energia, a segunda a porção dependente da rigidez. O melhor ajuste para a densidade $I_0(t)$ pode ser definido como:

$$I_0(t) = I'_0 + I''_0 \quad (3.7)$$

que é o mesmo que $I_{1,1}^0(t)$ para o canal vertical de Nagoya ($P_m = 59$ GV). Para calcular o menor conjunto de parâmetros de melhor ajuste, deve-se minimizar o resíduo S que é dado pela relação:

$$S = \sum_{i,j} \frac{\left(I_{i,j}^{obs}(t) - I_{i,j}^{aj}(t) \right)^2}{\sigma_{ci,j}^2} \quad (3.8)$$

na qual σ é a taxa de erro de contagem no j -ésimo canal direcional do i -ésimo detector de múons.

Em uma primeira etapa ajusta-se a Equação 3.5 para o desvio percentual $r_{i,j}^{obs}(t)$ observado da taxa de contagem horária corrigida para a pressão de uma média calculada sobre cada rotação solar o que resulta em uma grande variação diurna da anisotropia, especialmente se a diferença entre a taxa de múons verticais

detectada entre as observações de Nagoya e São Martinho tornar-se significativa. Essa variação ocorre por um efeito da temperatura atmosférica, pois o ajuste da Equação 3.5 leva a uma anisotropia da direção com a maior taxa de contagem. A fim de driblar essa variação diurna espúria na anisotropia ao calcular-se os parâmetros de melhor ajuste da Equação 3.5, faz-se uma normalização da média corrida (“trailing moving average” – TMA) de $r_{i,j}^{obs}(t)$ para aquele do canal vertical do detector de Nagoya, proposta por Kuwabara et al, (2004):

$$I_{i,j}^{obs}(t) = r_{i,j}^{obs}(t) \cdot \frac{\bar{I}_{1,1}(t)}{\bar{I}_{i,j}(t)} \quad (3.9)$$

onde $\bar{I}_{i,j}^{obs}(t)$ é a TMA de 24 horas do $r_{i,j}(t)$ dada por:

$$\bar{I}_{i,j}(t) = \sum_{t-23}^t \frac{r_{i,j}^{obs}(t)}{24} \quad (3.10)$$

e $\bar{I}_{1,1}(t)$ é a TMA para o canal vertical de Nagoya. No entanto esta normalização não funciona bem para a anisotropia NS. Na Equação (3.5) é possível perceber que ξ_z^{GEO} não vem acompanhada da variável t como é o caso de ξ_x^{GEO} e ξ_y^{GEO} que por estarem atrelados aos termos $\cos \omega t$ e $\sin \omega t$ implicam na variação diurna ainda que eles próprios sejam constantes. Mas o mesmo não ocorre com a anisotropia NS, representada por ξ_z^{GEO} , que é eliminada por completo se permanecer constante por um tempo maior que 24 horas. Por outro lado esta normalização remove de maneira eficiente a variação espúria e funciona adequadamente para períodos menores que 24 horas.

Rockenbach (2010) propõe outra abordagem cuja finalidade é identificar mais precisamente precursores que possibilitam a previsão de tempestades geomagnéticas. A técnica minimiza a variação diurna dos dados causada pela rotação da Terra e salienta efeitos que ocorrem em uma escala menor, como por exemplo, a aproximação de uma estrutura solar que se propaga pelo meio interplanetário, isso torna este método bem mais adequado a esta pesquisa, cuja

finalidade é investigar a relação entre as componentes do IMF e a intensidade de raios cósmicos, e isso será feito através das variações que são observadas pela ação de uma estrutura solar sobre em ambos.

Na proposta de Rockenbach (2010), o ajuste $\bar{I}_{i,j}^{fit}$ para $I_{i,j}^{obs}$ é dado por:

$$\begin{aligned} \bar{I}_{i,j}^{fit} = & \bar{I}^0(t) + \bar{\xi}_x^{GEO}(t)(c_{1i,j}^1 \cos \omega t_i - s_{1i,j}^1 \sin \omega t_i) + \\ & \bar{\xi}_y^{GEO}(t)(s_{1i,j}^1 \cos \omega t_i - c_{1i,j}^1 \sin \omega t_i) + \\ & \bar{\xi}_z^{GEO}(t) c_{1i,j}^0 \end{aligned} \quad (3.11)$$

onde $c_{1i,j}^1$, $s_{1i,j}^1$ e $c_{1i,j}^0$ são os coeficientes de acoplamento, t_i é o tempo local do i-ésimo detector, $\omega = \pi/12$. Os parâmetros de ajuste, calculados para uma média corrida de 12 horas, podem ser determinados pelo seguinte conjunto de equações:

$$\bar{I}^0(t) = \sum_{t-11}^t \frac{I_0(t)}{12} \quad (3.12)$$

$$\bar{\xi}_x^{GEO}(t) = \sum_{t-11}^t \frac{\xi_x^{GEO}(t)}{12} \quad (3.13)$$

$$\bar{\xi}_y^{GEO}(t) = \sum_{t-11}^t \frac{\xi_y^{GEO}(t)}{12} \quad (3.14)$$

$$\bar{\xi}_z^{GEO}(t) = \sum_{t-11}^t \frac{\xi_z^{GEO}(t)}{12} \quad (3.15)$$

Por fim, ao realizar a subtração:

$$\Delta I_{i,j}^{cal}(t) = I_{i,j}^{obs}(t) - \bar{I}_{i,j}^{fit} \quad (3.16)$$

a anisotropia diurna é eliminada, flutuações de larga escala são suprimidas e os efeitos de menor escala são destacados.

Em suma, o método estabelecido por Rockenbach (2010) faz uso de coeficientes de acoplamento, que incorporam os elementos terrestres (latitude geomagnética, pressão atmosférica, etc.) para determinar informações sobre a densidade e a direção das partículas de raios cósmicos primários que incidem na Terra. Em conjunto com as observações do satélite ACE, estes serão os dados utilizados para averiguar características da relação entre o IMF e os raios cósmicos no Geoespaço.

4. REDES NEURAIS

A rede neural é uma ferramenta computacional cuja aplicação é relativamente nova na ciência, mas sua origem remonta a modelos matemáticos e de engenharia que buscam explicar o funcionamento do neurônio biológico que foi identificado e descrito no século 19 (Kovács, 2006). A definição de rede neural é um conceito bastante discutido na literatura, mas está sempre ligado a três palavras-chave: *neurônio*, *arquitetura* e *aprendizagem*. De modo geral, o neurônio constitui o elemento fundamental de toda a rede, a arquitetura é a estrutura topológica pela qual os neurônios estão conectados entre si e a aprendizagem é o processo que adapta a rede para que esta efetue a tarefa a ela determinada (Fernandes, 2005).

Uma definição mais específica é a de que:

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que tem propensão natural a armazenar conhecimento experimental e torná-lo disponível para uso. (HAYKIN, 2001)

A aplicação óbvia deste tipo de processador é o de generalizar resultados a partir das informações disponíveis, em situações nas quais opções mais convencionais de modelagem matemática são inadequadas, ou incapazes de fazê-la. Contudo deve-se ter o bom senso de não considerar NNs como uma panaceia a todo tipo de problema científico, encontrando soluções onde a mente humana não é capaz. A quantidade enorme de neurônios, aliada a topologia extremamente complexa que une uma quantidade ainda maior de conexões sinápticas, dá ao cérebro biológico tal capacidade de processamento de dados que é inimaginável reproduzi-la com os meios tecnológicos atuais. É muito mais sensato interpretar uma NN como uma ferramenta que aprende através da relação intrínseca que existe entre os dados do problema, ao invés de basear-se em um conjunto de regras pré-determinado (Tagiaferri et al, 2003) como fazem os modelos matemáticos comuns.

Mesmo que as condições do problema sejam adequadas à aplicação de uma NN, cuidados operacionais devem ser tomados para garantir o bom funcionamento do material tecnológico que a suporta. Também é importante obter uma rede que não seja rigorosa a ponto de ignorar a influência de dados relevantes e não flexível o bastante para computar o ruído estatístico que acompanha os dados. A seleção do

tipo de rede e sua subsequente configuração vêm de identificar tanto a tarefa que a NN deve realizar quanto as condições dentro das quais ela deve ser realizada. Os dados que serão introduzidos na rede também devem ser adequadamente normalizados para evitar sobrecargas na capacidade computacional do equipamento.

Alguns elementos da rede podem ser previamente preparados. Outros porém são dificilmente determinados antes que a rede esteja funcionando, e dependem muito da intuição do pesquisador atribuir os valores para tentativas iniciais. Embora haja na literatura alguma referência sobre como determinar estatisticamente o número de neurônios e/ou o número de camadas ocultas em uma NN (Murata et al, 1994) é usual que se determine estes valores empiricamente por meio de tentativa e erro (Ciaramella, 2005; Folkes et al, 2006; Almeida et al, 2010). A atribuição destes valores é outra tarefa essencial. Tome-se como exemplo o número de neurônios em cada camada. Se for grande demais pode haver um ajuste excessivo (“*overfitting*”) que faz com que a NN perca sua capacidade de generalizar, por outro lado se ele for muito pequeno há o risco de um ajuste muito pobre (“*underfitting*”), ou seja, a rede não converge durante o processo de aprendizagem. Neste trabalho os valores foram determinados com base na literatura existente, mas várias tentativas foram necessárias até que os indicadores de eficiência e aprendizado da NN tivessem atingido valores ótimos.

4.1 Neurônio

O neurônio ou nodo é o elemento unitário de toda a rede neural, seja ela artificial ou biológica. Sua arquitetura nos modelos artificiais é inspirada em seu paralelo biológico, portanto uma breve explicação do neurônio biológico faz se relevante.

Kovács (2006) descreve o neurônio biológico como composto por uma *soma*, que se trata do corpo celular onde os processos metabólicos da célula acontecem e a partir do qual dois tipos de filamentos se projetam: Os *dendritos*, cujo conjunto forma uma *árvore dendrital* que algumas vezes ocupa um espaço maior que o próprio corpo celular, e o *axônio* ou *fibra nervosa*, que se estende por distâncias superiores a pouco mais de um metro. Os vertebrados ainda contam com uma capa

segmentada de mielina sobre o axônio que serve, dentre outras coisas, para acelerar a transmissão do sinal nervoso (Kovacs, 2006). A Figura 4.1 ilustra a descrição acima.




Figura 4.1 - Ilustração de um neurônio com as principais estruturas de interesse identificadas.

As pesquisas sobre as propriedades elétricas da célula nervosa começaram ainda no século 19 e prosseguiram até ao final da década de 1970, já sendo bem aceita então a ideia de que o neurônio era na verdade uma unidade de computação do sistema nervoso e que, como em qualquer máquina computacional, possui dispositivos de entrada e saída de dados. A árvore dentrital é o dispositivo de entrada ligando-se as terminações dos axônios de vários neurônios anteriores por meio de *conexões sinápticas*. Dependendo do tipo de neurônio ele pode receber sinal de mais de dez mil conexões sinápticas (Haykin, 2001). Os sinais recebidos podem ser de caráter excitatório ou inibitório e são todos integrados na região de soma. Os sinais juntos podem ou não criar um *potencial de ação* suficiente para fazer com que o corpo celular dispare um impulso elétrico através do axônio em cujas terminações estão as conexões sinápticas com os neurônios seguintes. A velocidade de transmissão pode ir de algumas dezenas de centímetros por segundo, para fibras sem mielina, até 150 metros por segundo, para células que contam com a capa de mielina, e um único axônio pode ter conexões sinápticas com milhares de outros neurônios (Kovács, 2006).

Os neurônios têm sido alvo de intensa investigação e muita coisa se sabe sobre sua função, fisiologia e anatomia, mas a informações sobre suas capacidades

como elemento computacional ainda são poucas, vindas de generalizações com base em estudos de caso realizados em ambientes laboratoriais. Como resultado, os modelos de neurônios artificiais são elementos simples que extraem seu poder computacional do processamento paralelo que efetuam em conjunto.

O modelo de neurônio artificial como proposto por Haykin (2001) é composto de três partes básicas: O conjunto das *sinapses*, o corpo do neurônio ou *soma* e a *função de ativação*. Um grafo representativo de um neurônio artificial pode ser visto na Figura 4.2.




Figura 4.2 - Grafo de um neurônio artificial. A série x_j representa os diversos sinais de entrada recebidos pelo neurônio, enquanto y representa o sinal de saída emitido.

As sinapses recebem cada sinal de entrada x_j , e o multiplicam por um fator w_j , denominado *peso sináptico* que, ao contrário de seu paralelo biológico, pode ser positivo ou negativo. A soma integra todos os sinais já ponderados pelas sinapses através de um combinador linear. Dependendo do neurônio, outro valor denominado *bias* pode ser acrescido ou reduzido. Finalmente, a função de ativação emite o sinal de saída que é uma versão normalizada do sinal que recebeu da soma, deste modo a função de ativação também pode ser chamada de *função restritiva*.

É possível descrever o i -ésimo neurônio de uma NN como um construto matemático através das seguintes equações (Kovács, 2006):

$$u_i = \sum_{j=1}^n w_{ij} x_j \quad (4.1)$$

$$y_i = \varphi(u_i + b_i) \quad (4.2)$$

nelas x_j é o j -ésimo sinal de entrada recebido pelo neurônio, w_{ij} é o j -ésimo peso sináptico do neurônio i , e u_i é o resultado obtido pela combinação linear dos sinais de entrada e dos pesos sinápticos desse neurônio. Na Equação 4.2, y_i indica o sinal de saída do i -ésimo neurônio calculado por sua função de ativação com base no valor obtido para u_i somado ao bias b_i . Para referência futura é interessante considerar

$$v_i = (u_i + b_i) \quad (4.3)$$

onde v_i é conhecido como *potencial de ativação* do i -ésimo neurônio.

Na verdade a função de ativação tem um papel de destaque no funcionamento de neurônio, pois é ela que após operacionalizar os dados que obtém da soma apresenta o resultado final computado pelo neurônio. Além disso, a escolha da função de ativação apropriada interfere diretamente no tipo de tarefa que se atribuirá a NN e várias funções matemáticas podem servir como função de ativação. Dentre as mais comumente aplicadas se destacam, a *função limiar*, a *função linear*, a *função logística* e a *função tangente hiperbólica*.

Uma das mais antigas a ser utilizada, a função limiar é bastante simples e pragmática. Também conhecida como função degrau, ela aparece juntamente com um dos primeiros modelos de neurônio no trabalho de McCulloch e Pitts (1943) que se referem a ela como uma função tudo ou nada (*all-or-none*) que eles supõem corresponder ao comportamento do neurônio biológico. Tudo que esta função faz é atribuir o valor 1 ao sinal de saída caso o potencial de ativação seja não-negativo, e atribuir o valor 0 em caso contrário. Ela pode ser matematicamente expressa pela relação:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (4.4)$$

Muito embora seja útil em muitas ocasiões, esta função apresenta a dificuldade de não ser contínua e, portanto não diferenciável o que é uma exigência necessária à maioria dos métodos de aprendizagem de NNs.

A função linear é ainda mais simples que a limiar, porém ela não tem nenhuma ação restritiva, já que tudo que esta função faz é atribuir ao sinal de saída o mesmo valor do potencial de ativação que recebeu da soma, ou seja:

$$\varphi(v) = v \quad (4.5)$$

Dadas suas características, é comum utilizar essa função na camada de saída de redes destinadas a aproximação de funções. Uma maneira alternativa de aplicar a função linear seria combinando-a com a função limiar e tornando sua formulação:

$$\varphi(v) = \begin{cases} 1 & \text{se } v \geq K \\ v & \text{se } K > v > -K \\ 0 & \text{se } v \leq -K \end{cases} \quad (4.6)$$

onde K é um parâmetro ajustável de valor entre zero e um, que permite que a função de ativação recupere seu poder restritivo, mas como consequência a função deixa de ser contínua.

Alguns dos métodos de aprendizagem de redes neurais tornam necessário calcular as derivadas, algumas vezes de segunda ordem, das funções de ativação para determinar o ajuste da rede de modo a se obter o melhor resultado (Haykin, 2001). Com as duas funções já apresentadas essa tarefa se torna complicada, ou porque as derivações não são possíveis, ou por apresentarem valores nulos e/ou constantes que não se dão bem com os algoritmos de aprendizagem. Ambas as funções a seguir são sigmóides, isto é, tem o gráfico no formato de um “s” e além de possuírem derivadas contínuas também são simétricas.

Dentre as funções de ativação, a *função logística* é a mais popular em trabalhos atuais (Kóvacs, 2006). Como toda função sigmoide ela é estritamente crescente, e seu perfil naturalmente restringe o sinal de saída para valores entre zero e um. A função logística pode ser matematicamente representada por:

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

novamente K é uma constante de ajuste que define a inclinação da função.

Contudo é importante perceber que se o valor estipulado para a constante K for muito grande, então a função logística acaba tendendo a função limiar, com seus respectivos problemas.

Como se pôde observar, todas as funções anteriores apresentam, ou são ajustadas para apresentar, respostas de saída no intervalo de [0,1], no entanto alguns benefícios analíticos poderiam advir se a função sigmoide fosse ímpar, incluindo também sinais de resposta negativos (Haykin, 2001), deixando o conjunto imagem da função no intervalo de [-1,1]. Quando é interessante suprir essas exigências se aplica como função de ativação a *função tangente hiperbólica* dada por (Piskunov, 1983):

$$\varphi(v) = \tanh(K \cdot v) = \frac{e^{K \cdot v} - e^{-K \cdot v}}{e^{K \cdot v} + e^{-K \cdot v}} \quad (4.8)$$

mais uma vez K surge como um parâmetro de ajuste para a inclinação da curva, e as mesmas ressalvas feitas a ele ao se discutir a função logística se aplicam também para a função tangente hiperbólica.

O comportamento das quatro funções acima citadas pode ser melhor compreendido ao observar os gráficos da Figura 4.3. Nela, o gráfico do painel (i) corresponde a função limiar e o gráfico no painel (ii) mostra o comportamento da função linear segundo a Equação (4.5). Nos painéis inferiores os gráficos da função logística no painel (iii) e da função tangente hiperbólica no painel (iv), para diferentes valores do parâmetro K que acentua ou suaviza a inclinação da sigmoide.




Figura 4.3 – Gráficos correspondentes às funções de ativação mais típicas. No painel (i) o gráfico da função limiar. No painel (ii) o gráfico da função linear sem restrições. Nos painéis (iii) e (iv) gráficos da função logística e tangente hiperbólica, respectivamente, para diferentes valores do parâmetro K.

4.2. Arquitetura de Rede

Não basta conhecer a unidade básica da NN, também é necessário entender a arquitetura ou topologia da rede, ou seja, a maneira como o agrupamento de neurônios é disposto e como interagem entre si.

Uma das arquiteturas mais simples já elaborada para uma NN seria a de um *perceptron*, que foi inicialmente proposto como um construto que ilustra algumas das principais características dos sistemas inteligentes, evitando a complexidade das condições específicas dos elementos neurológicos nos seres vivos (Rosenblatt, 1958). Um perceptron pode ser até mesmo um único neurônio que graças ao ajuste dos pesos sinápticos e do bias é capaz de diferenciar elementos *linearmente separáveis*⁸. Nesta configuração, todavia, ele se mostra capaz de discernir elementos de apenas duas classes e para diferenciar dentre mais classes, é necessário incluir outros neurônios, formando o que convencionou chamar *perceptron de camada única* (Haykin, 2001), cujo grafo representativo pode ser observado na Figura 4.4A. A designação, todavia, não é amplamente aceita, pois enquanto alguns autores interpretam o vetor de entrada como uma simples

⁸ Dois conjuntos de pontos A e B em um espaço de n dimensões, são ditos linearmente separáveis se existem $n+1$ números reais $w_1, w_2, \dots, w_{n+1}$ tais que todo ponto $(x_1, x_2, \dots, x_n) \in A$ satisfaça $\sum_{i=1}^n w_i x_i \geq w_{n+1}$ e todo ponto $(x_1, x_2, \dots, x_n) \in B$ satisfaça $\sum_{i=1}^n w_i x_i < w_{n+1}$ (Rojas, 1996).

atribuição de valores à camada de saída (Hagan et al,2002), outros o aceitam como sendo de fato uma camada de neurônios com transmissão direta (Almeida et al, 2010), ou seja, neurônios cuja função é introduzir valores à rede sem alterá-los de qualquer forma e, sob esta óptica, a arquitetura do perceptron seria de duas camadas e não de uma. Entende-se por camada de saída a última da rede, ou seja, aquela cujo sinal de saída também é o sinal de saída da rede.

O perceptron se revelou um classificador linear limitado, e uma generalização capaz de tratar problemas não lineares, com recursos suficientes para realizar outras tarefas, como a aproximação de funções, foi elaborada ,sendo chamada de *Perceptron de Camadas Múltiplas* (“*Multilayer Perceptron*” – MLP). Nele, entre o vetor de entrada e o vetor de saída, são dispostas outras camadas usualmente denominadas *camadas ocultas*, pois o usuário não tem acesso direto aos valores que entram ou saem dos neurônios destas camadas (Almeida et al, 2010). Um esquema de uma rede com topologia MLP está exposto na Figura 4.4B. Elas são amplamente empregadas em tarefas difíceis, e são conhecidas por sua capacidade de interpolação que já foram inclusive aplicadas em pesquisas astronômicas (Tagliaferri et al, 2003), razão pela qual essa foi a arquitetura selecionada para uso nesta dissertação.




Figura 4.4 – A. Grafo representativo de um perceptron de camada única. B. Exemplo de perceptron de múltiplas camadas, (MLP).

O sentido que o fluxo de informação segue na rede fornece um importante critério de categorização: há redes alimentadas apenas adiante (“feedforward”) também chamadas acíclicas e existem as redes recorrentes ou cíclicas. Nas redes alimentadas adiante a informação só se propaga no sentido do vetor de entrada para a camada de saída, o que a torna a rede uma poderosa ferramenta de mapeamento da informação, mas não permite que lide com a informação que ela própria produziu. Em redes recorrentes a informação de saída de um nodo pode retornar a entrada deste próprio, criando uma *recorrência local*, ou de outro modo, retornar a entrada de um nodo de uma camada anterior graças à ação de um operador de atraso unitário, produzindo uma *recorrência global*. Operadores de atraso não são exclusivamente usados em redes recorrentes, mas toda rede recorrente deve possuir ao menos um já que sua função é estabelecer uma memória fazendo com que a NN produza uma resposta com base em dados que, ou foram introduzidos em iterações anteriores ou foram produzidos pela própria rede.

O caráter dinâmico e não linear das redes recorrentes tornam-nas muito mais eficientes e o processo de aprendizagem muito mais preciso. Obviamente há um custo para tais benefícios: a rede se torna consideravelmente mais complexa e a sua estabilidade é posta em risco (Haykin, 2001). Dentre os vários modelos topológicos de redes recorrentes disponíveis, a que se destaca na predição e modelagem de séries temporais discretas são as *redes recorrentes NARX* (*Nonlinear AutoRegressive model with eXogenous inputs*), pois mesmo com uma estrutura relativamente simples de um MLP mostraram se capazes de realizar as mesmas tarefas que outras arquiteturas conectadas de modo muito mais complicado (Siegelmann; Horne; Giles, 1997).

Supondo uma grandeza dinâmica e não-linear $\mathbf{y}(n)$ de uma série temporal, a rede recorrente NARX produz estimativas, $\mathbf{y}^{net}$, considerando além das componentes do vetor de entrada $\mathbf{x}$, valores anteriores de $\mathbf{y}$, e pode fazê-lo de duas maneiras distintas (Jiang; Song, 2011):

- (1) O modo *série-paralelo*, como mostra a Figura 4.5 não é propriamente cíclico. Nele são utilizados valores previamente conhecidos de $\mathbf{y}(n)$ juntamente com o vetor $\mathbf{x}$ para produzir uma previsão de curto termo, $\mathbf{y}^{net}(n+1)$, um único passo a frente.




Figura 4.5 - Representação de uma rede NARX no modo série-paralelo. Os operadores de atraso retêm dados de uma única iteração anterior tanto para $x(n)$ quanto $y(n)$, mais operadores podem ser adicionados para aumentar a memória da rede.

- (2) No modo *paralelo*, ilustrado pelo grafo da Figura 4.6, a arquitetura é de fato retroalimentada, introduzindo-se na primeira camada o(s) valor(es) de y^{net} determinado(s) em iterações anteriores tornando o sistema apto a fazer previsões a médio e longo prazo.




Figura 4.6 – Representação simplificada de uma rede recorrente NARX operando no modo paralelo. A estrutura topológica é muito semelhante à de um MLP, diferindo pela presença do atrasador e pelo sentido bilateral do fluxo de informação.

É sempre conveniente que o processo de aprendizado da rede NARX se dê no modo série-paralelo independentemente do modo em que se pretende aplicá-la. Treinar a rede no modo paralelo eleva o tempo de aprendizado, o custo computacional não produz melhora no resultado final (Beale; Hagan; Demuth, 2011). Também é importante notar que a noção intuitiva de que previsões de curto termo são muito mais acuradas que previsões de médio ou longo termo é correta, em parte devido as limitações de memória da rede e em parte, pois o algoritmo de aprendizagem dos MLPs, nos quais a NARX é fundamentada é incapaz de eficientemente reter a informação necessária à generalização sem se tornar suscetível demais a efeitos do ruído estatístico de séries temporais, como será discutido mais adiante.

Para fins de análise, utilizou-se tanto redes alimentadas adiante quanto recorrentes. Em uma primeira abordagem, a intensidade I de raios cósmicos no meio interplanetário é interpretada simplesmente como uma função não linear das componentes do IMF, ficando a cargo de um MLP emular tal função. Na segunda etapa, consideram-se os dados de I como uma série temporal dinâmica dependente do IMF que uma rede NARX deve simular. Em ambos casos o número de camadas ocultas e a quantidade de neurônios nestas camadas foi obtido empiricamente por meio de um algoritmo de busca, tendo como ponto de partida a informação obtida nas referências bibliográficas (Almeida et al., 2010; Silva e Oliveira, 2001).

4.3 Aprendizado

Haykin (2001) define aprendizagem como o processo através do qual os parâmetros livres de uma NN são modificados por meio da estimulação provocada pelo ambiente em que a rede está inserida. Basicamente isso significa que por meio de comparações a rede ajusta os valores dos pesos sinápticos e dos bias de cada um de seus neurônios até chegar a uma meta previamente estipulada.

Assim como a arquitetura das redes neurais se divide em dois grandes setores: o das redes alimentadas adiante e o das redes recorrentes; também os processos de treinamento podem ser separados em duas modalidades fundamentais: *aprendizado supervisionado* e *aprendizado não-supervisionado*. O aprendizado

supervisionado ocorre quando se apresenta à rede exemplos das respostas esperadas, para que por meio do ajuste de seus parâmetros tente-se emular tais repostas e a partir daí produzir extrapolações. No aprendizado não supervisionado a rede calcula, de maneira independente, indicadores da qualidade de suas respostas e quando estes indicadores atingem valores aceitáveis, a rede está suficientemente bem treinada e reconhece as regularidades estatísticas dos dados de entrada (Haykin, 2001).

Como o interesse é verificar a inter-relação entre duas grandezas, o aprendizado será supervisionado buscando averiguar, pela capacidade de generalização demonstrada pela NN, o quanto é provável haver uma relação de causalidade entre elas, produzindo pistas sobre o modelo matemático dessa relação durante o processo.

O processo de aprendizagem supervisionado de MLPs se dá usualmente pelo algoritmo de retropropagação (“*Backpropagation*”) também conhecido como regra delta generalizada. O termo retropropagação vem do fato de que o ajuste de pesos e bias é feito da última camada para a primeira, em sentido oposto a transmissão dos dados pela NN. Kovacs (2006) demonstra-o supondo um conjunto de L observações $\Psi = \{x_l^d, y_l^d\}_{l=1}^L$ para o qual, dado um determinado valor de l , x_l^d é o valor que, uma vez introduzido na NN, deveria produzir a resposta mais próxima de y_l^d possível. Para conseguir isso é preciso determinar o conjunto, $\mathbf{w}$, de parâmetros ajustáveis (pesos sinápticos e bias) da rede tal que o erro quadrático, $E(\mathbf{w})$, dado por:

$$E(\mathbf{w}) = \sum_{l=1}^L (y_l - y_l^d)^2, \quad (4.9)$$

sobre todo o conjunto das observações seja o menor possível, chegando a um conjunto de parâmetros otimizados, $\mathbf{w}^*$, tal que $E(\mathbf{w}^*) \leq E(\mathbf{w})$ para qualquer $\mathbf{w} \in \Re^n$. Na Equação 4.9, y_l é o valor de saída da rede para o dado de entrada x_l^d que vêm de calcular a função de ativação ϕ , para o valor obtido da combinação linear de w e x_l^d , ou seja:

$$y_l = \phi(\mathbf{w}^t \mathbf{x}_l^d) \quad (4.10)$$

A lógica empregada para chegar a $\mathbf{w}^*$ é que dada uma superfície de erro $E(\mathbf{w})$, conhecida como *panorama da função erro*, (Kovacs, 2006), é possível, partindo de um ponto arbitrário $\mathbf{w}(0)$, chegar ao ponto de mínimo seguindo na direção oposta ao gradiente naquele ponto. Assim obtém-se o seguinte algoritmo iterativo para calcular valores $\mathbf{w}(k)$ cada vez mais próximos do ponto de mínimo:

$$\mathbf{w}(k + 1) = \mathbf{w}(k) - \eta' \frac{d}{d\mathbf{w}}(E(\mathbf{w}(k))) \quad (4.11)$$

no qual η' determina o tamanho do passo em direção ao mínimo da superfície.

Aplicando as Equações 4.9 e 4.10 na Equação 4.11, o algoritmo se expande para:

$$\begin{aligned} \mathbf{w}(k + 1) &= \mathbf{w}(k) - 2\eta' \sum_{l=1}^L (\varphi(\mathbf{w}^t x_l^d) - y_l^d) \frac{d\varphi(\mathbf{w}^t x_l^d)}{d\mathbf{w}} \\ &= \mathbf{w}(k) - 2\eta' \sum_{l=1}^L (\varphi(\mathbf{w}^t x_l^d) - y_l^d) \frac{d\varphi(v)}{dv} \frac{d(\mathbf{w}^t x_l^d)}{d\mathbf{w}} \\ &= \mathbf{w}(k) - 2\eta' \sum_{l=1}^L (y_l - y_l^d) \frac{d\varphi(v)}{dv} x_l^d \end{aligned} \quad (4.12)$$

Por fim fazendo:

$$\delta_l = (y_l - y_l^d) \frac{d\varphi(v)}{dv} \quad (4.13)$$

e

$$\eta = 2\eta' \quad (4.14)$$

Chega-se a equação que se convencionou denominar *regra delta generalizada*:

$$\mathbf{w}(k + 1) = \mathbf{w}(k) - \eta \sum_{l=1}^L \delta_l \mathbf{x}_l^d. \quad (4.15)$$

Um critério de parada deve ser estabelecido para identificar o momento em que a rede está suficientemente treinada, que se dá no tênue equilíbrio entre a maior capacidade de generalização e a mínima taxa de erro. Assim do conjunto de dados de entrada e saída são usualmente separados em dois subconjuntos correspondentes que não são usados durante o treinamento: um que pode ser denominado de *conjunto de validação* que avalia a precisão da rede calculando o erro para pontos com os quais ela não foi treinada, se o ajuste da rede para o conjunto de treinamento for muito bom e muito pobre para o conjunto de validação isso significa que houve treinamento excessivo (“*overtraining*”) e a NN perdeu capacidade de generalizar. O segundo conjunto tem a finalidade de uma revalidação, recebendo o nome de *conjunto de teste*. Esse conjunto é necessário pois uma validação pobre também pode ser explicada por uma má escolha dos dados, tendo sido selecionada uma região de comportamento particularmente incomum da função para conjunto de validação, o que é provável quando o resultado do ajuste difere apenas na validação e não no teste, ou quando ocorre o inverso. Além dos indicadores de otimização produzidos pela divisão dos dados de treinamento também podem ser usados como critério de parada o número máximo de iterações ou um valor mínimo na variação do parâmetro δ_l , referido na Equação 4.13.

Embora este seja um método de aprendizagem muito comum para problemas não-lineares, a técnica do gradiente descendente tem suas limitações: É possível que a superfície de erro não possua um mínimo e o método simplesmente não converge ou ao contrário, a superfície de erro pode ter vários mínimos locais e o ponto de partida das iterações se torna absolutamente crucial. Outra questão é o fato de já haver sido provado que, quando utilizado em séries dinâmicas para previsões a longo termo, o algoritmo não pode ser robusto o suficiente para evitar a entrada de ruído e ao mesmo tempo eficientemente treinável (Bengio; Simard;

Frasconi, 1994). Assim foram adotados o algoritmo de treinamento de Levenberg-Marquardt e a arquitetura NARX para o estudo da dependência de longo termo, ambos os elementos se não contornam os problemas completamente mostraram se bem menos suscetíveis a eles.

O algoritmo de Levenberg–Marquardt é o método mais comum de treinamento de MLP para uma tarefa de ajuste de função (Beales; Hagan; Deamuth, 2011), e daí sua aplicação neste trabalho. A maneira como se dão as iterações desse método ajudam a evitar, todavia não completamente, mínimos locais. Hagan e Menhaj (1994) fazem uma síntese do método da seguinte maneira: Imagine que haja uma função $E(\mathbf{w})$ a qual se queira minimizar a respeito de um vetor de parâmetros $\mathbf{w}$, nesse caso o método de Newton seria dado por:

$$\Delta \mathbf{w} = -[\nabla^2 E(\mathbf{w})]^{-1} \nabla E(\mathbf{w}) \quad (4.16)$$

onde $\nabla^2 E(\mathbf{w})$ é a matriz Hessiana e $\nabla E(\mathbf{w})$ é o gradiente. Se a função $E(\mathbf{w})$, for tal que:

$$E(\mathbf{w}) = \sum_{l=1}^L e_l^2(\mathbf{w}) \quad (4.17)$$

Então é possível mostrar que:

$$\nabla E(\mathbf{w}) = \mathbf{J}^T(\mathbf{w}) \mathbf{e}(\mathbf{w}) \quad (4.18)$$

$$\nabla^2 E(\mathbf{w}) = \mathbf{J}^T(\mathbf{w}) \mathbf{J}(\mathbf{w}) + S(\mathbf{w}) \quad (4.19)$$

onde $\mathbf{J}(\mathbf{w})$ é a matriz Jacobiana:

$$\mathbf{J}(\mathbf{w}) = \begin{bmatrix} \frac{\partial e_1(\mathbf{w})}{\partial \mathbf{w}_1} & \frac{\partial e_1(\mathbf{w})}{\partial \mathbf{w}_2} & \dots & \frac{\partial e_1(\mathbf{w})}{\partial \mathbf{w}_l} \\ \frac{\partial e_2(\mathbf{w})}{\partial \mathbf{w}_1} & \frac{\partial e_2(\mathbf{w})}{\partial \mathbf{w}_2} & \dots & \frac{\partial e_2(\mathbf{w})}{\partial \mathbf{w}_l} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_L(\mathbf{w})}{\partial \mathbf{w}_1} & \frac{\partial e_L(\mathbf{w})}{\partial \mathbf{w}_2} & \dots & \frac{\partial e_L(\mathbf{w})}{\partial \mathbf{w}_l} \end{bmatrix} \quad (4.20)$$

e

$$S(\mathbf{w}) = \sum_{l=1}^L e_l(\mathbf{w}) \nabla^2 e_l(\mathbf{w}) \quad (4.21)$$

A partir daqui outro algoritmo de aprendizagem denominado método de Gauss-Newton apenas assume que $S(\mathbf{w}) \approx 0$, e assim de (4.16), (4.18) e (4.19) vem que:

$$\Delta \mathbf{w} = [\mathbf{J}^T(\mathbf{w})\mathbf{J}(\mathbf{w})]^{-1} \mathbf{J}^T(\mathbf{w})\mathbf{e}(\mathbf{w}). \quad (4.22)$$

A modificação de Levenberg-Marquardt é adicionar ao método de Gauss-Newton um termo extra, deixando a equação do seguinte modo:

$$\Delta \mathbf{w} = [\mathbf{J}^T(\mathbf{w})\mathbf{J}(\mathbf{w}) + \mu \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{w})\mathbf{e}(\mathbf{w}), \quad (4.23)$$

onde $\mathbf{I}$ representa a matriz identidade e μ é um parâmetro modificado de maneira que se após a iteração $E(\mathbf{w})$ aumenta μ é multiplicado por um fator β , por outro lado se $E(\mathbf{w})$ diminui então μ é dividido por β . O valor de β deve ser previamente escolhido. Isso torna o algoritmo de Levenberg-Marquardt uma técnica mista, pois se μ se tornar muito grande então ela tende ao método do gradiente descendente, se inversamente μ ficar muito pequeno então ela se aproxima do método de Gauss-Newton. De outra forma: quando afastado do mínimo da superfície de erro o

algoritmo funciona como gradiente descendente progredindo em direção a solução de modo convergente e estável, conforme chega as vizinhanças do mínimo passa a operar como Gauss-Newton atingindo-o rapidamente.

É importante mencionar que Bengio, Simard e Frasconi (1994), mostraram que algoritmos baseados no método do gradiente descendente, quando utilizados para predições de longo termo em NNs recorrentes apresentam um problema de *dissipação de gradiente* e assim as redes que os usam não podem simultaneamente ser otimamente treináveis e reter a informação de memória necessária a uma estimativa acurada. No mesmo artigo, contudo os autores buscam abordagens alternativas e demonstram que algoritmos derivados do método de Newton, graças ao computo da matriz Hessiana são menos suscetíveis ao efeito. Não obstante, Lin et al. (1999) argumentaram que a arquitetura NARX também é menos afetada pois os atrasos da saída reduzem a sensibilidade da rede a dependências de longo termo, além do fato de que não necessariamente a propagação de informação tem que passar por uma não-linearidade a cada passo no tempo evitando que o gradiente seja modificado por uma derivada parcial de não-linearidade.

O algoritmo de Levenberg-Marquardt é aplicado em todas as redes propostas nessa dissertação, pois é um método rápido, estável e eficiente, todavia algumas considerações devam ser feitas: na aplicação do MLP para aproximação de função o caráter estático do sistema torna-o praticamente imune ao efeito da dissipação de gradiente. As NNs temporais de curto termo também são pouco afetadas, pois não precisam reter a informação por períodos superiores a uma iteração. Restam as redes temporais de longo termo, mas o caráter misto do algoritmo, que divide sua ação entre os métodos de gradiente descendente e de Gauss-Newton, somado aos fatos de que parte do ruído que deteriora a informação foi eliminado pela abordagem de Rockenbach (2010), e que adotou-se a arquitetura NARX sabidamente menos suscetível, garante uma grande possibilidade de resultados de interesse, ainda que a busca nem sempre seja curta.

5. DADOS E CÁLCULOS

As redes neurais têm-se provado uma ferramenta de análise com boa capacidade de produzir resultados de relevância científica. Foram as propriedades não-lineares e dinâmicas exibidas em estudos anteriores de elementos astronômicos e astrofísicos (Almeida, 2010; Jiang; Song, 2011) que inspiraram a elaboração deste trabalho cuja finalidade é buscar indícios do modelo teórico da relação de causalidade entre o IMF e os dados de raios cósmicos.

Utilizaram-se dados horários do campo magnético interplanetário obtidos *in situ* pelo satélite ACE e determinações da intensidade de raios cósmicos no mesmo intervalo, calculadas através do método estabelecido por Rockenbach (2010) para quatro diferentes intervalos de tempo e identificados pelo mês e ano de sua ocorrência: de 09 de abril de 2001 a 14 de abril de 2001 (evento de abril de 2001), de 27 de outubro de 2003 a 01 de novembro de 2003 (evento de outubro de 2003), de 16 de novembro de 2003 a 24 de novembro de 2003 (evento de novembro de 2003) e de 12 de dezembro de 2006 a 18 de dezembro de 2006 (evento de dezembro de 2006). Nestas datas, ejeções de massa coronal interplanetária (ICMEs) perturbaram a eletrodinâmica do Geoespaço e causaram tempestades magnéticas registradas como superintensas (abril de 2001, outubro e novembro de 2003) e intensa (dezembro de 2006) no ambiente terrestre, de acordo com a classificação do índice Dst exposta na Tabela 2.1. Todos os quatro eventos foram descritos por Rockenbach (2010) com as respectivas indicações da intensidade B do campo magnético, das componentes do vetor campo magnético interplanetário B_x , B_y e B_z , da densidade de raios cósmicos I e das componentes da anisotropia de raios cósmicos ξ_x , ξ_y e ξ_z assumindo como referencial o sistema de coordenadas geocêntrico-solar-eclíptico (GSE). Os dados do satélite ACE sobre o campo magnético interplanetário também podem ser encontrados online no endereço eletrônico http://www.srl.caltech.edu/ACE/ASC/level2/lvl2DATA_MAG.html⁹.

Fundamentalmente buscou-se simular o perfil de comportamento dos raios cósmicos no meio interplanetário em função dos dados disponíveis sobre o campo magnético interplanetário da região, a fim de extrair o máximo de informação possível sobre a relação entre as grandezas.

⁹ Acesso em 08 de agosto de 2012

5.1 TRATAMENTO DE DADOS

Todas as tarefas computacionais foram desenvolvidas no ambiente de programação oferecido pelo software Matlab® versão R2011b, que foi escolhido por ser amplamente aplicado em tarefas técnico-científicas contando com ampla referência de apoio. Outra razão foi a de empregar pacotes complementares de software desenvolvidos especificamente para o Matlab® e estão disponíveis no comércio o que tornou o desenvolvimento das redes neurais uma tarefa mais fácil e intuitiva, permitindo que maior esforço de pesquisa fosse dedicado a análise dos resultados.

Nesse trabalho foram atribuídos dois tipos de função de ativação aos neurônios dependendo de sua posição na topologia da rede: a função tangente hiperbólica e a função linear. A finalidade da função tangente hiperbólica é inferir o valor da contribuição de seu neurônio sobre o seguinte, como os dados de entrada e saída incluem valores negativos ela foi escolhida em detrimento da mais convencional função logística. Já a função linear foi usada sem qualquer limitação, em sua forma contínua e mais simples, para que ao final do processamento dos dados a rede simulasse os valores da intensidade de raios cósmicos durante um evento significativo no Clima Espacial.

Antes de serem aplicados todos os dados foram normalizados para não sobrecarregar as funções de transferência. Como os dados da intensidade já eram percentuais seus valores foram ajustados da seguinte forma:

$$I_{net} = I_{cal} - 100 \quad (5.1)$$

onde I_{net} são os valores usados no treinamento da rede e I_{cal} é a intensidade de raios cósmicos determinadas por Rockenbach(2010). No entanto, as componentes do IMF são dadas em unidades do campo magnético e apresentam uma variação significativamente maior e para normaliza-las usou-se a técnica de *normalização de média zero*, como utilizada por Camargo (2010):

$$B_{x,net} = \frac{B_x - \bar{B}_x}{\sigma_{B_x}} \quad (5.2)$$

na qual, $B_{x,net}$ é o dado a ser utilizado no treinamento da rede, B_x o valor observado pelo satélite, $\bar{B}_x$ a média do período e σ é desvio padrão do conjunto de dados observado. Embora só faça referência a componente B_x , a Equação 5.2 também foi utilizada para normalizar as demais componentes do IMF no plano cartesiano, bastando para tanto substituir o índice x , por y e depois z .

Adotando esses procedimentos todos os dados ajustados da intensidade de raios cósmicos ficaram dentro do intervalo de $[-3,3]$, com a grande maioria contida no intervalo de $[-1,1]$. Os valores re-escalados das componentes do IMF entre $[-4,4]$, com a maior parte também entre $[-1,1]$. As funções sigmóides funcionam bem nessa faixa de valores, como se verifica ao observar os gráficos nos painéis (iii) e (iv) da Figura 4.3.

Para estabelecer a melhor combinação de dados a utilizar, testou-se a capacidade de uma mesma rede neural (NN) de reproduzir o perfil de raios cósmicos para o evento dezembro de 2006, tendo por base diferentes componentes do IMF. A fim de manter a simplicidade, a arquitetura escolhida foi de um perceptron de múltiplas camadas (MLP), com 20 neurônios na camada oculta, treinada pelo algoritmo de Levenberg-Maquardt. O vetor de entrada e a camada de saída foram sucessivamente modificados da seguinte maneira: o vetor de entrada era sempre composto de uma componente, ou uma combinação das componentes do IMF enquanto da mesma forma a camada de saída era composta de diferentes agrupamentos dos dados sobre raios cósmicos. O evento de dezembro de 2006 foi selecionado devido ao comportamento mais simétrico e contínuo exibido pela densidade de raios cósmicos e as componentes de anisotropia em comparação aos outros eventos selecionados, uma vez que as funções de ativação foram escolhidas de modo a adequar a NN para a tarefa de aproximação de função (Beale; Hagan; Demuth, 2011). Após a rede treinada, calculou-se o coeficiente de correlação linear, R , entre os resultados de fato obtidos pela NN e os valores determinados por Rockenbach (2010) para os raios cósmicos, que são os resultados que se esperava

obter, de forma que em caso de uma simulação perfeita R seria igual 1 e enquanto R tendendo a zero significaria uma simulação muito ruim.

O algoritmo de Levenberg-Marquardt funciona, em parte, como o método de gradiente descendente e assim a maneira pela qual se divide as amostras de dados nos subconjuntos de treinamento e validação influencia significativamente o resultado da NN já que pode levar a descoberta de mínimos locais. Durante o processo de treinamento o software separava os dados em um conjunto de treinamento e dois conjuntos menores de validação de modo aleatório. O software utilizava, então, os conjuntos de validação como indicadores de *overtraining*, parando o treinamento após seis falhas sucessivas na validação. O número de falhas sucessivas foi escolhido com base no valor usualmente usado (Beale; Hagan; Demuth, 2011). Como a separação dos conjuntos foi randômica cada rede foi testada ao menos cinco vezes, a média dos coeficientes R registrada na Tabela 5.1 e variações acima de 0,2 unidades no coeficiente foram registradas como grande variação.

Outro elemento anotado foi o fato de que ao se treinar redes com dois ou mais neurônios na camada de saída, ou seja, mais de uma única componente da anisotropia, coeficientes de correlação altos começaram a surgir, contudo uma simples operação de regressão linear entre os resultados obtidos e os resultados esperados mostrou que o valor do coeficiente não se dava em função do bom alinhamento dos pontos, mas pelo surgimento de dois focos de acúmulos de pontos como no gráfico ilustrado na Figura 5.1 obtido em uma tentativa de simular ξ_x e ξ_y em função de B_x, B_y e B_z .

Tabela 5.1 – Coeficientes de correlação linear para o cálculo do MLP para diferentes dados de entrada e saída.

Entradas	Saídas	R	Anotações
B_x	ξ_x	0,45	
B_x	ξ_y	0,30	
B_x	ξ_z	0,30	
B_x	ξ_x, ξ_y	0,91	Dois focos de acúmulos de pontos
B_x	ξ_x, ξ_z	0,86	Dois focos de acúmulos de pontos
B_x	ξ_y, ξ_z	0,41	Grande variação
B_x	ξ_x, ξ_y, ξ_z	0,89	Dois focos de acúmulos de pontos
B_x	I	0,12	
B_y	ξ_x	0,45	
B_y	ξ_y	0,27	

Tabela 5.1 – (Continuação)

Entradas	Saídas	R	Anotações
B_y	ξ_z	0,40	
B_y	ξ_x, ξ_y	0,90	Dois focos de acúmulos de pontos
B_y	ξ_x, ξ_z	0,86	Dois focos de acúmulos de pontos
B_y	ξ_y, ξ_z	0,17	Grande variação
B_y	ξ_x, ξ_y, ξ_z	0,89	Dois focos de acúmulos de pontos
B_y	I	0,40	
B_z	ξ_x	0,19	
B_z	ξ_y	0,32	Grande variação
B_z	ξ_z	0,26	
B_z	ξ_x, ξ_y	0,87	Dois focos de acúmulos de pontos
B_z	ξ_x, ξ_z	0,90	Dois focos de acúmulos de pontos
B_z	ξ_y, ξ_z	0,36	Dois focos de acúmulos de pontos
B_z	ξ_x, ξ_y, ξ_z	0,89	Dois focos de acúmulos de pontos
B_z	I	0,36	
B_x, B_y	ξ_x	0,57	
B_x, B_y	ξ_y	0,46	
B_x, B_y	ξ_z	0,40	
B_x, B_y	ξ_x, ξ_y	0,92	Dois focos de acúmulos de pontos
B_x, B_y	ξ_x, ξ_z	0,90	Dois focos de acúmulos de pontos
B_x, B_y	ξ_y, ξ_z	0,52	
B_x, B_y	ξ_x, ξ_y, ξ_z	0,90	Dois focos de acúmulos de pontos
B_x, B_y	I	0,49	
B_x, B_z	ξ_x	0,52	
B_x, B_z	ξ_y	0,39	
B_x, B_z	ξ_z	0,31	
B_x, B_z	ξ_x, ξ_y	0,92	Dois focos de acúmulos de pontos
B_x, B_y	ξ_x, ξ_z	0,89	Dois focos de acúmulos de pontos
B_x, B_z	ξ_y, ξ_z	0,44	
B_x, B_z	ξ_x, ξ_y, ξ_z	0,91	Dois focos de acúmulos de pontos
B_x, B_z	I	0,68	
B_y, B_z	ξ_x	0,51	
B_y, B_z	ξ_y	0,41	
B_y, B_z	ξ_z	0,41	Grande variação
B_y, B_z	ξ_x, ξ_y	0,92	Dois focos de acúmulos de pontos
B_y, B_z	ξ_x, ξ_z	0,89	Dois focos de acúmulos de pontos
B_y, B_z	ξ_y, ξ_z	0,47	
B_y, B_z	ξ_x, ξ_y, ξ_z	0,91	Dois focos de acúmulos de pontos
B_y, B_z	I	0,63	
B_x, B_y, B_z	ξ_x	0,60	
B_x, B_y, B_z	ξ_y	0,42	
B_x, B_y, B_z	ξ_z	0,45	
B_x, B_y, B_z	ξ_x, ξ_y	0,92	Dois focos de acúmulos de pontos
B_x, B_y, B_z	ξ_x, ξ_z	0,90	Dois focos de acúmulos de pontos
B_x, B_y, B_z	ξ_y, ξ_z	0,55	
B_x, B_y, B_z	ξ_x, ξ_y, ξ_z	0,92	Dois focos de acúmulos de pontos
B_x, B_y, B_z	I	0,68	

Apesar de todas as considerações, a tabela indica claramente que a partir de uma única componente do IMF a NN tem dificuldade em representar as condições dos raios cósmicos, e que os resultados sofrem uma sensível melhora quando acrescidos de outras componentes, particularmente ao simular a componente isotrópica dos raios cósmicos I. Também é importante notar o fato de que a componente B_z , quando acompanhada de outra componente produziu valores de correlação similares aos conseguidos com a utilização das três componentes simultaneamente. Com base nos resultados selecionou-se para vetor de entrada as três componentes do IMF e como resultado da camada de saída a densidade de raios cósmicos I, para maximizar a quantidade de informação de entrada sem que surjam duplas regiões de acúmulo de plotagem e contar com a rede que mostrou melhor capacidade de generalização.




Figura 5.1 – Gráfico ilustrando um falso resultado para o coeficiente de correlação. Embora as linhas de melhor ajuste e ajuste da curva estejam próximas, o espalhamento dos pontos mostra o verdadeiro potencial da rede.

5.2 CARACTERÍSTICAS DOS EVENTOS

Pesquisas com dados observados *in situ* devem sempre considerar que as grandezas estudadas estão sujeitas a uma quantidade enorme de variáveis que nem sempre podem ser compensadas e às vezes sequer são suficientemente compreendidas, desta forma é de considerável importância uma análise mais minuciosa de cada evento selecionado. E embora apenas os elementos relacionados diretamente ao IMF e a densidade de raios cósmicos tenham sido discutidos obviamente outros fatores como, por exemplo, os pertencentes à

magnetohidrodinâmica do Vento Solar (densidade, velocidade, etc.) influenciam a intensidade de raios cósmicos. O fato de relegá-los a um segundo plano além de tornar os esforços de pesquisa factíveis, também permite que se possa discutir a intensidade e extensão de sua influência.

5.2.1 Evento de Abril de 2001

A Figura 5.2 mostra os dados do meio interplanetário durante a passagem de uma ICME no período denominado abril de 2001. Os dados do índice Dst no primeiro gráfico de cima para baixo foi obtido do endereço http://wdc.kugi.kyoto-u.ac.jp/dst_final/¹⁰. Os dois gráficos a seguir, foram obtidos do magnetômetro a bordo do satélite ACE. No de cima está representada a variação de intensidade do IMF, $|B|$, e abaixo a intensidade das componentes, $B_{x,y,z}$, do vetor campo magnético da seguinte forma: em azul a componente x , em verde a componente y e a componente z em vermelho. O quarto e o quinto gráficos representam respectivamente a densidade de raios cósmicos, I , e as componentes de anisotropia de raios cósmicos $\xi_{x,y,z}$ calculadas por Rockenbach (2010). As componentes permanecem distintas pelas cores onde novamente o azul está relacionado a componente x , verde a y e vermelho a z .




Figura 5.2 – Dados do meio interplanetário para o período de 09 de abril de 2001 a 14 de abril de 2001. De cima para baixo: o índice DST registrado no período, a intensidade do campo magnético $|B|$, as componentes do vetor campo magnético, $B_{x,y,z}$ separadas por cores de modo que a componente x está em azul, y em verde e a z em vermelho, a intensidade I de raios cósmicos e as componentes do vetor anisotropia de raios cósmicos $\xi_{x,y,z}$ distinguidos por cores da mesma forma que o vetor campo magnético.

¹⁰ Acesso em 04 de Março de 2013

Echer et al. (2008) estabelece que o distúrbio magnético registrado pelo índice DST nesse período foi causado pelos campos presentes entre a região de choque e sua respectiva ICME, ou seja, “campos de bainha” (*Sheath Fields*).

Pode-se observar que após uma queda de cerca de 2,5% na intensidade de raios cósmicos inicia-se um lento processo de recuperação. Também é possível notar que após o primeiro choque a componente y do campo magnético está acentuadamente negativa para também se recuperar aos poucos. As componentes y e z oscilaram nas proximidades do zero e a componente x se manteve quase sempre nas proximidades do zero exceto no momento do choque.

5.2.2 Evento de Outubro de 2003

A Figura 5.3 exibe dados do meio interplanetário durante o evento de outubro de 2003 e está organizado da mesma forma que a Figura de 5.2. Ela mostra que o decréscimo calculado foi de 11%, valor bastante superior aos dos demais períodos. As componentes do campo magnético que pouco antes do choque estavam muito próximas ao zero se tornam negativas com uma abrupta recuperação da componente y . As componentes anisotrópicas demonstram ter havido um aumento no fluxo de partículas no sentido do positivo de todas.




Figura 5.3 – Como a Figura 5.2, mas para o período de 27 de outubro de 2003 a 01 de novembro de 2003.

Nesse período Echer et al. (2008) identifica como causas da perturbação geomagnética tanto os campos de bainha quanto uma nuvem magnética.

É possível perceber que no período considerado houve duas perturbações no IMF, e que embora a segunda não seja muito menos intensa que a primeira os efeitos causados na variação da densidade de raios cósmicos são consideravelmente menores que a primeira.

5.2.3 Evento de Novembro de 2003

O evento de Novembro de 2003 traz diversas peculiaridades interessantes como pode ser observado na Figura 5.4 que está organizada como a Figura 5.2. Apesar de registarr uma tempestade geomagnética superintensa (Rockenbach, 2010) o decréscimo na intensidade de raios cósmicos foi de apenas 1,5% e passou por uma recuperação rápida para em seguida sofrer nova queda. As componentes do campo magnético apresentaram comportamentos bastante distintos após o choque: a componente x permaneceu com pouca oscilação em torno do zero, enquanto a componente y se tornou positiva para em seguida ficar pouco negativa e por fim retornar as vizinhanças do valor nulo, de maneira oposta a componente z que, como condição necessária a ocorrência de tempestades geomagnéticas, primeiro assume valores negativos e depois se recupera. As componentes x e y da anisotropia não apresentam grandes variações, porém a componente z se torna positiva para novamente decair.




Figura 5.4 – Como a Figura 5.2 mas para o período de 16 de novembro de 2003 a 24 de novembro de 2003.

No meio interplanetário, embora a nuvem magnética tenha sido precedida por uma região de choque rápida, a tempestade foi causada apenas pela ação do campo magnético da MC. (Echer et al., 2008)

5.2.4 Evento de Dezembro de 2006

Uma característica do evento de Dezembro de 2006 que não é mostrada nos gráficos da Figura 5.5 que estão organizados como os da Figura 5.2, é o fato de que este foi o primeiro evento intenso observado pela GMDN, após estar completa. A variação na densidade de raios cósmicos que chega a 1,5% tem um perfil bastante simétrico sem queda ou ascensão muito abruptos, contudo vale notar que a recuperação foi um pouco mais longa que o decréscimo. Foi esse perfil que levou a este ser o evento selecionado para os teste da seção 5.1. Durante o primeiro choque a componente z do campo magnético assume um valor bastante negativo para depois ficar positiva e seguir decaindo lentamente, componente y novamente se comporta de maneira oposta a z, se tornando muito negativa após o choque e começa ascendendo lentamente em seguida. A componente x da anisotropia permanece negativa em todo o período considerado, as componentes y e z tem um ligeiro aumento no sentido positivo que logo diminui a ponto da componente z inverter seu sentido.




Figura 5.5 – Como a Figura 5.2, mas para o período de 12 de dezembro de 2006 a 18 de dezembro de 2006.

Tal como o evento de novembro de 2003, a variação do índice DST ocorreu devido apenas a dos campos de uma MC embora esta tenha sido precedida por uma região de choque. (Echer et al., 2008)

5.3 TOPOLOGIA DAS REDES

Com o propósito de simular a intensidade de raios cósmicos três arquiteturas diferentes de NN foram adotadas: (1) um perceptron de camadas múltiplas, (2) uma rede NARX no modo paralelo e (3) uma rede NARX no modo série paralelo.

A aplicação do perceptron caracteriza a densidade de raios cósmicos I , como uma simples função não linear das componentes do vetor campo magnético. A topologia da rede NARX não é muito diferente da do MLP, apenas inserindo na NN propriedades dinâmicas, permitindo a ela lidar com informações de iterações anteriores, seja pela mera ação de operadores de atraso (modo série paralelo), ou pela ação conjunta dos operadores e de um processo de retroalimentação (modo paralelo). De qualquer forma, em todas as arquiteturas utilizadas o vetor de entrada básico foi composto das componentes B_x , B_y e B_z do IMF para que a camada de saída determinasse o valor da intensidade de raios cósmicos. Sempre foram utilizados o mesmo algoritmo de treinamento, Levenberg-Maquardt, e as mesmas funções de ativação: para as camadas ocultas a função tangente hiperbólica e para a camada de saída a função linear não restringida. A quantidade de camadas ocultas e do número de neurônios nelas contidos foi obtida pelo método da tentativa e erro com auxílio de um algoritmo de busca elaborado pelo autor deste trabalho no ambiente do Matlab®.

No algoritmo, as características relativas à arquitetura das camadas ocultas da rede eram selecionadas empiricamente e um coeficiente de correlação mínimo entre a simulação e os dados observados também era escolhido de forma empírica. O programa encarregava-se, então, de treinar a rede e obter os dados da simulação para determinar o coeficiente de correlação alcançado. Se o valor do coeficiente fosse inferior ao mínimo estipulado, o processo de treinamento era descartado, a rede reiniciada e um novo treinamento realizado. De outra forma, se o coeficiente resultante da simulação fosse maior que o mínimo, o algoritmo traçava os gráficos sobrepostos da simulação e dos dados observados, além de produzir um pequeno

relatório informando o número de treinamentos realizados, os maiores coeficientes de correlação alcançados, e o tempo de busca decorrido na busca.

Uma janela com um botão de parada súbita foi implementada, para o caso do processo de busca estender-se por um período de tempo muito longo. Quando pressionado o botão, o gráfico resultante da última simulação era traçado e o relatório de busca produzido.

Considerar grande um intervalo de tempo de busca depende muito da arquitetura e do modelo de rede testados. Um MLP com poucos neurônios por camada oculta era capaz de realizar mil treinamentos em menos de uma hora. O modelo de rede NARX – P, com várias dezenas de neurônios por camada, poderia demorar mais de três horas para realizar a mesma quantidade de treinamentos.

Se mesmo após várias horas nenhum treinamento realizado tivesse êxito em superar o coeficiente mínimo, a busca era interrompida e o relatório de busca avaliado. Caso os coeficientes de correlação obtidos fossem próximos ao valor mínimo previamente estipulado pequenos ajustes eram feitos na arquitetura das camadas ocultas, caso contrário ajustes mais drásticos eram executados.

Depois de vários processos de ajustes terem sido realizados sem que o coeficiente mínimo fosse alcançado, o valor do coeficiente mínimo era reduzido e o todo processo de busca reiniciado. De forma contrária, se o valor mínimo fosse alcançado muito rapidamente um coeficiente mínimo maior era escolhido e o processo de busca reiniciado.

A escolha de um valor inicial para o coeficiente de correlação mínimo advinha principalmente do modelo de rede testado. Para os MLPs, sem elementos de memória e de realimentação, valores de correlação entre 0,50 e 0,60 eram inicialmente utilizados. O modelo NARX no modo série paralelo (NARX – SP) só realiza previsões de curto termo, pois funciona como que adicionando ao vetor de entrada mais um item: o valor que foi observado, no momento anterior, da grandeza a ser calculada. Embora sua capacidade de extrapolação fique restrita a uma única iteração, os resultados devem ser mais precisos, pois além da rede não sofrer o efeito de dissipação de gradiente, é sempre alimentada com o valor esperado da grandeza. Desta forma, coeficientes mínimos por volta de 0,90 eram esperados. Em contrapartida quando no modo paralelo (NARX – P) a NN ao invés de utilizar os valores observados da grandeza, aplica no vetor de entrada o valor que ela própria

estimou para grandeza em iterações anteriores permitindo extrapolações de médio e longo prazo, mas traz como consequência o ônus da perda de precisão. Os coeficientes mínimos inicialmente selecionados para este modelo de rede ficavam no intervalo entre 0,7 e 0,8.

A fim de evitar bons resultados advindos de treinamento excessivo as simulações foram realizadas de modo cruzado, isto é, treinada a rede com o conjunto de dados de um período a simulação era realizada apenas com os demais e nestas condições produziram-se doze conjuntos de três simulações.

5.4 RESULTADOS

5.4.1 Redes Treinadas com Evento de Abril de 2001

O evento de abril de 2001 se mostrou um dos mais eficientes para fins de treinamento, produzindo NNs capazes de efetuar simulações bastante satisfatórias quando comparadas as das redes treinadas com os demais períodos.

Os gráficos da Figura 5.6 mostram o resultado final das simulações, e está organizado de modo que no primeiro painel de cima para baixo, traçado em verde, está a simulação realizada pelo perceptron. No painel seguinte, em vermelho, a simulação realizada pela rede NARX no modo paralelo e por último, em azul, a simulação realizada pela rede NARX no modo série paralelo. Em todos os painéis a linha preta ilustra a variação de densidade de raios cósmicos no meio interplanetário como calculada por Rockenbach (2010). Pode se afirmar que todas as três NNs foram capazes de perceber a existência de uma queda por volta da metade do dia 302, mas apenas as redes dinâmicas foram capazes de mais se aproximar da real intensidade do decréscimo incomumente grande.

Os dados obtidos das tentativas de simular o evento de Outubro de 2003 estão resumidos na Figura 5.6 indicando a topologia das camadas e o coeficiente de correlação obtido. Um número único de quantidade de neurônios mostra que uma única camada oculta foi implementada, a presença de dois números mostra que duas camadas foram necessárias indicando a quantidade de neurônios na primeira e na segunda camada consecutivamente, da esquerda para a direita. Sobre cada gráfico de simulação está uma representação gráfica da diferença entre os valores obtidos pela NN e os valores observados, aonde o valor médio e o desvio padrão das diferenças também pode ser auferido. Pode-se notar que a rede baseada no

perceptron de múltiplas camadas, MLP, obteve um índice de correlação R, de 0,56, mas que a presença de características dinâmicas melhorou significativamente esse valor.




Figura 5.6 – Gráficos das simulações obtidas ao simular o evento de outubro de 2003 com redes treinadas pelo evento de abril de 2001. No primeiro painel de cima para baixo, em verde, a simulação realizada pelo perceptron no painel seguinte em vermelho a simulação realizada pela rede NARX no modo paralelo e no painel mais baixo a simulação da rede NARX no modo série paralelo. O painel sobre cada gráfico de simulação mostra a diferença ponto a ponto entre os valores obtidos pelas NNs e os valores observados. Nestes painéis constam ainda, os valores da diferença média ($\bar{D}$) e do desvio padrão (σ) das diferenças obtidas.

O grande número de oscilações ocorridas no perfil da intensidade de radiação cósmico durante o evento de novembro de 2003 produziram as simulações mais pobres dentre as redes treinadas pelo evento de abril de 2001, como se pode notar nos índices de correlação resumidos nos gráficos da Figura 5.7, que estão organizados como os da Figura 5.6. O traçado dos gráficos mostra, contudo, que o resultado não é tão ruim quanto se pode inferir pelos valores de correlação, na verdade as principais oscilações são bem representadas mesmo pelo perceptron, mas oscilações menores ou são ignoradas ou representadas de modo incorreto o que provavelmente acabou por gerar valores pequenos para a correlação. A

simulação de curto prazo mostrou-se bastante eficiente, principalmente após a metade do dia 324.




Figura 5.7 – Como a Figura 5.6, mas para a simulação do evento de novembro de 2003 por redes treinadas pelo evento de abril de 2001.

Organizados como os gráficos da Figura 5.6, os gráficos da Figura 5.8 mostram que as redes com elementos dinâmicos determinaram pontos com valores consideravelmente mais próximos aos valores realmente mensurados, como os valores da diferença média ($\bar{D}$) e do desvio padrão das diferenças (σ) indicam. De maneira diferente ao anterior o evento de dezembro de 2006 é o que produziu simulações com os melhores índices de correlação. Um possível motivo para isso é ao fato de que este evento tem características muito similares ao de uma função. É possível notar que mesmo a rede MLP que não conta com elementos dinâmicos, isto é, componentes relativos a retroalimentação apresentou um coeficiente de correlação não tão distante dos obtidos pelas redes recorrentes.




Figura 5.8 – Como a Figura 5.6, mas para a simulação do evento de dezembro de 2006 por redes treinadas pelo evento de abril de 2001.

5.4.2 Redes Treinadas com Evento de Outubro de 2003

As redes treinadas com o período de Outubro de 2003 tiveram pouco sucesso em reproduzir o perfil da densidade de raios cósmicos dos demais eventos. Uma possível justificativa é o decréscimo registrado na densidade partículas de raios cósmicos ser anormalmente grande no período. É fácil notar que essa característica teve forte influencia nos processos de treinamento. A maioria das simulações replicou o perfil da variação de I com correlações equiparáveis as obtidas pelas redes treinadas com o evento de abril de 2001, porém a magnitude da variação determinada pela rede foi, na maioria das vezes, muito superior a dos dados reais.

A simulação do evento de abril de 2001 foi a que obteve índices de correlação mais altos dentre as treinadas pelo evento de outubro de 2003. É interessante notar a maneira pela qual a densidade de raios cósmicos variou no evento de abril de 2001 é a que mais se assemelha ao evento de outubro 2003.

Os gráficos exibidos pela Figura 5.9 demonstram que as simulações de longo termo (MLP e NARX – P) se afastaram consideravelmente dos valores esperados. A

simulação de curto termo (NARX – SP) exibiu pontos com o mesmo comportamento principalmente no momento de maior perturbação. No modo série paralelo a rede NARX é alimentada com o valor esperado da iteração anterior ao invés do valor que própria rede determinou, o que permite uma “correção” constante de seu comportamento.




Figura 5.9 – Como a Figura 5.6, mas para a simulação do evento de abril de 2001 por redes treinadas pelo evento de outubro de 2003.

Os coeficientes obtidos pelas redes treinadas com o evento de outubro de 2003 ao simular o evento de novembro de 2003 foram bastante baixos. O perfil muito oscilatório do evento de novembro de 2003 obviamente dificultou a tarefa das redes.

Os gráficos mostrados na figura 5.10 exibem o pouco sucesso da simulação e novamente mostram que os valores determinados pelas redes ficaram bem longe dos valores esperados, com exceção da simulação realizada pela rede NARX – SP que demonstrou uma notável precisão ainda que o coeficiente correlação tenha ficado abaixo de 0,9.




Figura 5.10 – Como a Figura 5.6, mas para a simulação do evento de novembro de 2003 por redes treinadas pelo evento de outubro de 2003.

Os gráficos da Figura 5.11 mostram que há uma diferença entre as simulações de dezembro de 2006 e as demais simulações feitas por redes treinadas como o evento de outubro de 2003: mesmo a rede NARX – SP não foi capaz de manter os dados simulados nas vizinhanças dos valores esperados, quando a época de maior variação ocorreu. Os coeficientes de correlação resumidos nos gráficos da Figura 5.11 não são tão baixos quanto os das simulações de novembro de 2003, mas também não são altos com os das simulações de abril de 2001.

É importante notar o modo suave como ocorreu a variação de intensidade de raios cósmicos durante o evento de dezembro 2006, que se contrapõem a súbita descontinuidade de 11% registrada no evento de outubro de 2003. O evento de dezembro de 2006 não é portanto, um candidato natural a simulações realizadas por redes treinadas pelo evento de outubro de 2003.




Figura 5.11 – Como a Figura 5.6, mas para a simulação do evento de dezembro de 2006 por redes treinadas pelo evento de outubro de 2003.

5.4.3 Redes Treinadas com Evento de Novembro de 2003

O evento de novembro de 2003 se mostrou o mais difícil de reproduzir com simulações de outros períodos, porém as redes treinadas com este período mostraram resultados razoavelmente bons. Duas justificativas plausíveis para esse fato são que: (1) as muitas oscilações da densidade de raios cósmicos ocorridas no período, sem a presença de uma variação majoritária evidente, atribuiu as redes que treinou uma capacidade de adaptação que possibilitou simulações mais eficientes. (2) A simulação dos demais eventos é realmente mais simples ficando ao encargo das redes treinadas pelo evento de novembro de 2003 simulações que não exigiram uma capacidade preditiva tão severa quanto às exigidas pelo evento de novembro de 2003.

É importante salientar também que os perceptrons, que não contavam com qualquer componente de memória ou retroalimentação (redes MLP), mostraram se muito ineficientes. Este fato indica a relevância das componentes dinâmicas para obtenção de boas simulações.

Os gráficos ilustrados na Figura 5.12, mostram que mesmo a rede MLP conseguiu replicar a queda da densidade de raios cósmicos após a metade do dia 101 e a suave recuperação que se segue, embora os valores após a queda se afastem significativamente daqueles que seriam os esperados.

Novamente as simulações feitas para o evento de abril de 2001 foram as que obtiveram os maiores índices de correlação e gráficos com pontos nas vizinhanças dos valores esperados.




Figura 5.12 – Como a Figura 5.6, mas para a simulação do evento de abril de 2001 por redes treinadas pelo evento de novembro de 2003.

Ao observar a Figura 5.13 que exibe os gráficos das simulações do período de novembro de 2003 fica claro que a simulação produzida pelo MLP é bastante ruim, principalmente após o dia 302. A intensa queda de 11% quase não é percebida, e pequena queda ocorrida na metade do dia 304 é praticamente ignorada. As redes com componentes dinâmicos produziram simulações satisfatórias nas quais o perfil de variação da intensidade de raios cósmicos fica bem representado. A rede NARX – P, no entanto, em diversos momentos se afastou dos valores de densidade de raios cósmicos esperado, e apenas por volta do dia 304 representou os adequadamente.




Figura 5.13 – Como a Figura 5.6, mas para a simulação do evento de outubro de 2003 por redes treinadas pelo evento de novembro de 2003.

Nas simulações do evento de dezembro de 2006 se destaca o fato do coeficiente de correlação obtido pela rede NARX – SP ser o mais baixo dentre as redes NARX – SP treinadas pelo evento de novembro de 2003.

Os gráficos da Figura 5.14 mostram que o MLP conseguiu determinar a existência da queda na densidade de raios cósmicos e sua subsequente recuperação, no período entre a metade do dia 348 e a metade do dia 349. Porém a simulação ilustra uma queda e recuperação mais bruscas do que as observadas. Também é possível perceber na simulação um curto período em que a densidade mínima permanece constante, o que não corresponde ao esperado. A rede NARX no modo paralelo, também simulou um comportamento diferente do esperado durante a queda de densidade e também exibiu um período de mínimo constante embora mais curto. Por outro lado, a recuperação foi bem simulada e o período de duração da variação principal foi o esperado.




Figura 5.14 – Como a Figura 5.6, mas para a simulação do evento de dezembro de 2006 por redes treinadas pelo evento de novembro de 2003.

5.4.4 Redes Treinadas com Evento de Dezembro de 2006

Exceto pelas simulações produzidas pelas redes NARX – SP o conjunto de dados do evento de dezembro de 2006 mostrou se um treinador apenas razoável. As principais variações estão perceptíveis na maioria das simulações, porém algumas flutuações menores ou foram suprimidas ou surgem fora do período esperado.

Os gráficos resultantes das simulações do evento de abril de 2001 estão exibidos na Figura 5.15. Embora o valor do coeficiente de correlação da simulação feita pela rede NARX no modo paralelo seja o mesmo da simulação da rede NARX no modo série-paralelo, a análise dos gráficos mostra que a qualidade da simulação não foi a mesma. A rede NARX – SP manteve-se muito mais próximo aos valores esperados e simulou as flutuações menores com muito mais eficiência.




Figura 5.15 – Como a Figura 5.6, mas para a simulação do evento de abril de 2001 por redes treinadas pelo evento de dezembro de 2006.

Os gráficos da Figura 5.16 mostram que todas as simulações do evento de outubro de 2003 indicaram a existência de uma severa redução na densidade de raios cósmicos por volta do dia 302, mas da mesma maneira que ocorreu para redes treinadas com outros eventos, tiveram dificuldade em reproduzir a magnitude da queda ocorrida. O desvio padrão das diferenças entre os pontos da rede e os pontos observados na simulação da rede NARX - SP foi um dos valores mais altos atingidos dentre todas as simulações realizadas, mas o alto valor dos coeficientes de correlação obtidos pelas redes com características dinâmicas indica que o perfil de variação foi reproduzido de maneira razoavelmente adequada.




Figura 5.16 – Como a Figura 5.6, mas para a simulação do evento de outubro de 2003 por redes treinadas pelo evento de dezembro de 2006.

As simulações que as redes treinadas com o evento de dezembro de 2006 produziram para o evento de novembro de 2003 foram excepcionalmente ruins.

O fato de que o índice de correlação da rede NARX – SP poder ser considerado baixo é intrigante quando se observa a simulação que produziu. A Figura 5.17 mostra os gráficos obtidos nas simulações do evento de novembro de 2003. De fato, o MLP omite praticamente todas as flutuações menores observadas antes do dia 324 e após o dia 325. E, quando dentro deste intervalo a simulação se afasta bastante dos valores esperados para a intensidade de raios cósmicos. A simulação da rede NARX – P também ficou bastante diferente do que deveria ser, ainda que os pontos da simulação tenham ficado mais próximos aos pontos do evento observado. De maneira totalmente oposta a simulação da rede NARX – SP foi excepcionalmente acurada, acompanhando com bastante precisão mesmo as flutuações menores.




Figura 5.17 – Como a Figura 5.6, mas para a simulação do evento de abril de 2001 por redes treinadas pelo evento de dezembro de 2006.

5.4.5 Simulações do IMF

Por último utilizou-se duas redes NARX, uma no modo paralelo e outra no modo série-paralelo com a intenção de verificar a aplicabilidade das redes neurais recorrentes para, com dados de observações em solo, estimar as condições do Geoespaço utilizando dados de raios cósmicos.

As redes utilizaram as componentes do vetor anisotropia determinados por Rockenbach (2010) para simular a intensidade do campo magnético interplanetário. A arquitetura das redes permaneceu com três elementos no vetor de entrada, um único nodo na última camada e um número variável de camadas ocultas entre elas. As componentes do vetor anisotropia não necessitaram ser normalizadas uma vez que seus valores já se encontravam dentro do intervalo $[-1,1]$, a intensidade do IMF foi normalizada pelo mesmo método de *média zero* utilizado para re-escalar as componentes do vetor IMF para as outras redes e que é descrita pela Equação (5.2).

As redes foram treinadas com dados referentes ao evento de abril de 2001 e aplicadas para simular os valores do IMF durante o evento de dezembro de 2006, para novamente reduzir a possibilidade de *overfitting*. As simulações produzidas

estão representadas nos gráficos da Figura 5.18, bem como a arquitetura das camadas ocultas e os coeficientes de correlação atingidos pelas redes estão resumidos em seus respectivos gráficos.

A simulação da rede NARX – P, foi eficiente ao indicar os períodos em que a intensidade do IMF ultrapassou 10 nT, mas atribui valores bem inferiores aos esperados. Uma justificativa plausível é a de que durante o evento utilizado para o treinamento (abril de 2001) a intensidade do IMF atingiu valores superiores a 40 nT, enquanto durante o evento simulado (dezembro de 2006) a intensidade do IMF ultrapassou 20 nT por um breve período o que levou a rede a subestimar as variações que os componentes do vetor anisotropia apresentaram. A simulação da rede NARX – SP mostrou se bastante precisa tanto quanto ao período de ocorrências quanto à magnitude das variações, mesmo tendo sido treinada pelo mesmo conjunto de dados.




Figura 5.18 – Gráficos das simulações da variação da intensidade do campo magnético durante o evento de dezembro de 2006 realizadas por redes treinadas pelo evento de abril de 2001. No primeiro painel de cima para baixo, em vermelho a simulação realizada pela rede NARX no modo paralelo e no painel mais baixo a simulação da rede NARX no modo série paralelo.

6. CONCLUSÕES

A contagem de raios cósmicos demonstrou ser uma importante fonte de dados e as redes neurais mostraram ser ferramentas bastante poderosas e promissoras quando aplicadas com as devidas precauções.

As partículas de raios cósmicos que atingem a Terra a todo o momento trazem informação espacial, que com o auxílio de métodos e tecnologias adequados, pode ser tão profícua quanto os dados obtidos por meio de tecnologia espacial. O desenvolvimento de estudos e trabalhos que envolvam raios cósmicos fornece não só uma complementação, mas também uma alternativa mais confiável aos dados de origem espacial.

Por meio da GMDN é possível obter informações sobre as condições do Sol e da heliosfera. Flutuações na contagem de raios cósmicos permitem que se obtenham dados sobre eventos como ICMEs e MCs que podem ser utilizados para desenvolver um sistema de alerta de distúrbios magnéticos que não seja tão sensível às condições do Clima Espacial.

As redes neurais oferecem um viés de tratamento empírico de dados, que pode elucidar várias questões sobre raios cósmicos que permanecem em aberto por falta de uma estrutura puramente teórica completamente adequada.

As redes em cuja arquitetura se incluíram componentes de memória, e de retroalimentação (NARX – P e NARX – SP) obtiveram resultados gráficos e coeficientes de correlação sempre superiores as redes estáticas (MLP), sugerindo que a relação temporal entre o IMF e a densidade de raios cósmicos é de caráter não linear e diferencial. Outra constatação foi a de que a componente B_z do IMF tem influência maior se equiparando a ação das outras duas componentes juntas.

A qualidade dos resultados depende muito da atenção e minúcia que se dedica na preparação dos dados, no ajuste dos parâmetros iniciais e no desenvolvimento da arquitetura da NN. Índices matemáticos de qualidade devem ser estabelecidos para que se possa acelerar a busca por uma configuração otimizada. Várias tentativas são necessárias antes de se chegar a uma estrutura computacional que desenvolva as melhores simulações possíveis. Também é necessário estar atento ao efeito de *overfitting*, pelo qual NNs podem produzir indicadores de qualidade altos para redes com pouca capacidade de generalização.

A seleção do conjunto de dados empregado no processo de treinamento é fundamental, já que várias características deste permanecerão impregnadas nas simulações produzidas. Neste sentido, estabelecer um conjunto de dados de treinamento muito grande que englobe vários eventos tornaria o processo de treinamento uma tarefa computacional muito longa e difícil. Uma sugestão interessante para trabalhos futuros seria dividir vários conjuntos de dados de treinamento em classes representativas dos perfis de variação, separando-os por característica como a evolução temporal e a magnitude da variação. Uma vez classificados os conjuntos é possível realizar o treinamento com um conjunto que seja a união de ao menos um representante de cada classe. Isso possivelmente ampliaria a capacidade de generalização da rede sem que o processo de treinamento se tornasse muito complexo e computacionalmente caro. Outro viés para trabalhos futuros seria a inclusão de mais elementos característicos do meio interplanetário, como dados sobre o vento solar e a densidade de partículas no vetor de entrada das redes buscando um conjunto de treinamento de maior qualidade.

Por fim, é sempre importante que qualquer instrumento de simulação e análise seja continuamente avaliado por esforços de pesquisa para que o aproveitamento de suas capacidades computacionais evolua na mesma proporção da necessidade de obter novos dados e informações sobre fenômenos físicos.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ALFVÉN, H., Electric Currents in cosmic plasmas. **Reviews of Geophysics**. v. 15, n. 3, p. 271-284, 1977

ALMEIDA, C.; BAUGH, C. M.; LACEY, C. G.; FRENK, C. S.; GRANATO, G. L.; SILVA, L.; BRESSAN, A., Modelling the Dusty Universe I: Introducing the Artificial Neural Network and first applications to Luminosity and Colour Distributions, **Monthly Notices of the Royal Astronomical Society**, v. 402, p.544-564, 2010

BABCOCK, H. W., The Topology of the Sun's Magnetic Field and the 22-Year Cycle, **Astrophysical Journal**, v. 133, p.572-587, 1961

BEALE, M.; HAGAN, M.T.; DEMUTH, H.B., **Neural Network Toolbox: User's Guide**, Natick: The Mathworks Inc, 2011.

BENGIO, Y.; SIMARD, P.; FRANCONI, P., Learning Long-Term Dependencies with Gradient Descent is Difficult, **IEEE Transactions on Neural Networks**, v. 5, n. 2, p. 157-166, 1994.

BHATTACHAJEE, P.; HILL, C.T.; SCHRAMM, D. N., Grand Unified Theories, Topological Defects and Ultrahigh-Energy Cosmic Rays, **Physical Review Letters**, v. 64, n. 4, p. 567-570, 1992.

BUTCHER, J. C., **Numerical Methods for Ordinary Differential Equations**, Chichester: John Wiley & Sons, 2003.

CAMARGO, S.S., **Um Modelo Neural de Aprimoramento Progressivo para Redução de Dimensionalidade**, Tese (Doutorado), UFRGS, Porto Alegre, 2010.

CANE, H. V., Coronal Mass Ejections and Forbush Decreases, **Space Science Reviews**, v. 93, p. 55 – 77, 2000.

CAVALCANTI, R.R.; GOMES, R.G.C., **Normalização dos Trabalhos Acadêmicos da Univap**, SIBI/UNIVAP, 2009.

CIARAMELLA, A.; DONALEK, C.; STAIANO, A.; AMBROSIO, M.; ARAMO, C.; BENVENUTI, P.; LONGO, G.; MILANO, L.; RAICONI, G.; TAGLIAFERRI, R.; VOLPICELLI, A., Applications of neural networks in astronomy and astroparticle physics, **Recent Research developments in Astronomy and Astrophysics**, v. 2, p. 27-58, 2005

CRONIN, J. W., Cosmic Rays: The Most Energetic Particles in the Universe. **Reviews of Modern Physics**, v. 71, n.2, p. s165-s172, 1999

ECHER, E., GONZALEZ, W. D., TSURUTANI, B. T., GONZALEZ, A. L. C., Interplanetary Conditions Causing Intense Geomagnetic Storms ($Dst \leq -100$ nT) during solar cycle 23 (1996-2006), **Journal of Geophysical Research**, v. 113, 2008

FERNANDES, A. M. R., **Inteligência Artificial: Noções Gerais**, 3. imp, Florianópolis: Visual Books, 2005.

FOLKES, S.R.; LAHAV, O.; MADDOX, S. J., An Artificial Neural Network Approach to Classification of Galaxy Spectra, **Monthly Notices of the Royal Astronomical Society**, v. 283, p.651-665, 1996

GONZALEZ, W. D.; TSURUTANI, B. T. Criteria of interplanetary parameters causing intense magnetic storms ($dst < -100$ nt). **Planet and Space Science**, v. 35, p. 1101-1109, 1987

GONZALEZ, W. D.; JOSELYN, J. A.; KAMIDE, Y.; KROEHL, H.W.; ROSTOKER, G.; TSURUTANI, B. T.; VASYLIUNAS, V.M., What is a geomagnetic storm?, **Journal of Geophysical Research**, v. 99, n. A4, p. 5771-5792, 1994.

GRIEDER, P. K. F., **Cosmic Rays at Earth: Researcher's Reference Manual and Data Book**, Amsterdam: Elsevier Science B.V., 2001.

HAGAN, M.T.; DEMUTH, H.B.; BEALE, M., **Neural Network Design**, Pequim: China Machine Press, 2002.

HAGAN, M.T.; MENHAJ, M.B., Training Feedforward Networks with Marquardt Algorithm, **IEEE Transactions on Neural Networks**, v. 5, n. 6, 1994.

HALL, D. L., DULDIG, M.L., HUMBLE, J.E., The North-South Anisotropy and the Radial Density Gradient of Galactic Cosmic Rays at 1 AU, **Astronomical Society of Australia**, v. 12, p. 153-158, 1995.

HAYKIN, S., **Redes Neurais: Princípios e Prática**, 2. ed, Porto Alegre: Bookman, 2001.

KÓTA, J.; JOKIPII, J.R., Effects of drift on transport of cosmic rays. VI – A three dimensional model including diffusion, **Astrophysical Journal**, v. 265, p. 573-581, 1983.

JIANG, C.; SONG, F., Sunspot Forecasting by Using Chaotic Time-Series analyses and NARX Network, **Journal of Computers**, v. 6, n.7, p. 1424 – 1429, 2011.

JOKIPII, J. R., Propagation of Cosmic Rays in the Solar Wind, **Reviews of Geophysics and Space Physics**, v. 9, n. 1, p. 27 – 87, 1971.

JONES, C. A.; THOMPSON, M. J.; TOBIAS, S.M., The Solar Dynamo, **Space Science Review**, v. 152, p.591-616, 2010

KIVELSON, M. G.; RUSSELL, C. T., **Introduction to Space Physics**, Nova York: Cambridge University Press, 1995.

KOVÁCS, Z.L., **Redes Neurais Artificiais: Fundamentos e Aplicações: Um texto básico**, 4. Ed, São Paulo: Editora Livraria da Física, 2006.

KUWABARA, T. et al, Geometry of an interplanetary CMR on October 29, 2003 deduce from cosmic rays, **Geophysical Research Letters**, v. 31, L19803, 2004

LANGNER, U.W.; POTGIETER, M.S., Modulation of Galactic Protons in an Asymmetrical Heliosphere, **The Astrophysical Journal**, v. 630, p. 1114 – 1124, 2005.

LATTES, C.M.G.; MUIRHEAD, H.; OCCHIALINI, G.P.S.; POWELL, C.F., Processes Evolving Charged Mesons, **Nature**, v. 159, p. 694 – 697, 1947.

LIN, T; HORNE, B.G.; TINO, P.; GILES, C.L., Learning Long-term Dependencies in NARX recurrent networks. In: MEDSKER, L.R.; JAIN, L.C., **Recurrent Neural Networks: Design and Applications**. Boca Raton: CLC Press LLC, 1999.

LONGCOPE, D. W., Topological Methods for the Analysis of Solar Magnetic Fields, **Living Reviews in Solar Physics**, v. 2, n. 7, 2005. Disponível em: <<http://solarphysics.livingreviews.org/Articles/lrsp-2005-7/download/lrsp-2005-7Color.pdf>>. Acesso em: 15 de Outubro de 2012.

MAVROMICHALAKI, H.; SOUVATZOGLOU, G.; SARLANIS, C.; MARIATOS, G.; PLAINAKI, C.; GERONTIDOU, M.; BELOV, A.; EROSHENKO, E.; YANKE, B. Introduction to Space Weather, **Advances in Space Research**, 37, p.1141-1147, 2006.

MCCULLOCH, W.S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity, **Bulletin of Mathematical Biophysics**, v. 5, p.115-133, 1943

MUNAKATA, K.; YASUE, S.; KATO, C.; KOTA, J.; TOKUMARU, M.; KOJIMA, M.; DARWISH, A. A.; KUWABARA, T.; BIEBER, J. W., On the Cross-Field Diffusion of Galactic Cosmic Rays into an ICME, **Advances in Geosciences**, v. 2, p. 115 – 124, 2006.

MURALIKRISHNA, A. **Previsão do índice geomagnético DST utilizando redes neurais artificiais e árvores de decisão**. Dissertação (Mestrado) – INPE, São José dos Campos, 2009.

MURATA, N.; YOSHIZAWA, S.; AMARI, S., Network Information Criterion – Determining the number of hidden units for an artificial neural network model, **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 865-872, 1994

MURSULA, K.; USOSKIN, I. **Heliospheric Physics and Cosmic Rays**. (Oulu University, Finland, 2003), 2003, Lectures Notes

NAGASHIMA, K.; FUJIMOTO, K.; FUJII, Z.; UENO, H.; KONDO, I. Three-dimensional cosmic ray anisotropy in interplanetary space. iv. origin of solar semi-diurnal variation. **Report Ionosphere Space Research Japan**, v. 26, p.31–68, 1972.

OKAZAKI, Y. **Three dimensional anisotropy and density gradient of galactic cosmic rays measured by global muon detector network**. Tese (Doutorado) - Tohoku University, 2008.

PAGANINI, S., **Os múons observados com o detector central do EASCAMP**, Tese (Doutorado) – IFGW, Campinas, 2001.

PARKER, E. N., The Passage of Energetic Charged Particles Through Interplanetary Space, **Planetary and Space Science**, v.13, p. 9-49, 1965

PILKKINEN, T. Space weather: Terrestrial Perspective. **Living Reviews in Solar Physics**, v. 4, n. 1, 2007. Disponível em: <<http://solarphysics.livingreviews.org/Articles/lrsp-2007-1/download/lrsp-2007-1Color.pdf>>. Acesso em: 29 de Abril de 2012.

POMERANTZ, M. A., **Cosmic Rays**, Nova York: Van Nostrand Reinhold Momentum Books, 1976.

PISKUNOV, N., **Cálculo Diferencial e Integral 1**, 6. ed, Moscou: Editorial MIR, 1983

ROJAS,R., **Neural Networks: A Systematical Introduction**, Berlim: Springer, 1996.
Disponível em: <[http:// page.mi.fu-berlin.de/rojas/neural/neuron.pdf](http://page.mi.fu-berlin.de/rojas/neural/neuron.pdf)>. Acesso em: 21 de Maio de 2012.

ROCKENBACH, M.; CONTREIRA, D. B.; MONTEIRO, S.; TRIVEDI, N. B.; MUNAKATA, K.; KUWABARA, T.; SCHUCH, N. J.; Cosmic Ray Muon Observation at Southern Space Observatory – SSO (29°S, 53°W), **Astrophysics and Space Science**, v. 290, p. 389-397, 2004.

ROCKENBACH, M., **Detecção de distúrbios solar-interplanetários combinando observações de satélites e de raios cósmicos de superfície para aplicação em Clima Espacial**. Tese (Doutorado) – INPE, São José dos Campos, 2010.

ROSENBLATT, F., The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, **Psychological Review**, v. 65, n. 8, 1958.

RUSSEL, C. T., **The Solar Wind Interaction with the Earth's Magnetosphere: A Tutorial**, Disponível em: <http://www-ssc.igpp.ucla.edu/ssc/tutorial/solwind_interact_magsphere_tutorial.pdf> . Acesso em: 29 de Abril de 2012.

SCHATTEN, K. H., Current sheet magnetic model for the solar corona. **Cosmic Electrodynamics**, v. 2, p. 232 – 245, 1971

SCHWENN, R., Space weather: The solar perspective. **Living Reviews in Solar Physics**, v. 3, n. 2, p. 5-76, 2006. Disponível em: < <http://solarphysics.livingreviews.org/Articles/lrsp-2006-2/download/lrsp-2006-2Color.pdf> >. Acesso em: 29 de Abril de 2012.

SIEGELMANN, H.T.; HORNE, B.G.; GILES, C.L., Computational Capabilities of Recurrent NARX Neural Networks, **IEEE Transactions on Systems, Man and Cybernetics – Part B: Cybernetics**, v. 27, n. 2, 1997

SILVA, A. V. R., **Nossa Estrela: O Sol**, São Paulo: Editora Livraria da Física, 2006.

SILVA, E.; OLIVEIRA, A.C., **Dicas para a Configuração de Redes Neurais**, Rio de Janeiro, 2001. Disponível em: <http://www.nce.ufrj.br/labic/downloads/dicas_cfg_rna.pdf>. Acesso em 12/05/2012.

SUBRAMANIAN, P. **Forbush Decreases and Space Weather**. Disponível em: <http://www.iiap.res.in/ihy/school/prasad_lecture.pdf>. Acesso em: 30 de Abril de 2012.

STIX, M., **The sun: An Introduction**, 2. ed, New York: Springer-Verlag Heidelberg, 2004

TAGLIAFERRI, R. et al, Neural Networks in Astronomy, **Neural Networks**, v. 16, Special Issue, p. 279-319, 2003.