

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

CENTRO DE CIÊNCIAS MATEMÁTICAS E DA NATUREZA

OBSERVATÓRIO DO VALONGO

DEPARTAMENTO DE ASTRONOMIA

TÍTULO : REDES NEURAS APLICADAS A PREVISÃO DE MANCHAS
SOLARES

ALUNO : Marco Antônio Ribeiro de Almeida

ORIENTADOR : Prof. Dr. Ing. Luiz Pereira Calôba - UFRJ/E.E./COPPE

Projeto de Final de Curso para a obtenção do título de Astrônomo

Agradecimentos

- Ao meu orientador, Prof. Luiz Pereira Calôba, por ter confiado em mim, pela paciência, o apoio e a amizade.
- A diretoria da Escola de Engenharia pelo apoio dado ao longo desses anos.
- A Prof. Encarnación pelo belo ensino de estatística, no qual me possibilitou este trabalho e pelo apoio nas horas mais necessárias ao longo do curso.
- Aos meus amigos do curso de Astronomia.
- Ao Prof. Maurício Bezerra de Souza Jr. da Escola de Engenharia Química pela atenção dada e pelo fornecimento do Redes Neurais Statistica.
- Em especial, ao meu pai (in memorian) e a minha mãe , Bela, pela orientação de vida, carinho e a dedicação sempre sem medir esforços para me ajudar. A minha esposa Mônica, pela compreensão e pelo incentivo. A minha princesa, Tirza, minha adorável filha que ficou algumas horas, talvez dias e muitos finais de semana sem minha companhia e que agora posso retribuir.
- Como não poderia deixar de ser, agradeço a Deus por tudo, pela força, pela inspiração e por ter me orientado para terminar este trabalho.

RESUMO

Este projeto final de curso faz um estudo introdutório sobre Redes Neurais Artificiais (RNA) como uma ferramenta de previsão de séries temporais aplicada a Astronomia, onde se analisa o estudo da série temporal Números de Manchas Solares. O trabalho é dividido em seis capítulos principais: o capítulo um introduz e dá uma idéia geral do trabalho, o capítulo dois analisa conceitualmente as redes neurais, o capítulo três analisa os fundamentos básicos sobre séries temporais, o capítulo quatro estuda a atividade solar, e os dois capítulos seguintes, cinco e seis, desenvolvem os procedimentos práticos estatísticos e sobre redes neurais artificiais.

No estudo sobre RNA analisa-se as partes mais importantes, tais como: função de ativação, arquitetura, treinamento, etc. Para o treinamento das redes optou-se pelo modelo de retropropagação do erro, pois demonstrou resultados satisfatórios.

Para o estudo de séries temporais faz-se um levantamento preliminar sobre a suas componentes principais, os modelos de previsão e alguns conceitos básicos.

Em relação a atividade solar estuda-se as características básicas do Sol e Manchas Solares.

Para os procedimentos práticos estatísticos e sobre redes neurais artificiais estuda-se passo a passo todas as etapas estatísticas e retira-se todas as informações lineares da série para deixar a série residual adequada para o treinamento da rede. Para os procedimentos práticos sobre RNA analisa-se os grupos de treinamento, validação e teste, a função erro - RMS (Root Mean Square) e MSE (Mean Square Error) e determina - se o número ótimo de neurônios na camada intermediária.

Para a avaliação de desempenho da rede foram utilizadas os métodos do cálculo da potência e do erro RMS.

Palavras - Chaves: Séries Temporais, Redes Neurais, Número de Manchas Solares.

ABSTRACT

This report investigates the use of Artificial Neural Networks (ANNs) in time series forecasting in Astronomy. The report covers six major issues: part one introduces and discusses a general idea of the report, part two introduces the Artificial Neural Networks, part three discusses the time series technique, part four presents some aspects on the solar activity and the two following parts presents the development of the statistical analysis and the ANN applications.

In the ANN chapter we analyse some major subjects: the activation function, the architecture, training and some others subjects. The results confirm the Backpropagation as the best training algorithm in this case.

For the application of the ANN procedures, we studied the statistical properties of the sample in order to let the residual series adequate to the neural network training.

For the practical ANN procedures we used training, verification, and testing groups and error functions RMS (Root Mean Square) and MSE (Mean Square Error) to obtain the optimal number of neurons in the hidden level.

The metrics used to evaluate the ANN performance were: Energy and RMS (Root Mean Square) error.

Key - Words: Time Series, Artificial Neural Networks, Sunspot Number

SUMÁRIO

1 - Introdução.....	1
1.1 - Ciência da Computação como Ferramenta para Previsão.....	1
1.2 - Objetivo.....	3
2 - Conceitos sobre Redes Neurais Artificiais.....	4
2.1 - Fundamentos Básicos de Redes Neurais Artificiais.....	4
2.1.1 - Notas Históricas.....	4
2.1.2 - O Sistema Nervoso.....	5
2.1.3 - Neurônio Artificial.....	6
2.1.4 - Função de Ativação.....	7
2.1.5 - Tipos de Arquitetura das Redes Neurais Artificiais.....	9
2.1.6 - Tipos de Treinamento.....	10
2.2 - Modelo "Backpropagation" ou Retropropagação do Erro.....	11
3 - Conceitos Básicos de Séries Temporais.....	13
3.1 - Séries Temporais.....	13
3.2 - Modelos de Previsão.....	14
3.3 - Conceitos Básicos.....	15
3.3.1 - Coeficiente de Correlação.....	16
3.3.2 - Função de AutoCorrelação.....	17
3.4 - Redes Neurais Artificiais como Previsores de Séries Temporais.....	18
3.4.1 - Previsão "Single" e "Multi-Step".....	18
3.4.1.1 - Previsões "Multi-Step".....	19
3.4.1.2 - Previsões "Single-Step".....	19
3.5 - Termos Comparativos entre Redes Neurais e Modelos Estatísticos.....	20
4 - Estudo sobre Atividade Solar.....	21
4.1 - Atividade Solar.....	21
4.1.1 - Sol.....	21
4.1.2 - Manchas Solares.....	23
4.1.2.1 - Introdução.....	23

4.1.2.2 - Visão Geral sobre Manchas Solares.....	24
5 - Procedimentos Práticos Estatísticos.....	26
5.1 - Procedimentos Práticos.....	26
5.1.1 - Pré-Processamento.....	26
6 - Procedimentos Práticos sobre Redes Neurais Artificiais.....	39
6.1 - Grupos de Treinamento, Validação e Teste.....	39
6.2 - Função Erro.....	40
6.3 - Taxa de Aprendizado.....	40
6.4 - Procedimentos Práticos para Viabilizar a Rede Neural Artificial.....	40
6.5 - Desempenho da Rede Neural Artificial.....	46
7 - Conclusão e Proposta para outros trabalhos.....	54
8 - Referências Bibliográficas.....	55

LISTA DE FIGURAS

Figura 1.1 - Exemplo de uma Rede Neural Artificial Multicamada.....	2
Figura 2.1 - Neurônio Humano.....	6
Figura 2.2 - Neurônio Artificial.....	7
Figura 2.3 - Função Logística.....	8
Figura 2.4 - Função Tangente Hiperbólica.....	8
Figura 2.5 - RNA Não Recorrente.....	9
Figura 2.6 - RNA Recorrente.....	10
Figura 2.7 - RNA Multi-Camada com Algoritmo de Retropropagação.....	12
Figura 3.1 - Série Temporal.....	15
Figura 3.2 - Função Autocorrelação.....	17
Figura 4.1 - Diagrama Borboleta.....	25
Figura 5.1 - Número de Manchas Solares.....	27
Figura 5.2 - Série retirada a média.....	28
Figura 5.3 - Série retirada a tendência.....	29
Figura 5.4 - Densidade Espectral indicando um ciclo de 122,4.....	31
Figura 5.5 - Ciclo 122,4 retirado no domínio do tempo.....	31
Figura 5.6 - Ciclo 122,4 retirado no domínio da frequência.....	32
Figura 5.7 - Ciclo 306 retirado no domínio do tempo.....	32
Figura 5.8 - Ciclo 306 retirado no domínio da frequência.....	33
Figura 5.9 - Ciclo 68 retirado no domínio do tempo.....	33
Figura 5.10 - Ciclo 68 retirado no domínio da frequência.....	34
Figura 5.11 - Função Autocorrelação da série residual.....	35
Figura 5.12 - Série Residual diferenciada de ordem 1.....	36
Figura 5.13 - Série retirada a magnitude.....	37
Figura 5.14 - Série retirada a dependência linear.....	37
Figura 5.15 - Série retirada a magnitude no domínio do tempo.....	38
Figura 5.16 - Série retirada a magnitude no domínio da frequência.....	38
Figura 6.1 - RMS Treinamento/Validação x N. Neurônio na camada intermediária.....	42
Figura 6.2 - RMS Validação x N. Neurônio na camada intermediária.....	42
Figura 6.3 - Erro Treinamento/Validação x Época.....	43
Figura 6.4 - Valores do Alvo e da Saída da Rede para o intervalo entre os cases 3 e 20.....	44

Figura 6.5 – Valores do Alvo e da Saída da rede para o intervalo entre os cases 240 e 257.....	44
Figura 6.6 – Valores do Alvo e da Saída da rede para o intervalo entre os cases 420 e 437.....	45
Figura 6.7 – Valores do Alvo e da Saída da rede para o intervalo entre os cases 510 e 527.....	45
Figura 6.8 - Valor Previsto pela RNA x Valor Alvo 1 passo a frente.....	47
Figura 6.9 - Valor Previsto pela RNA x Valor Alvo 2 passos a frente.....	47
Figura 6.10 - Valor Previsto pela RNA x Valor Observado 1 passo a frente.....	50
Figura 6.11 - Valor Previsto pela RNA x Valor Observado 2 passos a frente.....	50
Figura 6.12 - Série Prevista atrasada 1 mês x Série Observada	53

LISTA DE TABELAS

Tabela 3.1 - Termos entre RNA e Modelos Estatísticos.....	20
Tabela 5.1 - Valores Previstos pela RNA e Valores Alvos para 1 passo a frente.....	48
Tabela 5.2 - Valores Previstos pela RNA e Valores Alvos para 2 passos a frente.....	48
Tabela 5.3 - Valores Previstos pela RNA e Valores Observados para 1 passo a frente.....	51
Tabela 5.4 - Valores Previstos pela RNA e Valores Observados para 2 passos a frente.....	51
Tabela 5.5 – Resultados das Potências e erro RMS da Série atrasada.....	51

Capítulo 1 - Introdução

Este capítulo tem como função introduzir de forma rápida a computação neural, dar uma idéia geral do trabalho, e demonstrar como ele está organizado.

1.1 - Ciência da Computação como Ferramenta para Previsão

De certa forma, a Inteligência Artificial é a parte da ciência da computação onde se desenvolvem sistemas inteligentes, que possuem uma capacidade de execução de trabalhos específicos, em que os sistemas tradicionais não são eficazes. Assim, a computação neural tenta copiar o funcionamento do cérebro humano na resolução de problemas de reconhecimento de padrões, pois suas características são desejáveis em qualquer sistema artificial tais como: robustez; tolerância a falhas; flexibilidade; capacidade para lidar com informações probabilísticas, ruidosas ou inconsistentes; processamento paralelo; arquitetura compacta e com pouca dissipação de energia. Outras características, tais como: capacidade de aprendizado, generalização e associação, geraram um crescimento no estudo deste tipo de computação[1].

No estudo da ciência da computação destacam-se dois conceitos diferentes quanto aos tratamentos das funções cognitivas: simbolista e conexionista.

Conforme citado por Raposo[2]:

“Os sistemas simbolistas são compostos de símbolos, combinando-se e assim formando as expressões e estruturas que operam sobre expressões. As estruturas são capazes de modificar, destruir, reproduzir ou criar novas expressões. A concepção simbolista toma as soluções ou problemas como um processo essencialmente algorítmico, e tem sido largamente utilizado, em certas áreas, tais como: robótica, sistemas especialistas, etc. Porém, tem encontrado grandes limitações, pelo seu caráter seqüencial e centralizador em tarefas como percepção, controle motor, associação e outras atividades, por serem difíceis de algoritmizar de forma eficiente.”

Em relação aos conexionistas Raposo[2], cita que:

“Os conexionistas se inspiram no sistema neuronal biológico. Para eles as informações inteligentes devem ser processadas tal como no cérebro: de forma paralela por um conjunto de elementos computacionais simples, ex.: redes neuronais.”

A Rede Neural Artificial (RNA) é um software contendo elementos processadores (EPs) com várias interligações, fazendo processamento em paralelo com o intuito de executar determinadas tarefas (fig.1.1). Os EPs foram elaborados a partir dos neurônios biológicos, atuando e organizando-se de forma semelhante aos neurônios do cérebro. Os EPs tem uma estrutura muito mais simples do que os neurônios biológicos, possuindo apenas um algoritmo matemático que tem como objetivo processar as informações em resposta aos estímulos de outros EPs que o antecederam.




Figura 1.1-Exemplo de uma Rede Neural Artificial Multicamada

As RNAs são muito aplicadas na área de reconhecimento de padrões, que representam uma grande classe de problemas do mundo real: processamento de imagens, processamento de linguagem natural, previsão e otimização, etc. Vários dos problemas acima continuam sem soluções razoáveis quando se tenta resolvê-los pelos métodos clássicos[1].

Um dos problemas que tem recebido bastante prioridade nos últimos anos é a previsão de séries temporais. As RNAs compõem uma poderosa ferramenta na previsão de séries temporais.

As RNAs possuem capacidade de estabelecer relações não lineares complicadas através de dados de entrada ruidosos, produzindo ótimos resultados, na maioria das vezes superiores aos obtidos por métodos estatísticos clássicos.

1.2 - Objetivo

O objetivo principal deste trabalho é estudar o uso de Redes Neurais Artificiais como ferramenta para previsão de séries temporais, usando o modelo de "Retropropagação" do erro. Este trabalho aplica a modelagem por RNAs para previsão de séries de MANCHAS SOLARES.

No capítulo 1 é fornecido o conhecimento básico sobre a ciência da computação como ferramenta de previsão. São abordados conceitos sobre funções cognitivas, características do cérebro importantes para as RNAs e aplicações de um modo geral.

No capítulo 2 analisa-se as RNAs. São dadas informações sobre sua história, o sistema nervoso central do ser humano e neurônio artificial. Posteriormente, aborda-se tecnicamente a função de ativação, tipos de arquitetura, treinamento e o modelo de retropropagação do erro.

Já no capítulo 3 analisam-se os conceitos básicos de séries temporais, informando-se as principais etapas para modelagem. Conceituam-se também as componentes de uma série temporal e os procedimentos de previsão. Estuda-se o uso de RNA na previsão de séries temporais.

No capítulo 4 fornecemos dados sobre o Sol e as manchas solares. Em relação ao Sol são dadas suas características básicas, informações sobre as manchas solares e a fórmula para se calcular o índice R, número de manchas solares.

No capítulo 5 faz-se a decomposição e a padronização da série temporal do número de manchas solares por mês, com objetivo de melhorar o desempenho da rede.

No capítulo 6 trabalha-se diretamente com a rede para obtenção dos resultados e análise dos mesmos.

Por fim, no capítulo 7 são tiradas as conclusões e são feitas propostas para trabalhos futuros.

Capítulo 2 – Conceitos sobre Redes Neurais

2.1 - Fundamentos Básicos de Redes Neurais

2.1.1 - Notas Históricas

Podemos dizer que a era moderna das redes neurais iniciou-se em 1943, através do trabalho pioneiro de McCulloch e Pitts. De acordo com Rall (1990), em 1943 McCulloch e Pitts mostraram a comunidade internacional seu célebre trabalho sobre modelagem neural.

Outro trabalho importante foi o livro de Wiener, chamado *Cybernetics*, publicado em 1948, onde ele demonstra conceitos de controle, comunicação e processamento de sinal; em 1961, já na segunda edição, Wiener adiciona novos materiais sobre aprendizagem e auto organização. Wiener no seu livro apresenta o alcance do significado físico da mecânica estatística no contexto do assunto, sendo que Hopfield, 30 anos mais tarde, é quem vai fazer a conexão entre a mecânica estatística e o sistema de aprendizagem.

Em 1949, Hebb publica o livro *The Organization of Behavior*, em que estabelece pela primeira vez uma regra de aprendizagem por modificação sináptica. Seu trabalho não recebeu a devida atenção da comunidade de engenharia. Deve-se salientar que o conceito de grupo neural tem maiores implicações do que o postulado de aprendizagem de Hebb. O trabalho de Hebb é fonte para o desenvolvimento de modelos computacionais de "aprendizagem e sistemas adaptativos".

Em 1956, o trabalho de Rochester, Holland, Habit e Duda foi a primeira tentativa de se usar simulação computacional para testar o postulado de Hebb para aprendizagem.

Neste mesmo ano, Uttley demonstrou que uma rede neural com sinapses suscetíveis a modificação podiam aprender a classificar grupos simples de padrões binários dentro das classes correspondentes.

Temos em 1954, o trabalho de doutorado de Minsky que se chamava: "Theory of Neural-Analog Reinforcement System and Its Application to the Brain-Model Problem".

Em 1961, Minsky produziu um trabalho sobre inteligência artificial que se chamava "Steps Toward Artificial Intelligence", onde se encontra um capítulo sobre o que nós chamamos hoje de redes neurais.

Também, em 1954, Gabor propõem a idéia de um "Filtro Adaptativo Não Linear" e em 1956 Taylor desenvolve o trabalho sobre "Memória Associativa".

No final da década de 50, Rosenblatt (1958) apresenta seu trabalho sobre o "Perceptron" que trata do problema de reconhecimento de padrão. O entusiasmo de muitos pesquisadores na área foi enorme e estes passaram a acreditar que os "perceptrons" seriam uma base para uma inteligência artificial. Mas, em 1969, o livro de Minsky e Papert, demonstram com uma matemática elegante os limites impostos das redes neurais de uma única camada de Rosenblatt.

A década de 70 e início da de 80 foi marcada pelo desinteresse nas redes neurais. Poucos pesquisadores como Amari Grossberg, Anderson, Hopfield, Marr, Kohonen, von der Malsburg e Copper continuaram trabalhando nessa área. Em 1982, Hopfield introduz a noção de função energia e dá ênfase a noção de memórias como atratores dinamicamente estáveis.

Em 1983, Kirkpatrick, Galatt e Vecchi demonstram uma técnica nova, para resolver problemas de otimização, que se chama Simulated Annealing (Recozimento Simulado). Esta técnica é baseada em termodinâmica estatística.

Contudo, na década de 80 a idéia de Rasenblatt, através dos "perceptrons" ainda continua a ter influência, já que através de suas teorias, outros pesquisadores desenvolveram algoritmos para os ajustes dos pesos das redes neurais multi-camadas, de onde surge o algoritmo "Backpropagation"(retropropagação). Discute-se que Werbus em 1974, na sua tese de doutorado já teria proposto o "Backpropagation" e, em 1985, através de trabalhos independentes, Rumelhart, Hinton e Williams teriam desenvolvido o algoritmo "Backpropagation" e Parker e Le Cun propuseram algoritmos semelhantes.

Com o advento do "Backpropagation" o interesse em redes neurais torna a crescer agora com bases mais maduras e conscientes. Hoje, a teoria de redes neurais é aplicada a várias áreas, daí o interesse das companhias na comercialização desta tecnologia. Paralelamente a isto as pesquisas tem crescido de forma significativa onde novas áreas de atuação de redes neurais tem surgido: compressão de imagem e voz, reconhecimento de caracteres manuscrito (correio), em diagnóstico médico, na área de energia elétrica e previsões de séries temporais, por exemplo em Astronomia.

2.1.2 - O Sistema Nervoso

O sistema nervoso central do ser humano é formado pelo encéfalo(do qual faz parte o cérebro) e pela medula espinhal, onde sua função básica e as condições de comunicação são feitas através de sinais elétricos entre o cérebro e os outros órgãos do ser humano.

O cérebro do ser humano possui células chamadas neurônios (fig. 2.1). São cerca de 10 bilhões de neurônios no cérebro.

A estrutura básica de um neurônio é formada pelo núcleo localizado no corpo celular também chamado de pericário, mas por norma vamos chamar de soma. Os prolongamentos que partem do corpo celular, com aparências de raízes são chamados de dendritos e estabelecem conexões com outras células. Existe um único prolongamento mais longo que parte do corpo da célula e que se chama axônio, em cuja terminação existem ramificações e sub - ramificações. Os pontos de conexão entre os neurônios estão localizados no final dessas ramificações, estas são chamadas de junções sinápticas ou sinapses. As sinapses estabelecem a conexão de um axônio com os dendritos ou mesmo com o corpo celular de um outro neurônio. Tipicamente, um axônio é capaz de estabelecer milhares de sinapses com outras células nervosas. A idéia corrente é que as sinapses são responsáveis pelo conhecimento e aprendizagem dos seres vivos.

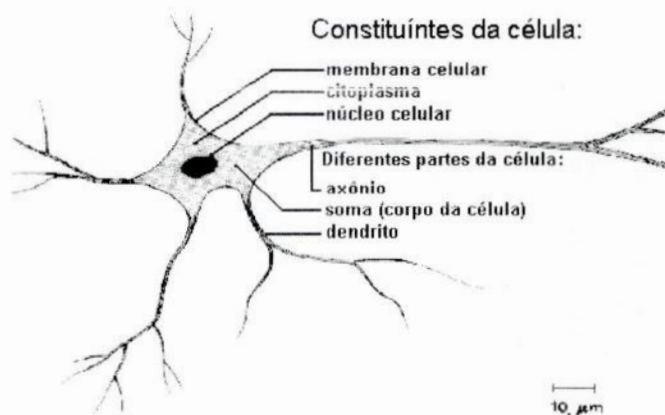


Fig. 2.1 - Neurônio Humano

2.1.3 - Neurônio Artificial

Sabe-se que a transmissão do sinal entre células é um processo muito complexo, sendo liberadas substâncias chamadas neurotransmissoras a partir da terminação pré-sináptica. Após a ligação do neurotransmissor com o receptor existente na terminação pós-sináptica produz-se um efeito no qual o potencial elétrico no corpo da célula receptora pode apresentar um aumento ou uma queda. O potencial elétrico alcançando um determinado limite de ativação, a

célula libera um pulso de tempo fixo que é enviado através do axônio. Nesta condição considera-se o neurônio ativo.

O neurônio artificial (NA) foi desenvolvido para reproduzir as características de um neurônio biológico em primeira ordem [1]. A fig. 2.2 mostra um esquema de um NA.




Fig. 2.2 - Neurônio Artificial

De certa forma, os neurônios artificiais apresentam um conjunto de entradas e assim também representam a saída de outros neurônios. Cada entrada é multiplicada por um peso (W_{ij}) onde normalmente varia entre $-0,1$ e $0,1$ inclusive, formando entradas ponderadas, podendo assumir valores positivos, negativos ou nulos, correspondendo, respectivamente, as sinapses excitatórias, inibitórias e a ausência de sinapse.

Logo a seguir somam-se todas as entradas ponderadas, obtendo-se um valor soma que será comparado com o valor limite para ativação do neurônio (A). Assim, determinamos um padrão de ativação.

2.1.4 - Função de Ativação

A função de ativação A é responsável pelo processamento do sinal soma e produzirá a saída final do neurônio, no caso chamamos de OUTPUT. A função A pode ser de várias formas, podemos ter: uma função linear, uma função limiar (função degrau). Se A for uma função linear, o neurônio terá a seguinte saída:

$$\text{OUTPUT} = C * (\text{soma}) \quad (2.1),$$

onde C é uma constante. Se for uma função limiar, a saída do neurônio será :

$$\text{OUTPUT} = 1 \quad \text{Se soma} > D$$

$$\text{OUTPUT} = 0 \quad \text{Caso contrário} \quad (2.2)$$

onde D é o valor de limiar do neurônio artificial. A função de ativação com maior uso é a função logística (fig.2.3), e sua representação matemática é dada por:

$$F(x) = (1 + e^{-x})^{-1}$$

Para o caso do nosso neurônio artificial tem-se:

$$\text{OUTPUT} = (1 + e^{-\text{soma}})^{-1} \quad (2.3)$$

Uma outra função de ativação muito usada é a tangente hiperbólica (fig.2.4). Tem sua forma similar a da sigmóide e sua representação matemática é:

$$F(x) = [\exp(x) - \exp(-x)] / [\exp(x) + \exp(-x)].$$

$$\text{OUTPUT} = \tanh(\text{soma}) \quad (2.4)$$




Fig. 2.3 - Função logística




Fig. 2.4 - Função tangente hiperbólica

2.1.5 – Tipos de Arquitetura das Redes Neurais Artificiais

Das diversas topologias de redes neurais podemos distinguir basicamente entre duas classes :

- Não-recorrente

As RNAs não recorrentes são aquelas onde os neurônios estão conectados com os neurônios das camadas posteriores, não podendo se conectar com os neurônios da mesma camada. As RNAs não-recorrentes podem ser de uma camada (camada única) ou mais de uma camada (multi-camadas). As redes multi-camadas são representadas por um conjunto de neurônios de entrada, uma ou mais camadas intermediárias e uma camada de saída. A camada de saída é aquela onde os neurônios fornecem a saída da rede(fig.2.5).

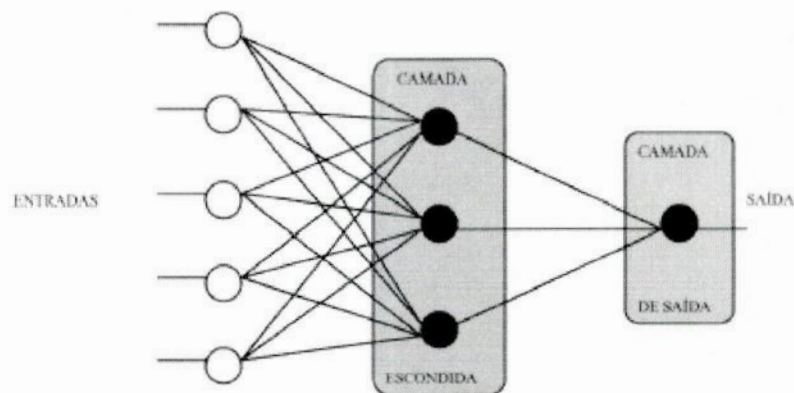


Fig. 2.5 - RNA Não Recorrente

- Recorrentes

As RNAs recorrentes (fig.2.6) são aquelas onde os neurônios estão conectados aos neurônios das camadas anteriores, posteriores e da mesma camada, criando interconexões complexas.

Com relação as suas estruturas podem ou não ser organizadas em camadas.




Fig. 2.6 - RNA Recorrente

2.1.6 – Tipos de Treinamento

A idéia do treinamento é ajustar os pesos das sinapses com a finalidade de otimizar o desempenho da rede. O treinamento é feito através da apresentação em seqüência de um conjunto de dados de entrada (vetor de entrada) e desta forma os pesos são ajustados e assim convergindo para determinados valores obtendo um conjunto de dados de saída (vetor de saída).

As regras de aprendizado são classificadas em dois tipos:

- Supervisionado

No treinamento supervisionado o sistema é treinado com exemplos, ou seja, com padrões de entrada juntamente com o vetor de saída ou alvo: aplica-se o vetor de entrada; com isto a saída da rede é obtida através de cálculo e comparada com o vetor alvo. O erro é obtido e realimentado através da rede e os pesos são ajustados de acordo com um algoritmo determinado, com a finalidade de minimizar o erro. O treinamento é realizado várias vezes até que os erros para os padrões de entrada atinjam o objetivo final.

- Não - supervisionado

No treinamento não supervisionado não é dado nenhum tipo de informação a não ser os vetores de entrada. O próprio sistema aprende, sem ter conhecimento prévio da saída desejada. Neste processo de treinamento obtêm-se as propriedades estatísticas do conjunto de treinamento e agrupa-se os vetores similares em classes.

Com respeito aos algoritmos de treinamento usados, existe uma enorme variedade, tanto para o treinamento supervisionado, como para o não - supervisionado, sendo o mais usado o algoritmo de retropropagação do erro (“Error Backpropagation”) que é o utilizado neste trabalho.

2.2 – Modelo “Error Backpropagation” ou Retropropagação do erro

No algoritmo de retropropagação alteramos os pesos da RNA, tentando minimizar o erro obtido na saída através do aprendizado do vetor de treinamento. Neste caso, o algoritmo está baseado no método do gradiente descendente, onde para uma medida de erro $E[W]$ tenta-se aprimorar o conjunto de pesos W_{ij} . O método do gradiente descendente tenta mudar os pesos W_{ij} por uma quantidade ΔW_{ij} proporcional ao gradiente de E :

$$\Delta W_{ij} = -\eta * (\partial E / \partial W_{ij}) \quad (2.5)$$

onde $\eta > 0$ (variando entre 0.1 e 0.001 inclusive) é chamado de taxa de aprendizado, i refere-se ao neurônio i da camada posterior e j ao neurônio j da camada anterior. Calculando-se a derivada temos, para a camada de saída:

$$\Delta W_{ij} = \eta * \delta_i * X_j \quad (2.6) \quad , \text{ onde :}$$

$\delta_i = (D - O) * A'(soma) \quad (2.7)$ e X_j é o resultado da função de ativação.

Na equação (2.7) $A'(soma)$ é a derivada da função de ativação, D é o vetor alvo e O é a saída fornecida pela RNA.

No entanto, para as camadas intermediárias o procedimento é mais complicado. Demonstra-se que, para se calcular o delta (δ) deve-se substituir a diferença entre o vetor alvo e a saída dada pela RNA, na equação (2.7) pelo somatório dos produtos entre os pesos que ligam o neurônio analisado com os neurônios da camada de saída e os deltas dos respectivos neurônios da camada de saída:

$$\delta_i = (\sum_j (\delta_j * W_{ij})) * A'(soma) \quad (2.8)$$

Depois de se calcular o δ para o neurônio i , os pesos deste neurônio podem ser ajustados através da equação (2.6) e assim sucessivamente para todos os neurônios da camada intermediária. Se existir mais de uma camada intermediária procede-se da mesma forma, ou seja, os deltas devem ser calculados e todos os pesos ligados àquela camada devem ser ajustados, com uma vantagem já que a camada intermediária posterior é considerada como referência para o cálculo do delta.

A fig.(2.7) mostra uma rede multi-camada apropriada para o treinamento com o algoritmo de retropropagação.




Fig. 2.7 - RNA Multi-Camada com Algoritmo de Retropropagação

Como procedimento de início do treinamento, escolhe-se aleatoriamente valores pequenos para todos os pesos, desta forma tem-se a certeza de que não haverá saturação da rede por pesos com valores altos, prevenindo-se assim certos problemas de treinamento.

O procedimento para o treinamento é dado por:

1. Selecionar o conjunto de treinamento.
2. Aplicar o vetor de entrada a rede.
3. Calcular a saída de rede.
4. Calcular o erro entre a saída da rede e a saída do alvo.
5. Ajustar os pesos da rede de forma a minimizar o erro.
6. Repetir o passo 1 até o 4 para cada vetor do conjunto de treinamento, até que o erro se torne baixo o suficiente para o conjunto inteiro.

Apesar de tudo o que foi dito anteriormente existem alguns aspectos negativos das RNAs, tais como a não existência de um procedimento analítico confiável para se determinar o número de camadas intermediárias ou o número de neurônios na camada intermediária. Os resultados obtidos pelas RNAs estão ligados aos pesos das sinapses o que impossibilita a unicidade dos resultados. Um outro problema encontrado nas RNAs é quanto a sua não convergência, em decorrência da presença de mínimos locais. Daí criou-se um fator chamado termo de momentum, com o objetivo de minimizar este problema.

Capítulo 3 - Conceitos Básicos de Séries Temporais

3.1 – Séries Temporais

Uma série temporal é um conjunto de observações dependentes no tempo, executadas de forma seqüencial. A análise de séries temporais nos dias atuais é muito importante para a Metodologia Estatística, já que fenômenos físicos (p.e.: Manchas Solares), biológicos, econômicos, etc. fazem parte desta categoria.

O principal objetivo do estudo de uma série temporal é elaborar um modelo para facilitar a compreensão do comportamento do fenômeno que originou a série, facilitar o controle, determinar períodos importantes e fazer previsões para o futuro.

A importância da análise de uma série temporal é tentar reunir suas propriedades e identificar suas características relevantes. Esta análise pode ser feita no domínio do tempo ou da frequência de forma complementar. No domínio do tempo devemos analisar a relação entre as observações ao longo do tempo em instantes diferentes; já no domínio da frequência desejamos verificar a frequência de ocorrência dos eventos ao longo de certos períodos de tempo.

Em relação a modelagem deve-se criar um modelo adequado para uma série temporal.

Devem-se destacar três principais etapas para modelagem:

1. Identificação do modelo
2. Ajuste do modelo
3. Diagnóstico do modelo

Para todos os modelos probabilísticos ou estocásticos construídos para as séries temporais devemos estar atentos a alguns detalhes, tais como: o princípio da parcimônia, a simplicidade do modelo e de certa forma a facilidade de uso do modelo por outras pessoas com interesse em manipulá-lo.

Segundo SPEIGEL[4] as séries temporais podem ser classificadas em quatro tipos principais, que denominamos componentes de uma série temporal:

1. Tendência
2. Cíclica
3. Sazonal

4. Erro

As componentes de tendência: São alterações lentas a longo prazo. Como exemplo, temos o Produto Interno Bruto.

As componentes cíclicas: Estas componentes relacionam-se com as alterações de alta e baixa ao longo da reta de tendência. Normalmente, os ciclos podem apresentar ou não períodos, ou seja, podem acompanhar ou não os padrões idênticos, após intervalos de tempos iguais. Como exemplo, temos os ciclos de negócios.

As componentes sazonais: São componentes com comportamento oscilatório de alta e baixa nas séries que apresentam padrões idênticos em um determinado período, que pode ser mês, ano, semana ou dia.

A componente de erro (ou irregular ou aleatória): Apresenta alterações ascendente e descendente da série, provocados por eventos de curto período, depois do surgimento de um efeito de tendência, cíclico, ou de sazonalidade, tais como: políticos, climáticos, etc.

3.2 – Modelos de Previsão

Em relação às técnicas de previsão um dos tipos utilizados é quanto ao número de séries temporais.

As técnicas de previsão podem ser classificadas em três tipos[1]:

Modelo Univariado: É aquele modelo que utiliza uma única série histórica.

Modelo de Função de Transferência: Este modelo utiliza uma série histórica, onde ela é analisada pelo seu histórico anterior e também para outras séries temporais que não são correlacionadas entre si.

Modelo Multivariado: Tipo de modelo que trabalha com duas ou mais séries temporais ao mesmo tempo e não tem necessariamente uma relação de causalidade entre si.

3.3 – Conceitos Básicos

Uma série temporal é um conjunto de observações de uma variável, Z , onde esta variável é observada em intervalos de tempo iguais ou não (fig. 3.1). Se uma série tiver n observações será denotada por Z_1, \dots, Z_n . Deve-se salientar que as observações são dependentes e o seu estudo consiste em analisar essa dependência. Neste trabalho vamos analisar séries no domínio do tempo e igualmente espaçadas.

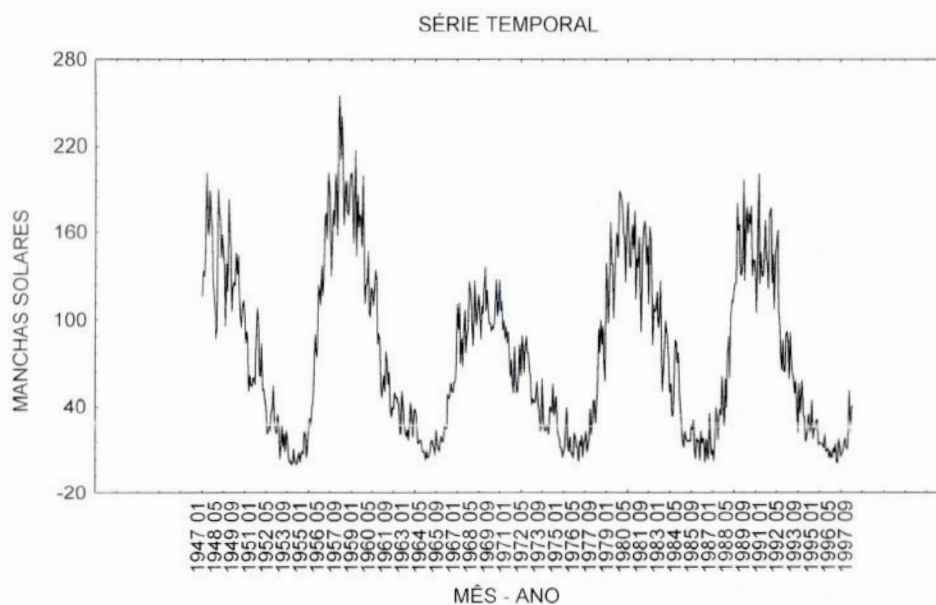


Fig. 3.1 - Série temporal

Considerações a serem feitas.

A variável Z pode ser:

- Discreta ou contínua
- Univariada ou multivariada

O índice T , que neste trabalho é "tempo" pode ser:

- Discreto ou contínuo
- Unidimensional ou multidimensional

Para este trabalho, Z é o número de manchas solares, de natureza discreta, unidimensional e observado em intervalos equiespaçados. Desta forma, para cada t , Z_t é uma variável aleatória, ou seja, para instantes t_1, \dots, t_n , teremos uma série temporal qualquer, Z_1, \dots, Z_n .

Com isto vê-se que a seqüência de variáveis aleatórias acima $[Z_1, \dots, Z_n]$ é conhecida como processo estocástico. Em um processo estocástico, cada observação é uma variável aleatória dada por leis probabilísticas e estas observações evoluem no tempo.

3.3.1 - Coeficiente de correlação

O coeficiente de correlação (ρ) é uma quantidade adimensional que varia entre -1 e +1, e mede o grau de dependência linear entre duas variáveis. Se ρ possui valores próximos de +1 ou -1 temos uma forte relação linear entre as variáveis, sendo que ρ próximo de zero significa que não existe tal relação, podendo existir outra. Quando as variáveis são independentes, o coeficiente de correlação é nulo, mas o fato de termos ρ igual a zero não significa que possamos afirmar nada quanto a sua dependência[3].

$$\rho_{t,s} = \text{Corr}(Z_t, Z_s) \text{ para } t, s = 0, 1, 2, \dots \quad \text{onde}$$

$$\text{Corr}(Z_t, Z_s) = \text{Cov}(Z_t, Z_s) / [\text{Var}(Z_t)\text{Var}(Z_s)]^{1/2} = \gamma_{t,s} / (\gamma_{t,t}\gamma_{s,s})^{1/2}, \quad \text{onde}$$

Z_t e Z_s são processos estocásticos nos tempos t e s , respectivamente.

$\gamma_{t,s} = \text{Cov}(Z_t, Z_s)$ é a covariância entre Z_t e Z_s para $t, s = 0, 1, 2, \dots$ e é dado por:

$$\text{Cov}(Z_t, Z_s) = E[(Z_t - \mu_t)(Z_s - \mu_s)] = E(Z_t Z_s) - \mu_t \mu_s, \quad \text{sendo que:}$$

$\mu_t = E(Z_t)$ e $\mu_s = E(Z_s)$ para $t, s = 0, 1, 2, \dots$, onde μ_t e μ_s são os valores esperados do processo nos tempos t e s , respectivamente.

Conforme Gonzalez[3]:

"A covariância é uma medida da dependência linear entre variáveis aleatórias mas a correlação, por ser adimensional, é mais fácil de ser analisada."

3.3.2 - Função de Autocorrelação

A Função de Autocorrelação (FAC) mede a linearidade entre as observações numa série temporal dado por um passo k .

A Função Autocorrelação é obtida ao plotarmos $\rho(k)$ contra k (fig. 3.2). Considera-se a FAC a principal ferramenta para análise de uma série temporal no domínio do tempo.

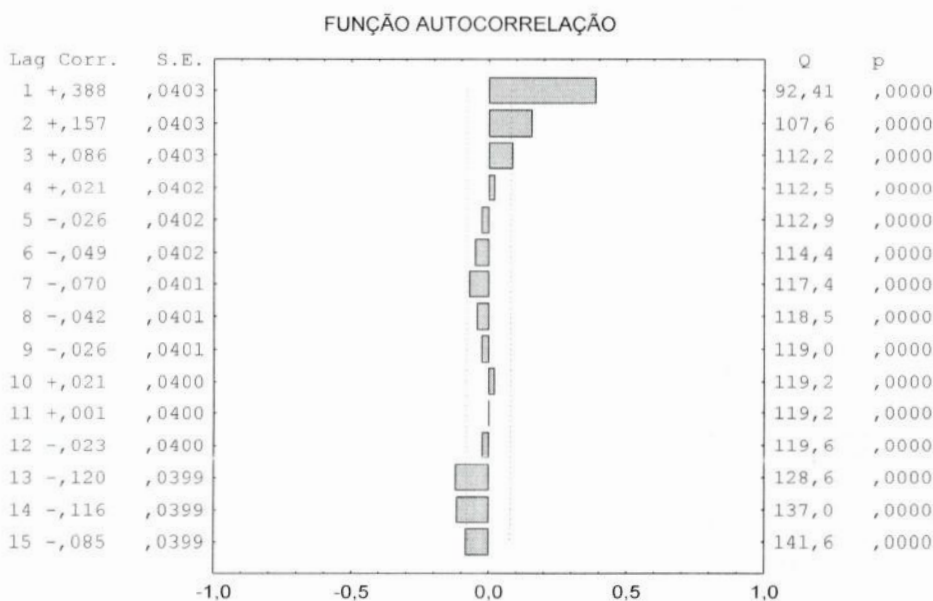


Fig. 3.2 - Função Autocorrelação

3.4 - Redes Neurais Artificiais como Previsoras de Séries Temporais

Ao se fazer uma análise ou previsão de séries temporais utilizando métodos estatísticos deve-se trabalhar a série com o intuito de deixá-la nas melhores condições possíveis e ainda criar um modelo matemático para esta série. Ainda hoje, as técnicas tradicionais apresentam problemas quando se tenta trabalhar com amostras pequenas e não lineares.

Diante disto, os pesquisadores procuraram desenvolver outros métodos de previsão. Neste caso, as RNAs tiveram um grande êxito, pois apresentam uma capacidade de generalização e aprendizado, possuem uma habilidade de associação de padrões e trabalham em paralelo. Fora isto, possuem capacidade para tratar dados não lineares.

3.4.1 - Previsão "Single" e "Multi-Step"

As RNAs para previsão tomam como base a filosofia dos métodos para análise de séries temporais clássicas, analisando as observações dos dados da série histórica do fenômeno e assim tentando identificar certas regularidades [1]. Assim sendo, as RNAs podem ser agrupadas em dois tipos.

- Previsões "multi-step"
- Previsões "single-step"

3.4.1.1 - Previsões "Multi-Step"

Estas previsões tem como característica utilizar os dados de saída das RNAs para alimentar as entradas das mesmas. Com este procedimento introduz-se um erro a cada nova previsão. Este método é capaz de prever alguns passos à frente com um nível de erro aceitável.

3.4.1.2 - Previsões "Single-Step"

Estas previsões tem como característica não realimentar as RNAs com os dados de saída das mesmas. Neste caso, usam-se os valores anteriores da série para prever um ou poucos passos à frente.

3.5 - Termos comparativos entre Redes Neurais e Modelos Estatísticos

As redes neurais podem ser usadas como ferramentas para utilização em Estatística, sendo assim segue abaixo a tabela 3.1, comparativa entre termos usados em RNA e Modelos Estatísticos[9]:

RNA	ESTATÍSTICA
Entrada da Rede	Variáveis independentes, regressores
Saída da Rede	Valores previstos
Valores de Treinamento, alvos	Variáveis dependentes
Erros	Resíduos
Treinamento, aprendizagem, adaptação, organização própria	Estimação
Função erro, função custo	Critério de Estimação
Padrões	Observações
Pesos	Estimativas dos parâmetros
Neurônios de alta ordem	Interações
Conexões funcionais	Transformações
Aprendizado supervisionado	Regressão e análise discriminante
Aprendizado não - supervisionado	Redução dos dados
Aprendizado competitivo	Análise de conglomerados

Tabela 3.1 - Termos entre RNA e Modelos Estatísticos

Capítulo 4 - Estudo da Atividade Solar

4.1 - Atividade Solar

4.1.1 - Sol

Para este trabalho, o estudo do Sol se faz necessário, pois o mesmo é a fonte geradora das manchas solares. O Sol produz sua própria energia através de dois processos:

1. Cadeia próton-próton
2. Ciclo de CNO

Através destes dois processos obtemos um resultado líquido no qual a fusão de quatro núcleos de H torna-se ${}^4\text{He}$.

Para a cadeia próton-próton ser consumada é necessária uma temperatura próxima de 15×10^6 K. O ciclo de carbono requer temperaturas maiores. No Sol, 91% da energia é produzida pela cadeia próton - próton cabendo ao ciclo de carbono a produção do restante de energia. As reações nucleares nos núcleos estelares produzem fótons de alta-energia (raios gama) que interagem com elétrons livres e perdem energia quando deslocam-se em direção a superfície devido a contínuas absorções e reemissões.

O núcleo do Sol possui um raio de 170.000 Km (24% do raio solar), uma temperatura de 15×10^6 K e densidade de 160g/cm^3 . Acima do núcleo temos a camada radiativa (entre 170.000 a 590.000 Km ou 60% do raio solar). Sua função é transferir energia pelos fótons. Acima desta camada existe a camada convectiva (entre 590.000 a 695.500 Km ou 15% do raio solar). As camadas anteriormente citadas consistem de aproximadamente 72% de H, 26% de He e 2% de elementos pesados (por massa).

A densidade média é de $1,4 \text{g/cm}^3$. O Sol é mantido pela pressão dos fótons no núcleo tentando alcançar a superfície.

A camada superficial do Sol que emite a luz que nós vemos é a fotosfera e tem 450 Km de espessura e sua temperatura varia de 8.000 K no seu ponto inferior e 4000 K na superfície (média = 5.770 K). A densidade é aproximadamente 10^{-6}g/cm^3 .

A superfície da fotosfera solar é altamente turbulenta, com granulações que se formam e desaparecem em poucos minutos. Os grãos estão acima das colunas de gases quentes, 500 - 5.000 Km de espessura, com velocidade de 2 - 3 Km/s, com bordas mais finas entre eles, onde os gases afundam para o núcleo.

Na fotosfera temos as manchas solares, que são regiões de 50.000 Km de diâmetro ou mais. Sua aparência é escura porque sua temperatura é 1500 °C menor que seu contorno. As manchas solares são mantidas por fortes campos magnéticos, 1.000 a 4.000 Gauss.

Acima da fotosfera encontra-se a cromosfera, com 2.500 Km de espessura e possui gases rarefeitos. Sua densidade tem um gradiente de 10^{-8} até 10^{-14} g/cm³. A superfície da cromosfera exibe espículas, que são jatos de gases quentes, com 1.000 Km de espessura lançado a uma altura acima de 10.000 Km, com velocidades entre 20-30 Km/s.

A corona é a camada externa do Sol, diminuindo lentamente para dentro do espaço exterior. Na corona aparecem proeminências, lâminas de gases ionizados que movem como cortina através da mesma. Elas seguem a direção do campo magnético solar e podem alcançar uma altitude de 10^6 Km acima da fotosfera. Explosões solares são luminescências efêmeras na cromosfera superior - corona inferior causadas por explosões repentinas de energia. Estas explosões liberam partículas para o espaço na forma de vento solar. As partículas que são principalmente prótons e elétrons, viajam a uma velocidade média de 500 Km/s, e na vizinhança da Terra são defletidas pelo campo magnético da Terra em direção as áreas polares, onde ionizam gases atmosféricos a altitudes de 100 - 200 Km provocando as auroras borealis em altas latitudes do hemisfério norte e as aurora australis em altas latitudes do hemisfério sul.

A fotosfera, cromosfera e corona tem aproximadamente a mesma composição: 78,4% de H, 19,8% de He e 1,8% de elementos pesados (principalmente C, O, N, Ne, Mg, Si, Fe e S), em percentagens de massa. Em termos de números de átomos, a percentagem de hidrogênio é 93,9%, hélio 5,9% e elementos pesados 0,2%. Esta composição é similar a composição das camadas radiativas e convectivas.

As camadas externas do Sol exibem uma rotação diferencial, ou seja, na superfície do Sol o equador rotaciona uma vez a cada 25.4 dias, nas proximidades dos pólos a cada 36 dias. Este comportamento singular é devido ao fato do Sol não ser um corpo sólido como a Terra. Este efeito se alonga consideravelmente para dentro do Sol, sendo que no núcleo seu comportamento se dá como um corpo sólido.

Alguns dados extras sobre o Sol:

- No núcleo do Sol sua pressão é de aproximadamente de 250 bilhões de atmosfera.
- No centro do seu núcleo sua densidade é muito mais que 150 vezes a da água.
- A energia produzida pelo Sol que é gerada pelas reações de fusão nuclear é da ordem de $3,86 \times 10^{33}$ erg ou 386 bilhões MW.
- A cada segundo 700.000.000 ton de hidrogênio são convertidos em aproximadamente 695.000.000 ton de hélio e 5.000.000 ton (aproximadamente $3,86 \times 10^{33}$ ergs) de energia na forma de raios gama.
- O campo magnético do Sol é muito forte se comparado aos padrões da Terra, e muito complicado. Sua magnetosfera, mais conhecida como heliosfera, tem sua extensão bem além de Plutão.

4.1.2 - Manchas Solares

4.1.2.1 - Introdução

Hoje é muito importante que tenhamos condições de prever os níveis de distúrbios magnéticos, pois os mesmos afetam o dia-a-dia do ser humano, seja através de interrupção das transmissões de satélites, em apagões em centrais elétricas e também pelo seu efeito no clima da Terra.

Estas previsões podem ser feitas por modelos solares-terrestres e para que estas previsões sejam bem sucedidas é necessário obter índices solares e geomagnéticos para que possamos especificar níveis de distúrbios magnéticos. Estes índices (manchas solares, fluxo de rádio solar, aa – anti-podal, etc) são parâmetros monitorados continuamente. Assim, os registros dos dados desde longas datas são necessários para previsões confiáveis destes índices para o futuro.

Neste trabalho vamos nos deter somente na série temporal referente ao número de manchas solares. A seguir será dada uma visão geral sobre a mesma.

4.1.2.2 - Visão Geral sobre Manchas Solares

Ao falarmos de Manchas Solares vem logo em nossa mente o nome Wolf, mas a primeira pessoa que sugeriu publicamente a existência do ciclo de manchas solares foi Samuel Heinrich Schwabe, um astrônomo amador alemão que cuidadosamente observou o Sol por mais de quatro décadas entre 1826 e 1868, em Dessau, Alemanha. Schwabe informou seus estudos no *Astronomische Nachrichten*, descrevendo que os números de manchas solares variam com um período de 11 anos aproximadamente. Apesar dos créditos a Schwabe sobre os ciclos de manchas solares, Hoyt e Schatten mostraram que as bases para o ciclo de manchas solares existiam claramente nos registros de observações feitas por Christian Horrebow et al, entre 1761 e 1777.

Seguindo a descoberta de Schwabe, Johann Rudolph Wolf, um astrônomo suíço partiu para estabelecer a validade da conclusão de Schwabe. O índice, número de manchas solares é freqüentemente chamado de número de Wolf, em sua homenagem, pois este o introduziu em 1848. Outra denominação para este índice é o número de manchas solares de Zurique, Rz. A partir de 1981, o índice número de manchas solares passa a ser chamado de número de manchas solares internacional, Ri. Este índice é obtido no Centro Mundial de Dados C para manchas solares, em Brussels, Bélgica. Os índices Rz e Ri são calculados como a média ponderada de manchas individuais e grupos de manchas registrados por uma rede mundial de observatórios solares. A Associação Americana de Observadores de Estrelas Variáveis possui seu índice para o número de manchas solares, denominado, Ra. Sabe-se que o número de manchas solares anuais está disponível desde a criação do telescópio em 1610, sendo que são dados não muito confiáveis em vista das condições de monitoramento daquela época.

Fala-se sobre o índice R, número de manchas solares, mas o que é isto? É a medida da área da superfície solar coberta por manchas. Quando ocorre o aumento de manchas solares e sua complexidade cresce, notadamente as manchas tornam-se fontes de grandes erupções de energia conhecidas como flares solares.

Um dado importante é o que se chama Mínimo de Maunder que vem a ser um grande período no qual o número de manchas solares foi muito baixo e é datado da última metade do século XVII.

Analizando os longos registros de observações, tem-se encontrado que o tempo do ciclo varia de 10 a 12 anos com uma média de 11 anos.

Ao se falar em ciclo, vemos que o tempo médio de um ciclo de mínimo para máximo é de 4,3 anos e de um máximo para um mínimo é de 6,6 anos. Os ciclos, de mínimo para máximo, são numerados cronologicamente, onde o ciclo atual é o de número 23.

Um fato interessante recai sobre a polaridade magnética do Sol que reverte durante o máximo de manchas solares, tal que o ciclo magnético solar tem uma periodicidade de 22 anos. Este fato pode ser demonstrado pelo Modelo Dínamo, o que não faremos aqui, pois foge ao escopo deste trabalho.

Uma ferramenta que fornece dados importantes é o diagrama borboleta (fig. 4.1), que foi aplicado primeiramente para manchas solares por E. W. Maunder, em 1904. Com este diagrama pode se obter medidas e posições de manchas solares.

Abaixo segue a fórmula para o índice R, número de manchas solares:

$$R = k(10g + s), \text{ onde:}$$

g = número de grupos de manchas solares

s = número de manchas solares individuais

k = fator de escala (menor que 1) que depende do observador, do local, do telescópio; tem como objetivo padronizar as diferentes opiniões constituintes dos grupos ou mesmo manchas solares.

O número 10 vem do fato que a maioria dos grupos possuem em média 10 manchas.




Fig. 4.1 - Diagrama Borboleta

Capítulo 5 - Procedimentos Práticos Estatísticos

5.1 - Procedimentos Práticos

Neste capítulo abordam-se os procedimentos práticos para o pré-processamento dos dados que irão ser usados para o treinamento das redes neurais.

Na etapa de pré-processamento executa-se a regularização dos dados (retirada da média, diferenciação, magnitude, etc) com o objetivo de melhorar o desempenho da rede neural. Nesta etapa a parte estatística vinculada a melhora do desempenho da rede está relacionada com a retirada de tendência, dependência linear e ciclos.

5.1.1 - Pré-Processamento

Seguindo o determinado acima nesta seção preparamos os dados para o treinamento da rede. Para isto se faz necessário padronizar os dados objetivando melhorar o desempenho da rede.

Cada etapa do pré-processamento será descrito conceitualmente a seguir junto com o resultado gráfico e a análise relativa dos resultados quando necessário.

1º Passo - Plotar a série temporal

Plota-se o gráfico da série propriamente dita para primeira avaliação geral, com isto verifica-se o comportamento da mesma, fig.5.1. Neste trabalho a análise da série temporal número de manchas solares será entre 01/01/1947 até 31/12/1997, com periodicidade mensal. Este intervalo foi definido para que nos trabalhos futuros possam ser usados outras séries temporais índices geomagnéticos para ajudar na RNA.




Fig.5.1 - Número de Manchas Solares

2º Passo - Retirada da Média

Conforme dito anteriormente este é um passo da regularização. Sabe-se que nas séries importantes informações encontram-se em variações mínimas agregadas a um valor de compensação alto. Se este valor de compensação não é valioso para a série pode-se retirá-lo, assim o treinamento tende a melhorar. Para executar este procedimento basta retirar de cada componente dos vetores da série sua média, fig.5.2.

vetor $s'' = \text{vetor } s - \text{vetor } s'$ (5.1), onde vetor s = os valores da série temporal

vetor s' = média dos valores da série temporal

vetor s'' = nova série temporal sem a média

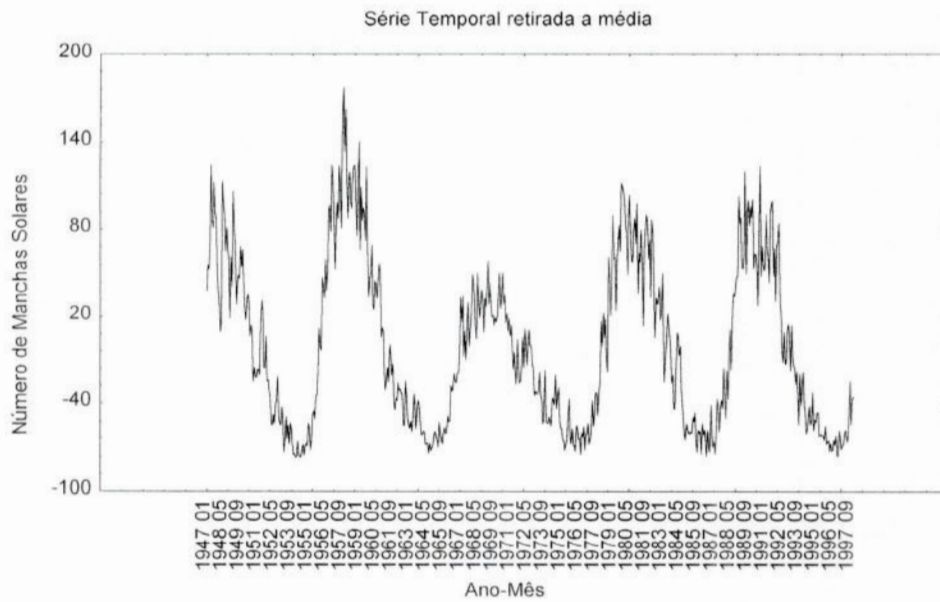


Fig.5.2 - Série retirada a média

3º Passo - Retirada da Tendência

A tendência são aqueles pontos seqüenciais da série que variam a longo prazo. Uma das formas de se obter a tendência é através da regressão linear. Neste caso a estimativa é feita pelo Método dos Mínimos Quadrados, ajustando o melhor polinômio de 1º grau, ou seja, uma reta. Para uma análise mais detalhada, ver[4].

A fórmula para obter a regressão linear:

$$\text{Min } \sum_{i=1, \dots, n} (Y_i - Y'_i)^2 \quad (5.2), \text{ onde}$$

$$Y'_i = aX_i + b \quad (5.3), \text{ sendo que } a = -0,054 \text{ e } b = 16,447$$

Assim, vê-se que os parâmetros a e b são alterados de forma a minimizar o valor da soma quadrática das distâncias entre a ordenada do ponto e a ordenada da reta de regressão.

A partir do momento que a reta de regressão é ajustada, pega-se cada ordenada e subtrai-se do valor ajustado, fig.5.3.




Fig.5.3 - Série retirada a tendência

4º Passo - Retirada de Ciclos

Nesta parte da dissertação é feita a retirada de ciclos. Neste trabalho, ciclo tem como significado: repetição de todos os padrões em períodos determinados, sendo inteiros ou fracionários. Como se sabe, as séries temporais podem ser representadas no domínio do tempo (o que se faz nesta etapa) ou da frequência. A ferramenta usada é a FFT (Fast Fourier Transform) ou transformada rápida de Fourier.

Desta forma, tem-se a seguinte idéia de ciclo que será utilizada nesta etapa: As oscilações sazonais em frequências significativas são os ciclos e abrangendo o espectro de frequência inteiro ou metade deste espectro.

Assim, na Análise de Fourier cada frequência ou período observado, informa a densidade espectral, tanto no domínio do tempo como no domínio da frequência. A partir do momento em que se identificam os períodos com maior densidade espectral, remove-se da série, subtraindo a componente deste período.

A fórmula para se retirar esta componente (C):

$$C(t) = a \cdot \sin(2\pi t/p) + b \cdot \cos(2\pi t/p) \quad (5.4)$$

onde a é componente do seno do período

b é componente do cosseno do período

p é o período que se deseja retirar

t é o número do ponto da série no qual se calcula a componente, sendo a mesma ordem que se executa a análise de Fourier.

Para se verificar se o procedimento está correto, deve-se subtrair os valores da componente calculada dos valores da série sem tendência, e neste caso a soma quadrática dos resíduos deve ser menor que a série original.

Demonstração do procedimento acima:

$$S = \frac{1}{N} \sum_{i=1, \dots, n} S_i^2 \quad \text{onde } S \text{ é a série da soma quadrática média das componentes da}$$

série retirada a tendência.

$$S^1 = S_i - C \quad \text{onde } S^1 \text{ é a série sem a componente (C)}$$

$$S^2 = \frac{1}{N} \sum_{i=1, \dots, n} (S^1_i)^2 \quad \text{onde } S^2 \text{ é a soma quadrática média da série sem a componente}$$

desta forma $S^2 < S$, logo implica que o procedimento está correto. Isto também é conhecido como energia ou potência.

Na seqüência foram retirados três períodos significativos: 122,4 meses (fig. 5.5 e 5.6); 306 meses (fig. 5.7 e 5.8) e 68 meses (fig. 5.9 e 5.10); abaixo encontram-se as respectivas densidades espectrais, no domínio do tempo e da freqüência.

Na fig. 5.4 verifica-se a densidade espectral da série sem tendência que é a série que deu origem a análise acima.

Todos procedimentos de retirada das componentes foram executados no Excel através do Solver por procedimento de otimização linear.

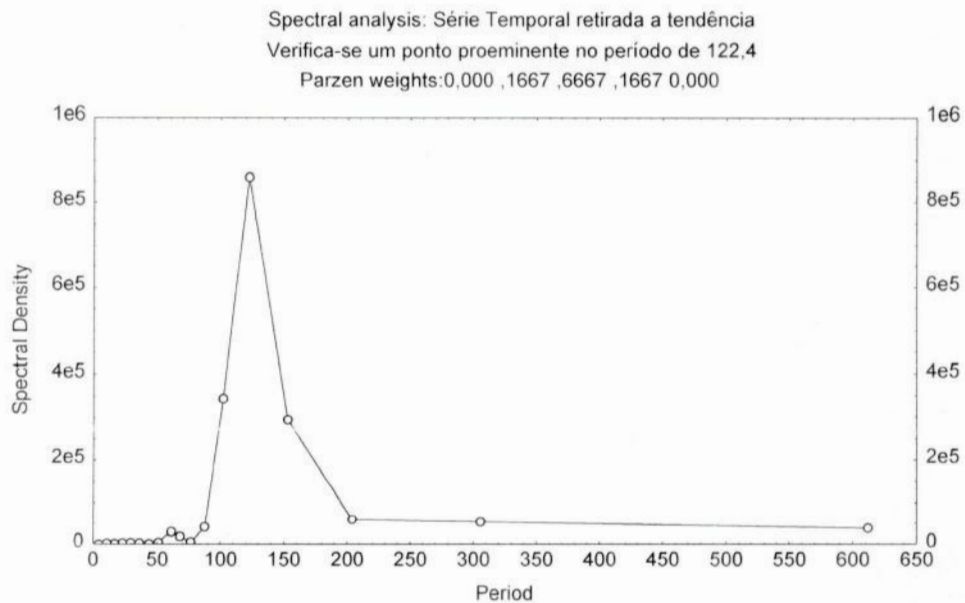


Fig. 5.4 - Densidade Espectral indicando um ciclo de 122,4 meses

Após a retirada deste ciclo sazonal temos:

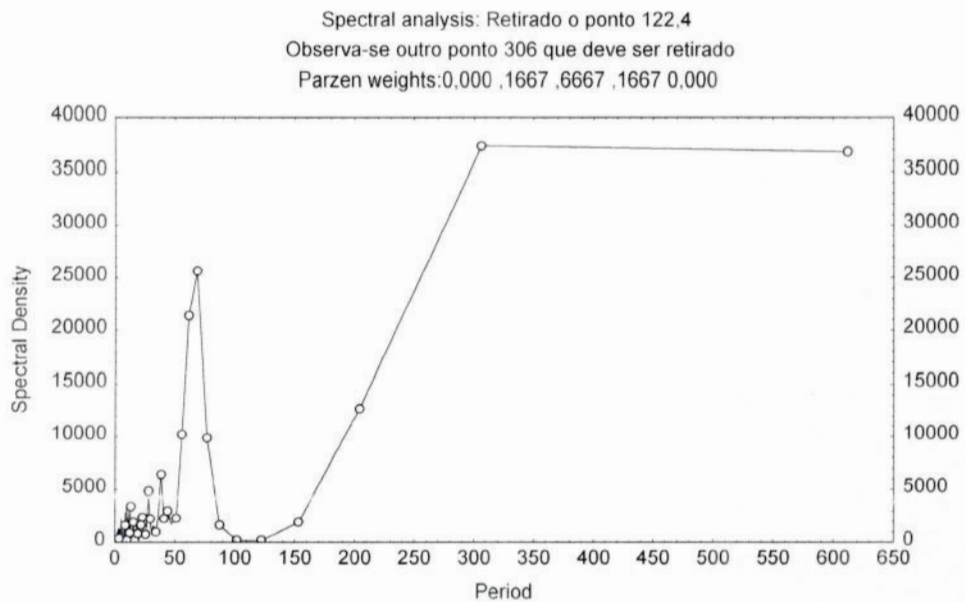


Fig. 5.5 - Ciclo 122,4 meses retirado no domínio do tempo




Fig. 5.6 - Ciclo 122,4 meses retirado no domínio da frequência

O próximo ciclo retirado foi 306 meses.

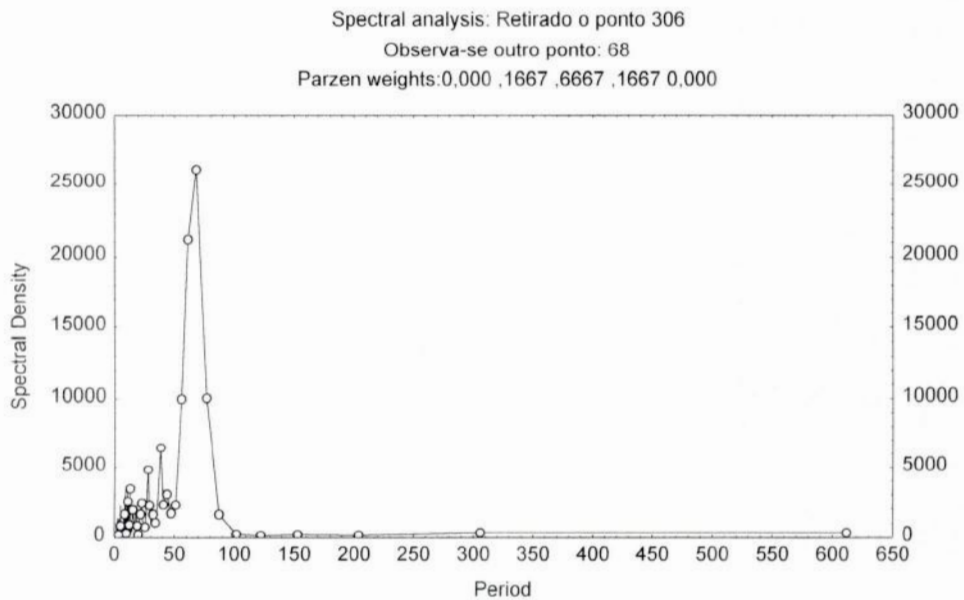


Fig. 5.7 - Ciclo 306 meses retirado no domínio do tempo

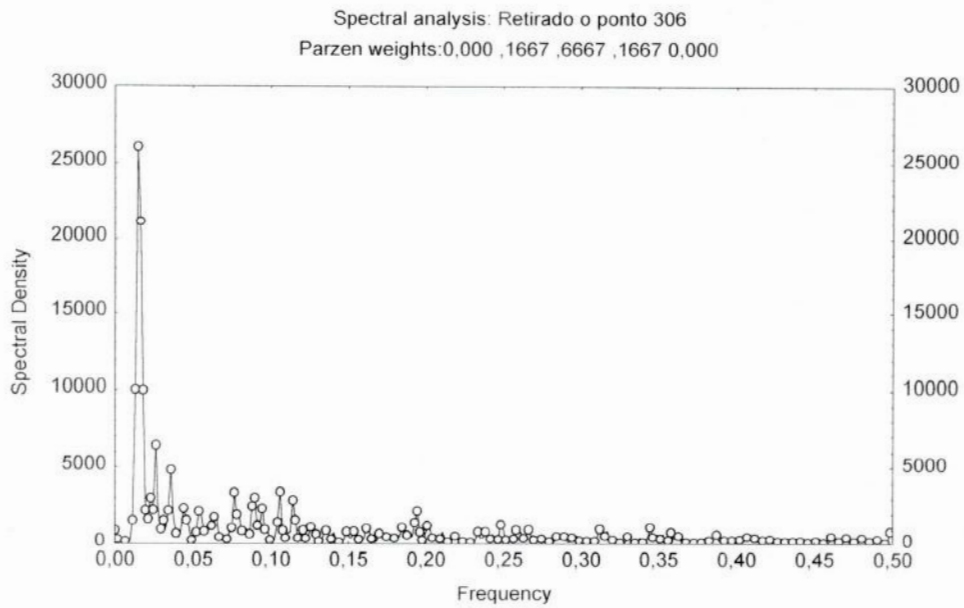


Fig. 5.8 - Ciclo 306 meses retirado no domínio da frequência

Por último retira-se o ponto 68 meses.

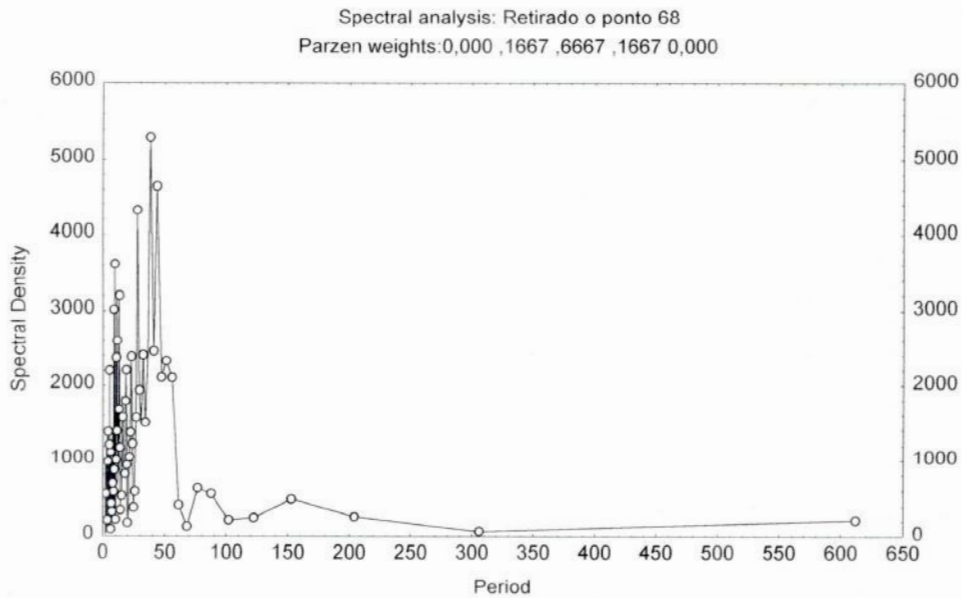


Fig. 5.9 - Ciclo 68 meses retirado no domínio do tempo

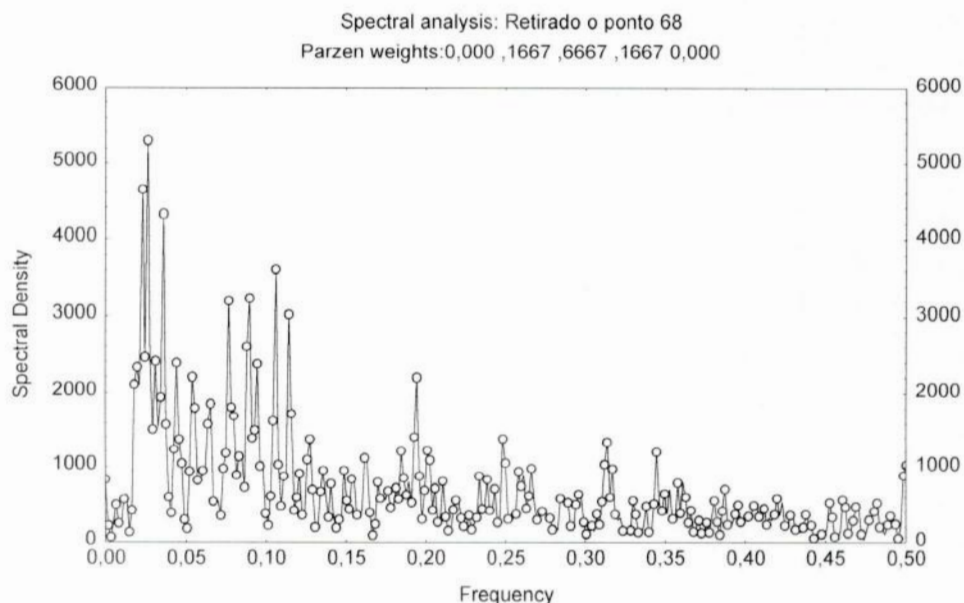


Fig. 5.10 - Ciclo 68 meses retirado no domínio da frequência

A idéia de se retirarem estes períodos ou frequências senoidais significativas vem do fato que ao analisarmos a função de autocorrelação, que indicará a quantidade de entradas atrasadas da rede, implicará em muitas entradas complicando o treinamento da RNA.

Em relação aos procedimentos de retiradas das componentes das frequências significativas param no ciclo 68 porque a densidade espectral no domínio da frequência demonstra que todas as frequências tem a mesma magnitude deixando de ter uma frequência dominante e assemelha-se a um espectro de ruído não correlato.

5º Passo - Análise da Função de Autocorrelação (FAC)

Neste passo ao observarmos a FAC, fig. 5.11 encontra-se uma dependência temporal na série. No gráfico os pontos pontilhados indicam dois desvios padrão da correlação de uma série estocástica, isto significa que a correlação acima deste ponto tem uma significância maior que 95% para a hipótese de correlação. Para retirarmos esta dependência temporal faz-se a regularização da série pela diferenciação e depois divide-se esta série pela raiz quadrada da regularização da magnitude, o que será visto mais adiante.

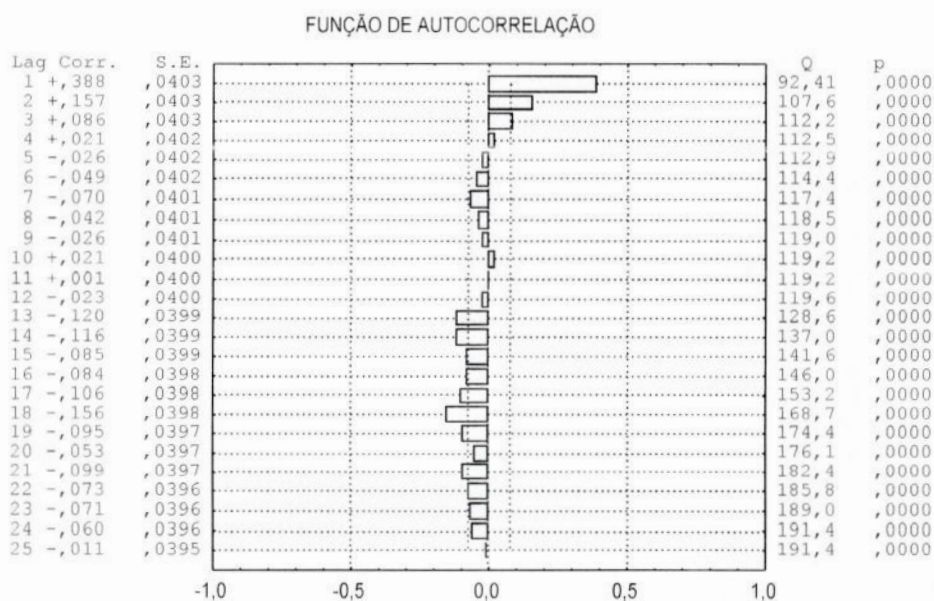


Fig. 5.11 - Função de Autocorrelação da série residual

6^o Passo - Diferenciação

A padronização chamada diferenciação, fig.5.12 tem sua utilidade a partir do momento que se observa valores com alterações absolutas mínimas, desta forma a informação principal localiza-se na variação percentual dos valores. Estas variações mínimas em valores absolutos encobre informações significativas prejudicando o desempenho da rede. Para cada componente executa-se:

$$\text{vetor } D = [\text{vetor}(t) - \text{vetor}(t-1)]/\Delta t \quad (5.5)$$

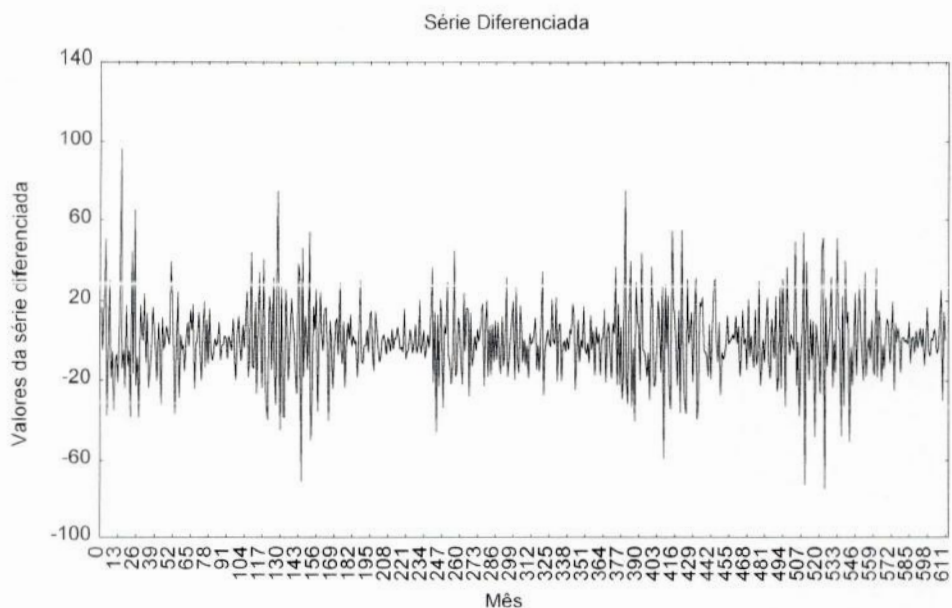


Fig. 5.12 - Série residual diferenciada de ordem 1

7º Passo - Retirada da Magnitude

A retirada da magnitude, fig. 5.13 tem como objetivo retirar grandes oscilações das componentes da série, isto para não prejudicar no treinamento da rede. Um dos métodos para isto é retirar a raiz quadrada da série retirada a média, tendência e ciclos sazonais (SMTC) para cada componente do vetor da série temporal dada pela diferenciação.

$$\text{vetor } M = \text{vetor } D / \text{vetor } \sqrt{SMTC} \quad (5.6) \quad \text{onde } SMTC = \text{componente da média} + \text{componente da tendência} + \text{componente dos ciclos sazonais}$$

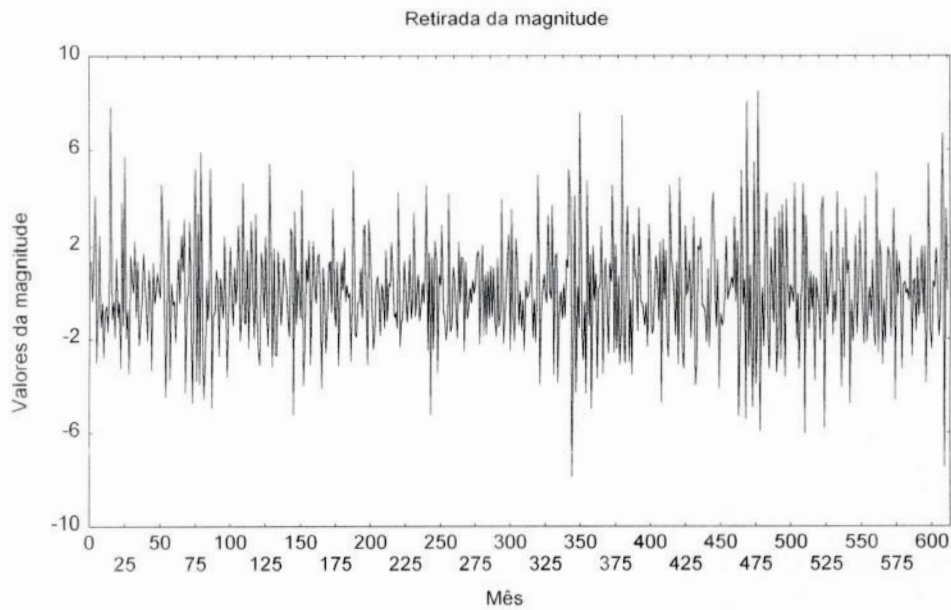


Fig. 5.13 - Série retirada a magnitude

Após executada esta etapa a FAC, fig. 5.14 se apresenta como abaixo, onde apenas se verifica dependência linear nos dois primeiros defasamentos. Outra análise é que a série se torna quase estacionária, ou seja, média igual a zero e variância igual a constante, fig. 5.13.




Fig. 5.14 - Série retirada a dependência linear

Com a retirada da magnitude a série final, que a partir de agora chamaremos de série residual apresenta suas respectivas densidades espectrais no domínio do tempo, fig. 5.15 e no domínio da frequência, fig. 5.16, onde se observam grandes frequências ou baixos períodos indicando que a RNA só poderá prever curtos períodos de tempo (meses).

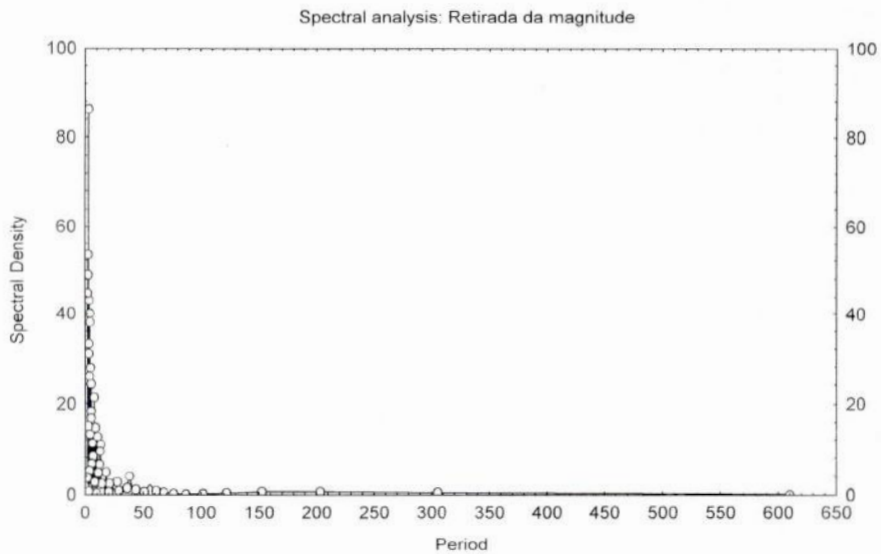


Fig. 5.15 - Série retirada a magnitude no domínio do tempo

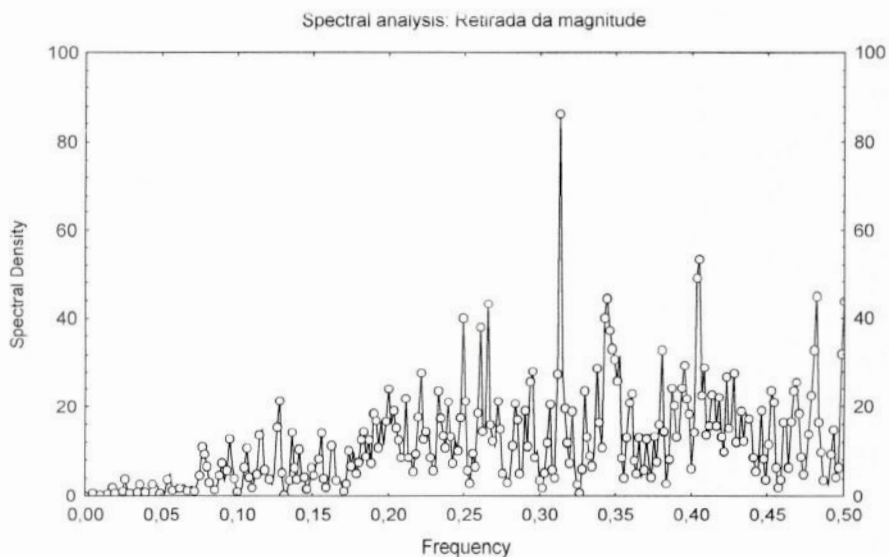


Fig. 5.16 - Série retirada a magnitude no domínio da frequência

Capítulo 6 - Procedimentos Práticos sobre Redes Neurais Artificiais

Neste capítulo analisam-se os procedimentos práticos para a própria RNA onde se determina os parâmetros da rede, tais como: função de ativação, função erro, número ótimo de neurônios na camada intermediária, etc.

Nos problemas resolvidos através das RNAs, deve-se observar três propriedades importantes: convergência, generalização e escalabilidade.

Ao se falar em convergência pretende-se avaliar o desempenho das RNAs quanto a capacidade da mesma em aprender certos conjuntos de dados de treinamento.

Em relação a generalização é a capacidade das RNAs em reconhecer padrões que não sejam do grupo de treinamento e de certa forma é a mais importante propriedade de uma RNA.

Quanto a escalabilidade, que está intimamente relacionada a convergência e a generalização, é uma propriedade que envolve os ajustes dos parâmetros da RNA, obtendo-se boa convergência e generalização. Para as RNAs o seu desempenho está ligada ao fato da rede não ter um tamanho extremamente grande para aprender os padrões, isto é, convergir, e o menor possível para generalizar bem os padrões.

6.1 - Grupos de Treinamento, Validação e Teste

Ao tentar resolver problemas com RNAs deve-se introduzir pares entrada-saída conhecidos visando a treinar a rede.

Por isto os conjuntos de treinamento irão fazer o treinamento da rede. Em outra etapa apresenta-se outro grupo de dados, denominados dados de validação, estes dados são diferentes dos dados de treinamento e sua função é determinar quando a rede deve parar seu aprendizado. Após esta etapa, apresentam-se os dados de teste para verificar a performance da rede.

Um fator importante quanto ao treinamento da rede por longos períodos é que o mesmo não acarrete o chamado overtraining, onde a rede acaba se tornando superespecializada e também perde sua capacidade de generalização.

6.2 - Função Erro

Esta função tem sua aplicação relacionada com o nível de convergência da RNA. A função erro dirá o quanto a rede está aprendendo os padrões inseridos pelo grupo de treinamento, dado pelo algoritmo de aprendizagem Backpropagation. A função erro pode ser de várias formas: Erro Médio Quadrático (EMQ), Desvio Médio Absoluto (DMA) ou Raiz Média Quadrática (Root Mean Square - RMS) que será a utilizada neste trabalho:

$$RMS = [1/n \sum_{i=1}^n (\text{alvo}_i - \text{saída}_i)^2]^{1/2} \quad (6.1)$$

6.3 - Taxa de Aprendizado

Esta taxa funciona como um controlador do desempenho do aprendizado no algoritmo de retropropagação, principalmente no controle do gradiente descendente, onde influenciará no tempo de treinamento. Esta área de influência está relacionada com a magnitude das alterações dos pesos sinápticos. Uma análise sobre o tamanho da taxa de aprendizado é importante, visto que, taxa pequena significa pequenas variações, mesmo se for necessário grandes variações, daí o treinamento ser lento e suas chances de encontrar mínimos locais são grandes. No caso contrário, grande taxa implica em grandes variações nos pesos, desta forma o tempo de treinamento é menor e os mínimos locais não ocorrerem. Outro problema que pode ocorrer com altas taxas é a saturação da rede, inviabilizando o aprendizado. Para este trabalho foi escolhido uma taxa de aprendizado 0,001 para evitar problemas de convergência e mínimos locais, para o momentum trabalha-se com um valor igual a zero pelo mesmo motivo.

6.4 - Procedimentos Práticos para viabilizar a Rede Neural Artificial

Esta é a etapa no qual se toma as decisões necessárias para construir as RNAs e que dará condições da mesma fazer sua previsão corretamente, independentemente dos resultados obtidos.

Assim, inicialmente selecionam-se os padrões que irão ser apresentados à rede neural. Neste trabalho dividiram-se os 611 pontos em 4 grupos: 400 pontos para treinamento, 100 pontos para validação e 100 pontos para teste e os 11 pontos restantes para verificar o desempenho da

RNA quanto sua capacidade de previsão. Porém, antes de começar o treinamento, deve-se reescalar os padrões para valores próximos do unitário que serão apresentados à rede neural através da divisão da série residual por 2σ , ou 2 desvios padrões, ficando a série dentro dos limites entre -1 e 1.

Os procedimentos serão por etapas como no capítulo 5.

1º Passo - Seleção das Funções de Ativação

Para entrada da rede será usada a função linear, para camada intermediária a função tangente hiperbólica e para camada de saída função linear.

2º Passo - Seleção dos Padrões para Treinamento, Validação e Teste

Como dito anteriormente os grupos de treinamento, validação e teste foram sorteados aleatoriamente. Esta etapa procura manter os dados no mesmo nível de média e desvio padrão dando a rede condições de aprender os padrões de forma homogênea.

3º Passo - Seleção dos neurônios na entrada e saída da rede

Conforme analisado na FAC, no capítulo 5, verifica-se que os dois primeiros lags são os mais correlacionados com os dados da série, isto indica que, teremos dois neurônios na entrada da rede. Como o trabalho é prever a própria série e só existe uma única variável (número de Wolf), na camada de saída tem-se um único neurônio.

4º Passo - Seleção do número de neurônios na camada intermediária

Este passo é mais complicado, pois necessita de testar várias arquiteturas de redes. Nesse projeto para a camada intermediária obteve-se redes de 1 a 15 neurônios. Depois plota-se o gráfico RMS x Número de neurônio na camada intermediária para o grupo de treinamento e de validação (ou teste de parada). Assim, procura-se determinar o menor resultado, ou o número de neurônio ótimo na camada intermediária, fig. 6.1. A partir desta etapa todos os procedimentos são executados no software Redes Neurais Statistica.




Fig. 6.1 - RMS Treinamento/Validação x N. neurônio na camada intermediária

Na fig. 6.2, o gráfico RMS x Número de neurônio para o grupo de validação demonstra que a rede 2:2:1 é a que possui o menor erro. Quando se fala em rede 2:2:1 a informação dada é: 2 neurônios na entrada da rede, 2 neurônios na camada intermediária e 1 neurônio na saída da rede.




Fig. 6.2 - RMS Validação x N. neurônio na camada intermediária

5º Passo - Análise gráfica do Grupo de Treinamento e Validação x Época

Quando se efetua esta etapa procura-se verificar se ocorre overtraining e determina-se o erro mínimo em função do número de épocas, fig. 6.3. Época aqui é quantidade de vezes em que os dados de treinamento e validação são apresentados a rede. Neste trabalho foram usados 10.000 épocas. O erro mínimo é calculado através do método do erro soma quadrada (ESQ) para o grupo de treinamento e validação. O método do erro soma quadrada é a soma da diferença quadrada entre o alvo e o valor de saída da rede. Alvo é o valor que serve como parâmetro da rede para o aprendizado e valor de saída é o valor encontrado pelo algoritmo de treinamento.

$$ESQ = \sum_{i=1, \dots, n} (\text{alvo}_i - \text{previsto}_i)^2 \quad (6.1)$$




Fig. 6.3 - Erro Treinamento/Validação x Época

Abaixo segue uma seqüência de gráficos referentes aos valores da saída da rede e dos alvos para alguns intervalos dos grupos de treinamento, verificação e teste para observarmos que a rede aprendeu os padrões apresentados.

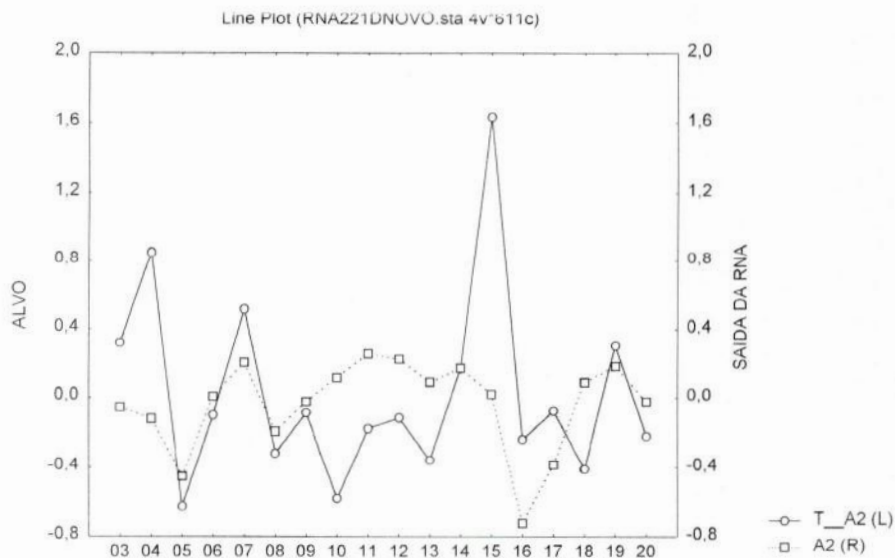


Fig. 6.4 – Valores do Alvo e da Saída da Rede para o intervalo entre os cases 3 e 20

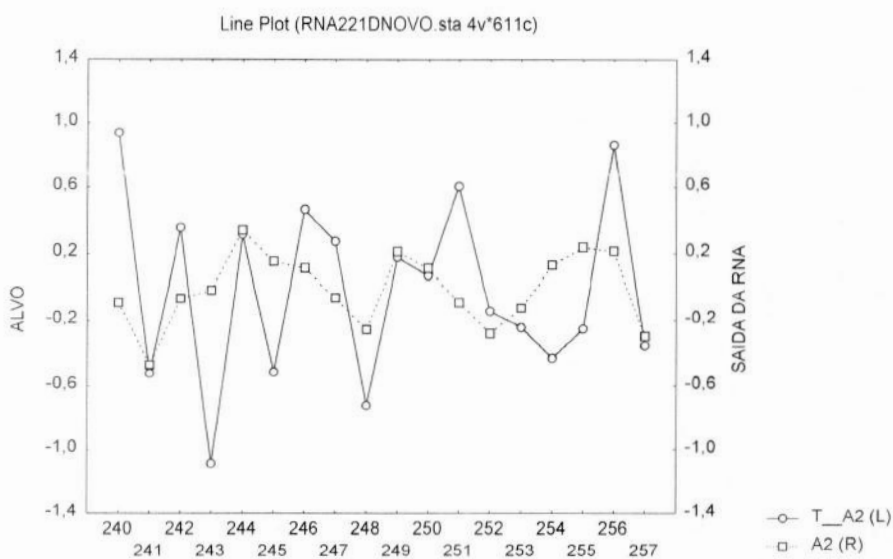


Fig. 6.5 – Valores do Alvo e da Saída da Rede para o intervalo entre os cases 240 e 257

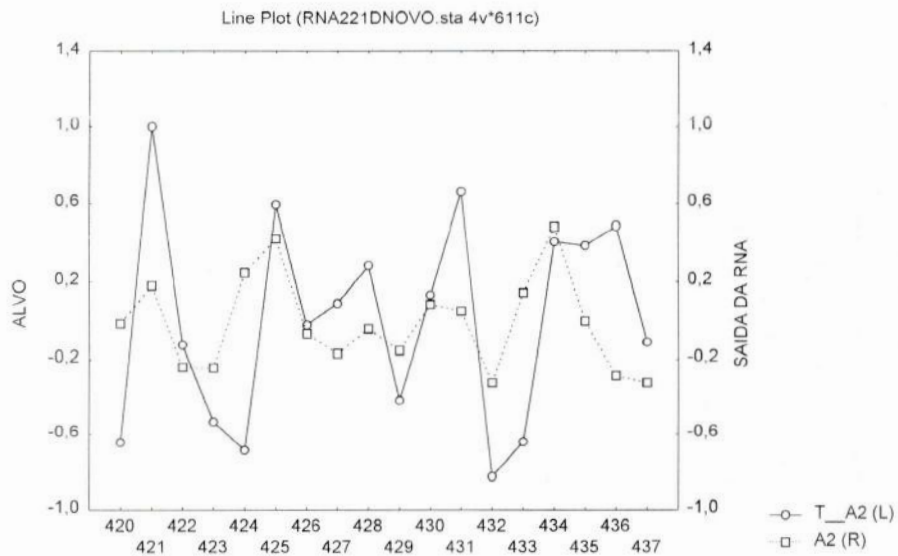


Fig. 6.6 – Valores do Alvo e da Saída da Rede para o intervalo entre os cases 420 e 437




Fig. 6.7 – Valores do Alvo e da Saída da Rede para o intervalo entre os cases 510 e 527

Observamos que a rede aprende os padrões apresentados e isto é confirmado através do cálculo da Potência para os valores do Alvo e a Potência do erro entre os valores da Saída da rede

e do Alvo para todos os 598 pontos da série. Segue abaixo a fórmula para o cálculo da potência e os resultados.

$$\text{Potência}_{\text{ALVO}} = 1/N(\sum_{i=1,\dots,N} (\text{alvo}_i)^2) \quad (6.2),$$

onde $\text{Potência}_{\text{ALVO}} = 0,245$

$$\text{Potência}_{\text{ERRO}} = 1/N(\sum_{i=1,\dots,N} (\text{alvo}_i - \text{saída da rede}_i)^2) \quad (6.3),$$

onde $\text{Potência}_{\text{ERRO}} = 0,205$

Estes valores indicam que a rede aprendeu os padrões apresentados no treinamento e verificação e quando menor a $\text{Potência}_{\text{ERRO}}$ melhor o grau de aprendizado da rede.

6.5 - Desempenho da Rede Neural Artificial

Depois de determinada a arquitetura da rede e executado o treinamento faz-se uso da mesma para prever os 11 pontos restantes da série para verificar como está o desempenho da mesma. Como mencionado na terceira etapa da seção 6.4, os 2 lags mais correlacionados indicam que a rede só pode prever um passo a frente e no máximo dois passos a frente; passo aqui indica mês.

Os resultados encontrados pela rede para um passo a frente e dois passos a frente encontram-se nas tabelas 5.1 e 5.2 e nas fig.6.8 e 6.9, respectivamente; onde informam os valores previstos e valores a serem atingidos.

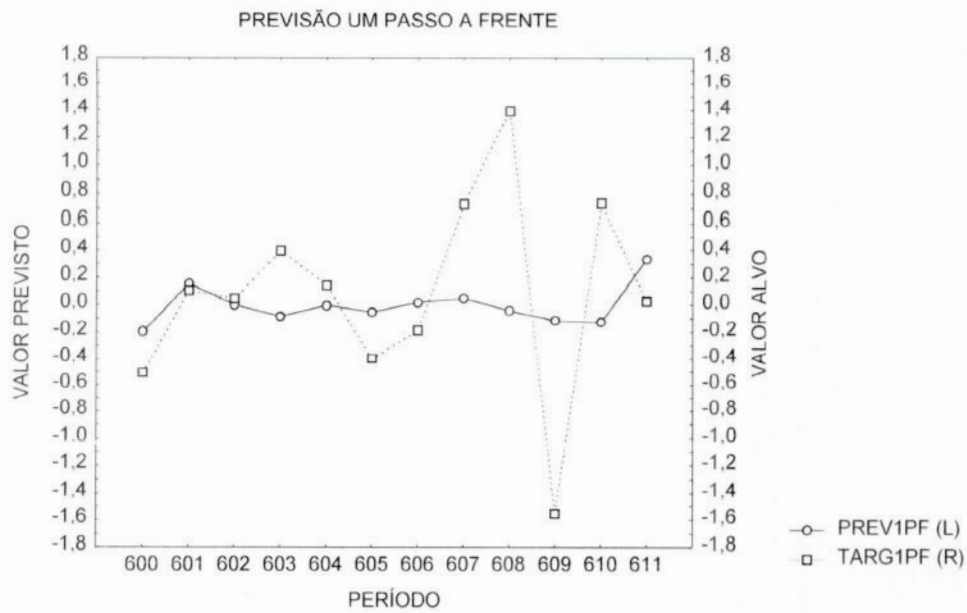


Fig. 6.8 - Valor Previsto pela RNA x Valor Alvo 1 passo a frente




Fig. 6.9 - Valor Previsto pela RNA x Valor Alvo 2 passos a frente

PREVISÃO 1 PASSO A FRENTE				
CASE	PREVISTO	ALVO	POTÊNCIA ALVO	POTÊNCIA ERRO
600	-0,20511718	-0,51	0,2601	0,092953534
601	0,161939378	0,106881	0,011423527	0,003031436
602	0,012224978	0,04606	0,002121524	0,001144809
603	-0,07534375	0,398194	0,158558063	0,224237531
604	0,002663859	0,145732	0,021237874	0,02046855
605	-0,04335931	-0,3961	0,15689521	0,124425993
606	0,026620629	-0,1878	0,03526884	0,045976206
607	0,053095844	0,728275	0,530384621	0,455867027
608	-0,03094939	1,392988	1,940415568	2,027597696
609	-0,10950164	-1,555995	2,42112044	2,092343049
610	-0,08548434	0,735333	0,540714768	0,673741265
611	0,313273437	0,02647	0,000700661	0,082256212
			0,506578425	0,487003609

Tabela 5.1 - Valores Previstos pela RNA e Valores Alvos para 1 passo a frente

PREVISÃO 2 PASSOS A FRENTE				
CASE	PREVISTO	ALVO	POTÊNCIA ALVO	POTÊNCIA ERRO
600	-0,20511718	-0,51	0,2601	0,092953534
601	0,288617239	0,106881	0,011423527	0,033028097
602	-0,01886921	0,04606	0,002121524	0,004215802
603	-0,09549607	0,398194	0,158558063	0,243729396
604	-0,00180846	0,145732	0,021237874	0,021768246
605	0,006554625	-0,3961	0,15689521	0,162130747
606	0,061886821	-0,1878	0,03526884	0,062343509
607	0,031341984	0,728275	0,530384621	0,485715769
608	-0,06332968	1,392988	1,940415568	2,120861178
609	-0,04632918	-1,555995	2,42112044	2,279090892
610	0,108954324	0,735333	0,540714768	0,392350371
611	0,243250693	0,02647	0,000700661	0,046993869
			0,506578425	0,495431784

Tabela 5.2 - Valores Previstos pela RNA e Valores Alvos para 2 passos a frente

Relembrando que o cálculo das potências acima é dado pelas fórmulas 6.2 e 6.3, sendo que agora calculamos as potências para os pontos da previsão que vai de 600 a 611. Também deve-se ressaltar que neste caso a $Potência_{ERRO} = 1/N(\sum_{i=1, \dots, N} (alvo_i - \text{previsão da rede}_i)^2)$ tanto serve para a previsão de um passo a frente como dois passos a frente. Os resultados para as previsões um passo a frente e dois passos a frente é dado a seguir:

Previsão um passo a frente:

$$\text{Potência}_{\text{ALVO}} = 0,507$$

$$\text{Potência}_{\text{ERRO}} = 0,487$$

Novamente observamos que a rede consegue melhorar a previsão (nada significativo), pois o valor da $\text{Potência}_{\text{ERRO}}$ é menor do que a $\text{Potência}_{\text{ALVO}}$.

Previsão dois passos a frente:

$$\text{Potência}_{\text{ALVO}} = 0,507$$

$$\text{Potência}_{\text{ERRO}} = 0,495$$

Novamente observamos que a rede consegue melhorar a previsão (nada significativo), pois o valor da $\text{Potência}_{\text{ERRO}}$ é menor do que a $\text{Potência}_{\text{ALVO}}$. Observamos que a previsão para um passo a frente é melhor do que para dois passos a frente.

Como foi visto no capítulo 5 as etapas dos procedimentos estatísticos incluem a retirada da média, tendência, ciclos sazonais, diferenciação e retirada da magnitude. No capítulo 6 no início fizemos a normalização. Agora com os valores previstos pela rede devemos recompor a série, que nada mais é do que multiplicar a série por 2σ , depois multiplicar por \sqrt{SMTC} , recompor a diferenciação e somar os ciclos sazonais retirados, a tendência e a média. Desta forma com os valores encontrados vamos comparar com os valores da série original referente a cada observação. Os resultados encontrados pela rede para um passo a frente e dois passos a frente encontram-se nas tabelas 5.3 e 5.4 e nas fig.6.10 e 6.11, respectivamente; onde informam os valores previstos e valores observados.




Fig. 6.10 - Valor Previsto pela RNA x Valor Observado 1 passo a frente



Fig. 6.11 - Valor Previsto pela RNA x Valor Observado 2 passos a frente

PREVISÃO UM PASSO A FRENTE				
TEMPO	S. PREVISTA	S. OBSERVADA	POTÊNCIA OBERVADA	POTÊNCIA ERRO
1996 12		13,3		
1997 01	10,3	5,7	32,5	21,5
1997 02	8,4	7,6	57,8	0,7
1997 03	8,2	8,7	75,7	0,3
1997 04	8,0	15,5	240,3	55,9
1997 05	16,2	18,5	342,3	5,3
1997 06	18,6	12,7	161,3	34,3
1997 07	14,1	10,4	108,2	13,5
1997 08	12,4	24,4	595,4	143,8
1997 09	25,0	51,3	2631,7	689,7
1997 10	50,6	22,8	519,8	770,3
1997 11	22,6	39	1521,0	269,2
			571,4	182,2
			RMS	13,5

Tab. 5.3 - Valores Previstos pela RNA e Valores Observados para 1 passo a frente

PREVISÃO DOIS PASSOS A FRENTE				
TEMPO	S. PREVISTA	S. OBSERVADA	POTÊNCIA OBERVADA	POTÊNCIA ERRO
1996 12		13,3		
1997 01		5,7		
1997 02	10,4	7,6	57,8	7,7
1997 03	7,7	8,7	75,7	1,0
1997 04	7,7	15,5	240,3	60,8
1997 05	16,1	18,5	342,3	5,7
1997 06	19,4	12,7	161,3	44,8
1997 07	14,7	10,4	108,2	18,3
1997 08	12,0	24,4	595,4	153,3
1997 09	24,4	51,3	2631,7	721,4
1997 10	51,8	22,8	519,8	839,0
1997 11	26,5	39	1521,0	156,8
			625,3	200,9
			RMS	14,2

Tab. 5.4 - Valores Previstos pela RNA e Valores Observados para 2 passos a frente

Como próximo passo devemos analisar os resultados para as previsões um passo a frente e dois passos a frente. Segue abaixo os resultados obtidos:

Previsão um passo a frente

$$\text{Potência}_{\text{OBSERVADA}} = 571,4$$

$$\text{Potência}_{\text{ERRO}} = 182,2$$

$$\text{RMS} = 13,5$$

Em relação a séries temporal prevista (recomposta) pela RNA mostra que para a previsão um passo a frente o resultado melhora significativamente, mas o erro RMS é muito alto.

Previsão dois passos a frente

$$\text{Potência}_{\text{OBSERVADA}} = 625,3$$

$$\text{Potência}_{\text{ERRO}} = 200,9$$

$$\text{RMS} = 14,2$$

Para a série dois passo a frente o resultado obtido melhora significativamente e o seu erro RMS também é muito alto. Em relação as duas séries discutidas a de um passo a frente apresenta resultados melhores.

Outra observação a ser feita é que para as respectivas previsões ocorrem um “atraso” (delay) de um mês entre as séries previstas e as observadas, e como consequência destes atrasos geram altos erros RMS. O fenômeno de delay já foi encontrado em trabalhos anteriores relativo a previsão da série número de manchas solares. Conforme Conway[7], este efeito pode estar relacionado a dependência do uso do erro RMS como critério de sucesso para o algoritmo de treinamento backpropagation e uma solução encontrada pelo autor para este problema de delay é utilizar um algoritmo de treinamento híbrido entre backpropagation e algoritmo genético. Neste trabalho não foi executado esta etapa porque foge ao escopo do mesmo. Para mais detalhes sobre este assunto ver as referências [5], [6], [7] e [8].

Para confirmar que o efeito de delay está influenciando nos resultados da previsão vamos atrasar de um mês a série relativa a previsão dois passos a frente, pois é a única que tem previsão para um passo a frente e dois passos a frente e assim obtemos valores previstos pela RNA. Segue abaixo o gráfico da série atrasada, fig.6.12 e os respectivos valores na tabela 5.5.




Fig. 6.12 – Série Prevista atrasada 1 mês x Série Observada

S. ATRASADA 1 MÊS			
S. OBSERVADA	S. PREVISTA	POTENCIA OBSERVADA	POTENCIA ERRO
13,3			
5,7	10,4	32,5	22,1
7,6	7,7	57,8	0,01
8,7	7,7	75,7	1,0
15,5	16,1	240,3	0,4
18,5	19,4	342,3	0,8
12,7	14,7	161,3	4,0
10,4	12,0	108,2	2,6
24,4	24,4	595,4	0,002
51,3	51,8	2631,7	0,3
22,8	26,5	519,8	13,7
39			
		476,5	4,5
		RMS	2,1

Tabela 5.5 – Resultados das Potências e erro RMS da série atrasada

Conforme dito anteriormente os resultados da tabela 5.5 mostram que o valor da Potência_{ERRO} = 4,5 é menor que o valor da Potência_{OBSERVADA} = 476,5 e que o erro RMS = 2,1 é coerente com os resultados encontrados por RNAs para previsão de séries temporais. Vemos também que se não ocorresse o efeito de delay a RNA forneceria uma previsão excelente.

7 - Conclusão e Proposta para outros Trabalhos

O estudo de Inteligência Artificial (IA) que neste caso trata-se de Redes Neurais Artificiais mostrou que é um campo fértil para várias pesquisas, mas de certa forma trouxe outras questões que até então não imaginava, como por exemplo: as limitações das RNAs em determinadas pesquisas.

Em relação aos resultados obtidos neste trabalho, eles não foram bons quanto desejado, não melhoraram a previsão da parte não-linear da série temporal de forma significativa em decorrência do fenômeno de delay e os valores encontrados são obtidos pelas partes lineares das séries. Confirmando o delay, uma melhora significativa é obtida.

Uma proposta para continuar este trabalho, seria desenvolver um modelo clássico de previsão para comparação, resolver o problema de delay e também utilizar outras séries temporais (Fluxo Solar em 10,7 cm, índice geomagnético K_p , índice aa etc) como uma série auxiliar para ajudar a RNA a prever melhor a série temporal número de manchas solares.

Como dito anteriormente as RNAs tem aplicações em várias atividades na Astronomia. Além de previsores em séries temporais, podem também ser utilizadas para resolver problemas de identificação entre estrela e galáxia, ou mesmo, tratar problemas de compressão de imagens, entre outros.

8 - Referências Bibliográficas

- [1] Abelém, Antonio J.G., Redes Neurais Artificiais na Previsão de Séries Temporais, Tese de M.Sc., PUC, Rio de Janeiro, RJ, Brasil, 1994.
- [2] Raposo, Carlos Maurício, Redes Neurais na Previsão de Séries Temporais, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 1992.
- [3] Gonzalez, Encarnación A.M., Séries Temporais, Departamento de Astronomia/UFRJ, Rio de Janeiro, RJ, Brasil, 1999.
- [4] Spiegel, Murray R., Estatística, Makron Books, 1993 - Coleção Schaum.
- [5] Conway, A. J., Time Series Neural Networks and the Future of the Sun. *News Astronomy Reviews*, v.42, n.5, October 1998.
- [6] Conway, A. J., Neural Networks in Astronomy, Echoed Time Series Predictions, *Neural Networks and Genetic Algorithms. Vistas in Astronomy*, v.38, part 3, p.351 - 356, 1994.
- [7] Conway, A. J., MacPherson, K. P., Brown, J. C., Delayed Time Series Predictions with Neural Networks. *Neurocomputing* 18, p.81 - 89, 1998.
- [8] Conway, A. J., MacPherson, K. P., Blacklaw, G. and Brown, J. C., A Neural Network Prediction of Solar Cycle 23. *Journal of Geophysical Research*, v.13, n.A12, p.29,733 - 29,742, December 1998.
- [9] Pereira, Basílio B. and Cleide Vital da Silva Rodrigues, *Redes Neurais em Estatística*, 13^o SINAPE - CAXAMBU, 1998.
- [10] Hipel, Keith W., et al, *Advances in Box-Jenkins Modeling, Model Construction*. *Water Resources Research*, v.13, n.3, p.567-575, June 1977.
- [11] Mcleod, Angus I. et al, *Advances in Box-Jenkins Modeling, Applications*. *Water Resources Research*, v.13, n.3, p.577-586, June 1977.
- [12] Kulkarni, D. R., Pandya, A. S., Parikh, J. C., *Modeling and Predicting Sunspot Activity - Statespace Reconstruction + Artificial Network Methods*. *Geophysical Research Letters*, v.25, n.4, p.457-460, February 1998.
- [13] Sofia, Sabatino, Fox, Peter, Schatten, Kenneth, *Forecast Update for Activity Cycle 23 from a Dynimo - Based Method*. *Geophysical Research Letters*, v.25, n.22, p.4149 - 4152, November 1998.
- [14] Mei, Shen, Cai - Pei, Yang, *Fractal Dimension and Prediction of the Sunspot Number*.
- [15] Jia - Long, Wang, Yeu - Hua, Bai - Sem, Lin, Hui - Fang, Xue, *Prediction of Sunspot Numbers for the Ascending Part of Cycle 21*. *Chinese Astronomy* 3, p.217 - 221, 1979.

- [16] Wilson, R. M., Hathaway, D. H., Reichmann, E. J., Estimating the Size and Timing of Maximum Amplitude for Cycle 23 from its Early Cycle Behavior. *Journal of Geophysical Research*, v.103, n.48, p.17,411 - 17,418, August 1998.
- [17] De Meyer, F., Modulation of the Solar Magnetic Cycle. *Solar Physics* 181, p.201 - 219, 1998.
- [18] Beer, J., Tobias, S., Weiss, N., An Active Sun Throughout Mounder Minimum. *Solar Physics* 181, p.237 - 249, 1998.
- [19] Park, Young R., Murray, Thomas J. and Chen, Chung, Prediction Sunspot Using a Layered Perceptron Neural Network. *IEEE Transactions on Neural Networks*, v.7, n.2, March 1996.
- [20] Allen, J. H., Some Commonly Used Magnetic Activity Indices: Their Derivation, Meaning and Use. NOAA/EDIS/NGDC - World Data Center - A.
- [21] Rangarajan, G. K. and Barreto, L. M., Use of Kp Index of Geomagnetic Activity in the Forecast of Solar Activity. *Earth Planets Space*, 51, p.363 - 372, 1999.
- [22] Hertz, John, Krogh, Anders, Palmer, Richard G., *Introduction to the Theory of Neural Computation*, Addison - Wesley Publishing Company.
- [23] Haykin, Simon, *Neural Networks A Comprehensive Foundation*, Macmillan College Publishing Company, Inc., 1994.
- [24] Wasserman, Philip D., *Neural Computing Theory and Practice*, Van Nostrand Reinhold.