



20 e 21 de outubro
Instituto Nacional de Pesquisas Espaciais - INPE
São José dos Campos - SP

Uma Abordagem Computacional para o Problema do Reconhecimento de Padrões das Linhas de Força do Campo Magnético na Coroa Solar

Claudinei Walker da Silva¹, Reinaldo Roberto Rosa², Joaquim E. R. Costa³

¹Programa de Doutorado em Computação Aplicada – CAP
Instituto Nacional de Pesquisas Espaciais – INPE

²Laboratório Associado de Computação e Matemática Aplicada – LAC
Instituto Nacional de Pesquisas Espaciais – INPE

³Divisão de Astrofísica – DAS
Instituto Nacional de Pesquisas Espaciais – INPE

{claudinei.walker, reinaldo}@lac.inpe.br, jercosta@das.inpe.br

Abstract. *The study of magnetic fields observed in the solar corona has a great importance on Solar Astrophysics, due to strong evidence of their association with various phenomenon verified that region, such as flares and coronal mass ejections. From a few years ago we have available images of the solar corona obtained on instruments board satellites, and various techniques for the recognition of patterns formed by magnetic force field lines in these images were developed to verify the physical models of the solar atmosphere. We present here a new approach for the recognition of patterns of the magnetic force field lines observed in the solar corona, based on the development of an algorithm for the segmentation of the field lines. Recognition of the characteristic curvilinear patterns of the field lines can be obtained by using techniques of Neural Networks, and to demonstrate this feasibility, we develop a conceptual neural network, obtaining satisfactory results.*

Resumo. *O estudo dos campos magnéticos observados na coroa solar tem uma grande importância em Astrofísica Solar, devido à forte evidência de sua associação com os diversos fenômenos verificados naquela região, como os flares e as ejeções de massa coronal. Há alguns anos tem-se disponíveis imagens da coroa solar obtidas por instrumentos a bordo de satélites, e várias técnicas de reconhecimento dos padrões formados pelas linhas de força do campo magnético nestas imagens foram desenvolvidas a fim de verificar os modelos físicos da atmosfera solar. Apresentamos neste trabalho uma nova abordagem para o reconhecimento de padrões de linhas do campo magnético observado na coroa solar, baseada no desenvolvimento de um algoritmo para a*

segmentação das linhas de campo. O reconhecimento dos padrões curvilíneos característicos das linhas de força do campo pode ser obtido por meio de técnicas de Redes Neurais, e para demonstrar esta viabilidade, desenvolveu-se uma rede neural conceitual obtendo resultados satisfatórios.

Palavras-chave: *Reconhecimento de Padrões, Processamento de Imagens, Redes Neurais, Astrofísica Solar, Computação Científica.*

1. Introdução

Em termos gerais, define-se o Sol como uma estrutura aproximadamente esférica, onde o plasma é mantido nesta configuração pela ação da força gravitacional. A região do Sol visível a olho nu é chamada de Fotosfera, e as camadas acima dela constituem a atmosfera solar. A Coroa Solar é a região mais exterior da atmosfera solar, podendo ser observada durante eclipses totais do Sol. Nela ocorrem uma série de fenômenos ainda não totalmente compreendidos, como as explosões solares e as ejeções de massa coronal.

Supõe-se que os campos magnéticos desempenhem papel preponderante na dinâmica destes fenômenos, e portanto, estudar os campos magnéticos na coroa solar é algo de grande relevância científica. Estes campos ainda não são observados em todos os níveis da atmosfera solar, e somente nos últimos quinze anos é que puderam ser obtidas imagens no Extremo Ultra-Violeta (EUV) e raios-X da Coroa Solar evidenciando a presença de linhas de força de campos magnéticos [Aschwanden 2005]. Sabe-se que as linhas de força do campo magnético coronal estão associadas à presença de manchas solares observadas na Fotosfera por meio de magnetogramas, que são uma representação gráfica das variações de intensidade dos campos magnéticos. Na impossibilidade de realizar observações das linhas de força do campo magnético em todos os níveis da atmosfera, desenvolveram-se alguns modelos físicos dos campos magnéticos, sendo que praticamente todos procuram reconstruir as linhas de campo magnético a partir de condições de contorno especialmente estabelecidas e das manchas solares. Estes são os métodos de *extrapolação* das linhas de campo [Nakagawa and Raadu 1972], onde um dos métodos muito utilizados é o do *campo livre de forças linear* ou no inglês, *Linear Force-Free Field*. Os métodos de extrapolação resultam em uma boa aproximação do comportamento das linhas de força do campo magnético na Coroa Solar, e com as imagens em raios-X e EUV, torna-se natural a comparação do modelo físico com as observações. Esta tarefa foi realizada durante muito tempo de forma manual ou semi-assistida, o que resulta em baixa eficiência e pouca utilidade prática. Não há ainda um método totalmente automático que faça o reconhecimento das linhas de força do campo magnético coronal solar nas imagens EUV e sua comparação com as linhas geradas sinteticamente pelos métodos de extrapolação.

Este trabalho tem como objetivo desenvolver uma metodologia automática de reconhecimento das linhas de campo magnético nas imagens da Coroa Solar obtidas no EUV, comparando as linhas extraídas das imagens com aquelas geradas sinteticamente pelo modelo físico. Para isto adotamos uma abordagem computacional para o problema, voltada principalmente ao processamento das imagens da Coroa Solar, o cálculo das linhas de campo a partir do modelo físico, e o reconhecimento dos padrões de linhas de campo nas imagens observadas, para comparação com aquelas geradas pelo modelo.

Nas próximas seções apresentaremos os detalhes deste trabalho, abordando a metodologia utilizada para o desenvolvimento.

2. Metodologia e resultados

Este trabalho surgiu da necessidade de desenvolver-se uma metodologia de reconhecimento totalmente automática das linhas de força do campo magnético coronal solar, levando em consideração as informações do campo magnético fornecidas pelos magnetogramas. Uma revisão bibliográfica nesta área mostrou o ineditismo desta abordagem, pois os métodos desenvolvidos até o momento são semi-assistidos, ou utilizam apenas as informações fornecidas pelas imagens obtidas no EUV para o reconhecimento das linhas de força. A presente abordagem utiliza o pré-processamento das imagens, sua segmentação, a interconexão dos segmentos de linhas, e uma etapa de reconhecimento de padrões baseada em técnicas de redes neurais. Detalharemos a seguir as etapas utilizadas no desenvolvimento do trabalho.

2.1. Pré-processamento

As imagens utilizadas no presente trabalho foram obtidas pelo satélite TRACE no EUV, na linha espectral de 171\AA , por ser uma das linhas onde verifica-se maior intensidade da emissão do ferro ionizado (Fe IX, em 171\AA) [Aschwanden and Nightingale 2005]. A base do pré-processamento das imagens consiste na aplicação de sucessivas fases de eliminação do ruído e melhoramento na nitidez e contraste das imagens, utilizando diferentes técnicas. A primeira delas, o filtro de mediana, consiste em corrigir o valor da intensidade de um pixel da imagem com base na mediana dos valores dos pixels vizinhos àquele que está sendo corrigido. Imaginando um conjunto de nove pixels dispostos em três linhas por três colunas, formando uma matriz 3×3 , o pixel central teria seu valor de intensidade substituído pela mediana dos valores da intensidade dos outros oito pixels vizinhos. Neste desenvolvimento aplicou-se um filtro de mediana, com uma máscara de tamanho 3×3 pixels, para minimizar a presença de ruído na forma de pixels claros e escuros (conhecido como ruído *salt and pepper*) associado à partículas altamente energéticas que chegam nos sensores do instrumento. A utilização do filtro de mediana garante que a intensidade dos pixels seja mantida em um nível próximo de seus pixels adjacentes, considerando uma vizinhança do tamanho da máscara selecionada. Em seguida, aplicamos na imagem uma nova correção na intensidade dos pixels com o objetivo de aumentar a nitidez da imagem. Este procedimento é conhecido como "máscara *unsharp*", onde o valor final da intensidade de cada pixel é o resultado da subtração do valor da intensidade dos pixels da imagem original por um valor de intensidade calculado. Este valor calculado é obtido por meio da aplicação de um filtro de média na imagem resultante da aplicação do filtro de mediana. O filtro de média opera da mesma forma que o filtro de mediana descrito anteriormente, com exceção da operação realizada, que no caso é uma média entre os valores de intensidade dos pixels. Para o filtro de média utilizamos uma máscara de tamanho 11×11 . O resultado final do aumento da nitidez da imagem é obtido destacando-se os pixels pertencentes à estrutura das linhas de campo. Finalmente, aplicamos um melhoramento no contraste, gerando uma nova imagem cujo valor de intensidade de cada pixel foi obtido calculando a raiz quadrada do valor da intensidade do pixel da imagem cuja nitidez foi melhorada. O resultado destas etapas sucessivas podem ser observados na Figura 1.

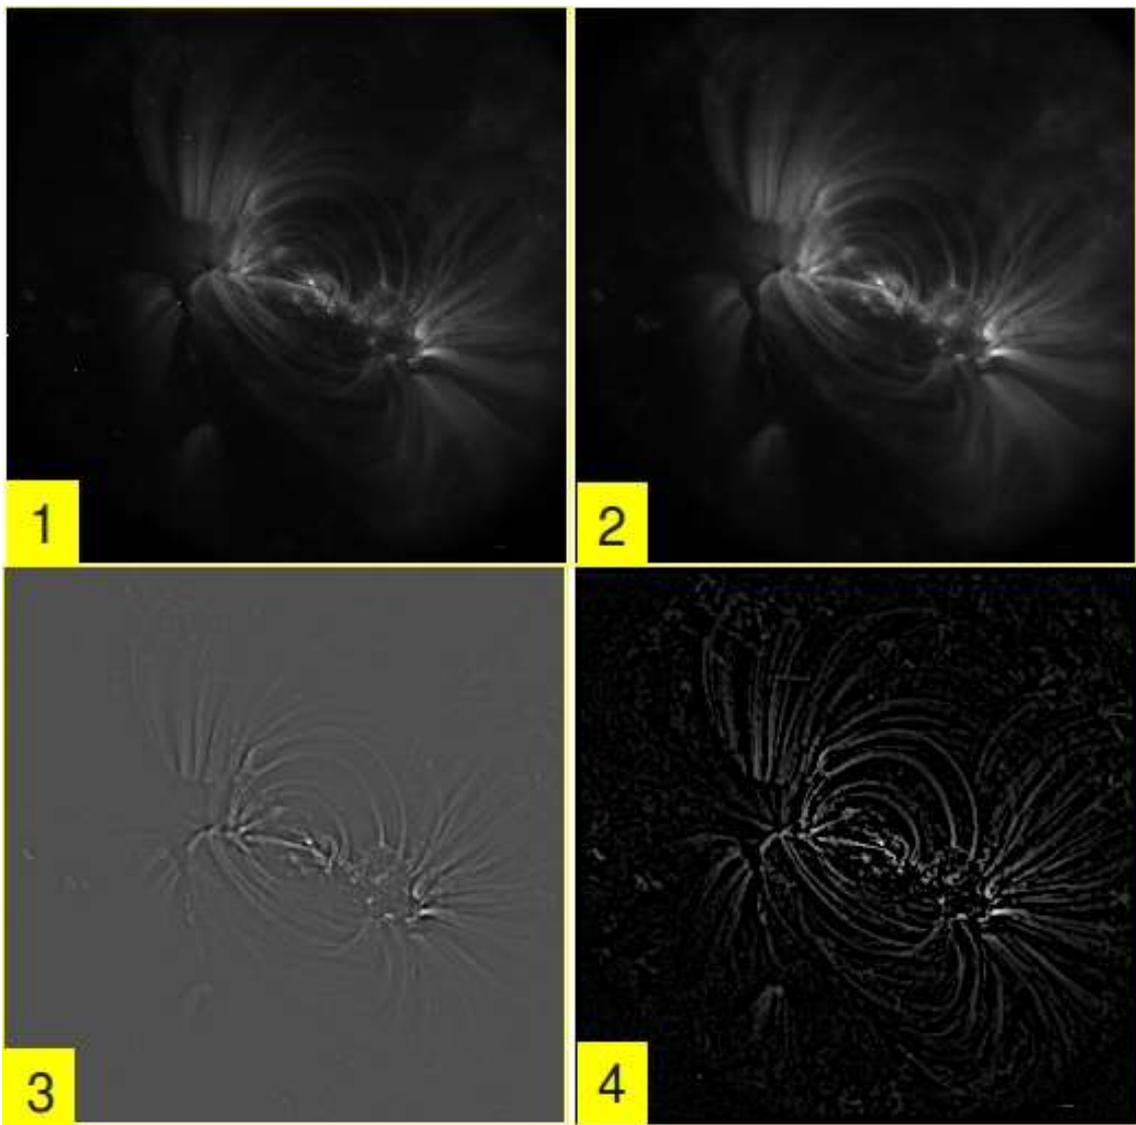


Figura 1. Pré-processamento das imagens obtidas no EUV pelo instrumento TRACE. (1) Imagem TRACE original, de 22/05/1998 22:21 UT. (2) Aplicação de um filtro de mediana, com uma máscara 3X3. (3) Aplicação da uma máscara *unsharp*. (4) Melhoramento do contraste utilizando um filtro de raiz quadrada.

2.2. Segmentação

O objetivo na etapa de segmentação foi destacar as linhas de força do campo magnético coronal, de forma que as imagens segmentadas pudessem posteriormente ser utilizadas em outras etapas de análise. As imagens utilizadas neste trabalho apresentam características bastante específicas. Os pixels de interesse estão geralmente dispostos em estruturas na forma de arcos alongados e estreitos, de forma que o uso de algoritmos clássicos de segmentação, como o de segmentação por regiões (crescimento de regiões ou detecção de bacias) e aqueles baseados em contornos (detecção de bordas) não são os mais indicados para as imagens com as quais estamos trabalhando, por não retornarem as regiões mais brilhantes dos arcos com apenas poucos pixels de largura. O ideal seria utilizar um algoritmo que segmentasse as linhas retornando estruturas muito estreitas, da ordem de um pixel de largura.

Deste modo buscou-se utilizar um algoritmo de segmentação que levou em conta a direção das estruturas presentes nas imagens. A abordagem nesse estudo utilizou o algoritmo de Strous, que consiste em uma técnica que basicamente destaca os pixels de uma estrutura com base em seu gradiente de brilho [Strous 2007]. Há duas variações do algoritmo de Strous, por simplicidade chamadas 1 e 2, onde na primeira o pixel que está sendo processado é comparado com seus pares de vizinhos, para cada uma das direções vertical, horizontal, e as duas diagonais. Se o pixel em questão for simultaneamente maior que seus vizinhos na vertical, por exemplo, soma-se 1 em um acumulador do mesmo tamanho da imagem original. Repete-se o processo para as outras direções. Ao final do processamento, somam-se essas quatro matrizes, de forma que a matriz resultado poderá conter valores de zero a quatro. Fica claro que estruturas que tenham componentes direcionais tenderão a ser destacadas, e aparecerão com valores significativos no acumulador (valores 3 ou 4, por exemplo). Outra característica interessante do algoritmo de Strous é o fato de mesmo recuperar a parte mais brilhante da estrutura, ao contrário de suas bordas, como acontece com alguns algoritmos de detecção de bordas. Numa linha de certa largura de pixels, se aqueles mais brilhantes estiverem ao longo da faixa central da linha, serão estes os pixels recuperados. No algoritmo 2 Strous variou a comparação: ao invés de testar se o pixel processado é simultaneamente maior do que seus vizinhos nas direções consideradas, a comparação foi feita utilizando-se a média dos dois pixels vizinhos com o pixel processado, nas direções indicadas. A Figura 2 apresenta esquematicamente o funcionamento do algoritmo de Strous.

Aplicou-se a variação 1 do algoritmo de Strous a cada uma das imagens obtidas na etapa de pré-processamento (Figura 1, imagens 2, 3 e 4). Foi possível verificar que os melhores resultados foram obtidos com o uso da imagem 4 da Figura 1. Isto ocorreu justamente porque nesta imagem os arcos coronais estão destacados, com sensível diminuição do ruído, em comparação com a imagem original (Figura 1, imagem 1). Podemos verificar estes resultados na Figura 3.

Buscou-se melhorar a segmentação já obtida com o algoritmo de Strous utilizando uma técnica de extração de linhas nas imagens baseada no fato de que muitas linhas de força do campo magnético apresentam uma estrutura geométrica curva e alongada. A idéia utilizada foi a de que dividindo-se uma linha curva em pequenos fragmentos, cada um deles se aproximará de um segmento de reta. Assim, seria possível utilizar a Transformada de Hough [Duda and Hart 1972] para esta tarefa, pois a mesma apresenta

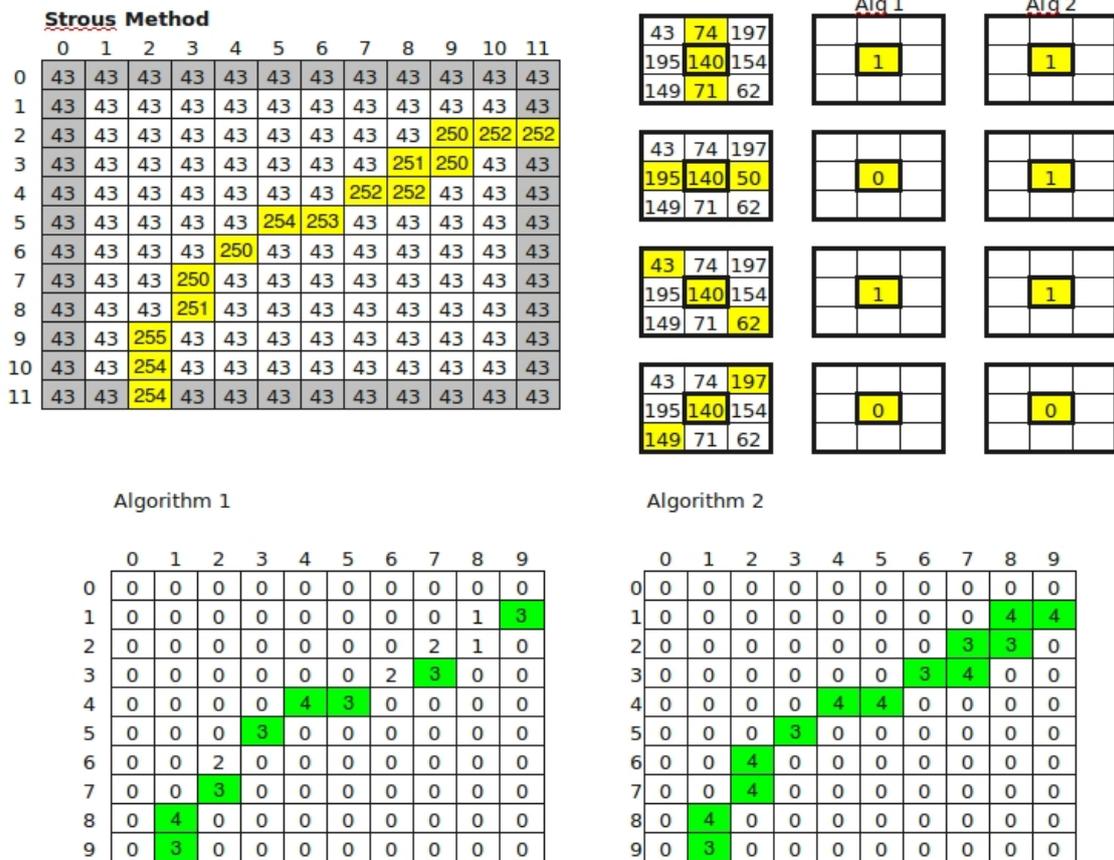


Figura 2. O algoritmo de Strous compara o pixel processado com seus vizinhos, considerando quatro direções. A variação 1 do algoritmo considera o máximo valor, enquanto que a variação 2 considera a média dos pixels vizinhos.

boa eficiência na recuperação de linhas retas em imagens ruidosas. A Transformada de Hough baseia-se na parametrização da equação da reta e na criação de um espaço discreto destes parâmetros chamado espaço de Hough. Para a reta $ax + b$ o espaço de Hough seria formado por uma matriz acumuladora cujas colunas representariam o parâmetro a e as linhas o parâmetro b . O algoritmo da Transformada de Hough percorre toda a imagem pixel a pixel, e avalia para cada um deles se o mesmo encontra-se sobre uma reta cujos parâmetros sejam a e b , e neste caso, somando um ao elemento $[a, b]$ da matriz. Ao final do processamento, existirão regiões do espaço de Hough onde haverá uma maior contagem para um determinado par $[a, b]$, de forma que um ponto no espaço de Hough representa uma reta no espaço da imagem.

Desenvolveu-se uma algoritmo capaz de fragmentar uma imagem, aplicar a Transformada de Hough em cada fragmento e finalmente recompor a imagem por completo. A imagem obtida a partir da segmentação inicial utilizando o algoritmo de Strous foi dividida em fragmentos de tamanhos iguais. Para cada fragmento, aplicou-se a Transformada de Hough, armazenando o espaço de Hough correspondente. Para que fosse possível separar os aglomerados de pontos no espaço de Hough, a partir do algoritmo k -means, muito utilizado nos problemas de *análise de agrupamentos (clustering analysis)*, implementou-se um algoritmo que devolve as coordenadas médias do ponto que melhor representa cada

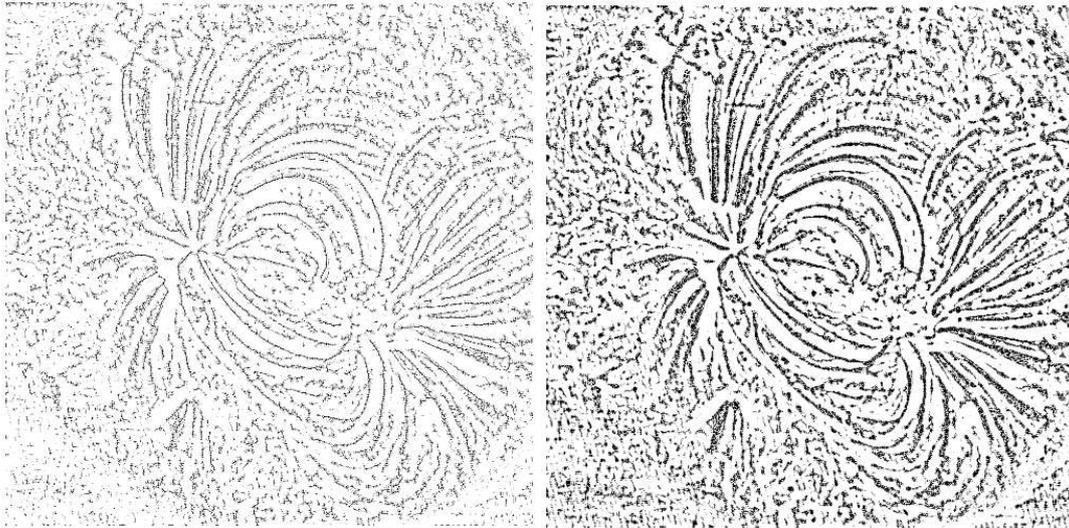


Figura 3. Aplicação do Algoritmo de Strous na imagem 4 da Figura 1. À esquerda observamos a variação 1 do algoritmo, que leva em conta o valor máximo do pixel frente aos seus vizinhos. À direita vemos a variação 2 do algoritmo, que leva em conta o valor do pixel central contra a média dos valores dos pixels vizinhos. Ao longo do trabalho utilizou-se o algoritmo 1, por resultar em uma imagem com linhas mais finas.

cluster de pontos daquele fragmento. Com isso foi possível separar no espaço de Hough, as coordenadas a e b que representam retas $ax + b$ no espaço da imagem do fragmento em questão. Desta forma obteve-se um mapeamento de todos os segmentos de linhas de cada fragmento da imagem, em suas coordenadas locais (do fragmento) e em suas coordenadas globais (da imagem). Ao final do processamento o algoritmo reconstrói toda a imagem a partir de cada fragmento. Devemos destacar o fato de que, além de extrair as linhas de campo da imagem original, o método devolve também as equações das retas que compõem as linhas em cada fragmento. A quantidade de fragmentos (e portanto o tamanho de cada um) e a quantidade de pixels de cada linha que pode ser recuperada são parâmetros de entrada do algoritmo. A Figura 4 ilustra o processo.

A fim de verificar a aplicação prática dos resultados obtidos até esta etapa do trabalho, integrou-se o desenvolvimento realizado com ambiente para análise em física solar *Solar Soft* [Bentley and Freeland 1998]. O ambiente *Solar Soft* disponibiliza uma série de rotinas para tratamento e exibição das imagens de diversos instrumentos nas pesquisas em astrofísica solar, incluindo o TRACE. Na figura 5 pode-se observar os resultados da integração das imagens processadas na etapa de segmentação com o *Solar Soft*: no quadro 1 observa-se um magnetograma do disco solar, com destaque para a região ativa no canto superior direito, mostrando as manchas solares em suas polaridades opostas (regiões claras e escuras); no quadro 2 observa-se uma ampliação da região destacada no quadro 1; o quadro 3 mostra uma imagem das linhas de força do campo magnético coronal obtida no EUV pelo instrumento TRACE da mesma região ativa; no quadro 4 observa-se uma fusão da imagem obtida no EUV e do magnetograma, com o objetivo de avaliar a correta justaposição dos pontos de destaque da região ativa; no quadro 5 observa-se o resultado do pré-processamento e da segmentação utilizando o algoritmo de Strous e a Transformada de Hough para a região ativa em estudo, e finalmente, no quadro 6 observa-se uma fusão

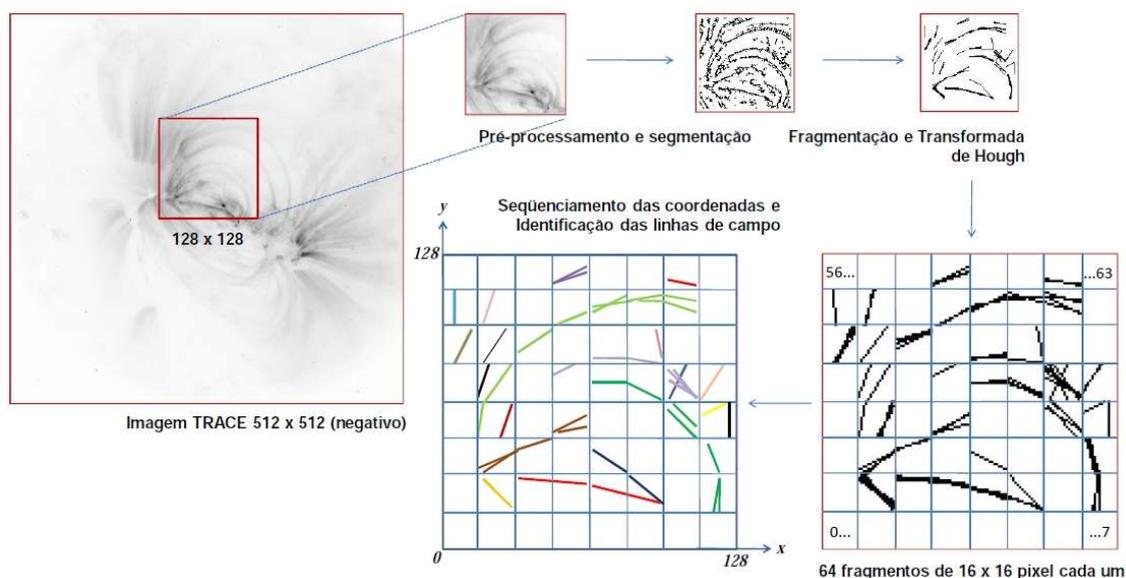


Figura 4. A partir de uma imagem das linhas de força do campo magnético coronal solar obtida no EUV, efetuou-se a segmentação aplicando o algoritmo de Strous e a Transformada de Hough.

do pré-processamento e da segmentação com o magnetograma. É importante destacar aqui que as imagens do magnetograma foram obtidas pelo instrumento MDI, e as imagens obtidas no EUV foram obtidas pelo instrumento TRACE. Ambos instrumentos estão posicionados em diferentes distâncias em relação ao Sol, sendo necessário ajustar as imagens para que seja realizado um registro adequado, de forma que as manchas solares se ajustem corretamente às linhas de campo mais intensas. Verificou-se no quadro 6 uma boa aproximação entre o magnetograma e as linhas de campo geradas, o que é de extrema importância para as fases que se seguem neste trabalho.

2.3. Reconhecimento das linhas de campo

Uma das abordagens utilizadas em física solar para os estudos da dinâmica das linhas de força do campo magnético é a extrapolação destas linhas de campo através do modelo de campos livres de força (*Linear Force-Free Field*) [Nakagawa and Raadu 1972]. Este modelo baseia-se em condições de contorno fornecidas pelos magnetogramas obtidos na Fotosfera solar e calcula a geometria das linhas de campo magnético no espaço tridimensional, num procedimento chamado extrapolação das linhas de campo. Partindo das equações de Maxwell e fazendo certas considerações, chega-se a uma formulação que representa o conjunto final de linhas por meio da equação rotacional $\nabla \mathbf{B} = \alpha \mathbf{B}$, onde do ponto de vista geométrico, α é o parâmetro que governa a torção das linhas. Quando $\alpha = 0$ não há excedente de energia na região ativa, e a estrutura geométrica das linhas é semelhante a de um dipolo magnético.

Para que o modelo *Linear Force-Free Field* possa ser verificado, torna-se necessário fazer uma comparação entre seus resultados e as imagens obtidas no EUV. Como neste caso, a geometria das linhas de campo (ou arcos coronais) é de suma importância, já que α pode variar de linha para linha, verificou-se ser necessário lançar mão de algum método que pudesse extrair a partir das imagens as feições das linhas de campo,

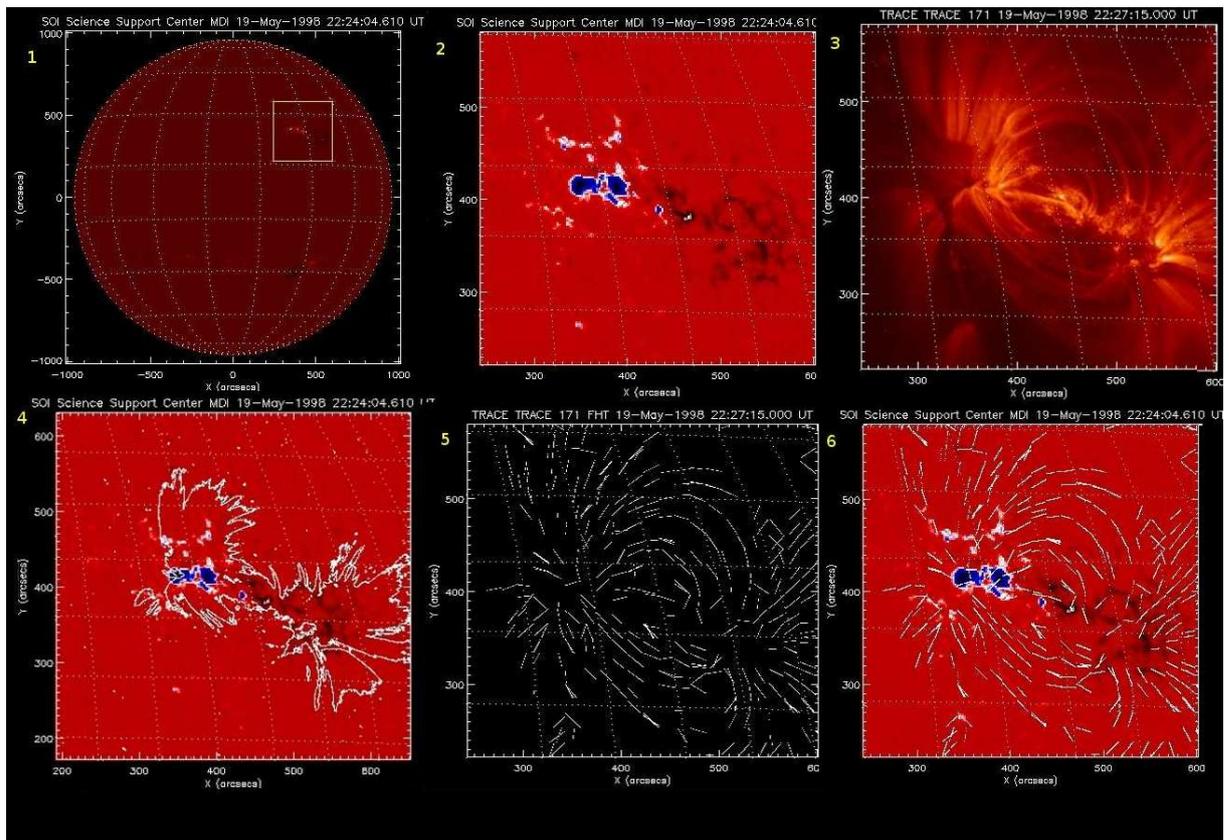


Figura 5. Resultados obtidos a partir da integração dos algoritmos de pré-processamento e segmentação com o ambiente *Solar Soft* para verificar a aplicabilidade prática da metodologia desenvolvida até o momento.

que normalmente apresentam padrões curvilíneos bastante regulares para pequenos valores de α , da ordem de $\pm 10^{-2}$.

Encontra-se na literatura diversas abordagens utilizadas para o reconhecimento dos padrões de linhas nas imagens na coroa solar. [Aschwanden et al. 2008] apresenta um resumo de métodos semi-automáticos desenvolvidos nos últimos anos. Estes métodos em geral conseguem reconhecer uma pequena quantidade de arcos, em condições muito favoráveis, diferentemente do que se encontra na realidade. A grande maioria dos métodos pesquisados utiliza uma abordagem de "busca de pixel" baseada em critérios obtidos no magnetograma e na própria imagem obtida no EUV, onde um algoritmo tenta percorrer o caminho das linhas de campo pixel a pixel, considerando uma série de critérios de decisão para selecionar o pixel correto. Estes métodos encontram muitos problemas, principalmente quando as linhas de campo possuem falhas (*gaps*), ou quando há o cruzamento de linhas (*cross-lines*) [Lee et al. 2006].

Para abordar a questão do reconhecimento das linhas de campo nas imagens, partiu-se da premissa de que as redes neurais, quando treinadas adequadamente, são robustas à presença de ruído nos dados, e já foi demonstrado por diversas aplicações que as mesmas se prestam bem à tarefas onde torna-se necessário interpolar valores em uma série de dados [Castro 2009].

A abordagem utilizada neste trabalho foi organizada de forma que a partir das imagens obtidas em EUV pré-processadas e segmentadas nas etapas anteriores fosse possível desenvolver um algoritmo de interconexão dos segmentos de linhas segmentados pela Transformada de Hough. Com todos os segmentos conectados, seria possível então submeter esta nova imagem a um método de reconhecimento de padrões baseado em redes neurais. Este algoritmo de interconexão dos segmentos de linhas ainda está em estudo e desenvolvimento, enquanto que para a etapa de reconhecimento de padrões utilizando redes neurais desenvolveu-se um ensaio conceitual para demonstrar a viabilidade de seu uso para o reconhecimento dos arcos coronais nas imagens segmentadas.

A construção da rede neural conceitual baseou-se na arquitetura MLP (*Multi-Layer Perceptron*) com o algoritmo de treinamento de *Retropropagação do erro*. Detalhes a respeito desta arquitetura podem ser obtidos em [Haykin 1994] e [Fausett 1994].

Desenvolveu-se o algoritmo **ang.m**, um código capaz de traçar arcos similares àqueles observados na Figura 1. Este algoritmo recebe os parâmetros necessários para a construção de um arco: as coordenadas cartesianas (x_c, y_c) do centro do arco, sua abertura (x_s, y_s) e seu raio r . Considerando um arco gerado por este algoritmo, podemos tomar uma série de pontos (x_i, y_i) que compõem este arco, onde cada ponto corresponderá às coordenadas de um pixel da imagem quando o arco for sobreposto à imagem das linhas de campo obtida no EUV, mapeando cada ponto (x_i, y_i) do arco com as coordenadas dos pixels da imagem. No entanto, para que fosse possível obter parâmetros geométricos a partir das linhas de campo da imagem, adotou-se uma estratégia oposta a isto: dado um conjunto de pontos em uma imagem EUV da coroa solar (pixels que estarão sobre uma linha de campo em forma de arco), obteve-se o conjunto de parâmetros que, se fornecidos ao algoritmo **ang.m** iriam gerar um arco que passa por aqueles pontos, e evidentemente, sobre a linha de campo da imagem EUV. Conceitualmente esta é a inversão do problema de determinar os pontos que fazem parte de uma curva cujos parâmetros são

conhecidos. Dados os pontos, deseja-se obter os parâmetros que definem uma curva que passa por estes pontos.

Assim, a hipótese é a de que, treinando uma rede neural cujos dados de entrada sejam os pontos que fazem parte de um arco cujos parâmetros geradores são conhecidos, obter-se-ia como conhecimento armazenado os parâmetros para a geração de um arco que passa por aqueles pontos conhecidos. Fazendo isto para uma quantidade suficiente de arcos, poderia-se, em uma etapa de generalização, fornecer para a rede pares ordenados de pontos, e a mesma devolveria os parâmetros dos arcos que passam por aqueles pontos. Construiu-se assim uma rede neural MLP com dez entradas (cinco pares ordenados representando as coordenadas $[x, y]$ de cada ponto), uma camada escondida com uma quantidade de neurônios variável (ajustado via parametrização do algoritmo), e cinco neurônios na camada de saída, representando parâmetros para a geração dos arcos. Matematicamente, a saída de cada neurônio da rede pode ser descrita pela Equação 1:

$$y_j(n) = \varphi \left(\sum_{i=0}^p w_{ji}(n) y_i(n) \right) , \quad (1)$$

onde $\varphi()$ representa a função de ativação do neurônio. Os neurônios da camada de escondida são ativados por funções logísticas sigmoidais da forma

$$\varphi(n) = \frac{1}{1 + e^{-\alpha v_j(n)}} , \quad (2)$$

onde α fornece a inclinação da função sigmoidal. Os neurônios na camada de saída são ativados por funções lineares, ou seja, fazemos $\varphi(v_j) = v_j$.

A Figura 6 apresenta esquematicamente a rede implementada.

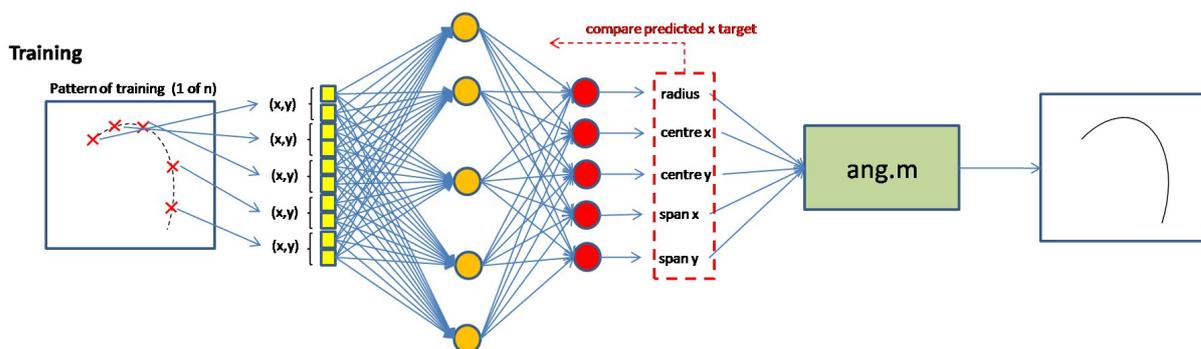


Figura 6. Rede Neural MLP implementada como um modelo conceitual para o reconhecimento de linhas de campo em imagens obtidas no EUV.

Para o treinamento da rede foram selecionados dez arcos utilizados como dados de entrada. Em cada arco destacou-se cinco pontos (seus pares ordenados (x_i, y_i)) totalizando cem valores reais. Para cada um dos dez arcos armazenados eram conhecidos previamente os valores dos cinco parâmetros necessários para que o algoritmo **ang.m** pudesse traçá-lo. Assim, definiu-se uma estrutura de dados de treinamento, com as coordenadas de cada um dos cinco pontos para cada um dos dez arcos na entrada, e na saída seus correspondentes dez conjuntos de cinco parâmetros para a geração de cada arco.

Definido o conjunto de dados de treinamento, passou-se à etapa de refinar a rede neural para que um treinamento satisfatório fosse realizado. Como pode ser observado na Figura 6, a rede é totalmente conectada, o que significa que todas as entradas estão conectadas aos neurônios da camada escondida, e todas as saídas da camada escondida estão conectadas aos neurônios da camada de saída.

A cada época de treinamento os pesos das conexões que interligam os neurônios são atualizados. Computacionalmente estes pesos são representados por matrizes de valores, e ao final do treinamento estas matrizes acumulam o "conhecimento" da rede. A atualização dos pesos foi realizada utilizando o algoritmo de retropropagação do erro. Este algoritmo busca atualizar os pesos da última até a primeira camada da rede (considerando-se a direção entrada \rightarrow camada(s) escondida(s) \rightarrow camada de saída), minimizando uma função custo. Nesta implementação a função custo era a diferença entre os valores de saída calculados pela rede e os valores-alvo estabelecidos no início do processo. O algoritmo de retropropagação do erro utiliza como heurística de otimização o Gradiente Estocástico Descendente. A solução inicial é dada na forma de valores aleatórios atribuídos às matrizes de peso da rede. Na primeira época de treinamento cada vetor de entrada é apresentado à rede, e a mesma é ativada, realizando todos os cálculos. Os valores obtidos na saída da rede são então comparados com os valores-alvo, e um vetor de erro é gravado com a diferença entre estes valores. Este processo é repetido para cada vetor de entrada. Após a ativação da rede pelo último vetor, calcula-se o erro quadrático médio daquele primeiro conjunto de vetores, encerrando a primeira época de treinamento. A partir do valor do erro quadrático da primeira época de treinamento, a rede atualiza os pesos das conexões sinápticas com base no algoritmo de retropropagação do erro. Uma nova época de treinamento é iniciada, e o processo repetido até que uma quantidade máxima de épocas seja atingida, ou o erro quadrático médio seja menor que um valor estabelecido.

Na fase de treinamento foram feitos vários ensaios, onde eram mantidos fixos todos os parâmetros da rede, com exceção de apenas um deles. Este parâmetro era alterado até que um valor satisfatório de erro fosse atingido. Repetia-se o procedimento para todos os outros parâmetros. Em uma primeira fase de testes para treinamento, foram obtidas algumas aproximações dos valores-alvo apenas se fossem utilizados por volta de 80 neurônios na camada escondida e cerca de 5.000 épocas de treinamento, valores relativamente altos para o problema em questão, evidenciando indícios de sobre-treinamento (*overfitting*) na rede [Haykin 1994].

Após uma série de testes, verificou-se que uma simples mudança de posição dos valores nos vetores de entrada e saída, de forma que a correspondência não fosse perdida, permitiu que a barreira de 80 neurônios fosse rompida, e a rede foi treinada com 15 neurônios em 1.834 épocas. A Figura 7 apresenta a evolução do erro quadrático médio por época de treinamento.

O principal objetivo da etapa de generalização foi o de verificar a qualidade do treinamento realizado. Sabe-se que ao apresentar para a rede os mesmos valores de entrada para os quais ela foi treinada, deve-se esperar na saída os mesmos valores obtidos na fase de treinamento. A questão é se os valores de entrada não forem os mesmos do que aqueles utilizados na fase de treinamento, e neste caso, a expectativa é que a rede apresente um comportamento "suave", ou seja, as variações nos dados de entrada devem influenciar muito pouco os valores obtidos na saída. A hipótese é a de que pequenas

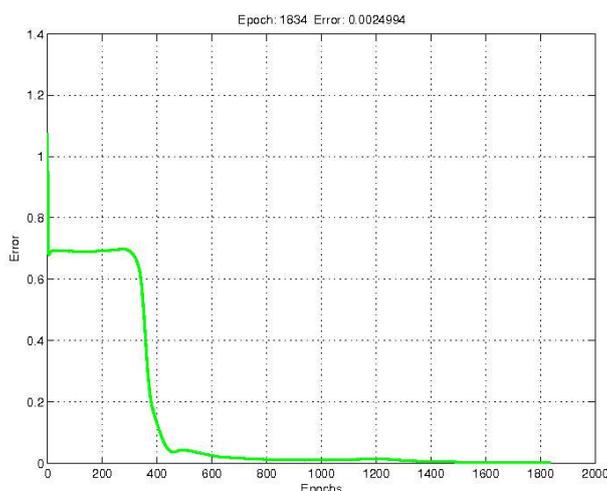


Figura 7. Evolução do erro durante o treinamento da rede. O erro mínimo foi fixado em 0,0025, o que foi atingido em 1.834 épocas de treinamento.

variações nos valores de entrada produzam pequenas variações na saída, ou até nenhuma variação de valores. A rede seria, portanto, tolerante a uma certa quantidade de ruído nos dados de entrada. Esta é a definição de robustez utilizada neste trabalho.

Em um primeiro teste foi fornecido para a rede o mesmo conjunto de vetores utilizados na etapa de treinamento, e como esperado a mesma devolveu seus correspondentes valores obtidos naquela fase. Acrescentou-se uma certa quantidade de ruído uniforme nos dados de entrada, à taxa de 10%. Os resultados foram avaliados e verificou-se que a presença de ruído não causou variação entre os padrões de entrada e saída, o que se repetiu para uma taxa de 50%. Diversos valores para a quantidade de ruído foram testados, de onde verificou-se que os valores de saída somente foram alterados se os dados de entrada fossem totalmente alterados, o que foi feito reduzindo estes valores para 10^{-6} dos valores originais. A Figura 8 apresenta estes resultados.

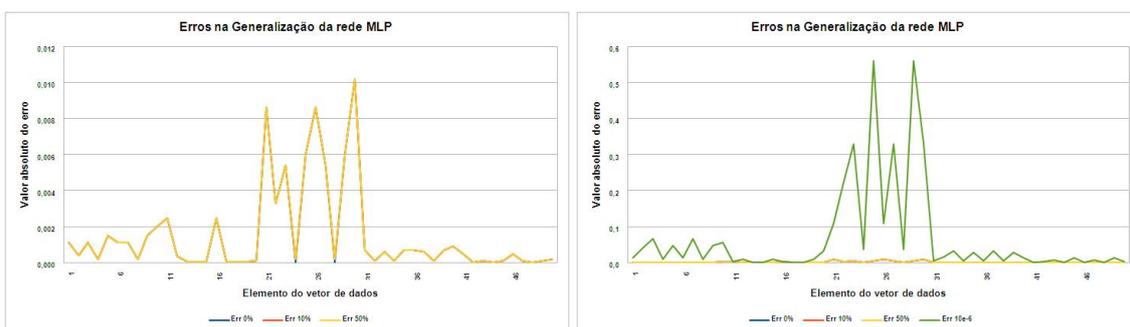


Figura 8. Diferenças entre os valores-alvo e os valores calculados pela rede, obtidos na fase de generalização. À esquerda observamos os valores sem ruído nos dados de entrada, para 10% e 50% de ruído. À direita observamos as diferenças para os valores de entrada alterados para 10^{-6} dos valores originais .

Diante destes resultados verificou-se que após o treinamento a rede apresentou grande robustez à variação de valores na entrada dos dados. No contexto deste trabalho isto significa que, ao seleccionar os cinco pontos iniciais para a construção de um arco,

admite-se alguma variação na correta seleção destes pontos. Imaginando que este processo de seleção seja feito a princípio através de um método assistido, o erro de marcação dos pontos por um operador humano seria admitido, pois a rede devolveria na saída os mesmos parâmetros para a construção daquele arco. Isto mostra que, como abordagem inicial do problema, a solução desenvolvida foi satisfatória, já que foi possível obter da rede os parâmetros necessários à construção dos arcos para os pontos de entrada selecionados em uma imagem. Com isto, numa aplicação de reconhecimento de padrões, seria possível gerar um arco sobreposto à uma linha de campo para os pontos marcados naquela linha.

3. Conclusões

Este trabalho teve como objetivo principal desenvolver uma metodologia robusta para o reconhecimento de padrões das linhas de força do campo magnético coronal solar. Verificou-se através de técnicas de processamento de imagens que a aplicação de sucessivos filtros é importante para ressaltar as linhas de campo, preparando a imagem para uma etapa de segmentação, que foi desenvolvida utilizando-se o algoritmo de Strous e a Transformada de Hough. Os resultados da segmentação se mostraram satisfatórios e compatíveis com as estruturas presentes no disco solar, o que foi verificado com o uso do ambiente *Solar Soft*. Para a etapa de reconhecimento de padrões, desenvolveu-se uma rede neural MLP como teste de conceito para o reconhecimento de padrões. Os resultados do treinamento e da generalização da rede foram também satisfatórios, concluindo-se que como abordagem inicial do problema, a solução desenvolvida atingiu seus objetivos, já que foi possível obter da rede os parâmetros necessários à construção das linhas de campo para os pontos de entrada marcados em uma imagem. Com isto, numa aplicação de reconhecimento de padrões, seria possível gerar um arco sobreposto à uma linha de campo para os pontos marcados naquela linha.

Este trabalho prosseguirá com o desenvolvimento de um método de interconexão dos segmentos de linhas obtidos após a etapa de segmentação, para que no desenvolvimento da etapa de reconhecimento de padrões seja possível obter a maior quantidade possível de dados com alta relação sinal-ruído. Para a etapa de reconhecimento de padrões os estudos prosseguirão a partir da rede conceitual apresentada, desenvolvendo-se uma rede neural que utilize dados reais, com a substituição do algoritmo **ang.m** por um outro baseado no modelo *Linear Force-Free Field*, onde a expressão $\nabla \mathbf{B} = \alpha \mathbf{B}$ governa as linhas de campo. Será desenvolvida também uma metodologia de avaliação das linhas de campo extraídas das imagens obtidas no EUV frente àquelas geradas pelo modelo físico, utilizando as linhas sintéticas geradas pelo modelo como padrões-alvo de treinamento de uma rede neural.

Referências

- Aschwanden, M. J. (2005). *Physics of the Solar Corona. An Introduction with Problems and Solutions (2nd edition)*. Springer-Praxis Publishing.
- Aschwanden, M. J., Lee, J. K., Gary, G. A., Smith, M., and Inhester, B. (2008). Comparison of Five Numerical Codes for Automated Tracing of Coronal Loops. *Solar Physics*, 248:359–377.

- Aschwanden, M. J. and Nightingale, R. W. (2005). Elementary Loop Structures in the Solar Corona Analyzed from TRACE Triple-Filter Images. *Astrophysical Journal*, 633:499–517.
- Bentley, R. D. and Freeland, S. L. (1998). SOLARSOFT - an Analysis Environment for Solar Physics. In *Crossroads for European Solar and Heliospheric Physics. Recent Achievements and Future Mission Possibilities*, volume 417 of *ESA Special Publication*, pages 225–+.
- Castro, A. P. A. d. (2009). *Restauração de imagens com operadores modelados por redes neurais artificiais*. PhD thesis, Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 27–02–09 - Devolução para normalização and 18–06–09 - área da Adriana.
- Duda, R. O. and Hart, P. E. (1972). Use of the hough transformation to detect lines and curves in pictures. *Commun. ACM*, 15(1):11–15.
- Fausett, L., editor (1994). *Fundamentals of neural networks: architectures, algorithms, and applications*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA.
- Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*. Macmillan, New York.
- Lee, J. K., Newman, T. S., and Gary, G. A. (2006). Oriented connectivity-based method for segmenting solar loops. *Pattern Recogn.*, 39(2):246–259.
- Nakagawa, Y. and Raadu, M. A. (1972). On Practical Representation of Magnetic Field. *Solar Physics*, 25:127–135.
- Strous, L. H. (2007). Loop detection. Disponível em: www.lmsal.com/aschwanden/stereo/2000_easton/cdaw.html. Acessado em 28/08/2007.