



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-10092-PRE/5637

**ESTUDO DE REDES NEURAS ARTIFICIAIS NA
IDENTIFICAÇÃO DE ALVOS MÓVEIS EM PROCESSAMENTO
DIGITAL DE IMAGENS**

Francis Garcia*
José Ernesto de Araújo Filho

* UNITAU – bolsista PIBIC/CNPq

Seminário de Iniciação Científica do INPE (SICINPE).

INPE
São José dos Campos
2003



MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

**ESTUDO DE REDES NEURAIAS ARTIFICIAIS NA
IDENTIFICAÇÃO DE ALVOS MÓVEIS
EM PROCESSAMENTO DIGITAL DE IMAGENS**

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

Francis Garcia (UNITAU, Bolsista PIBIC/CNPq)
E-mail: francis.garcia@bol.com.br

MSc. José Ernesto De Araujo Filho (LIT/INPE, Orientador)
E-mail: ernesto@lit.inpe.br

Maio de 2003

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	4
1.1) Considerações Iniciais.....	4
1.2) Objetivo e Motivação.....	5
1.3) Pesquisa sobre o tema	5
1.4) Desenvolvimento	6
CAPÍTULO 2 - IDENTIFICAÇÃO DE ALVOS MÓVEIS – UM BREVE HISTÓRICO	7
CAPÍTULO 3 - REDES NEURAIS KOHONEN NA IDENTIFICAÇÃO DE ALVOS MÓVEIS ..	10
3.1) Fundamentação Teórica	10
3.2) Implementação do algoritmo de Kohonen	12
3.3) Validação do algoritmo para 3 grupos de entradas e 3 condições iniciais.....	14
CAPÍTULO 4 - RESULTADOS E ANÁLISES	17
4.1) Validação do Algoritmo de Kohonen em simulação de movimento	17
4.2) Validação do algoritmo de Kohonen em imagens digitais	21
4.2.1) Validação do algoritmo de Kohonen em imagens fixas com fundo de uma cor	21
4.2.2) Validação do algoritmo de Kohonen em imagens fixas com fundo de várias cores	21
4.2.3) Validação do algoritmo de Kohonen em sequências de imagens (alvos móveis)	24
CAPÍTULO 5 - CONCLUSÃO E TRABALHOS FUTUROS.....	26
5.1) Conclusão.....	26
5.2) Trabalhos Futuros	27
REFERÊNCIAS BIBLIOGRÁFICAS	28

ÍNDICE DAS FIGURAS

Figura 1 - Três classes em um espaço bidimensional	11
Figura 2 - Fluxograma do algoritmo de Kohonen.....	13
Figura 3 - Condições iniciais do treinamento.....	15
Figura 4 - Condições finais do treinamento	15
Figura 5 - Condições iniciais de um treinamento mal-sucedido	15
Figura 6 - Um neurônio tenta convergir para dois grupos	15
Figura 7 - Relação entre a porcentagem de sucesso obtida e o número de neurônios utilizados.....	16
Figura 8 - Baricentros durante o décimo treinamento.....	17
Figura 9 - Treinamento bem-sucedido (2 neurônios, 1 grupo).....	18
Figura 10 - Evolução da nuvem através do tempo	18
Figura 11 - Treinamento bem-sucedido (2 neurônios, 2 nuvens).....	19
Figura 12 - Evolução das duas nuvens através do tempo.....	19
Figura 13 - Treinamento bem-sucedido (5 neurônios, 3 grupos).....	19
Figura 14 - Ampliação da área de cruzamento dos neurônios	19
Figura 15 - Treinamento mal-sucedido (5 neurônios, 3 grupos).....	20
Figura 16 - Treinamento bem sucedido com intervalo de tempo pequeno a cada iteração	20
Figura 17 - Ampliação de uma das áreas de cruzamento da Figura 16.....	20
Figura 18 - Dois treinamentos utilizando dois neurônios e dois alvos.....	21
Figura 19 - Histograma da figura do jogador	22
Figura 20 - Rastreamento de um alvo em uma imagem colorida com fundo de várias cores (2 neurônios).....	22
Figura 21 - Rastreamento de 3 alvos em uma imagem com fundo de várias cores (3 neurônios).....	23
Figura 22 - Rastreamento de um alvo em uma imagem em preto e branco com fundo de várias cores (3 neurônios).....	23
Figura 23 - Sequência de imagens do movimento do avião.....	24
Figura 24 - Rastreamento de um alvo móvel utilizando 1 neurônio	25

CAPÍTULO 1 - INTRODUÇÃO

1.1) Considerações Iniciais

Neste trabalho são utilizadas redes neurais artificiais do tipo Kohonen para identificar e rastrear alvos móveis em processamento digital de imagens.

Redes Neurais Artificiais são técnicas de inteligência artificial inspiradas no modelo de funcionamento neuronal do cérebro humano. Uma rede neural consiste de várias unidades simples de processamento denominadas neurônios. As principais características que tornam desejáveis o estudo e o uso das redes neurais artificiais são a capacidade das mesmas de aprender através da experiência, a capacidade de se adaptar a situações adversas e a sua tolerância a ruídos. Essas características fazem com que as RNAs possam ser utilizadas com relativo sucesso na resolução de problemas tais como: identificação e classificação de padrões, processamento de imagens e controle [1] [8].

Pode-se classificar o aprendizado das redes neurais artificiais em dois tipos distintos [1]. No caso do *aprendizado supervisionado*, a rede é treinada fornecendo-se um conjunto de entradas e as saídas correspondentes e os pesos são atualizados de acordo com a diferença entre a entrada fornecida e a saída esperada. Já no *aprendizado não-supervisionado* as unidades de saída são treinadas para responder a padrões existentes nos valores das unidades de entrada. Ao contrário do treinamento supervisionado, não há um conjunto de categorias pré-definidas nas quais as entradas serão classificadas. A rede deve desenvolver sua própria representação para a classificação das entradas [1].

A rede Kohonen é uma rede neural de aprendizado não-supervisionado, com a capacidade de encontrar padrões entre as entradas apresentadas, agrupando-as de acordo com a sua similaridade [1] [4] [5]. Nesta abordagem o agrupamento se dá através do *treinamento competitivo* de forma que quando uma entrada é apresentada à rede, apenas um neurônio *vencedor* é ativado. Esse neurônio representa a classe a qual pertence essa dada entrada. Desta forma, não é necessário treinar a rede com antecedência apresentando a saída desejada para um determinado conjunto de entradas.

Essa técnica de encontrar agrupamentos de dados é chamada de *clustering*. Para uma rede corretamente treinada, todas as entradas em um mesmo agrupamento deverão selecionar o mesmo neurônio como vencedor.

1.2) Objetivo e Motivação

Este trabalho tem como objetivo verificar o comportamento das redes neurais artificiais na identificação de alvos móveis e analisar a eficiência do método escolhido. As redes neurais Kohonen apresentam a capacidade de reconhecer padrões e agrupar dados com características similares sem a necessidade de treinamento prévio. A rede atualiza-se a medida que vai sendo utilizada [1] [4] [5]. Essas características motivam a utilização da rede Kohonen na tentativa de rastrear alvos móveis, já que a rede não precisa ser treinada com antecedência para executar o rastreamento, podendo ser aplicada em tempo real. Além disso, a tolerância a ruídos apresentada pelas redes neurais em geral [1] [2] [3] é uma característica desejável para o reconhecimento do alvo. Isto nos permite utilizar a rede neural Kohonen na identificação de alvos espaciais, lançamentos de foguetes através de captação visual e imagens de satélites em movimento.

1.3) Pesquisa sobre o tema

Para formar uma base de conhecimento sobre redes neurais, livros e artigos a respeito do tema [1, 2, 3, 8] foram estudados. Após finalizar esta etapa inicial, foi realizada uma pesquisa sobre o tema através da Internet e de bibliotecas. As bibliotecas utilizadas foram: (1) Instituto Nacional de Pesquisas Espaciais; (2) Departamento de informática da Universidade de Taubaté; (3) Departamento de matemática e engenharia da Universidade de Taubaté.

Em seguida, artigos relacionados com o tema foram pesquisados através das seguintes bases de dados: (1) Web of Science – www.webofscience.com, e (2) Capes – www.periodicos.capes.gov.br. Adicionalmente, fontes de conhecimento alternativas relacionadas com o tema foram pesquisadas através de mecanismos de busca na Internet. Nesta busca foram empregados os bancos de sites: (1) yahoo (Brasil) – www.yahoo.com.br, e (2) yahoo (internacional) – www.yahoo.com; os robôs (Máquinas) de busca: (1) radix – www.radix.com.br, (2) uol – www.radaruol.com.br, e (3) google – www.google.com; e o robô (Metamáquina) de busca www.metaminer.com.

1.4) Desenvolvimento

Na primeira fase do projeto, o algoritmo das redes Kohonen foi implementado utilizando-se a linguagem de programação do software MatLab para executar o reconhecimento e rastreamento de alvos. Houveram duas etapas de validação. A primeira consistiu em aplicar o algoritmo no reconhecimento de conjuntos de pontos estáticos representando alvos fixos. Na outra etapa, a posição dos conjuntos de pontos era alterada a cada intervalo de iterações do algoritmo seguindo funções pré-estabelecidas afim de simular um alvo móvel. Através destas validações foi possível perceber a importância para o sucesso do treinamento das (1) Condições iniciais dos neurônios, (2) Quantidade de neurônios a serem treinados, e (3) Posição dos alvos a serem identificados.

Na segunda fase do projeto, o algoritmo foi validado no rastreamento de alvos em imagens digitais. O treinamento foi feito utilizando alvos fixos. Utilizou-se imagens com fundo constituído de uma cor e imagens com fundo constituído de múltiplas cores. No caso das imagens com fundo de múltiplas cores, torna-se importante a escolha do critério de exclusão do fundo da imagem para a execução correta do rastreamento. Em seguida foram feitos testes de rastreamento em sequências de imagens representando um alvo em movimento.

CAPÍTULO 2 - IDENTIFICAÇÃO DE ALVOS MÓVEIS – UM BREVE HISTÓRICO

O problema do rastreamento de alvos móveis é de interesse em diversas áreas de aplicação, no entanto, esta abordagem requer algoritmos que sejam rápidos o suficiente para permitir a sua aplicação em tempo real. O problema de rastreamento de um alvo em movimento é de interesse para diferentes áreas e, em particular, para a área de inteligência artificial.

Atualmente, técnicas de inteligência artificial aplicada a processamento digital de sinais tem sido usadas para a resolução de problemas de reconhecimento e rastreamento de alvos em imagens.

Redes neurais artificiais em conjunto com sistemas nebulosos foram empregados por Wu e Lin [26] como um método de rastreio num campo aproximado de um alvo em movimento.

Schram, VanderLinden, Krose e Groen [11] empregaram a rede neural *feedforward* na identificação de alvos estacionários e móveis para o controle de robôs através do uso de derivadas no tempo da posição do alvo e do manipulador.

Gaudiano, Zalama e Coronado [19] utilizam uma rede neural como controlador de um robô móvel. Esse controlador aprende de forma autônoma a indicar as distâncias percorridas de forma direta e inversa pelo robô através de um ciclo de treinamento não-supervisionado. Como o aprendizado é constante e não-supervisionado, perturbações significativas (como a mudança da planta do robô) levam a uma recalibração interna gradual de forma automática do controle do robô. Nas simulações realizadas, o robô foi capaz de rastrear alvos estacionários e móveis de forma correta dentro do erro mínimo estabelecido.

Chen e Hsueh [21] apresentam um sistema de composição de dados para uma câmera situada no braço do robô SCORBOT-ER VII. O sistema é capaz de realizar o rastreamento visual e a interceptação de alvos móveis utilizando uma rede neural Elman. A rede neural Elman é usualmente uma rede neural de duas camadas (a camada de entrada e a camada de saída) com um retorno (feedback) da camada de saída para a camada de entrada. Dessa forma, o valor da saída é armazenado para ser processado no passo seguinte juntamente com a próxima entrada. Assim, se duas redes Elman idênticas (com os mesmos valores para os pesos) receberem uma mesma entrada em um dado passo, suas saídas poderão ser diferentes devido a estados de retorno diferentes .

Wann e Thomopoulos [22] utilizam uma rede neural artificial de aprendizado não-supervisionado no desenvolvimento de um sistema de composição de dados. Os dados são aplicados em problemas de detecção de alvos em um sistema multicanal de indicação de alvos móveis. As características dos dados recebidos de três canais de radares diferentes são extraídas através de técnicas de processamento de sinais digitais.

Ma e Teng [10] exploram o problema do rastreamento de um alvo móvel em um campo aproximado usando redes neurais nebulosas. O alvo móvel irradia ondas de banda curta que incidem sobre uma série de sensores passivos. A posição do alvo é encontrada através de vários estimadores de ângulo e distância.

Yu e Azimi-Sadjadi [20] desenvolveram uma rede neural para a classificação de alvos explorando o comportamento dinâmico do alvo. O sistema consiste de um extrator de características, uma rede neural geradora de probabilidades condicionais diretas e um novo classificador Bayes sequencial.

Shams [27] utiliza redes neurais no rastreamento de alvos utilizando sensores passivos. Cada sensor fornece o ângulo formado pela linha estimada entre o alvo e o sensor. A partir dos dados de todos os sensores, a rede neural é capaz de estimar a posição dos alvos. A rede neural proposta é uma rede auto-associativa chamada de 'módulos elásticos múltiplos'.

Yang e Meng [25] propõem uma rede neural artificial para a geração de trajetórias em um ambiente não-estacionário. A rede é usada para gerar trajetórias livres de colisões, evitar obstáculos em foma de U e rastrear alvos móveis em ambientes com obstáculos.

Cameron, Grossberg e Guenther [23] utilizam uma RNA que recebe como entrada uma imagem e a posição do ponto de onde se está visualizando a imagem. Como saída a rede fornece a representação da direção, da profundidade do cenário e da localização de objetos móveis. Essas representações são usadas para a navegação em simulações envolvendo o desvio de obstáculos e o rastreamento de um alvo móvel.

Existem abordagens para a detecção e rastreamento de alvos inspiradas em técnicas de rastreamento encontradas nos sistemas visuais de organismos vivos. Missler e Kamangar [14] apresentam uma rede neural artificial que detecta e rastreia um objeto se movendo dentro de seu campo de visão. O trabalho é inspirado em funções de processamento observadas no sistema visual das moscas. A rede

é capaz de detectar mudanças de intensidade de luz, determinar a movimentação de um alvo e fornecer as informações necessárias para realizar o rastreamento. Dror, Florer, Rios e Zagaeski [17] realizaram estudos sobre a utilização de uma rede neural para reconhecimento de padrões que recebe dados em um formato similar ao do sonar de um morcego. A rede foi utilizada com sucesso no reconhecimento de rostos e para determinar a velocidade de um alvo que se movia em direção à câmera. Navabi e Agarwal [18] apresentam um modelo artificial de organização de resposta neural de retina que pode servir como um quadro para a análise da resposta dinâmica em redes neurais artificiais, especialmente nos sistemas visuais.

CAPÍTULO 3 - REDES NEURAIIS KOHONEN NA IDENTIFICAÇÃO DE ALVOS MÓVEIS

Nesta etapa, um algoritmo baseado em redes neurais artificiais do tipo Kohonen será implementado para identificar e rastrear alvos fixos e móveis. As redes neurais Kohonen são um tipo de rede neural capaz de realizar reconhecimento de padrões e agrupamento dos dados através de suas similaridades, ou seja, pela proximidade geométrica das entradas pertencentes a mesma classe. Isso significa que a rede não necessita de treinamento prévio fornecendo-se a saída esperada para uma dada entrada. O aprendizado é obtido apenas apresentando as entradas à rede, que adapta seus pesos de forma a agrupar os dados em conjuntos com características similares.

A rede Kohonen também pode ser considerada uma rede de treinamento competitivo *winner-takes-all*. Nesse tipo de treinamento, a cada entrada apresentada à rede apenas um neurônio é ativado. Esse neurônio é denominado o *neurônio vencedor*, e é neurônio mais apto entre todos os outros para representar o agrupamento o qual pertence a entrada.

3.1) Fundamentação Teórica

A rede Kohonen é uma rede *classificadora*, ou seja, uma rede que agrupa as entradas em classes. Assim, a uma entrada x^k corresponde uma saída y^k , sendo que $y_i^k \in \{-1, +1\}$, em que apenas um neurônio está ativo ($y_j^k = +1$) e os demais estão inibidos ($y_i^k = -1, \forall i \neq j$). O j -ésimo neurônio ativo indica que a entrada x^k pertence à classe j .

Nesse trabalho, tem-se como objetivo organizar, de acordo com a proximidade geométrica, os dados de entrada, x^k , e as classes. As entradas fornecidas à rede são bidimensionais, de forma que $x^k = [x_1^k, x_2^k]$.

Três classes estão representadas na Figura 1. As classes foram obtidas através da geração de pontos ao redor de 3 baricentros. Os pontos azuis representam as entradas geradas e os asteriscos vermelhos representam os baricentros utilizados na geração dos pontos.




Figura 1 - Três classes em um espaço bidimensional

Para cada entrada, um neurônio vencedor w^j é selecionado, sendo:

$$\|x^k - w^j\|^2 < \|x^k - w^i\|^2, \forall i \neq j \quad (1)$$

Após encontrar-se o neurônio vencedor, segue-se a etapa de treinamento. O treinamento consiste em deslocar o neurônio na direção da entrada x^k . Para isso atualiza-se o valor do neurônio vencedor w^j da seguinte forma:

$$w_{novo}^j = w_{anterior}^j + \gamma(x^k - w_{anterior}^j) \quad (2)$$

e para todos os demais neurônios perdedores:

$$w_{novo}^i = w_{anterior}^i, \forall i \neq j \quad (3)$$

sendo que $(\gamma > 0)$ é o passo do treinamento.

O treinamento competitivo da rede Kohonen requer que todas as entradas e neurônios estejam normalizados.

$$\|x^k\|^2 = \|w^i\|^2 = 1, \forall k, i \quad (4)$$

Sendo M o máximo da norma de x^k

$$M = \max \{ \|x^k\|^2 \}, \forall k \quad (5)$$

A normalização de x^k é obtida através do aumento da dimensão de x^k em uma unidade, com a introdução de uma nova componente:

$$x_{n+1}^k = (M - \sum_{i=1}^n (x_i^k)^2)^{1/2} \quad (6)$$

e o uso como entrada do vetor $x^k = M^{-1/2}[x_1^k, x_2^k, \dots, x_n^k, x_{n+1}^k]$, que tem norma unitária. Os neurônios também devem ter seus valores normalizados através do mesmo processo.

3.2) Implementação do algoritmo de Kohonen

Nessa primeira etapa do projeto, todos os algoritmos foram implementados utilizando-se a linguagem de programação do Software MatLab, devido à sua facilidade para a manipulação de matrizes e para a visualização dos resultados.

O algoritmo de Kohonen agrupa entradas em classes de acordo com a sua similaridade; Nesse caso, a proximidade geométrica da entrada em relação a um determinado neurônio caracteriza esta entrada como pertencente à classe representada por aquele neurônio. A cada passo, apenas um neurônio é ativado, sendo este chamado de neurônio vencedor. Este neurônio tem então seu peso atualizado, de forma que seu valor se aproxime um pouco mais do valor que represente a classe a qual pertencem as entradas.

A Figura 2 apresenta passo a passo o funcionamento do algoritmo. Os termos $w(i)$ representam as condições iniciais dos pesos de aprendizado, $x(k)$ está relacionado com as entradas fornecidas para a rede, γ é o coeficiente de aprendizado e K é número de entradas fornecidas.

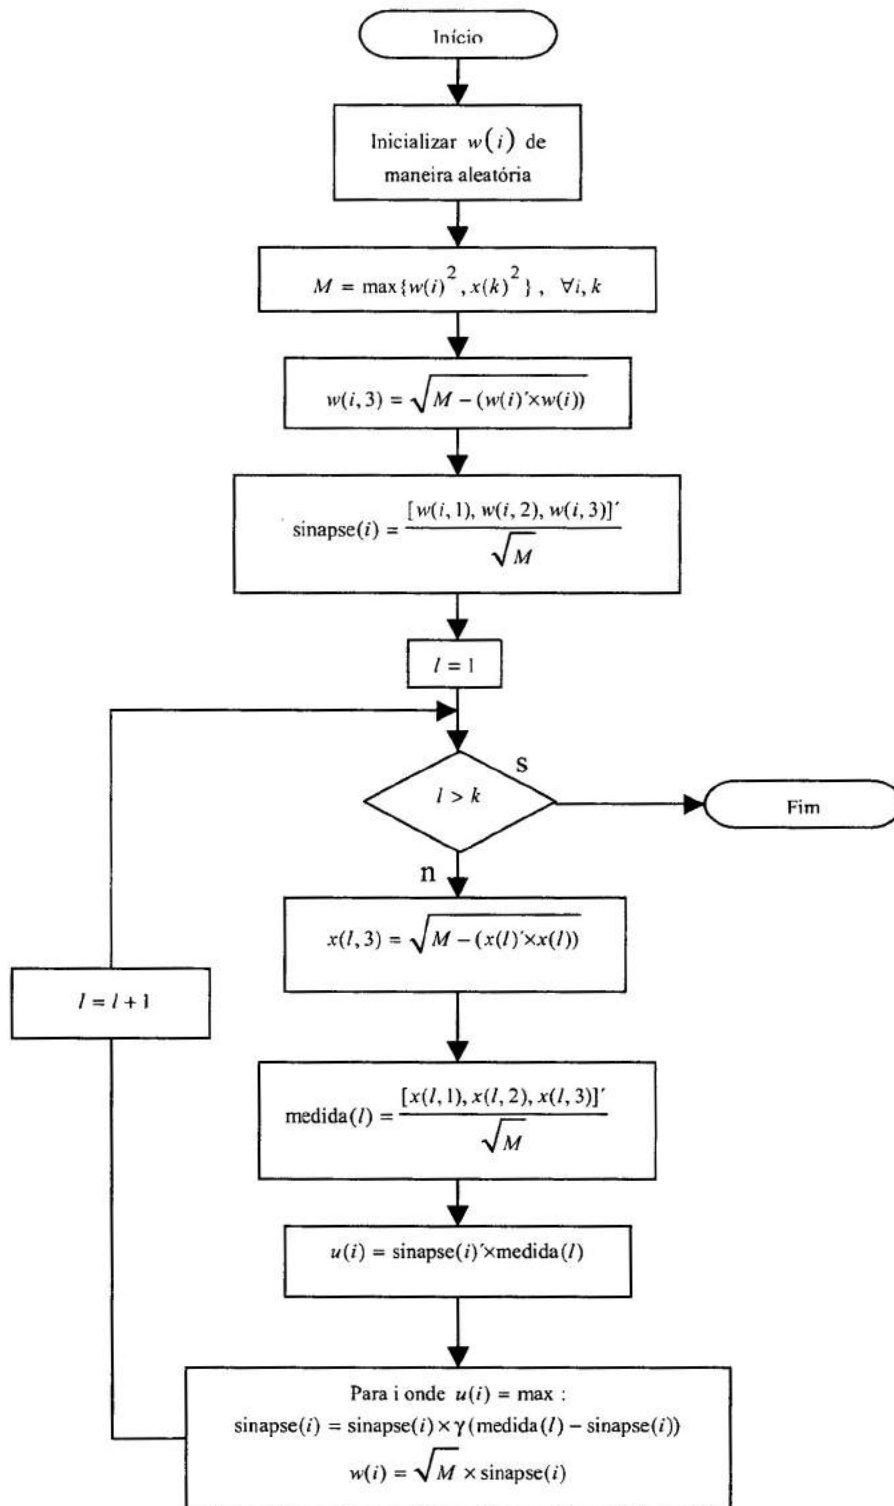


Figura 2 - Fluxograma do algoritmo de Kohonen

A seguir, tem-se a sequência descritiva dos passos:

- 1- São estabelecidas condições iniciais para os pesos dos neurônios w^i de forma aleatória.
- 2- É estabelecido um quociente de aprendizado γ para os pesos. Inicialmente, foi definido $\gamma = 0,1$.
- 3- Normaliza-se as entradas e os pesos de forma que $\|x^k\|^2 = \|w^i\|^2 = 1, \quad \forall i, k$

Os resultados da normalização serão os vetores sinapses (no caso dos pesos) e os vetores medidas (no caso das entradas)

- 4- Dado uma entrada, é calculado um neurônio vencedor, que será o neurônio que mais se aproxima da posição da entrada.
- 5- O peso do neurônio vencedor deverá ser atualizado da seguinte forma:

$$\text{sinapse}(i) = \text{sinapse}(i) \times \gamma (\text{medida}(k) - \text{sinapse}(i))$$

sendo que “i” representa o índice da sinapse vencedora e “k” a entrada apresentada para a rede, ambas normalizadas no passo 3.

- 6- Retorna-se ao passo 3, até que todas as entradas tenham sido apresentadas à rede.

3.3) Validação do algoritmo para 3 grupos de entradas e 3 condições iniciais

Inicialmente, o algoritmo foi testado fornecendo-se como entrada três conjuntos de pontos gerados a partir de baricentros distintos. A geração dos pontos se deu de forma aleatória para que obtivéssemos uma nuvem em torno de cada baricentro. Na Figura 3 estas nuvens estão representadas pelos pontos azuis. Afim de validar o sistema desenvolvido, o algoritmo deveria ser capaz de identificar estes 3 grupos distintos e convergir de maneira adequada para o baricentro de cada grupo. Três neurônios foram treinados, esperando-se que cada um deles identifique uma classe. As condições iniciais dos neurônios foram escolhidas também de forma aleatória. Os asteriscos de cores diferentes na figura 2 e 3 representam as condições iniciais.

A Figura 3 e Figura 4 demonstram o treinamento realizado com sucesso. Cada neurônio foi atualizado de forma a reconhecer um grupo de pontos. O traços coloridos representam os passos dados pelos neurônios a cada treinamento.

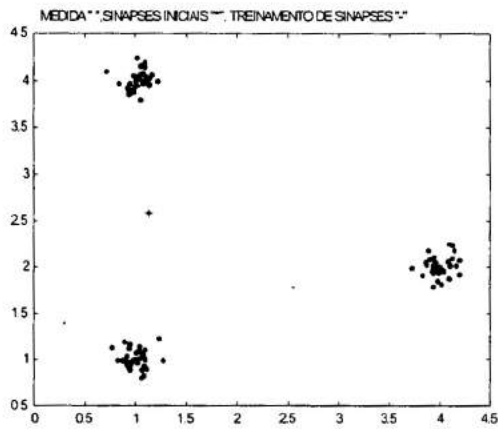


Figura 3 - Condições iniciais do treinamento




Figura 4 - Condições finais do treinamento

No entanto, há treinamentos nos quais os neurônios não conseguem identificar corretamente os grupos de pontos. Através das Figura 5 e Figura 6, percebe-se que um dos neurônios nunca foi treinado, pois nunca foi escolhido como vencedor por classe alguma. Desta forma, duas classes dividem um neurônio, que fica oscilando entre elas. Isso ocorre porque um único neurônio está mais próximo dos dois grupos do que quaisquer outros neurônios.




Figura 5 - Condições iniciais de um treinamento mal-sucedido

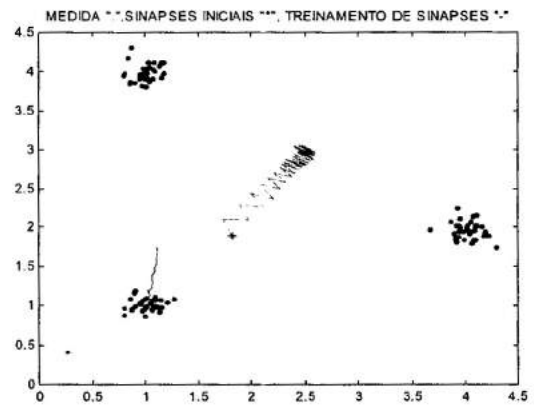


Figura 6 - Um neurônio tenta convergir para dois grupos

Através de diversas simulações foi possível confirmar que a posição inicial dos neurônios é crítica para o sucesso do treinamento [4]. Uma forma de minimizar esse problema seria aumentar o número de neurônios a serem treinados, esperando-se que dessa forma sempre exista um deles próximo o suficiente a uma classe para ser atraído apenas por ela. Isso pode ser comprovado através

do experimento descrito seguir. A rede foi treinada para identificar 3 classes utilizando inicialmente 3 neurônios, posteriormente 6 neurônios e finalmente 12 neurônios, inicializados aleatoriamente.

Tabela 1 - Porcentagem de sucesso no treinamento da rede utilizando diferentes quantidades de neurônios

	<i>Número de sucessos</i>	<i>Número de falhas</i>	<i>Porcentagem de sucesso</i>
3 neurônios	25	15	62,5 %
6 neurônios	30	10	75 %
12 neurônios	36	4	90 %

A Tabela 1 mostra a porcentagem de sucesso obtida treinando-se a rede 40 vezes a cada teste. A Figura 7 demonstra, através de um gráfico, o resultado dos treinamentos.




Figura 7 - Relação entre a porcentagem de sucesso obtida e o número de neurônios utilizados

Através desse experimento, percebe-se que aumentar o número de neurônios minimiza a chance de um neurônio tentar convergir para duas classes. No entanto, o custo computacional cresce a medida que adiciona-se neurônios. Sabe-se que uma das formas de minimizar o problema de um neurônio tentar identificar mais de uma classe é reduzir as chances de vitória de um neurônio a medida que ele vence [4]. Ou seja, quanto mais um neurônio for escolhido como vencedor, menos chance ele tem de vencer nas próximas vezes. Mais adiante serão estudados outros métodos na tentativa de alcançar a resolução desse problema.

CAPÍTULO 4 - RESULTADOS E ANÁLISES

Nesta etapa o algoritmo foi validado em uma simulação de rastreamento de alvos móveis representados por grupos de pontos. Em seguida o algoritmo foi validado no rastreamento de alvos reais em imagens. A validação foi feita a princípio com imagens contendo alvos fixos. Foram utilizadas imagens com o fundo constituído de uma cor e imagens com o fundo constituído de várias cores. Foram pesquisados métodos de exclusão de fundo para a identificação de alvos em imagens com fundo constituído de várias cores. O algoritmo foi então validado no rastreamento de alvos móveis em processamento digital de imagens. Finalmente, foi feita a análise das vantagens e limitações do método empregado.

4.1) Validação do Algoritmo de Kohonen em simulação de movimento

Nessa etapa, os baricentros das classes são gerados a partir de funções $f(x)$, determinando-se funções diferentes para cada baricentro. Dessa forma, após cada etapa de treinamento da rede, o x de cada baricentro será atualizado, gerando outros conjuntos de pontos que serão apresentados à rede para um novo treinamento. As condições iniciais dos neurônios nesse novo treinamento serão iguais às condições finais do treinamento anterior.

A Figura 8 mostra a evolução de três baricentros através das etapas de treinamento. A posição de cada baricentro nas etapas anteriores também é mostrada no gráfico, para que seja possível visualizar suas trajetórias.




Figura 8 - Baricentros durante o décimo treinamento

No caso anterior, os baricentros $x1$, $x2$ e $x3$ foram inicializados nas posições $(1,0)$, $(2,4)$ e $(3,2)$, respectivamente. A cada passo, o x foi incrementado em $0,5$, respectivamente para $x1$, $x2$ e $x3$, e os baricentros foram atualizados de acordo com as seguintes funções:

$$f1(x) = 1.4x - \cos(x) \tag{7}$$

$$f2(x) = x^{1.2} - \left(\frac{x}{2}\right)^3 \tag{8}$$

$$f3(x) = \sin(x) \tag{9}$$

Ao treinar-se a rede, espera-se que os neurônios sejam capazes de seguir as concentrações de pontos a medida que estas se deslocam.

Seguem-se amostras de alguns treinamentos: As estrelas pretas representam as condições iniciais das sinapses, os asteriscos representam os baricentros e os traços azuis representam o treinamento das sinapses. As nuvens de pontos em si foram omitidas, mas pode-se visualizar suas localizações através dos baricentros.

Na Figura 9, é apresentado um treinamento no qual há apenas um grupo de pontos se deslocando. Nessa situação, todos os testes realizados demonstraram que a rede é capaz de rastrear o alvo corretamente.

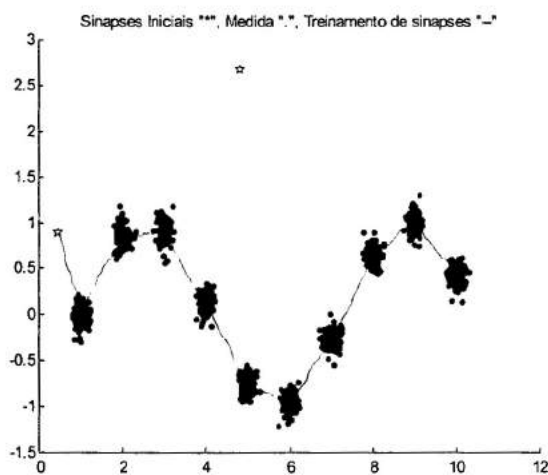


Figura 9 - Treinamento bem-sucedido (2 neurônios, 1 grupo)

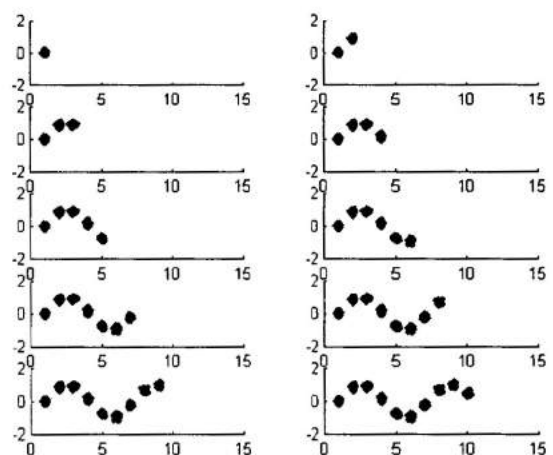


Figura 10 - Evolução da nuvem através do tempo

É de se esperar que o cruzamento entre as nuvens ocasione erros de treinamento. Isto significa que pode ocorrer a troca dos alvos entre os neurônios, ou então um neurônio pode passar a perseguir mais de um alvo. No ultimo caso não haverá convergência de treinamento. No entanto, nos treinamentos apresentados na Figura 11 e Figura 13, os neurônios reconheceram e rastream a corretamente as classes, apesar do cruzamento entre as nuvens. A Figura 14 é uma ampliação da Figura 13, focada no trecho da figura em que ocorre o cruzamento dos neurônios, demonstrando que cada um deles conseguiu rastrear devidamente o seu grupo.

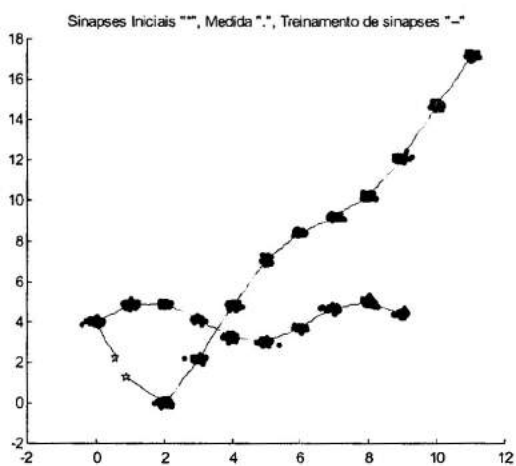


Figura 11 - Treinamento bem-sucedido (2 neurônios, 2 nuvens)




Figura 12 - Evolução das duas nuvens através do tempo

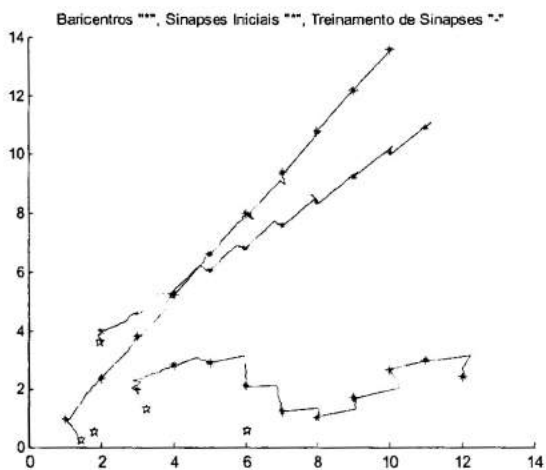


Figura 13 - Treinamento bem-sucedido (5 neurônios, 3 grupos)

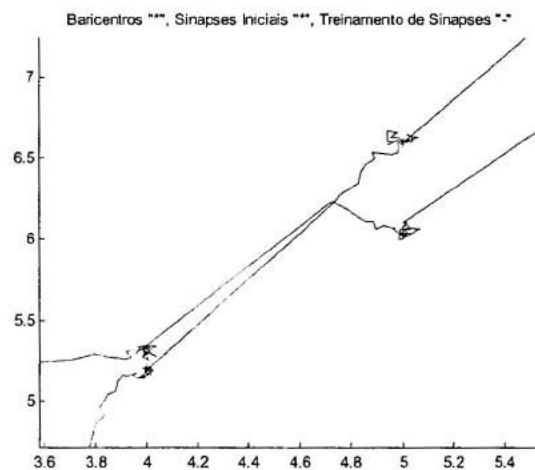


Figura 14 - Ampliação da área de cruzamento dos neurônios

A Figura 15 mostra um treinamento mal-sucedido. Pode-se visualizar que, em um primeiro momento, os grupos foram rastreados corretamente. Após o cruzamento das nuvens o rastreamento não é mais feito da forma correta, ocorrendo a troca de grupos entre os neurônios. Assim, percebe-se que a ocorrência de cruzamento entre os alvos é um fator que pode levar a falhas no rastreamento. Outro fator importante para determinar o sucesso no rastreamento é o salto dado pelas nuvens a cada intervalo de iterações. Quanto menor é o deslocamento das nuvens, mais fácil se torna o rastreamento. Nos exemplos apresentados anteriormente o deslocamento das nuvens em cada intervalo de iterações é grande. A Figura 16 mostra um rastreamento de alvos com intervalo de deslocamento menor.

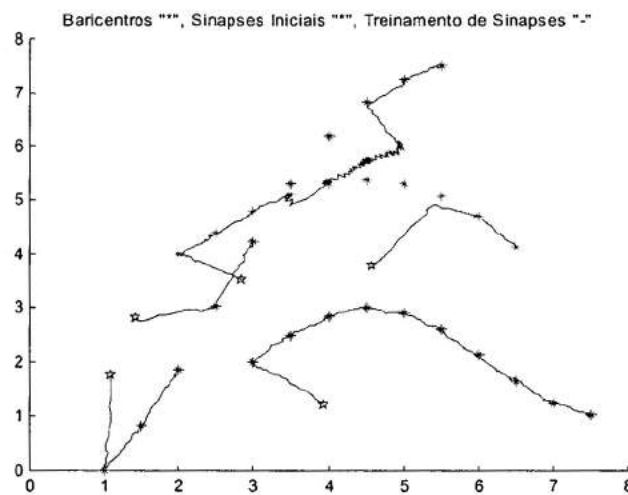


Figura 15 - Treinamento mal-sucedido (5 neurônios, 3 grupos)




Figura 16 - Treinamento bem sucedido com intervalo de tempo pequeno a cada iteração




Figura 17 - Ampliação de uma das áreas de cruzamento da Figura 16

4.2) Validação do algoritmo de Kohonen em imagens digitais

Nessa etapa o algoritmo foi validado no rastreamento de alvos em processamento digital de imagens.

Uma das dificuldades em se rastrear alvos em imagens digitais consiste na identificação dos *pontos válidos* contidos na imagem. Entende-se por *pontos válidos* o conjunto de pixels que compõe o alvo a ser rastreado.

4.2.1) Validação do algoritmo de Kohonen em imagens fixas com fundo de uma cor

A primeira simulação foi feita com uma imagem contendo duas figuras de aviões. O fundo da imagem é constituído de apenas uma cor, facilitando a identificação dos alvos. Dessa forma o conjunto de pontos válidos foi encontrado excluindo-se a cor do fundo. Os pontos foram apresentados à rede em uma sequência aleatória. O resultado das simulações é mostrado na Figura 18.




Figura 18 – Dois treinamentos utilizando dois neurônios e dois alvos

4.2.2) Validação do algoritmo de Kohonen em imagens fixas com fundo de várias cores

Para realizar o rastreamento dos alvos em imagens com fundo de várias cores foi utilizado um critério de exclusão para determinar quais pontos são válidos para executar o rastreamento. O critério de exclusão foi determinado através do histograma da imagem. É aplicado ao histograma um nível de corte que vai determinar as cores que pertencem ao fundo da imagem. Assim,

encontram-se as cores que aparecem com mais frequência no histograma, e os pontos constituídos por essas cores não serão rastreados. A Figura 19 mostra o histograma de uma das imagens utilizadas nos treinamentos. A linha vermelha representa o nível de corte para determinar o fundo da imagem e selecionar o alvo.




Figura 19 - Histograma da figura do jogador

A Figura 20 e Figura 21 mostram treinamentos realizados com sucesso em imagens coloridas. A Figura 22 mostra um treinamento realizado com sucesso utilizando uma imagem em preto e branco.




Figura 20 - Rastreamento de um alvo em uma imagem colorida com fundo de várias cores (2 neurônios)




Figura 21 - Rastreamento de 3 alvos em uma imagem com fundo de várias cores (3 neurônios)




Figura 22 - Rastreamento de um alvo em uma imagem em preto e branco com fundo de várias cores (3 neurônios)

O critério adotado para a seleção do alvo não é definitivo. Dentre as sugestões para trabalhos futuros inclui-se a pesquisa de métodos de seleção do alvo mais adequados para a aplicação do algoritmo.

4.2.3) Validação do algoritmo de Kohonen em sequências de imagens (alvos móveis)

Nessa etapa o algoritmo foi validado utilizando uma sequência de imagens contendo um alvo em movimento. As imagens utilizadas no treinamento possuem fundo de uma cor e apenas um alvo. A Figura 23 mostra a sequência de imagens utilizada.

Na Figura 24 pode-se observar o rastreamento de um alvo utilizando-se um neurônio. A linha vermelha representa o trajeto do neurônio desde o início do treinamento e o asterisco azul representa a posição do neurônio após o treinamento em cada quadro da imagem. O rastreamento foi executado corretamente durante todos os passos do treinamento. O critério de exclusão de fundo de imagem adotado para este treinamento é o mesmo já utilizado anteriormente para imagens com fundo de uma cor.

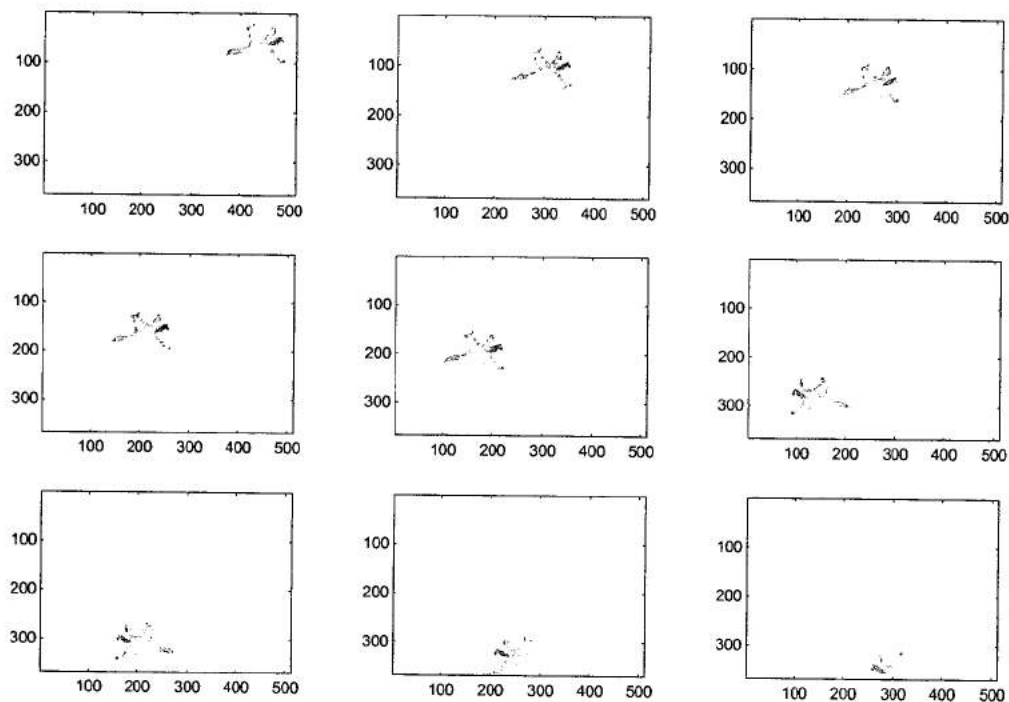


Figura 23 - Sequência de imagens do movimento do avião

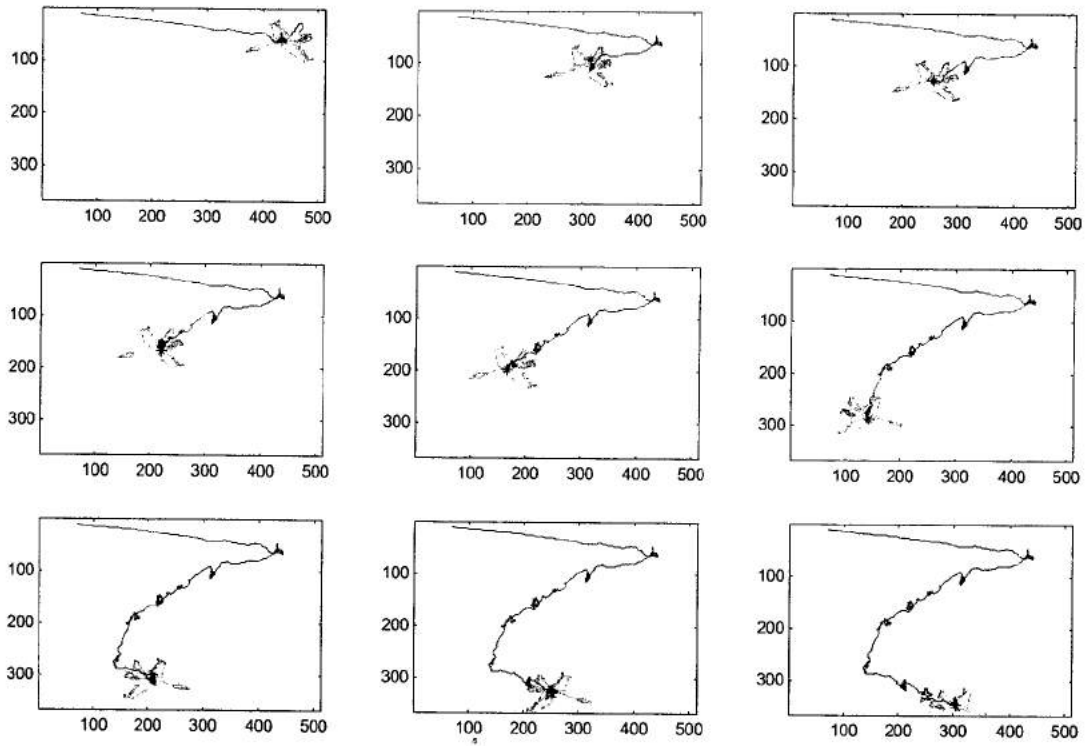


Figura 24 - Rastreamento de um alvo móvel utilizando 1 neurônio

CAPÍTULO 5 - CONCLUSÃO E TRABALHOS FUTUROS

5.1) Conclusão

No início da primeira fase do projeto foi feito um estudo sobre redes neurais artificiais através de livros e artigos apresentados pelo orientador. Logo após, foi feita uma pesquisa sobre a aplicação das redes neurais artificiais no rastreamento de alvos, além de um estudo sobre outras técnicas utilizadas para resolver o problema em questão. Essa pesquisa foi feita através de bibliotecas e bases de dados especializadas.

Em seguida foi implementado, através da linguagem de programação do software MatLab, um algoritmo baseado nas redes neurais artificiais Kohonen para a identificação de alvos. Inicialmente, o algoritmo foi validado através de simulações de rastreamento de alvos representados por grupos de pontos. A rede foi então treinada em diversas condições distintas para analisar a influência das variáveis envolvidas no sucesso do treinamento.

Verificou-se que a posição inicial dos neurônios é um fator de importância para o sucesso do treinamento, e que a adição de neurônios aumenta a probabilidade de sucesso, apesar de acarretar maior custo computacional. Além disso, comprovou-se que o cruzamento dos alvos móveis pode dificultar o rastreamento.

A segunda fase do projeto consistiu em validar o algoritmo de rastreamento na identificação de alvos em processamento digitais de imagens.

Foram utilizadas imagens com fundo de uma cor contendo alvos fixos e a rede foi capaz de rastrear os alvos corretamente. Em seguida, o algoritmo foi aplicado a imagens com fundo constituído de várias cores. Verificou-se que a escolha do critério de exclusão de fundo a ser utilizado exerce grande influência no sucesso do treinamento.

O algoritmo foi, então, validado no rastreamento de alvos móveis em imagens.

O critério de exclusão adotado na validação do algoritmo apresentou resultados satisfatórios para o rastreamento de alvos nas imagens utilizadas. Para o conjunto de imagens empregadas durante os experimentos iniciais e a validação do algoritmo, os treinamentos foram realizados com sucesso.

Todavia, a fim de generalizar a utilização da abordagem desenvolvida, novos experimentos representando um espectro maior de aplicações precisam ser realizados. É importante salientar ainda que este trabalho não tinha como objetivo obter sucesso no rastreamento considerando todas as limitações envolvidas no processo, como, por exemplo, o cruzamento entre os alvos. Por isto é preciso realizar novos testes e estudar a aplicação de outras técnicas para aumentar a área de aplicação do algoritmo, conforme apresentado no item *trabalhos futuros*.

5.2) Trabalhos Futuros

Como sugestões para trabalhos futuros tem-se:

- A) A pesquisa de como minimizar a chance de um neurônio classificar dois alvos diferentes, no caso de treinamentos envolvendo mais de um alvo.
- B) O estudo de técnicas que evitem que os neurônios troquem de alvos quando ocorre o cruzamento dos mesmos durante o movimento.
- C) A pesquisa de outros critérios de exclusão de fundo da imagem, além do critério utilizado neste trabalho, que possam aumentar a chance do rastreamento dos alvos

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Krose, Ben; Smagt, Patrick Van Der – **An Introduction to Neural Networks**, eighth edition.
- [2] Nascimento Jr., C. L.; Yoneyama, Takashi – **Inteligência Artificial em Controle e Automação**, Ed. Edgard Blucher Ltda, 2000.
- [3] Kovács, Zsolt L. – **Redes Neurais Artificiais: Fundamentos e Aplicações**, 2ª ed São Paulo: Edição Acadêmica, 1996.
- [4] Calôba, Luiz P. – **Introdução à Computação Neuronal**, IX Congresso Brasileiro de Automação, 1992, Vitória, ES. Mini-curso 2. p. 25-38.
- [5] Masters, Timothy – **Practical Neural Network Recipes in C++**, Academic Press.
- [6] LiMin Fu – **Neural Networks in Computer Intelligence**, University of Florida, Gainesville.
- [7] Rojas, Raúl – **Neural Networks: A Systematic Introduction**, Springer.
- [8] Balakrishnan, S. N.; Weil, R.D. – **Neurocontrol: A Literature Survey**, Elsevier Science Ltd, 1996.
- [9] Agbinya, Johnson I.; Rees, David – **Multi-Object Tracking in Video**, Academic Press, 1999.
- [10] Ma, C.W., Teng, C.C., **Tracking a near-field moving target using fuzzy neural networks**, Fuzzy Sets And Systems, 110 (3): 365-377 MAR 16 2000.
- [11] Schram, G., vanderLinden, F.X., Krose, B.J.A., Groen, F.C.A., **Visual tracking of moving objects using a neural network controller**, Robotics And Autonomous Systems, 18 (3): 293-299 AUG 1996.
- [12] Matthews, N.D., Na, P.E., Charnley, D., Harris, C.J., **Vehicle detection and recognition in greyscale imagery**, Control Engineering Practice, 4 (4): 473-479 APR 1996.
- [13] Kocjancic, R., Zupan, J. **Application of a feed-forward artificial neural network as a mapping device**, Journal Of Chemical Information And Computer Sciences, 37 (6): 985-989 Nov-Dec 1997.
- [14] Missler, J.M., Kamangar, F.A., **A Neural-Network For Pursuit Tracking Inspired By The Fly Visual-System**, Neural Networks, 8 (3): 463-480 1995.
- [15] Tipping, M.E., Lowe, D., **Shadow targets: A novel algorithm for topographic projections by radial basis functions**, Neurocomputing, 19 (1-3): 211-222 Mar 1998.
- [16] Amoozegar, F., **Neural-network-based target tracking state-of-the-art survey**, Optical Engineering, 37 (3): 836-846, 1998.
- [17] Dror, I. E., Florer, F. L., Rios, D., Zagaeski, M., **Using Artificial Bat Sonar Neural Networks for Complex Pattern Recognition: Recognizing Faces and the Speed of a Moving Target**, Biological Cybernetics, 74 (4): 331-338, 1996.

- [18] Navabi, H., Agarwal, A., **Adaptative Response Organizer Network for Space-time Patterns in Low Level Vision**, Neural Networks, 11 (5): 825-836, 1998.
- [19] Gaudiano, P., Zalama, E., Coronado, J.L., **An unsupervised neural network for low-level control of a wheeled mobile robot: Noise resistance, stability, and hardware implementation**, IEEE Transactions On Systems Man And Cybernetics Part B-Cybernetics, 26 (3): 485-496 JUN 1996.
- [20] Yu, X., Azimi-Sadjadi, M.R., **Neural network directed bayes decision rule for moving target classification**, IEEE Trans. on Aerospace and Electronic Systems, 36 (1): 176-188, 2000.
- [21] Chen, Y. M., Hsueh, C.S., **Complementary Data Fusion in Vision-guide and Control of Robotic Tracking**, Robotica, 19: 53-58 Part 1, 2001.
- [22] Wann, C.D., Thomopoulos, S.C.A., **Application of self-organizing neural networks to multiradar data fusion**, Optical Engineering, 36 (3): 799-813, 1997.
- [23] Cameron, S., Grossberg, S., Guenther, F.H., **A self-organizing neural network architecture for navigation using optic flow**, Neural Computation, 10 (2): 313-352, 1998.
- [24] Yu, N., Wu, H., Wang, R.S., **Morphological neural networks with applications to image target detection**, Chinese Journal Of Electronics, 10 (1): 85-90, 2001.
- [25] Yang, S. X., Meng, M., **Neural Network Approaches to Dynamic Collision-Free Trajectory Generation**, IEEE Transaction on System Man and Cybernetic Part B-Cybernetics, 31 (3): 302-318, 2001.
- [26] Wu, S. J., Lin, C. T., **Global Optimal Fuzzy Tracker Design Based on Local Concept Approach**, IEEE Transaction On Fuzzy Systems, 10 (2): 128-143, 2002.
- [27] Shams, S. **Neural Network Optimization for Multi-Target Multi-Sensor Passive Tracking**, proceedings of the IEEE, vol. 84, No. 10, October, 1996.



Título

ESTUDO DE REDES NEURAIS ARTIFICIAIS NA IDENTIFICAÇÃO DE ALVOS MÓVEIS EM PROCESSAMENTO DIGITAL DE IMAGENS.

Autor

Francis Garcia José Ernesto de Araújo Filho

Tradutor

Não há.

Editor

Origem	Projeto	Série	No. de Páginas	No. de Fotos	No. de Mapas
DMC	Pibic		28	24	0

Tipo

RPQ PRE NTC PRP MAN PUD TAE

Divulgação

Externa Interna Reservada Lista de Distribuição Anexa

Periódico / Evento

Seminário de Iniciação Científica do INPE - SICINPE 2003

Convênio

Autorização Preliminar

___/___/___
Data

Flávio Roberto Kuga
Chefe de Divisão de Mecânica Espacial
Controle - DMC
Titular da Unidade

Revisão Técnica

Solicitada Dispensada

Recebida ___/___/___ Devolvida ___/___/___

Leonel Fernando Perondi
Engenheiro de Controle e Instrumentação Especial
Titular de Nível "A"

Assinatura do Revisor

Revisão de Linguagem

Solicitada Dispensada

Recebida ___/___/___ Devolvida ___/___/___

Leonel Fernando Perondi
Engenheiro de Controle e Instrumentação Especial
Titular de Nível "A"

Assinatura do Revisor

Autorização Final

___/___/___
Data

Titular da Unidade

Palavras Chave

Redes neurais, processamento, imagens



Secretaria	
//_ Data	Recebida _/_/_ Devolvida _/_/_
_____	_____
Encaminhado Por	Devolvido Por

Controle e Divulgação		
//_ Data	Recebido Por: _____	Devolvido Para: _____
Pronto Para Publicação em: _/_/_		_/_/_ Data
No. _____	Quant. _____	_____
		Assinatura

Observações