

# Reconhecimento de Padrões em Imagens Utilizando Redes Neurais Artificiais como Estimador de Correlação Espectral

**Fernando César C. de Castro**

fernando@madona.pucrs.br

Depto. Eletrônica - PUCRS

90619 - 900 - Porto Alegre, RS

**José Nelson Amaral**

amaral@madona.pucrs.br

Depto. Eletrônica - PUCRS

90619 - 900 - Porto Alegre, RS

**Paulo Roberto G. Franco**

pfranco@madona.pucrs.br

Depto. Eletrônica - PUCRS

90619 - 900 - Porto Alegre, RS

## Resumo

Redes Neurais Artificiais são usadas como estimadores de correlação espectral entre duas imagens bidimensionais. Para cada imagem padrão a ser detectada, determina-se as  $m$  direções de máxima densidade espectral. Reproduções do padrão escalonadas são usadas para treinar  $m$  RNAs quanto ao módulo do espectro da imagem padrão em cada uma destas direções. O mínimo da variância entre o módulo do espectro da imagem alvo e do padrão nas  $m$  direções é utilizado para determinar o ângulo de rotação do padrão na imagem alvo. Esta técnica de detecção oferece a vantagem de ser invariante a rotação, translação e escalonamento do padrão.

## Abstract

Artificial Neural Networks are used as estimators of the spectral correlation between two two-dimensional images. For each pattern to be detected, the  $m$  directions of maximum spectral density are determined. Scaled copies of the same pattern are used to train  $m$  ANNs with the module of the spectrum of the pattern in these  $m$  directions. The minimum variance between the module of the spectrum of the pattern and the target image in this  $m$  directions is used to determine the angle in which the pattern is rotated in the target image. This technique has the advantage of invariance regarding rotation, translation and scaling of the pattern.

## 1 Introdução

O problema do reconhecimento de um padrão em uma imagem alvo bidimensional consiste em identificar a existência do padrão na imagem, a frequência de ocorrência do padrão e seu grau de escalonamento [5]. Dentre os algoritmos utilizados para o reconhecimento de padrões encontram-se o Método dos Descritores de Fourier [6], o Método da Extração de *Features* [7], o Método dos Momentos da Região Limítrofe [4] e as Redes Neurais Artificiais [8].

Na área médica, reconhecimento de padrão é utilizado para a identificação de anomalias fisiológicas em imagens radiográficas [9]. Na indústria de defesa, o reconhecimento de padrão é um importante instrumento na localização de alvos em imagens de satélite e aerofotogrametria [10]. Na indústria metal-mecânica imagens ultrassonográficas são usadas para detectar padrões de falha de peças submetidas a esforços.

Algoritmos para reconhecimento de padrões podem operar tanto no domínio espaço quanto no domínio frequência. Os algoritmos que operam no domínio espaço baseiam-se no processamento das

coordenadas de posição  $(x,y)$  da imagem alvo. A operação destes algoritmos é dificultada pelas variações na posição, no ângulo de rotação e no grau escalonamento da imagem padrão na imagem alvo. Os algoritmos que operam no domínio frequência utilizam o espectro da imagem obtido através de uma *Fast Fourier Transform* (FFT). Estes algoritmos usufruem do fato de que a informação de posição do padrão está contida no espectro de fase e a informação de formato está contida no espectro de módulo da imagem alvo. Lugt foi um dos pioneiros no uso de filtragem espacial complexa para o reconhecimento de padrões [1].

Tradicionalmente Redes Neurais Artificiais têm sido usadas para o reconhecimento de padrões no domínio espaço [11]. Este artigo propõe um novo método para a solução do problema de reconhecimento de padrões. Este método consiste em selecionar as  $m$  direções de maior energia espectral da imagem padrão e utilizar uma RNA para aprender as características do espectro de módulo em cada uma destas direções. Para o treinamento das  $m$  RNAs, imagens do padrão com diferentes graus de escalonamento são geradas, a

FFT destas imagens é computada e o valor do espectro de módulo na direção  $j$  é utilizado para treinar a  $j$ -ésima RNA.

A grande vantagem deste novo método de reconhecimento de padrão é a imunidade a variações de posição do padrão no alvo. Esta imunidade é obtida porque o espectro de módulo da representação da imagem alvo no domínio frequência é invariante à posição e rotação do padrão. A única informação contida neste espectro refere-se à forma do padrão. Como o treinamento das RNAs é feito antecipadamente, a única complexidade adicional no momento do reconhecimento do padrão é a transformação da imagem do domínio espaço para o domínio frequência através da FFT. A utilização apenas das informações contidas nas  $m$  direções de maior energia espectral reduz a complexidade computacional do método proposto. Caso fosse utilizada a totalidade das informações espectrais no domínio frequência o novo método poderia ser tão complexo quanto os métodos tradicionais que utilizam as informações no domínio espaço.

## 2 Quantificação de uma imagem

Seja uma imagem bidimensional contínua com largura  $L$  e altura  $H$ . Seja um conjunto de  $N^2$  células retangulares de dimensões individuais  $L/N$  x  $H/N$  obtido da subdivisão da imagem contínua em  $N$  partições por dimensão. Sejam  $x = 0, 1, \dots, N-1$  e  $y = 0, 1, \dots, N-1$  os índices associados às células respectivamente nas dimensões  $L$  e  $H$ .

Uma célula é caracterizada por um conjunto de atributos óticos tais como cor e intensidade luminosa. Seja uma matriz de representação espacial  $f$  de dimensão  $N \times N$ , onde  $f(x_0, y_0)$  representa o valor do atributo ótico predominante na célula  $(x_0, y_0)$  de uma imagem contínua. A célula retangular  $(x_0, y_0)$  é chamada de *pixel*, e  $f(x_0, y_0)$  é o “valor do pixel”. Doravante nos referiremos à matriz  $f$  como sendo a própria imagem contínua por ela representada.

## 3 O Espectro Bidimensional de uma Imagem

Seja uma imagem  $f(x,y)$  de dimensões  $N \times N$ .

Define-se o espectro  $F(u,v)$  de  $f(x,y)$  como sendo a Transformada Direta de Fourier em duas dimensões de  $f(x,y)$  [3]:

$$F(u,v) = \frac{1}{N^2} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x,y) e^{-i\frac{2\pi}{N}(ux+vy)} \quad (1)$$

Dado o espectro  $F(u,v)$  no domínio frequência, podemos retornar à imagem  $f(x,y)$  no domínio

espaço através da Transformada Inversa de Fourier em duas dimensões de  $F(u,v)$ :

$$f(x,y) = \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} F(u,v) e^{i\frac{2\pi}{N}(ux+vy)} \quad (2)$$

Dizemos que (1) e (2) definem pares equivalentes de representações,  $f(x,y)$  no domínio espaço e  $F(u,v)$  no domínio frequência. A equivalência aqui reside na dualidade de existência da imagem em ambos os domínios. Formalizamos esta dualidade através de:

$$f(x,y) \Leftrightarrow F(u,v) \quad (3)$$

## 4 Propriedades do Espectro Bidimensional

As seguintes propriedades são relevantes na detecção de padrões no domínio frequência:

### 4.1 Translação no Domínio Espaço

A relação (4) indica que enquanto a fase do espectro é alterada quando desloca-se uma imagem no domínio espaço, o módulo do espectro permanece inalterado. Esta propriedade garante que a detecção do padrão no domínio frequência seja independente de sua posição no domínio espaço.

$$f(x - x_0, y - y_0) \Leftrightarrow F(u,v) e^{-i\frac{2\pi}{N}(ux_0+vy_0)} \quad (4)$$

### 4.2 Rotação

Sejam as coordenadas polares em ambos domínios, espaço e frequência, definidas por:

$$x = r \cos \theta \quad y = r \sin \theta \quad (5a)$$

$$u = \omega \cos \phi \quad v = \omega \sin \phi \quad (5b)$$

Então

$$f(r, \theta + \theta_0) \Leftrightarrow F(\omega, \phi + \theta_0) \quad (6)$$

A relação (6) indica que se a imagem no domínio espaço  $f(x,y)$  é girada de  $\theta_0$ , então sua representação no domínio frequência  $F(u,v)$  é girada do mesmo ângulo.

### 4.3 Energia e Densidade Espectral de Energia

$$E = \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} (f(x,y))^2 = \frac{1}{N^2} \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} |F(u,v)|^2 \quad (7)$$

Esta propriedade afirma que a energia total  $E$  de uma imagem pode ser obtida tanto no domínio espaço quanto no domínio frequência. O termo  $|F(u,v)|^2$  denominado Densidade Espectral de Energia da imagem  $f(x,y)$ .

### 4.4 Giro de 180° no Domínio Espaço

$$f(-x,-y) \Leftrightarrow F^*(u,v) \quad (8)$$

Esta propriedade indica que ao girarmos 180° a imagem  $f(x,y)$ , implica o espectro resultante ser o conjugado do original.

## 5 Formação dos Conjuntos de Treino e o Sistema de RNA Utilizado

Obtido o espectro da imagem padrão, o primeiro passo consiste em treinar um conjunto de RNAs para reconhecer as características espectrais do padrão. Neste artigo o conjunto de treino foi formado considerando-se apenas variações do módulo do espectro  $P(u,v)$  resultante do escalonamento do padrão  $p(x,y)$  no domínio espaço. Especificamente, foi utilizada para treino a seqüência  $|P(u,v)|$  resultante do escalonamento de  $p(x,y)$  pelo conjunto de fatores  $\alpha=\{1, 0.98, \dots, 0.1\}$ . É possível acrescentar ao treino do sistema das RNAs qualquer variação adicional considerada relevante, tais como ruído, efeitos de desfocalização do sistema ótico de aquisição da imagem alvo e variações quanto ao ângulo de perspectiva do padrão no alvo. Não é necessário incluir no treino o efeito de rotação de  $p(x,y)$  no plano  $(x,y)$  visto que o sistema de detecção extrai amostras do módulo do espectro da imagem alvo utilizando um sistema de coordenadas polares.

Para reduzir a complexidade de processamento o treino das RNAs não é realizado com todos os valores de  $|P(u,v)|$ . Seja  $P(\omega,\phi)$  o espectro padrão  $P(u,v)$  expresso em coordenadas polares conforme equação (5b). Detecta-se as  $m$  direções  $\phi_j, j = 0, 1, \dots, m-1$ , de máxima energia  $E$ , e treina-se as  $m$  RNAs com os  $\omega=0, 1, \dots, N/2$  valores de  $|P(\omega,\phi_j)|$  extraídos ao longo da direção  $\phi_j$  para cada  $|P(u,v)|$  resultante do escalonamento de  $p(x,y)$  pelo conjunto de valores definido por  $\alpha$ . Por exemplo, considere a imagem  $p(x,y)$  de  $N \times N$  pixels,  $N=128$ , da letra “A” mostrada na Figura 1, e o módulo ( $\log(|P(u,v)|+1)$ ) de seu espectro juntamente com as  $m$  ( $m=3$ ) direções  $\phi_j$  ao longo das quais é máxima a energia definida por (9).

$$E(\phi_j) = \sum_{\omega=0}^{N/2} |F(\omega, \phi_j)|^2 \quad (9)$$




Figura 1: Letra “A” e módulo de seu espectro

Para cada  $|P(\omega,\phi)|$  resultante do escalonamento de  $p(x,y)$  por um dos valores de  $\alpha=\{1, 0.98, \dots, 0.1\}$  extraem-se os 65 ( $\omega=0, 1, \dots, N/2$ ) valores de  $|P(\omega,\phi)|$  ao longo das direções  $\phi_0 = 24^\circ$ ,  $\phi_1 = 156^\circ$  e  $\phi_2 = 90^\circ$ , a partir do centro do espectro ( $\omega=0$ ), formando os vetores  $S_0(\omega)$ ,  $S_1(\omega)$  e  $S_2(\omega)$  para cada valor de  $\alpha$ .

Para cada direção  $\phi_j$  forma-se o conjunto de treino  $T_j$  formado por  $V$  funções membro, cada uma delas constituída pelas 65 amostras espectrais contidas no vetor  $S_j(\omega)$ , mais um elemento adicional representando o valor do respectivo  $\alpha$  necessário para determinação do erro instantâneo no aprendizado por propagação reversa (*back-propagation*) [2]. O número de funções membro  $V$  é dependente dos valores máximo, mínimo e decremento adotados para  $\alpha$ . A expressão (10) ilustra este cálculo para o conjunto  $\alpha=\{1, 0.98, \dots, 0.1\}$ .

$$V = \frac{(1-0.1)}{(1-0.98)} + 1 = 46 \quad (10)$$

Após a normalização de seus valores numéricos para a faixa  $\{-1,1\}$ , cada  $T_j$  é utilizado para treinar a respectiva RNA  $R_j$ , resultando na matriz de pesos sinápticos  $W_j$ . Para ilustrar a utilização deste novo método, os padrões utilizados para reconhecimento foram os caracteres alfabéticos de A-Z do tipo de letra “Times New Roman”. Para a identificação destes padrões utilizou-se uma RNA treinada com o algoritmo de propagação reversa modificado, numa arquitetura 65-7-1, com uma razão de aprendizado entre 0.005 (para neurônios escondidos) e 0.01 (para neurônios de saída), um fator de momento de 0.1. O MSE final obtido é menor que 0.00018 e menos de 30000 épocas são processados.

Neste artigo foram utilizadas três direções espectrais de máxima energia para cada um dos padrões. Portanto, cada letra do alfabeto é representada por um conjunto de 3 RNAs cujos conjuntos de pesos sinápticos são  $W_0$ ,  $W_1$  e  $W_2$ . Cada matriz  $W_j$  de cada letra foi resultante do

treinamento pelo algoritmo de propagação reversa em cada um a das três direções de maior energia espectral. Cada letra terá um conjunto distinto de três direções de maior energia espectral. A utilização de três direções espectrais de máxima energia foi suficiente para a identificação de todos os formatos de letra de A a Z.

Utilizou-se o algoritmo de aprendizado com um Fator de Momento  $\rho$  na regra de atualização de  $W$  [12]. O efeito de  $\rho$  é o de variar a taxa de atualização de  $W$  em sua trajetória a uma razão inversa do valor absoluto da velocidade de  $W$ . A função de ativação utilizada foi a tangente hiperbólica devido à sua simetria ímpar, o que acelera o aprendizado da rede.

## 6 Detecção da Imagem Padrão

Seja uma imagem alvo  $a(x,y)$  de  $N \times N$  pixels na qual desejamos encontrar o padrão  $p(x,y)$ , que pode encontrar-se escalonado, rotacionado ou transladado. Sejam as matrizes  $W_0$ ,  $W_1$  e  $W_2$  relativas às RNAs representativas das direções de máxima energia espectral  $\phi_0$ ,  $\phi_1$  e  $\phi_2$  de  $p(x,y)$ .

Iniciamos o processo de detecção calculando o módulo do espectro de  $a(x,y)$ , isto é,  $|A(\omega,\phi)|$ . A seguir, para a direção  $\phi_j + \theta$ ,  $\theta = 0, 1, \dots, 180^\circ$ ,  $j=0, 1, \dots, m-1$ , ( $m=3$  neste trabalho) extraem-se os  $N/2+1$  ( $\omega=0,1\dots N/2$ ) valores de  $|A(\omega,\phi)|$  ao longo da direção em questão, e aplica-se estes valores na entrada da RNA definida por  $W_j$ . Para cada  $\theta$ , atribui-se o valor resultante do único neurônio de saída da RNA  $R_j$  ao vetor  $O_j(\theta)$ . Formamos então o *ensemble* constituído pelas  $m=3$  funções membros  $O_0(\theta)$ ,  $O_1(\theta)$  e  $O_2(\theta)$  e calculamos a média  $\mu(\theta)$  e a variância  $\sigma^2(\theta)$ .

$$\mu(\theta) = \frac{1}{m} \sum_{j=0}^{m-1} O_j(\theta) \quad (11)$$

$$\sigma^2(\theta) = \sum_{j=0}^{m-1} (O_j(\theta) - \mu(\theta))^2 \quad (12)$$

O padrão está presente na imagem alvo se o valor do máximo global da curva  $\sigma^2(\theta)$  está abaixo de um determinado threshold. Para os padrões apresentados neste artigo utilizou-se um valor de threshold de 0.055. O valor  $\theta=\theta_0$  para o qual ocorre o mínimo de  $\sigma^2(\theta)$  corresponde ao ângulo de rotação  $\theta_0$  (ou  $\theta_0 + 180^\circ$ ) sob o qual encontra-se rotacionado o padrão  $p(x,y)$  no alvo  $a(x,y)$ , e o valor  $\mu(\theta_0)$  corresponde ao fator de escalonamento  $\alpha=\alpha_0$  do mesmo na imagem alvo.

A Figura 2 mostra a imagem  $p(x,y)$  de  $N \times N$  pixels,  $N=128$ , da letra "C" e o módulo

( $\log(|P|+1)$ ) de seu espectro  $|P(\omega,\phi)|$ . Embora não seja aparente como na Figura 2, as direções de maior energia espectral neste caso são  $\phi_0 = 5^\circ$ ,  $\phi_1 = 179^\circ$  e  $\phi_2 = 21^\circ$ .

A Figura 3 mostra a imagem alvo  $a(x,y)$  resultante do padrão  $p(x,y)$  da Figura 2 multiplicado por um fator de escala  $\alpha_0=0.5$ , rotacionado  $\theta_0=60^\circ$ , e transladado 30 pixels para a esquerda e 40 pixels para cima.




Figura 2: Letra "C" e módulo de seu espectro.




Figura 3: Letra "C" rotacionada, escalonada e transladada.

A Figura 3 mostra também o espectro  $|A(\omega,\phi)|$  resultante da aplicação da FFT sobre  $a(x,y)$ . A imagem  $a(x,y)$  é a imagem alvo na qual iremos procurar o padrão  $p(x,y)$  mostrado na Figura 2.

Submetendo o espectro  $|A(\omega,\phi)|$  ao processo definido pelas equações (11) e (12), obtemos as curvas  $\mu(\theta)$  e  $\sigma^2(\theta)$  mostradas na Figura 4.

Embora a letra "C" seja um padrão difícil de ser reconhecido devido à simetria quase rotacional de seu espectro, o mínimo global da curva  $\sigma^2(\theta)$  ocorreu próximo ao ângulo de rotação  $\theta_0 = 60^\circ$  do padrão no alvo, assim como  $\mu(\theta_0)$  correspondeu ao fator de escala.

Assim, obtivemos a correlação entre as direções espectrais de máxima energia, as quais são fundamentalmente função da geometria do padrão.

A Figura 5 mostra a mesma imagem alvo da Figura 3, agora corrompida por ruído. A Figura 6

mostra as curvas  $\sigma^2(\theta)$  e  $\mu(\theta)$  resultantes do processo de detecção anteriormente descrito aplicado à imagem alvo  $a(x,y)$  da Figura 5, tendo como padrão  $p(x,y)$  a imagem da Figura 2.

Nesta situação ruidosa o mínimo global de  $\sigma^2(\theta)$  ocorreu próximo a  $\theta_0 = 60^\circ$ , tendo havido um aumento do nível médio de  $\sigma^2(\theta)$ . O valor de  $\mu(\theta_0)$  afastou-se ligeiramente de  $\alpha_0 = 0.5$ .

A detecção da existência do padrão no alvo pode ser feita comparando o valor médio  $\overline{S}_k$  da curva  $\sigma_k^2(\theta)$ , dado por (13), com um limiar  $\tau$  que é determinado experimentalmente para cada imagem padrão. Se  $\overline{S}_k < \tau$  padrão procurado encontra-se na imagem alvo. Outra possibilidade é treinar uma RNA para aprender o formato típico de “sela” apresentado pela curva  $\sigma^2(\theta)$  quando existe um padrão na imagem alvo.




Figura 4: Média e Variância do *ensemble* da letra “C” da Figura 3.

Para um conjunto de  $n$  imagens alvo caracterizadas respectivamente por  $n$  curvas  $\sigma_k^2(\theta)$ ,  $k=0, 1, \dots, n-1$ , aquela que apresenta a maior probabilidade de conter a imagem padrão é a que resulta no mínimo  $\overline{S}_k$ .

$$\overline{S}_k = \frac{1}{180} \sum_{\theta=0}^{180} \sigma_k^2(\theta) \quad (13)$$

A questão de qual filtragem deve ser aplicada sobre  $\sigma^2(\theta)$  para otimizar a definição de seu mínimo global no caso desta situação ruidosa será objeto de pesquisa futura.

Devido à simetria especular de  $|A(\omega, \phi)|$ , temos  $|A(\omega, \phi)| = |A(\omega, \phi + 180^\circ)|$ . Assim não há

como determinar se  $p(x,y)$  encontra-se rotacionado  $\theta_0$  ou  $\theta_0 + 180^\circ$  em  $a(x,y)$  (propriedade 4.4). Soluciona-se este problema ao incluir a informação da relação de fase entre  $A(\omega, \phi)$  e  $P(\omega, \phi)$  no processo de detecção, o que possibilitará a localização da imagem padrão na imagem alvo sem a incerteza acima mencionada.



Figura 5: Letra “C” corrompida por ruído




Figura 6: Média e Variância do *ensemble* da letra “C” da Figura 5.

## 7 Localização do padrão no alvo

Seja  $a(x,y)$  a imagem alvo na qual sabemos encontrar-se o padrão  $p(x,y)$  transladado das incógnitas  $(x_0, y_0)$ , rotacionado de  $\theta_0$  e escalado por  $\alpha_0$ . Seja  $p_T(x,y)$  a imagem padrão  $(x,y)$  rotacionada de  $\theta_0$  e escalada por  $\alpha_0$ . Seja  $P_T(\omega, \phi)$  o espectro de  $p_T(x,y)$  e  $A(\omega, \phi)$  o espectro de  $a(x,y)$  em coordenadas polares. Sejam os  $m$  vetores  $Q_j(\omega)$ ,  $j=0, 1, \dots, m-1$ , formados pelos  $N/2+1$  ( $\omega=0, 1, \dots, N/2$ ) valores complexos ao longo das direções espectrais  $\phi_j + \theta_0$  de máxima energia de  $P_T(\omega, \phi)$ . Analogamente, sejam os  $m$  vetores  $B_j(\omega)$ ,  $j=0, 1, \dots, m-1$ , formados pelos  $N/2+1$  valores

complexos a o longo das direções espectrais  $\phi_j + \theta_0$  de máxima energia de  $A(\omega, \phi)$ . Caso o processo de detecção tenha determinado  $\theta_0$  e  $\alpha_0$  corretamente, a diferença entre  $p_T(x, y)$  e  $a(x, y)$  é apenas translação  $(x_0, y_0)$ . Da propriedade 4.1,

$$Q_j(u, v) = B_j(u, v) e^{-i \frac{2\pi}{N}(ux_0 + vy_0)} \quad (14)$$

sendo  $u = \omega \cos(\phi_j + \theta_0)$  e  $v = \omega \sin(\phi_j + \theta_0)$ .

Rescrevendo (14) em coordenadas polares,

$$\Psi_j(\omega) = -\frac{2\pi\omega}{N} (x_0 \cos(\phi_j + \theta_0) + y_0 \sin(\phi_j + \theta_0)) \quad (15)$$

sendo  $\Psi_j(\omega) = \Psi\{Q_j(\omega) B_j^*(\omega)\}$  o ângulo de fase entre  $Q_j(\omega)$  e  $B_j^*(\omega)$ .

Resolvendo o sistema formado pela equação (15) para as direções  $\phi_j$  e  $\phi_{j+1}$ :

$$y_0 = \frac{-1}{\omega\Delta} (\Psi_j(\omega) \cos(\phi_{j+1} + \theta_0) - \Psi_{j+1}(\omega) \cos(\phi_j + \theta_0)) \quad (16)$$

$$x_0 = \frac{-1}{\omega\Delta} (\Psi_{j+1}(\omega) \sin(\phi_j + \theta_0) - \Psi_j(\omega) \sin(\phi_{j+1} + \theta_0)) \quad (17)$$

$$\Delta = \frac{2\pi}{N} (\cos(\phi_{j+1} + \theta_0) \sin(\phi_j + \theta_0) - \sin(\phi_{j+1} + \theta_0) \cos(\phi_j + \theta_0)) \quad (18)$$

Portanto, as equações (16), (17) e (18) definem a translação  $(x_0, y_0)$  forma geométrica padrão encontrada na imagem alvo  $a(x, y)$ .

## 8 Conclusão

Este trabalho propõe um novo método para detecção de padrões em imagens bidimensionais. Os resultados indicam que com um pequeno aumento de complexidade computacional em tempo real o procedimento é capaz de identificar formas geométricas a partir das características espectrais mais significativas do padrão armazenadas nas respectivas RNAs. Futuros estudos nesta linha de pesquisa incluem a determinação do número direções espectrais para definição ótima do padrão, da filtragem ótima da curva de variância e principalmente a inclusão da informação de fase no processo de detecção.

## 9 Referências

- [1] A. V. Lugt, "Signal Detection By Complex Spatial Filtering", *IEEE Trans. on Information Theory*, April, 1964.
- [2] S. Haykyn, *Neural Networks*, Macmillan College, New York, NY, 1994.
- [3] R. Gonzalez and P. Wintz, *Digital Image Processing*, Addison-Wesley, 1987.

[4] L. Gupta and M.D. Srinath, "Contour sequence moments for the classification of closed planar shapes", *Pattern Recognition*, vol 20, no.3, pp. 267-272, 1987.

[5] K. S. Fu, *Syntactic Pattern Recognition and Application*, Englewood Cliffs, Prentice Hall, NJ, 1982.

[6] E. Persoon and K.S. Fu, "Shape discrimination using Fourier descriptors", *IEEE Trans. Syst. Man, and Cybern.*, vol 7, pp. 170-179, 1977.

[7] R. Gordon and R.M. Rangayyan, "Feature enhancement of film mamograms using fixed and adaptive neighborhoods", *Appl. Optics*, vol. 23, no. 4, pp. 560-564, 1984.

[8] E. Säcker, B.E. Boser, J. Bromley, Y. LeCun, and L.D. Jackel, "Application of the ANNA neural network chip to high-speed character recognition", *IEEE Transactions on Neural Networks* 3, pp. 498-505, 1992.

[9] L. Shen, R. M. Rangayyan and J. E. Leo Desautels, "Application of shape analysis to mamographic calcifications", *IEEE Transactions on Medical Imaging*, vol 13, no 2, pp. 263-274.

[10] G.K. Moore and F.A. Waltz, "Objective procedures for lineament enhancement and extraction", *Photogrammetric Eng. Remote Sensing*, vol 49, pp. 641-647, 1983.

[11] Boahen, K.A and A.G. Andreou, "A contrast sensitive silicon retina with reciprocal synapses", *Advances in Neural Information Processing Systems* 4 (J.E. Moody, S.J. Hanson, and R.P. Lippmann, eds.), pp. 764-772, Morgan Kaufmann, San Mateo, CA, 1992.

[12] D.E. Rumelhart, G.E Hinton and R.J. Williams, "Learning representations by back-propagating errors", *Nature*, London, pp. 533-536, 1986.