

Rede de Pulso Acoplado Seqüencial para Reconhecimento de Padrões Invariantes

GUILLERMO CÁMARA¹, MARCIA CAROLINA MARRA DE OLIVEIRA¹

¹Departamento de Ciência da Computação - Universidade Federal de Minas Gerais
Av. Antônio Carlos 6627 - Campus Pampulha - Belo Horizonte - Minas Gerais - Brasil
gcamarac@dcc.ufmg.br, marsha@dcc.ufmg.br

Abstract. O problema de reconhecimento de padrões recai sobre a identificação de padrões que tenham sido alterados por uma variedade de transformações permitidas. Os padrões no mundo real podem apresentar transformações geométricas lineares (rotação, escala e translação), deformações não lineares e variâncias de iluminação e *background*, entre outros. Dessa forma, os métodos tradicionais de reconhecimento de padrões precisam ter a habilidade de reconhecer um mesmo padrão com certo tipo de variância. Portanto, a pesquisa e o desenvolvimento de técnicas e sistemas de extração de características invariantes dos padrões são importantes tanto para fins teóricos quanto práticos. Entre as principais técnicas de extração de características invariantes podemos citar os momentos estatísticos, as transformadas de Fourier, as transformadas de wavelets, o casamento de grafos e as redes neurais, onde se enquadram as redes de pulso acoplado. Este projeto tem como objetivo desenvolver um modelo de reconhecimento de padrões invariantes. O modelo proposto reconhece eficientemente padrões sem levar em consideração as possíveis variações de posição, escala e rotação.

1 Introdução

O *reconhecimento de padrões* é o estudo sobre as formas com as quais as máquinas observam seu entorno, aprendem a distinguir padrões de interesse e tomam decisões razoáveis sobre as categorias dos padrões [6]. Um *padrão* é uma descrição de um objeto, que pode ser classificado como concreto (espaciais: caracteres, imagens; e temporais: formas de onda, séries) ou abstrato (raciocínio, soluções de problemas, etc) [13]. Um computador consegue reconhecer padrões, convertendo-os em sinais digitais e comparando-os com outros sinais já armazenados na memória.

Um sistema de reconhecimento é geralmente composto por três fases principais: pré-processamento, extração de características e classificação. Na etapa de pré-processamento, os dados de entrada são manipulados por uma variedade de métodos que realizam operações de remoção de ruído, segmentação e melhoria de qualidade dos mesmos. Na extração de características, o objetivo é representar os dados de entrada em termos de medidas quantificáveis, que possam ser utilizados facilmente na etapa de classificação. Já na etapa de classificação, os padrões são agrupados em função de características comuns entre eles.

O problema do reconhecimento de padrões é reconhecer padrões que sejam, em algum sentido, “os mesmos” apesar de terem experimentado uma variedade de transformações permitidas. Os padrões no mundo real apresentam transformações geométricas lineares (rotação, translação e escala), deformações não-lineares e variância de iluminação e *background*, entre outros. Dessa forma, os métodos tradicionais de reconhecimento de padrões precisam ter a habilidade de reconhecer um mesmo padrão com certo tipo

de variância. Portanto, a pesquisa e o desenvolvimento de técnicas de Reconhecimento de Padrão Invariante (RPI) são importantes tanto para fins teóricos quanto práticos. Entre as principais técnicas de extração de características invariantes temos os momentos de Hu [5], os momentos de Zernike [9], as transformadas de Fourier [10], as transformadas de *wavelets* [8], o casamento de grafos e as redes neurais em que estão inseridas as redes de pulso acoplado (PCNN: *Pulse Coupled Neural Network*) [2].

Museran [11] combina as transformadas de Fourier com as PCNNs com o objetivo de atingir a invariância de escala e translação, mas devido à forma de acoplamento, as PCNNs já são invariantes à translação. Cheng [14] baseia seu trabalho na técnica de padrões binários locais, obtendo assim a invariância de rotação. No entanto esta técnica apresenta uma limitação, já que as rotações devem ser de 45 graus. Mauro [1] propõe uma técnica baseada em redes neurais e na representação das imagens através de grafos. Como a identificação de igualdade de duas imagens (grafos) depende da prova de que os grafos são isomórficos, essa técnica apresenta um alto custo computacional. Sendo que duas imagens (grafos) são iguais se são isomórficas, o problema desta técnica é o alto custo computacional. Zhang [15] faz uma revisão de várias técnicas de extração de características.

Os métodos para extração de características invariantes existentes possuem certas limitações, sendo a principal delas o alto custo computacional. Com isso surge a necessidade de desenvolvimento de um sistema de extração de características invariantes. As redes de pulso acoplado bidimensionais possuem uma estrutura semelhante à orga-

nização natural de padrões a serem reconhecidos, tais como por exemplo imagens, onde existe uma correspondência direta entre um neurônio e um pixel de uma imagem, facilitando a representação de padrões originais. No presente trabalho objetiva-se investigar redes de pulso acoplado para extração de características invariantes de padrões.

Este trabalho está organizado como segue: Na seção 2, será apresentada a rede de pulso acoplado seqüencial como técnica de reconhecimento de padrões invariantes. Na seção 3, serão apresentados os momentos de Zernike. Na seção 4, será apresentada a rede neural *fuzzy ART* (*Adaptive Resonance Theory*), que será usada como classificadora. Na seção 4, será apresentado o modelo proposto. Na seção 5, serão apresentados os resultados. E na seção 6, serão apresentadas as conclusões e futuros trabalhos.

2 Rede de pulso acoplado seqüencial (PCNN)

Em PCNNs [7], os elementos evoluem de forma paralela. Existe uma outra forma de geração de pulsos, onde os pulsos são transmitidos seqüencialmente (horizontal ou verticalmente). Esse tipo de rede é chamado de rede de pulso acoplado seqüencial, proposto por Dodwell [12].

2.1 Esquema de codificação do Dodwell

O modelo de Dodwell inclui uma matriz bi-dimensional de unidades. Estas unidades estão conectadas em cadeias, de tal forma que uma unidade tem, no máximo, dois vizinhos. De um deles receberá a excitação e a transmitirá ao outro vizinho. Cada cadeia horizontal (vertical) está organizada de tal forma que, quando uma borda horizontal (vertical) está projetada sobre a grade, as unidades da grade que são relacionadas com as unidades ativadas terminam em uma única cadeia [12].

Na Figura 1 representa-se uma grade de codificação típica, sendo que somente cadeias horizontais são mostradas explicitamente. Sejam $l \times c$ as dimensões da grade de codificação, onde l representa o número de linhas e c as colunas. Sejam as unidades pertencentes à coluna mais a esquerda da grade (representado por A na Figura 1) chamadas de conjunto final da grade. As unidades do conjunto final da grade possuem as seguintes propriedades:

- Elas são as geradoras das excitações. Elas transmitem a excitação, mas não recebem estímulo de nenhuma unidade.
- A direção de transmissão começa no conjunto final e vai até a saída do codificador (representado por uma seta na Figura 1).
- O conjunto final dispara os estímulos simultaneamente.

As outras unidades transmitem a excitação aos seus respectivos vizinhos ao longo do sentido de transmissão após

um tempo constante, que é definido como

- (a) T_p segundos, se a excitação não tiver sido ativada pelas projeções das bordas, e
- (b) $T_a (> T_p)$ segundos caso contrário.

Considere o caso em que nenhuma das unidades do codificador é ativada pelas projeções das bordas. Neste caso, o envio do sinal de excitação partindo do conjunto final da grade A induz uma varredura da matriz, sendo este um valor constante e cada cadeia atingirá a saída simultaneamente. A saída será então um único pulso de l unidades de amplitude, no tempo constante $c * T_p$ após o disparo do sinal pelo conjunto final.

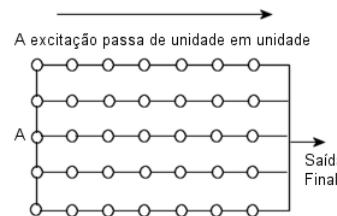


Figura 1: Grade de codificação.

2.2 Varreduras perpendiculares

Incorporar apenas a varredura horizontal na grade de codificação pode não ser vantajoso, já que é possível a geração de saídas semelhantes para padrões diferentes. O problema pode ser resolvido usando cadeias verticais, as quais são ativadas por bordas verticais. Essas cadeias são perpendiculares às cadeias horizontais. Dessa forma o codificador possui duas saídas separadas, que correspondem às varreduras verticais e horizontais, respectivamente.

Na Figura 2 está ilustrado o funcionamento da grade de codificação. A Figura 2 (a) é uma típica grade de codificação, onde as unidades ativadas (escursas) correspondem à presença de pontos nas bordas; a Figura 2 (c) corresponde aos pulsos, tanto no sentido horizontal quanto no vertical. Na Figura 2 (b) são mostradas as unidades ativadas da grade de codificação de uma borda rotacionada e a Figura 2 (d) corresponde às sequências de pulsos. Como pode ser percebido através dos gráficos, existem consideráveis diferenças entre as sequências da Figura 2 (c) e (d), confirmando que a presente grade de codificação não é invariante à rotação dos pontos das bordas [12].

Como podemos ver, a grade de codificação é invariante à translação, mas apresenta algumas características não desejáveis, tais como:

1. Não é invariante à rotação e escala.

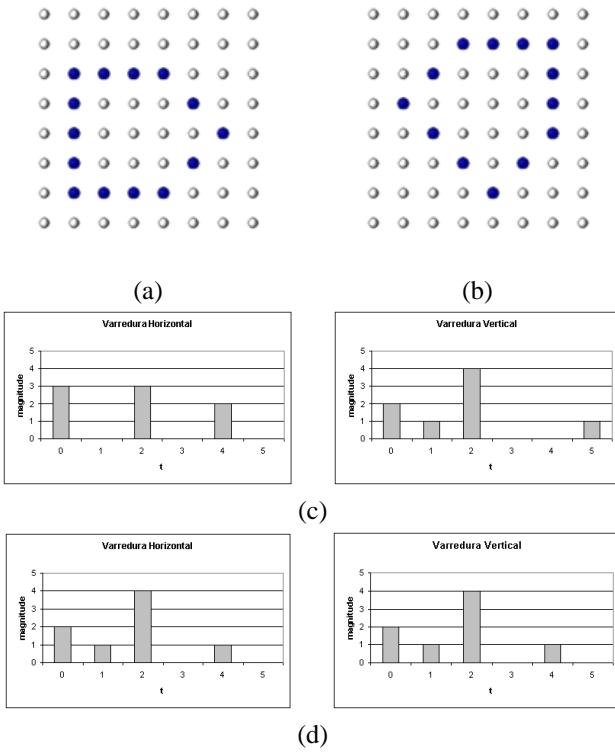


Figura 2: (a) Codificador de grade com unidades ativadas (escuras). (b) Codificador de grade com unidades ativadas (escuras) para um contorno rotacionado. (c) Ilustração da função do codificador de grade: pulsos correspondentes às varreduras horizontais e verticais de (a). (d) Ilustração da função do codificador de grade: pulsos correspondentes às varreduras horizontais e verticais de (b).

2. Uma pequena variação na borda de entrada dará como resultado saídas diferentes, ou seja, possui baixa tolerância a ruído.
3. Como a borda é alimentada diretamente sobre o codificador, o tamanho da matriz de codificação será grande, produzindo um pulso comprido.

Como pode ser visto, trabalhar com estas técnicas separadamente não é suficiente para atingir o objetivo. A fim de evitar as desvantagens associadas à grade de codificação de Dodwell, Rishikesh [12] propõe um modelo onde obtém a invariância utilizando a transformada *log-polar*, convertendo a imagem em coordenadas polares. Para isso, o centroíde é inicialmente encontrado tornando-se a origem do mapeamento. Desta forma, é possível garantir a invariância de translação e rotação. Como também é utilizado um mapeamento logarítmico, a imagem torna-se invariante à escala.

3 Momentos de Zernike

Os Momentos de Zernike (MZ) pertencem à classe de momentos ortogonais invariantes à rotação. Para obter invariância de escala e translação, a imagem é mapeada em um círculo unitário de coordenadas polares sendo as características invariantes à rotação extraídas [9].

Os momentos de Zernike pertencem à classe dos momentos ortogonais invariantes à rotação.

$$Z_{pq} = \frac{n+1}{\pi} \int_0^{2\pi} \int_0^1 f(\rho \cos \theta, \rho \sin \theta) \cdot V_{pq}^*(\rho, \theta) d\rho d\theta \quad (1)$$

$$V_{pq}(\rho, \theta) = R_{pq}(\rho) e^{jq\theta} \quad (2)$$

$$R_{pq}(\rho) = \sum_{s=0}^{p-|q|/2} \frac{(p-s)!}{s!(\frac{p+|q|}{2}-s)!(\frac{p+|q|}{2}-s)!} \cdot (-1)^s \rho^{p-2s} \quad (3)$$

p é um número inteiro positivo ou zero, q é um número inteiro positivo ou negativo tal que $p - |q| = \text{par}$ e $|q| \leq p$, $j = \sqrt[2]{-1}$

4 Rede neural fuzzy ART (Adaptive Resonance Theory)

A fuzzy ART foi criada por Carpenter e Grossberg [3] em 1991. Esta rede incorpora as características básicas de todos os sistemas ART1 [4], casamento de padrões entre a entrada *bottom-up* e o vetor protótipo *top-down* aprendido. Este processo de casamento conduz tanto a um estado de ressonância que focaliza a atenção no processo de aprendizado e coloca em funcionamento o protótipo estável aprendido quanto a uma busca na memória paralela auto-regulada. Se a busca termina na seleção de uma categoria (cluster) estabelecida, então o protótipo da categoria selecionada será refinado, incorporando uma nova informação ao padrão de entrada. Se a busca termina na seleção de um nó prévio não rotulado, uma nova classe é criada.

A fuzzy ART possui uma estrutura e mecanismo de funcionamento muito semelhante a ART1 e incorpora operações da teoria de conjuntos fuzzy, permitindo a classificação de padrões com valores contínuos. A Figura 3 apresenta um resumo das operadores da ART1 e sua correspondência na fuzzy ART.

Na Figura 4 é apresentada a arquitetura básica da fuzzy ART. Cada padrão de entrada \mathbf{I} é um vetor m -dimensional $(I_1, I_2, I_3, \dots, I_m)$. Cada cluster tem como correspondente um vetor $W_j = (W_{j,1}, W_{j,2}, W_{j,3}, \dots, W_{j,n})$ de pesos adaptativos. O número de possíveis clusters n ($j = 1, 2, \dots, n$) é arbitrário. O vetor de pesos da fuzzy ART é o equivalente, em um único vetor, aos vetores de pesos *top-down* e *bottom-up* da ART1 [3].

ART1 (Binário)	Fuzzy ART (Contínuo)
Seleção da Categoria	Fuzzy ART
$T_j = \frac{ I \cap W_i }{\alpha + W_i }$	$T_j = \frac{ I \wedge W_i }{\alpha + W_i }$
Critério de Semelhança	Critério de Semelhança
$\frac{ I \cap W_i }{ I } \geq \rho$	$\frac{ I \wedge W_i }{ I } \geq \rho$
Aprendizado Rápido	Aprendizado Rápido
$W_j^{(new)} = I \cap W_i^{(new)}$	$W_j^{(new)} = I \wedge W_i^{(new)}$
$\cap = \text{AND lógico}$	$\wedge = \text{fuzzy AND}$

Figura 3: Analogia entre ART1 e fuzzy ART.

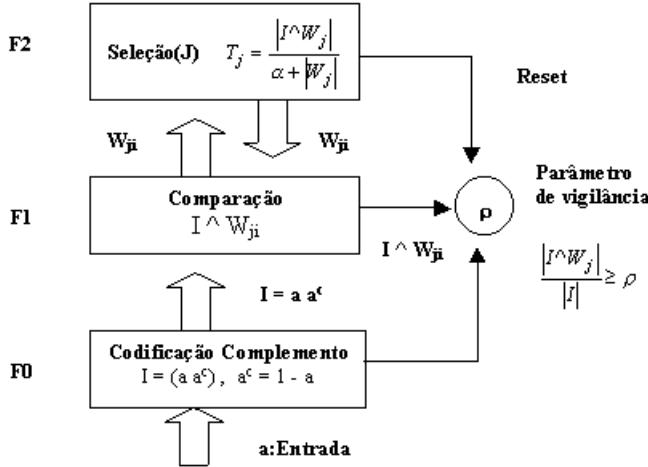


Figura 4: Arquitetura da fuzzy ART.

5 Modelo Proposto

O modelo proposto neste trabalho visa reconhecer padrões que tenham sofrido transformações geométricas (escala, translação e rotação). Ele visa ainda reduzir o custo computacional de extração de características.

A rede de pulso acoplado proposta por Rishikesh [12] extrai características invariantes à rotação de imagens binárias (bordas). Com o modelo proposto, além de extrair características invariantes de imagens binárias, também será possível extrair essas mesmas características de imagens em níveis de cinza.

5.1 Normalização em escala e translação

Os momentos regulares são utilizados para atingir a normalização em escala e translação. A invariância à transla-

ção é alcançada transformando a imagem original $f(x, y)$ em outra uma outra imagem $f(x + \bar{x}, y + \bar{y})$, onde \bar{x} e \bar{y} são as localizações do centróide da imagem. Em outras palavras, a origem é movida ao centróide da imagem. O centróide pode ser calculado através dos momentos regulares.

Os *momentos regulares* são definidos em termos das integrais de Reimann como [5]:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy \quad (4)$$

para $p, q = 0, 1, 2, \dots$ e m_{pq} é o momento 2D para a função $f(x, y)$. A ordem do momento é $(p + q)$.

Os momentos de primeira ordem são usados para encontrar o centróide (x_c, y_c) da imagem:

$$x_c = \frac{m_{10}}{m_{00}}, \quad y_c = \frac{m_{01}}{m_{00}} \quad (5)$$

onde m_{00} representa a massa ou área da imagem, m_{10} é m_{01} são as projeções em x e y respectivamente.

A invariância à escala é atingida quando o momento de ordem zero (m_{00}) da imagem atinge o valor pré-determinado β através do aumento e diminuição da imagem.

Dessa forma a imagem $f(x, y)$ pode ser normalizada em escala e translação transformando-se em $g(x, y)$, onde

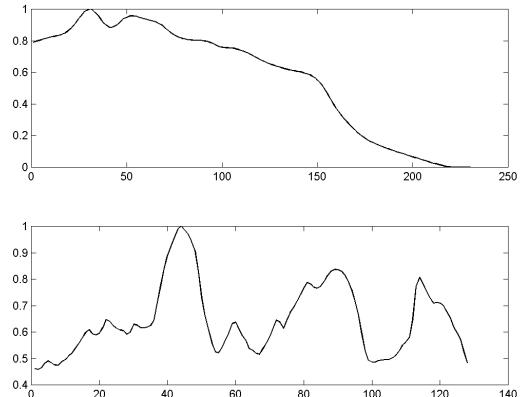
$$g(x, y) = f\left(\frac{x}{a} + \bar{x}, \frac{y}{a} + \bar{y}\right),$$

tal que (\bar{x}, \bar{y}) é o centróide de $f(x, y)$ e $a = \sqrt{\frac{\beta}{m_{00}}}$, onde b é um valor pré-determinado.

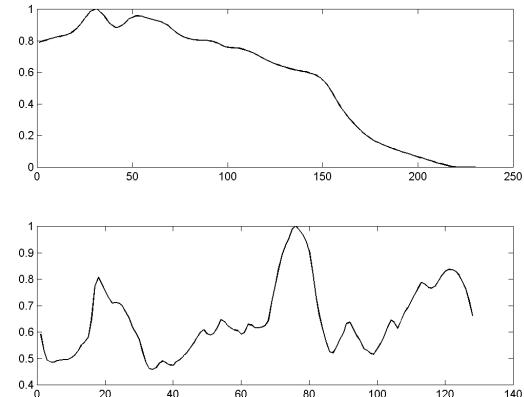
Com o objetivo de atingir a invariância à rotação, a imagem é transformada em coordenadas polares, tal que a imagem será representada pelo raio ρ e o ângulo θ formado entre raio e o eixo das abscissas. A transformação deve ser feita tendo como origem o centróide da imagem.

Uma vez que a imagem tenha sido transformada em coordenadas polares (ver figura 5), os vetores serão extraídos a partir das varreduras horizontal e vertical. É possível perceber que os vetores de varredura horizontal serão similares, já que as rotações em coordenadas polares são simplesmente deslocamentos circulares (*circular shift*). Por exemplo, quando existe uma rotação, a imagem é transladada horizontalmente e aquela parte que sai da janela pela parte direita apareceria pelo lado esquerdo da janela. A diferença entre as duas imagens estaria no vetor de varredura vertical. No lugar em que acontece o mesmo fenômeno na imagem, o vetor também possui um deslocamento circular, ver figura 6.

Até agora, encontramos um vetor de características que é invariante à rotação. No entanto, quando duas imagens são parecidas mas pertencem a classes diferentes, elas serão consideradas como sendo do mesmo cluster, o que



(a)



(b)

Figura 6: Vetores de varredura da imagem “araras”, em (a) vemos o vetor de varredura horizontal e vertical de imagem com zero graus de rotação e em (b) da imagem com 90 graus de rotação.

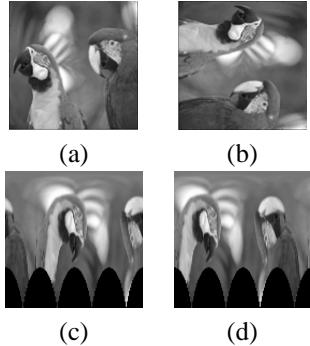


Figura 5: Representação polar da imagem “araras” com diferentes graus de rotação. Na primeira linha estão as imagens em coordenadas cartesianas e na segunda linha a respectiva representação polar.

pode representar um problema. Dessa forma é necessário o segundo vetor para atuar como discriminante entre imagens semelhantes, sendo importante encontrar uma maneira de representar o vetor de varredura vertical. Sendo que o histograma desse vetor fornece um vetor que também é invariante à rotação, ver figura 7.

A Figura 8 mostra o modelo que está sendo proposto neste projeto.

6 Resultados

Nesta seção serão apresentados os resultados de classificação das características invariantes usando a rede neural Fuzzy ART como classificador.

Foram utilizadas duas bases de dados para testar a qualidade das características extraídas com o método proposto

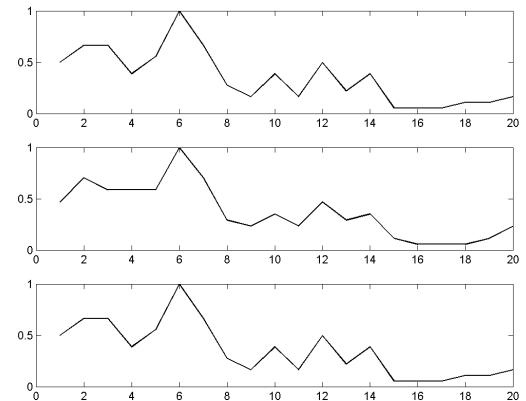


Figura 7: Histograma do vetor de varredura vertical da imagem “araras” com rotações de 0° , 45° e 90° graus.

neste trabalho. A primeira base consta de dez imagens binárias de números, e a segunda base esta formada por 13 grupos de texturas diferentes, as quais foram coletadas da base de dados de texturas Vistex¹. Em ambas as bases, cada imagem sofreu um conjunto de transformações geométricas, sendo que foram geradas 50 versões diferentes (rotacionadas e escaladas) de cada imagem, resultando em um total de 650 padrões. As rotações foram de 0° , 7° , 14° , 21° , 28° , 35° , 42° , 49° , 56° e 63° graus enquanto que as variações em escala foram de 0.5, 0.8, 1, 1.5 e 2.

Algumas texturas da base de dados são mostradas na Figura 9.

Os testes feitos com o modelo proposto visam avaliar

¹(<http://www-white.media.mit.edu/vismod/imager/>)

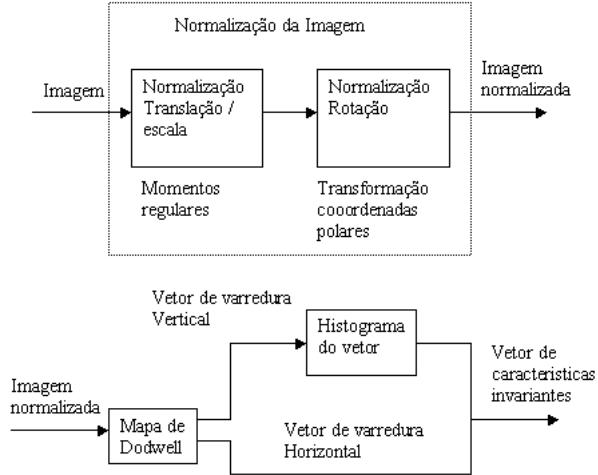


Figura 8: Modelo proposto.

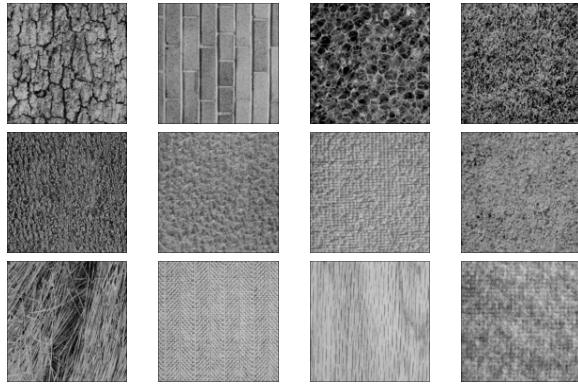


Figura 9: Exemplos de imagens da base de texturas.

a qualidade das características invariantes extraídas. Nesta primeira etapa, serão usadas imagens em níveis de cinza. Essas imagens sofreram variações geométricas, como pode ser visto no exemplo da Figura 10. Elas estão rotacionadas em 37° , 45° e 90° . Este modelo também é totalmente invariante à translações.

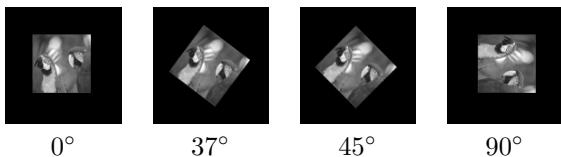


Figura 10: Transformações geométricas da imagem “araras” sendo rotacionada em 0° , 37° , 45° e 90° respectivamente.

Dois vetores são usados para armazenar as característi-

cas extraídas. O primeiro, chamado “vetor de varredura horizontal”, contém o somatório dos estados de cada linha da rede e o segundo, chamado “vetor de varredura vertical”, contém o somatório dos estados de cada coluna da rede (é importante notar que este vetor não é invariante à rotação). No entanto, é necessário calcular o histograma do vetor de varredura vertical. Depois de várias tentativas a conclusão foi que um histograma de 20 elementos é adequado.

A Figura 11 (a) mostra 4 vetores de varredura horizontal, um para cada imagem “araras” rotacionada. No caso de rotações de 90° o vetor é exatamente igual ao vetor gerado para a imagem original (rotação 0°). No caso de rotações de 37° e 45° , os vetores de varredura horizontal aparecem com uma pequena diferença em relação ao vetor de estados da imagem original. Isso acontece devido à característica discreta das imagens digitais. Ou seja, quando uma imagem digital é rotacionada, alguns pixels são perdidos enquanto outros pixels são introduzidos. No entanto, como as diferenças são pequenas os vetores continuam conservando características similares, permitindo que sejam classificados dentro do mesmo grupo. É possível observar que temos o mesmo comportamento para o histograma do vetor de varredura vertical, como pode ser visto na Figura 11(b).

Na Tabela 1 são mostrados os valores dos parâmetros da rede *fuzzy ART*, para o parâmetro de escolha α , a taxa de aprendizado β e o parâmetro de vigilância ρ . Foram classificados três bases de texturas, sendo a primeira povoada com imagens rotacionadas sem ruído, a segunda povoada por imagens rotacionadas com ruído e a terceira por imagens rotacionadas e escaladas.

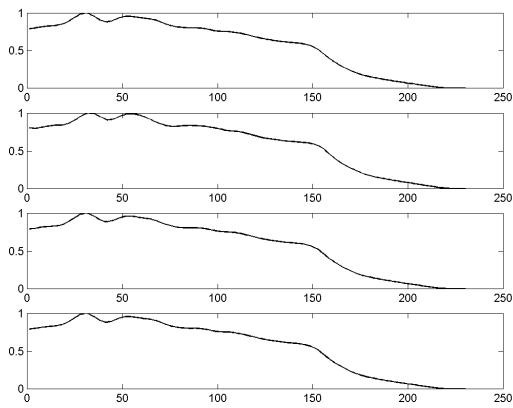
	Modelo Proposto		Mom. Zernike	
	Números	Texturas	Números	Texturas
α	10	100	40	30
β	1	1	1	1
ρ	0.73	0.89	0.95	0.82

Tabela 1: Valores dos parâmetros para a rede *fuzzy ART*.

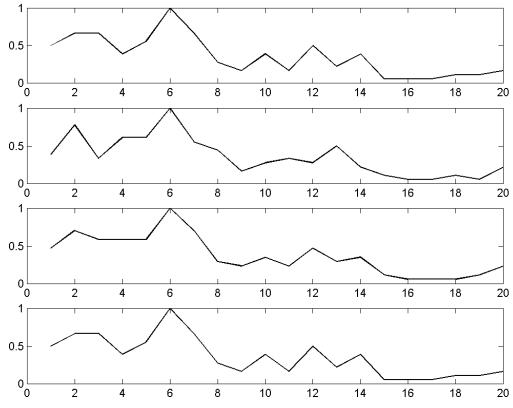
Na Tabela 2, podem ser vistos os resultados da classificação. No caso do modelo proposto, ele atinge 99.85% na base de números e 99.39% na base de texturas enquanto que utilizando os momentos de Zernike atinge-se 90.2% na base de número e 68.6% na base de texturas. Os resultados obtidos das simulações demonstram que a técnica proposta apresenta um desempenho razoável. Como as características extraídas por nosso modelo não dependem do classificador, é possível utilizar outras técnicas para classificá-los.

7 Conclusões

O uso de técnicas de extração de características invariantes como momentos estatísticos, transformada de Fourier, entre outras já foram estudadas amplamente, mas apresen-



(a)



(b)

Figura 11: Vetores de características da imagem “araras”, (a) vetores de varredura horizontal e (b) histograma do vetor de varredura vertical com rotações de 0° , 37° , 45° e 90° .

	Modelo Proposto	Momentos de Zernike
Números	99.85%	90.2%
Texturas	99.39%	68.6%

Tabela 2: Resultado da classificação.

tam certos problemas como a pouca tolerância ao ruído, além de exigirem um grande número de iterações conforme a complexidade da técnica é aumentada. Dessa forma surge a necessidade de se buscar um novo modelo capaz de realizar essa atividade de forma simples, conseguindo atingir os mesmos objetivos e com eficiência comparável ou melhor.

As redes de pulso acoplado sequencial são uma ferramenta promissora para resolver problemas de reconhec-

imento de padrões invariantes. Os resultados obtidos tanto para imagens binárias quanto para imagens em níveis de cinza foram aceitáveis. Portanto este modelo mostra ser uma tentativa interessante para extração de características invariantes, merecendo um estudo mais profundo.

Referências

- [1] DE MAURO, C., M. DILIGENTI AND, M. G., AND MAGGINI, M. Similarity learning for graph-based image representations. *Pattern Recognition Letter*, 24 (2003), 1115–1122.
- [2] ECKHORN, R., REITBOECK, H., ARNDT, M., AND DICKE., P. Feature linking via synchronization among distributed assemblies: Simulations of results from cat visual cortex. *Neural Comp.* 2 (1990), 293–307.
- [3] G. CARPENTER, S. GROSSBERG, D. B. R. Artmap: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Network* (1991).
- [4] G. CARPENTER, S. G. A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics and Image Processing* 37 (1987), 54–115.
- [5] HU, M. Pattern recognition by invariant moments. *Proc. IRE Transactions on Information Theory* (February 1961), 179–187.
- [6] JAIN, A., DUIN, R., AND MAO, J. Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 22, 1 (January 2000), 4–37.
- [7] JOHNSON, J. Pulse-coupled neural net: translation, rotation, scale, distortion, and intensity signal invariance for images. *Opt. Soc. of America* 33, 26 (1994), 6239–6253.
- [8] KAN, C., AND SRINATH, M. Combined features of cubic b-spline wavelet moments and zernike moments for invariant pattern recognition. In *International Conference on Information Technology: Coding and Computing*. (2001), IEEE, Ed., pp. 511–515.
- [9] KHOTANZAND, A., AND LU, J.-H. Classification of invariant image representations using a neural network. *IEEE Transactions on Acoustic, Speech, and signal Processing* 38, 6 (1990), 1028–1038.
- [10] LI, Y. Reforming the theory of invariant moments for pattern recognition. *Pattern Recognition* 25, 7 (1992), 723–730.
- [11] MURESAN, R. C. Pattern recognition using pulse-coupled neural networks and discrete fourier transforms. *Neurocomputing*, 51 (September 2003), 487–493.
- [12] RISHIKESH, N., AND VENKATESH, Y. Shape recognition using invariant pulse code and a hierarchical,

- competitive neural network. *Pattern Recognition* 34 (2001), 841–853.
- [13] WATANABE, S. *Pattern Recognition: Human and Mechanical*. Wiley, New York, 1985.
- [14] YAO, C.-H., AND CHEN, S.-Y. Retrieval of translated, rotated and scaled color textures. *Pattern Recognition*, 36 (2003), 913–929.
- [15] ZHANG, J., AND TAN, T. Brief review of invariant texture analysis method. *Pattern Recognition*, 35 (2002), 735–747.