

Meio-Tom Inverso Usando Redes Neurais Artificiais

Sidnei Alves de Araújo e Hae Yong Kim

Resumo— Meio-tom é o processo que converte uma imagem em níveis de cinza G na imagem binária correspondente B , tal que B aparente ser semelhante à G quando vista de uma certa distância. Meio-tom inverso é o processo reverso: é usado para reconstruir a imagem em níveis de cinza G a partir da imagem binária meio-tom B . Nos últimos anos, diversos métodos têm sido propostos para solucionar o problema de meio-tom inverso. Neste artigo, propomos um novo método baseado na aprendizagem por redes neurais artificiais, que denominamos MLP-IH. Aplicamos MLP-IH em imagens meio-tom difusão de erro e imagens meio-tom disparo ordenado. Depois, comparamos os resultados obtidos com os resultados de dois outros métodos de meio-tom inverso: filtragem gaussiana e aprendizagem por árvores de decisão. MLP-IH mostrou ser superior que a árvore de decisão usando janela e conjuntos de treinamento pequenos. Porém, permanece um problema em aberto como aplicar MLP-IH para grandes conjuntos de treinamento.

Palavras-Chaves – Meio-tom inverso, aprendizagem de máquina, redes neurais.

Abstract – Halftoning is a process that converts a grayscale image G into the corresponding binary image B , such that B looks like G when viewed from a certain distance. Inverse halftoning is the reverse process: it is used to reconstruct the grayscale image G from the binary halftone image B . In the last years, many works have been proposed to solve the inverse halftoning problem. In this paper, we propose a new inverse halftoning method based on artificial neural network learning called MLP-IH. We have applied MLP-IH on error diffusion halftone images and ordered dithering halftone images. Then, we have compared the obtained results with the results of two other inverse halftoning techniques: Gaussian filtering and decision-tree learning. MLP-IH have shown to be superior to decision-tree using small window and small sample sets. However, it is still an open problem using large sample sets to train MLP-IH.

Keywords – Inverse halftoning, machine learning, neural networks.

I. INTRODUÇÃO

Meio-tom (halftoning) é o processo usado para transformar uma imagem de tons contínuos (em níveis de cinza ou colorida) numa outra de tons discretos, tal que a imagem discreta pareça semelhante à imagem contínua quando vista de uma certa distância.

Sidnei Alves de Araújo e Hae Yong Kim, Departamento de Engenharia de Sistemas Eletrônicos, Escola Politécnica, Universidade de São Paulo, São Paulo, Brasil, E-mails: saraujo@lps.usp.br, hae@lps.usp.br.

As técnicas de meio-tom são amplamente utilizadas em impressão de jornais e revistas e também por praticamente todos os tipos de impressoras (laser, jato de tinta, etc.) para imprimir imagens em níveis de cinza e coloridas. Neste artigo, consideraremos somente os processos meio-tom que convertem uma imagem em níveis de cinza G numa imagem binária B .

A técnica de meio-tom inverso é o processo reverso: converte uma imagem binária meio-tom B na imagem em níveis de cinza G . Uma imagem em níveis de cinza pode ser manipulada com facilidade: pode-se ampliar, reduzir, rotacionar, acertar brilho/contraste, enfatizar bordas, eliminar ruídos, detectar texturas, segmentar, etc. Não existe a mesma facilidade para manipular as imagens meio-tom. Assim, aparecem diversas situações em que uma imagem meio-tom precisa ser convertida na imagem em níveis de cinza antes de sofrer outros processamentos.

Provavelmente, o processo mais simples de meio-tom inverso é um filtro passa-baixas, como a convolução com o núcleo gaussiano. Este tipo de meio-tom inverso tem o defeito de borrar as bordas da imagem. Um bom processo de meio-tom inverso deve ser melhor que o filtro gaussiano.

Na literatura recente, vários trabalhos propõem diferentes métodos de meio-tom inverso empregando técnicas tais como look-up-table [7], árvores de decisão (ADs) [6] e funções de base radial [5].

Chang, Yu e Lee [2] propuseram um método híbrido denominado LMS-MMSE baseado nos filtros LMS (least-mean-square) e MMSE (minimum mean square error) combinados com a técnica look-up-table para reconstruir imagens em níveis de cinza com alta qualidade. Os resultados descritos nesse trabalho são comparados com aqueles conseguidos através da filtragem gaussiana.

Mese e Vaidynathan [7] propuseram um método de meio-tom inverso baseado em aprendizagem usando look-up-table. A tabela é preenchida a partir das imagens-amostras de entrada (meio-tom) e de saída (níveis de cinza). Este processo pode ser utilizado para executar meio-tom inverso dos diferentes tipos de imagens meio-tom, bastando treinar a look-up-table com as imagens-amostras apropriadas. Este método pode ainda ser aplicado em imagens coloridas. Uma proposta para melhorar este método foi apresentada pelos mesmos autores num trabalho posterior [8].

Kim e Queiroz [6] propuseram um método baseado na aprendizagem por AD. Nesse trabalho, foram realizados testes com diferentes tipos de imagens meio-tom e os resultados foram comparados àqueles descritos em [7, 8], sendo superiores na maioria dos casos.

Recentemente, foi proposto um método baseado em funções de base radial e em redes neurais artificiais [5]. Este método reconstrói imagens em níveis de cinza a partir de imagens meio-tom geradas também por uma rede neural

artificial, denominada pelos autores como Single Layer Perceptron.

Neste artigo, propomos um novo método de meio-tom inverso baseado na aprendizagem por uma rede neural artificial supervisionada, que denominamos MLP-IH. Comparamos os resultados obtidos pelo MLP-IH com os resultados de dois outros métodos: a filtragem gaussiana e a aprendizagem por ADs [6]. Demonstramos que sob certas condições (pequena quantidade de amostras de treinamento e janela pequena) os resultados obtidos pelo método MLP-IH são superiores àqueles obtidos pela AD. Isto abre uma nova frente de pesquisa a ser explorada. Estamos pesquisando uma maneira de estender a técnica proposta para grandes quantidades de amostras de treinamento.

II. MEIO-TOM E MEIO-TOM INVERSO

A. Imagens digitais

Uma imagem digital é normalmente definida como uma função bidimensional $f(i, j)$, com $i, j \in \mathcal{B}$. Podemos definir uma imagem binária Q^x como segue:

$$Q^x : \mathcal{B} \rightarrow \{0,1\} \quad (1)$$

Uma imagem em níveis de cinza Q^y é uma função cujo contra-domínio representa diferentes níveis de cinza, por exemplo, o intervalo real de 0 a 1. O intervalo real é normalmente discretizado computacionalmente utilizando 1 byte, resultando em intervalo inteiro de 0 a 255.

$$Q^y : \mathcal{B} \rightarrow [0,1] \text{ ou } Q^y : \mathcal{B} \rightarrow [0, \dots, 255] \quad (2)$$

B. Meio-tom

Half-toning ou método de “meio-tom” é um processo que converte uma imagem de tons contínuos em uma outra de tons discretos [1, 3]. Existem diversos métodos utilizados para geração de imagens meio-tom entre os quais difusão de erro (error diffusion) e disparo ordenado (ordered dithering). Este último pode gerar imagens meio-tom com pontos dispersos ou aglutinados.

O meio-tom é usado para reproduzir imagens em níveis de cinza em dispositivos binários como uma impressora laser ou jato-de-tinta. A maioria das impressoras atuais reproduz uma imagem em tons de cinza gerando um padrão entrelaçado de minúsculos pontos pretos e brancos, que o olho humano mistura causando-nos a impressão de estar olhando para uma imagem com diferentes níveis de cinza.

O processo de meio-tom costuma ser formalizado (de modo grosseiro) como segue. Dada uma imagem em níveis de cinza Q^y com valores reais entre 0 e 1, construir uma imagem binária Q^x com valores discretos 0 ou 1 tal que

$$\bar{Q}^x(i, j) \approx Q^y(i, j) \quad (3)$$

onde $\bar{Q}^x(i, j)$ é a média dos valores de Q^x em torno do pixel (i, j) . Porém, a qualidade da imagem meio-tom depende das características psico-visuais da visão humana, muito difíceis de serem formalizadas matematicamente. Assim, não é inteiramente correto afirmar que um processo de

meio-tom é melhor ou pior que um outro, baseado apenas na equação (3).

C. Meio-tom inverso

Como o próprio nome diz, trata-se do processo inverso do meio-tom. Ou seja, dada uma imagem meio-tom Q^x (obtida por algum processo de meio-tom a partir de uma imagem original em níveis de cinza Q^y), construir a imagem estimada em níveis de cinza \hat{Q}^y tal que:

$$\hat{Q}^y(i, j) \approx Q^y(i, j). \quad (4)$$

No processo de meio-tom, independentemente do método utilizado, algumas informações da imagem original Q^y são perdidas. Por esta razão, dada uma imagem meio-tom Q^x , não é possível recuperar a imagem \hat{Q}^y exatamente igual à imagem original Q^y .

Para exprimir o grau de proximidade entre duas imagens em níveis de cinza (neste caso entre Q^y e \hat{Q}^y), costuma-se utilizar o PSNR (Peak Signal-to-Noise Ratio):

$$PSNR = -10 \log_{10} \left(\frac{\sum_i \sum_j (Q^y(i,j) - \hat{Q}^y(i,j))^2}{m \times 255^2} \right) \text{dB} \quad (5)$$

onde m é o número de pixels das imagens.

Assim como no meio-tom, a qualidade da imagem \hat{Q}^y gerada pelo meio-tom inverso depende das características perceptuais do sistema visual humano. Porém, parece não haver ainda uma métrica perceptual universalmente aceita. Por esta razão, utilizaremos o PSNR que apesar dos seus defeitos, é uma métrica simples e amplamente usada.

D. Meio-tom inverso pela aprendizagem

Um operador (de imagem binária para imagem em níveis de cinza) restrito à janela (W-operador) é uma função que mapeia uma imagem binária Q^x na imagem em níveis de cinza Q^y . Um W-operador Ψ é definido através de um conjunto de w pontos chamado de janela $W = \{W_1, \dots, W_w\}$, $W_i \in \mathcal{B}^2$, e uma função característica $\psi : \{0,1\}^w \rightarrow [0 \dots 255]$ como segue:

$$Q^y(p) = \Psi(Q^x)(p) = \psi(Q^x(W_1 + p), \dots, Q^x(W_w + p)), \quad (6)$$

onde $p \in \mathcal{B}^2$. Cada elemento W_i da janela é chamado de furo de espiar (peephole).

O problema de meio-tom inverso pela aprendizagem envolve 5 imagens: A^x , A^y , Q^x , Q^y , \hat{Q}^y que são respectivamente a imagem-amostra de entrada (meio-tom), a imagem-amostra de saída (em níveis de cinza), a imagem a ser processada (meio-tom), a imagem ideal de saída (em níveis de cinza, supostamente desconhecida) e a imagem de saída gerada pelo processo de meio-tom inverso (em níveis de cinza).

Podemos supor que existe um único par de imagens-amostras (A^x and A^y), pois se existirem mais pares, elas

podem ser “grudadas” para formarem um único par. Vamos denotar o conteúdo em A^x da janela W deslocada para $p \in \mathcal{P}^2$ como a_p^x e chamá-lo de instância de treinamento

ou padrão-amostra de entrada no pixel p :

$$a_p^x = (A^x(W_1 + p), A^x(W_2 + p), \dots, A^x(W_w + p)) \in \{0,1\}^w. \quad (7)$$

onde $w = |W|$. Cada padrão a_p^x está associado a uma cor de saída $A^y(p) \in [0 \dots 255]$. Vamos denotar o dado obtido

quando todos os pixels das imagens A^x e A^y são varridos por

$$a = \{(a_{p_1}^x, A^y(p_1)), \dots, (a_{p_m}^x, A^y(p_m))\} \quad (8)$$

e chamá-lo de conjunto de amostra ou conjunto de treinamento (m é a quantidade de pixels das imagens A^x e A^y). Vamos construir de modo semelhante o conjunto

$$q = \{(q_{p_1}^x, Q^y(p_1)), \dots, (q_{p_n}^x, Q^y(p_n))\} \quad (9)$$

a partir de Q^x e Q^y (n é a quantidade de pixels das imagens Q^x e Q^y). Cada $q_{p_i}^x$ é chamada padrão de busca ou uma

instância a ser processada e a saída $Q^y(p_i) \in [0 \dots 255]$ é chamada de cor de saída ideal.

Em meio-tom inverso pela aprendizagem, um algoritmo de aprendizagem A deve construir um W -operador $\hat{\Psi}$ baseado em A^x e A^y tal que, quando $\hat{\Psi}$ é aplicado a Q^x , espere-se que a imagem resultante $\hat{Q}^y = \hat{\Psi}(Q^x)$ seja semelhante à imagem de saída ideal Q^y .

Para descrever mais precisamente este processo, vamos definir uma função de perda ou de erro l que será usada para medir a diferença entre as saídas ideal e processada. No caso de se utilizar PSNR, a função de perda será a diferença ao quadrado. Reescrevendo o problema de meio-tom inverso pela aprendizagem, o aprendiz A deve construir uma função característica ou hipótese $\hat{\psi}$, baseado em conjunto amostra a tal que, quando $\hat{\psi}$ é aplicada ao padrão a ser processado $q_{p_i}^x$, resultando na cor $\hat{Q}^y(p_i) = \hat{\psi}(q_{p_i}^x)$, a perda $l(Q^y(p_i), \hat{Q}^y(p_i))$ deve ser baixa com alta probabilidade.

III. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA's) têm sido largamente empregadas em aprendizagem de máquina [4, 11, 12]. O Multi Layer Perceptron (MLP) é um modelo de RNA bem conhecido. Ele é caracterizado por possuir, além das camadas de entrada e saída, uma ou mais camadas ocultas.

O algoritmo de aprendizado de MLP, chamado retropropagação (backpropagation), é baseado em aprendizagem por correção de erro. O treinamento é composto por duas fases. Na primeira, um padrão é apresentado à rede através da camada de entrada e o sinal de ativação propaga até a camada de saída, produzindo uma resposta. Na segunda fase, a saída obtida é comparada com a saída desejada, produzindo um sinal de erro. Este sinal de erro é então retropropagado desde a camada de saída até a camada de entrada, e os pesos sinápticos vão sendo ajustados para que a resposta da rede se aproxime da resposta desejada.

IV. RESULTADOS EXPERIMENTAIS

A. MLP-IH

Denominamos o meio-tom inverso pela aprendizagem utilizando MLP de MLP-IH (multi layer perceptron inverse half-toning).

Testamos MLP-IH em imagens (meio-tom) geradas pela difusão de erro (error diffusion) e disparo ordenado (ordered dithering). Nos dois casos, utilizamos uma janela pequena (5x5) e imagens-amostras também pequenas (200x100 pixels). O treinamento do MLP-IH, usando um microcomputador Pentium-4 2.8 GHz durou aproximadamente 2 minutos. Temos evidências de que o processo de meio-tom inverso melhora de qualidade utilizando janelas maiores (por exemplo, 8x8) e imagens-amostras também maiores. Porém, nesses casos, o tempo de treinamento de MLP-IH torna-se proibitivo. O grande desafio é possibilitar o uso do MLP-IH para janelas e amostras de treinamento grandes.

Como o aprendizado do MLP-IH é supervisionado, na fase de treinamento a rede deve receber os padrões de entrada com suas respectivas saídas desejadas. O conjunto de treinamento da rede é o conjunto a (equação 8), formado a partir das imagens-amostras A^x e A^y , usando a janela 5x5:

$$W = \{(-2,-2); (-2,-1); \dots; (0,0); \dots; (+2,+2)\}.$$

Grudamos 6 diferentes imagens em níveis de cinza para compor uma única imagem A^y . Reduzimos essa imagem para 200x100 pixels. Daí, obtivemos as duas imagens meio-tom A^x aplicando as técnicas de difusão de erro e disparo ordenado (pontos dispersos) em A^y . Depois, geramos as duas imagens a serem processadas Q^x aplicando a difusão de erro e disparo ordenado numa outra imagem Q^y (saída ideal).

A camada de entrada da rede neural possui $|W|+1$ neurônios (no nosso caso, $5 \times 5 + 1 = 26$ neurônios). Utilizamos uma única camada oculta com 20 neurônios e apenas um neurônio na cama de saída. A função sigmóide $1/(1 + e^{-\alpha x})$, é utilizada como função de ativação em todas as camadas. A arquitetura da rede proposta é ilustrada na Figura 1.




Fig. 1. Arquitetura da RNA utilizada no problema de meio-tom inverso.

Após a fase de treinamento, aplicamos o método MLP-IH em diferentes imagens meio-tom (geradas tanto pela difusão de erro como disparo ordenado). Os resultados obtidos foram comparados com os resultados do método baseado

em AD [6] e também com os resultados conseguidos pela filtragem gaussiana.

B. Escolha de parâmetro do filtro gaussiano

Para convolução com filtro gaussiano, usamos $\sigma = 1,2$ pixels. O parâmetro σ ótimo foi criteriosamente escolhido. Aplicamos o filtro gaussiano nas 5 imagens do conjunto de testes, variando σ de 1.0 a 2.4. Desses experimentos, escolhemos o parâmetro σ que apresentou PSNR mais alto. Os resultados dos experimentos realizados para escolha de σ , é dado na Tabela I abaixo.

TABELA I
PSNR MÉDIO PARA O CONJUNTO DE IMAGENS VARIANDO O PARÂMETRO σ .

σ	PSNR Médio	σ	PSNR Médio	σ	PSNR Médio
1.0	25,86	1.5	26,01	2.0	25,07
1.1	26,23	1.6	25,84	2.1	24,90
1.2	26,32	1.7	25,63	2.2	24,73
1.3	26,30	1.8	25,45	2.3	24,58
1.4	26,17	1.9	25,27	2.4	24,40

C. Teste com janela 5x5

A Figura 2 ilustra parte das imagens-amostras A^x e A^y . A Figura 3 apresenta as imagens de entrada a serem processadas (Q^x). As Figuras 4, 5, 6 e 7 mostram, respectivamente, as imagens resultantes (\hat{Q}^y) dos métodos MLP-IH, AD-seqüencial, 10-ID3 (usando janela 5x5 e imagens de treinamento 200x100) e filtro gaussiano. A Figura 8 apresenta a imagem original Q^y .

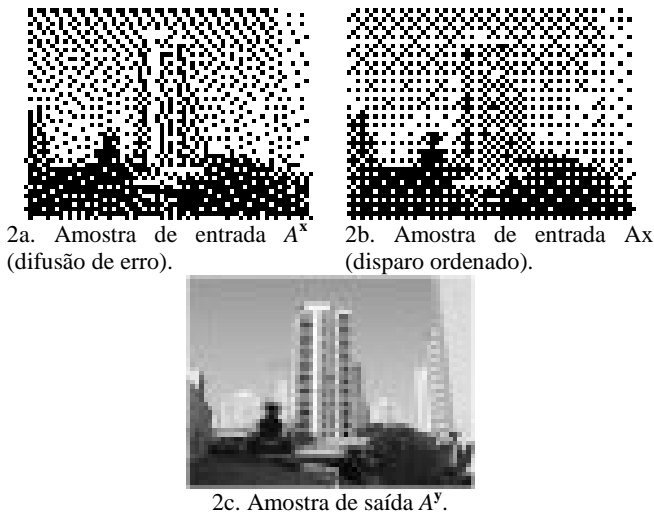


Fig. 2. Parte das imagens-amostras A^x e A^y usadas no treinamento.




Fig. 3. Parte das imagens a serem processadas Q^x .




Fig. 4. Parte das imagens (\hat{Q}^y) geradas por MLP-IH, usando janela 5x5 e imagens de treinamento 200x100.




Fig. 5. Parte das imagens (\hat{Q}^y) geradas por AD-seqüencial, usando janela 5x5 e imagens de treinamento 200x100.




Fig. 6. Imagens (\hat{Q}^y) geradas por 10-ID3, usando janela 5x5 e imagens de treinamento 200x100.

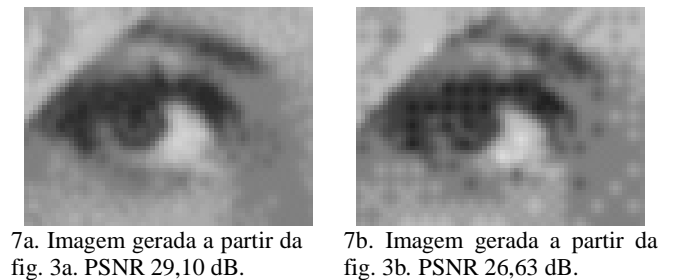


Fig. 7. Imagens (\hat{Q}^y) geradas pelo filtro gaussiano com $\sigma=1,2$ pixels.



Fig. 8. Imagem original (Q^y).

Comparando as imagens da Figura 4 geradas por MLP-IH com imagem original (Figura 8), percebe-se que a qualidade visual é muito boa. Observa-se também que visualmente as duas imagens obtidas por MLP-IH são melhores que as imagens geradas pelos outros dois métodos, apresentadas nas Figuras 5, 6 e 7.

TABELA II
RESULTADOS OBTIDOS (EM PSNR DB) USANDO 20.000 AMOSTRAS E JANELA 5x5.

	Imagem	AD		Filtro gaussiano	MLP-IH
		AD-seq	10-ID3		
Dif. erro	Lenna	23,29	27,95	29,10	31,52
	Peppers	22,45	25,80	28,11	27,43
	Mandrill	19,36	22,90	22,84	24,04
	Airplane	23,31	27,15	28,73	29,41
	Goldhill	21,96	25,81	28,03	27,84
	Média	22,07	25,92	27,36	28,05
Disp. ord.	Lenna	25,64	26,38	26,63	26,44
	Peppers	24,56	25,34	25,99	25,05
	Mandrill	20,03	20,91	21,57	21,11
	Airplane	24,97	25,87	26,59	25,46
	Goldhill	24,18	24,94	25,58	25,11
	Média	23,88	24,69	25,27	24,63
Média geral		22,98	25,31	26,32	26,34

Na Tabela II, apresentamos as qualidades das imagens medidas em PSNR. Todas as imagens meio-tom a serem processadas possuem o mesmo tamanho (512x512) e são dos tipos difusão de erro ou disparo ordenado pontos dispersos. O tempo de processamento gasto pelo MLP-IH, para a reconstrução da imagem em níveis de cinza correspondente a cada uma dessas imagens meio-tom foi de aproximadamente 2,5 segundos. Esse tempo é maior que o tempo gasto pelos métodos AD e filtragem gaussiana.

De acordo com a Tabela II, o MLP-IH apresenta resultados melhores que os outros métodos para a difusão de erro (janela 5x5 e imagens-amostras 200x100). Para o disparo ordenado, os resultados de MLP-IH são ligeiramente inferiores aos da filtragem gaussiana, porém superiores aos da AD.

D. Teste com janela 8x8

Como já mencionado, ADs fornecem resultados melhores que o MLP-IH quando treinado com conjunto de treinamen-

to e janela maiores. Na Tabela III, apresentamos os resultados de experimentos utilizando janelas 8x8. ADs foram treinadas com imagens 3198x1066. MLP-IH, entretanto, foi treinado com imagens 200x100, devido às limitações de desempenho computacional. Claramente, 10-ID3 foi o melhor método. Porém, deve-se levar em consideração que MLP-IH foi treinado utilizando imagens-amostras muito menores que 10-ID3.

TABELA III
RESULTADOS OBTIDOS (EM PSNR DB) USANDO JANELA 8x8. AD FOI TREINADA COM IMAGENS 3198x1066. MLP-IH FOI TREINADO COM IMAGENS 200x100.

	Imagem	Ads		MLP-IH
		AD-seq	10-ID3	
Dif. erro	3 imagens conj. A	25,46	31,85	29,71
	3 imagens conj. B	-	32,98	29,51
	Média	-	32,42	29,61
Disp. ord.	3 imagens conj. A	28,18	30,22	26,05
	3 imagens conj. B	-	31,46	27,06
	Média	-	30,84	26,56

V. CONCLUSÕES

Neste trabalho, apresentamos o método MLP-IH, baseado na aprendizagem por rede neural artificial supervisionada, para reconstrução de imagens em níveis de cinza a partir de imagens meio-tom. Com base nos experimentos descritos, concluímos que o método MLP-IH obteve, na média, resultados superiores aos demais métodos (usando janela de 5x5 e um pequeno conjunto de treinamento). Permanece desafio estender o método para que possa trabalhar janelas grandes e grandes conjuntos de treinamento. A vantagem do MLP-IH está em que ele apresenta bons resultados mesmo treinado com poucas amostras (deve-se notar que atualmente não é possível treinar MLP-IH com grandes conjuntos de treinamento devido ao tempo de processamento). Já AD apresenta resultados superiores quando o aprendizado é realizado com grandes conjuntos de treinamento.

AGRADECIMENTOS

Este trabalho foi financiado em parte pela FAPESP através do processo 2003/13752-9 e pela CNPq através dos processos 305065/2003-3 e 475155/2004-1.

REFERÊNCIAS

- [1] K. R. Castleman, *Digital Image Processing*, Prentice-Hall, New Jersey, 1996.
- [2] P. C. Chang, C. S. Yu and T. H. Lee, "Hybrid LMS-MMSE Inverse Halftoning Technique". *IEEE Transactions on Image Processing*. v. 10, n. 1, pp. 95-103, 2001.

- [3] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*. 2. nd., Prentice Hall, New Jersey, 2002.
- [4] S. Haykin, *Neural Networks – A Comprehensive Foundation*. 2nd., Prentice Hall, New Jersey, 1999.
- [5] W. B. Huang, Chang et al., “Halftone/Contone Conversion Using Neural Networks”. *IEEE Transactions on Image Processing*. v. 5, pp. 3547-3550, 2004.
- [6] H. Y. Kim, R. L. Queiroz, “Inverse Halftoning by Decision Tree Learning”. *In: IEEE Int. Conf. Image Processing*, v. 2, pp. 913 – 916, Barcelona, 2003.
- [7] M. Mese and P. P. Vaidyanathan, “Look-Up Table (LUT) Method for Inverse Halftoning”. *IEEE Transactions on Image Processing*. v. 10, n. 10, pp. 1566-1578, 2001.
- [8] M. Mese and P. P. Vaidyanathan, “Tree-Structured Method for LUT Inverse Halftoning and for Image Halftoning”. *IEEE Transactions on Image Processing*. v. 11, n. 6, pp. 644-655, 2002.
- [9] T. Mitchell, *Machine Learning*. McGraw Hill, 1997.
- [10] W. K. Pratt, *Digital image processing*, John Wiley, New York, 1991.
- [11] E. Rich, *Inteligência artificial*, Makron Books, São Paulo, 1994.
- [12] S. Russel and P. Norvig, *Artificial intelligence a modern approach*. Prentice Hall, New Jersey, 1995.