

1º Congresso Brasileiro de Redes Neurais

Escola Federal de Engenharia de Itajubá
Itajubá, 24 a 27 de outubro de 1994

Segmentação de Texturas Utilizando Operadores de Convolução e Redes Neurais

Evandro O. T. Salles*, Francisco J. N. Gomes**, Gutemberg H. Brasil***

*Departamento de Eng. Elétrica, **Departamento de Informática, ***Departamento de Estatística

Resumo: Neste trabalho testou-se a eficácia das máscaras de Laws, juntamente com os operadores propostos por Pietikäinen et al [1], para a segmentação de texturas. Estes operadores extraem características da imagem, que são utilizadas no treinamento de uma rede neural tipo *Counterpropagation*. Após a aprendizagem, uma imagem contendo várias texturas é varrida e seus pontos são classificados de acordo com a textura presente ao seu redor

1. Definições sobre Texturas

A textura é uma característica bastante importante em imagens, podendo encontrar-se desde explorações multiespectrais de aviões e satélites até fotos microscópicas de cultivos celulares [2]. Utilizam-se as texturas para a análise de regiões homogêneas como fotos aéreas de zonas urbanas e zonas rurais, florestas, zonas desmatadas, etc. Também pode-se utilizá-las como um fator importante em segmentação de imagens ou na determinação de zonas defeituosas em superfícies de madeira [3].

Não existe um procedimento genérico para a interpretação de texturas. Para descrevê-las utilizam-se características tais como regularidade, granulosidade, repetitividade, aleatoriedade, linearidade, irregularidades, suavidade, rugosidade, etc. Estes são descritores qualitativos que podem representá-las. Porém, é difícil quantificar tais adjetivos utilizando-se um computador. Nem sempre nossas sensações visuais podem ser traduzidas de maneira matemática, simples e compacta. Além de todas as características e primitivas anteriores, não se deve esquecer da distribuição dos níveis de cinza sobre a textura. Ainda que seu conceito genérico a diferencie de sua cor, tal procedimento não é correto. Segundo Munõz [2], nível de cinza-textura são conceitos dependentes e se relacionam entre si de maneira muito parecida ao relacionamento onda - partícula. Do mesmo autor tem-se :

- Quando uma pequena área de uma imagem possui uma pequena variação das primitivas tonais, a propriedade predominante é o tom de cinza.

- Quando esta mesma área possui uma grande variação das primitivas tonais, a propriedade predominante é a textura.

Devemos adequar a ferramenta correta a um problema específico. Seja qual for o tipo de textura, existem técnicas diferenciadas para cada caso. Use-se dividir sua análise em três categorias: análise estrutural, análise espectral e análise estatística [4]. Análise estrutural se refere ao estudo de primitivas e das relações topológicas entre elas. Este tipo de técnica se aplica a texturas altamente estruturadas e, sobretudo, com primitivas periódicas. Já a análise espectral utiliza as transformadas de Fourier para computar a frequência básica de toda a imagem, frequência de repetição de uma textura regular. As técnicas espectrais se baseiam na obtenção do espectro de Fourier e são usadas para identificar a periodicidade global de uma imagem, identificando-se picos estreitos e de alta energia que aparecem no espectro.

Ambas as técnicas se aplicam a texturas regulares que apresentam alguma lei de periodicidade de suas primitivas. Esta é uma característica bastante limitante. Na grande maioria dos casos, as imagens reais são misturas de texturas repetitivas e não repetitivas, sendo estas últimas de componente aleatório. Obviamente que as técnicas baseadas em medidas de regularidade não se adaptam a estes tipos de texturas com facilidade. Ademais, em ambos os casos, realiza-se uma análise global sobre a imagem e, para tanto, deve-se supor que as frequências de repetição das primitivas não se modifiquem [5]. A pergunta que se faz é como garanti-lo ao longo de toda a imagem?

2. Máscaras de Detecção de Texturas

K. I. Laws, lançou uma metodologia baseada em máscaras de convolução padrão, sendo estas capazes de detectar segmentos horizontais e

verticais, pontos, etc. Este tipo de análise se contrapõe à tradicional, baseada em pares de *pixels*, e se alinha com os micropadrões denominados *Textons*, propostos por B. Julesz em [6]. Para medir a energia de cada micropadrão, Laws propôs a utilização de estatísticas tipo ABSAVE, sobre uma região localizada (janela NxN), tendo como ponto central o *pixel* que carregará o resultado da convolução. Pietikäinen et al [1], estudando a eficácia das máscaras de Laws, propôs um novo conjunto de máscaras 5x5 baseadas não na definição quantitativa destas mas sim na sua forma geral. As novas máscaras são detectores simples de pequenos círculos concêntricos e de bordas centradas simetricamente em relação à máscara. Desta forma, conseguiu-se resultados melhores que apenas aplicando as máscaras de Laws 5x5. Os novos operadores, assim como os de Laws, possuem soma nula de seus componentes. No Apêndice podemos observar estes operadores

3. Procedimento

Para a aquisição de imagens empregou-se um *scanner*, já que não se dispunha de uma câmera e uma placa digitalizadora para barramento PC. O sistema foi desenhado para poder carregar uma imagem e permitir o treinamento da rede neural (*Counterpropagation*) com padrões significativos de texturas. Na fase de classificação, marca-se uma zona específica e sobre esta é realizada a segmentação de texturas.

Utilizou-se 64 tons de cinza, na representação da imagem. Esta não foi uma escolha e sim uma imposição do sistema computacional, já que não se encontrou um *driver* (para uma máquina tipo IBM-PC compatível) que pudesse manipular 256 níveis de cinza ao mesmo tempo. Cada imagem, contendo texturas, foi criada segundo os moldes mostrados na figura 1.




figura 1 - Moldes utilizados

Sobre as imagens são marcadas regiões retangulares (marcações em pontilhado) onde nestas se avalia a taxa de acertos obtida, através de tabelas. Utilizou-se uma rede neural *Counterpropagation* (CPN) do tipo *feed forward only* [7], [8], com mecanismo de consciência na camada de Kohonen [9]. O número de neurônios utilizado foi de, no

mínimo, 3 vezes o número de classes a serem reconhecidas. A rede foi preparada para gerar uma cor na saída diferente, correspondendo a uma classe detectada. A rede CPN possui um rápido treinamento, se comparada com uma *Perceptron* Multicamadas + algoritmo de retropropagação. Por contar com uma camada de Kohonen, possui a característica de capturar a distribuição estatística dos dados de entrada.

4. Testes e Resultados

Para os testes iniciais, utilizou-se as 9 (nove) máscaras propostas por Laws, de dimensões 3x3. Como estas possuem dimensões reduzidas, a computação de seus resultados é relativamente rápida. A configuração inicial do sistema (CPN + Laws + ABSAVE) segue na tabela abaixo:

Máscaras de Laws	3x3 - 9 máscaras
ABSAVE	9x9
nº de iterações	15000
Consciência	sim
Ptos. p/ Treino	80/(nº de classes)

Tabela 1 - Configuração inicial do sistema.

Na figura 2 observamos duas texturas, obtidas de [10]. Ambas são artificiais sendo que a textura da direita apresenta algumas distorções. Em 2(a) observamos as texturas a serem detectadas e em 2(b) o resultado da segmentação:




figura 2 - Em (a) temos dois tipos de texturas onde podemos observar em (b) o resultado da segmentação. A CPN foi preparada para gerar uma cor na saída diferente para cada classe detectada

Na tabela 2 podemos observar as taxas de erros e acertos na classificação:

Resultado	Textura A	Textura B
Textura A	92.59%	7.41%
Textura B	6.39%	96.61%

tabela 2

Na figura 3 foram misturadas as texturas, para se analisar o poder de separação do sistema entre fronteiras. O molde usado refere-se ao apresentado na figura 1(b). A configuração é dada pela tabela 1. Como se observa, a grau de acerto foi elevado. Entretanto, existem alguns problemas nas fronteiras entre as texturas.



figura 3 - Texturas de papelão misturadas

Na a solução do problema proposto na figura 3, modificou-se o tamanho da janela de ABSAVE (de 9x9 passou-se a 7x7), para que o sistema pudesse ficar mais sensível às fronteiras. Com isto, perdeu-se um pouco a capacidade em detectar variações de uma mesma textura. Isto explica as pequenas regiões mais escuras presentes em regiões mais claras. Neste caso, pode-se melhorar a aprendizagem, aumentando-se a quantidade de pontos a serem treinados, ou mesmo selecionando-os melhor durante o treinamento. Existem 4 áreas marcadas para avaliação conforme mostra o molde desenhado na figura 4. A1, A2 e B1, B2 são as texturas A e B.




figura 4 - Molde das áreas de testes usado na figura 3

Para a região B1 os resultados foram:

Resultado	Textura A	Textura B1
Textura B1	10.74%	89.26%

Tabela 3 (a)

Para a região A1-B2:

Resultado	Textura A1	Textura B2
Textura A1	100%	0%
Textura B2	32.94%	67.06%

Tabela 3 (b)

Observe que na segunda linha da tabela 3 (b), obtivemos uma baixa taxa de acertos (67.06%), junto a uma alta taxa de erros (32.94%). Isto representa uma inadequação dos parâmetros do sistema ao tentar resolver fronteiras.

Na próxima imagem, figura 5, foram misturadas 4 tipos de texturas [10] segundo o molde apresentado na figura 1(c). Estas texturas apresentam poucas tonalidades de cinza.




figura 5- Quatro tipos de texturas + fundo.

Ao tentarmos segmentar as texturas da figura 5, utilizando-se a configuração inicial, observou-se que à medida em que esta se tornava mais grossa, a janela de 9x9 perdia a capacidade em detectar o tamanho básico das microtexturas. Por isto, modificamos o tamanho original da janela de ABSAVE para 13x13 e obtivemos o resultado apresentado em 5(b). Na imagem original, podemos observar uma parte mais clara entre cada textura. Esta parte se refere ao fundo. Uma maneira de fazer com que o sistema separe as texturas do fundo é permitindo que este seja aprendido. Observe que apesar da separação ter sido boa entre as texturas A e B, o mesmo falha para C e D. Os resultados obtidos podem ser vistos na tabela 4

Res.	Text. A	Text. B	Text. C	Text. D
Text. A	94.95%	2.05%	1.74%	1.26%
Text. B	7.68%	85.58%	1.50%	5.24%
Text. C	12.54%	13.25%	74%	0.30%
Text. D	1.72%	0.87%	2.02%	95.39%

tabela 4

Na figura 6 observamos a presença de 5 (cinco) texturas mescladas em uma só imagem. As tres texturas menores (os retângulos menores) foram obtidas de tecidos. Na obtenção de cada uma delas, variou-se a resolução para podermos criar a sensação de textura grossa e textura fina. Novamente é possível notar problemas relativos com a resolução de fronteiras.



figura 6 - Exemplo onde se encontram 5 tipos diferentes de texturas

Como na fronteira, tanto as máscaras de Laws como a janela de ABSAVE estão entre uma e outra textura, a classificação penderá para aquele tipo que fornecer maior energia. Este problema aparece e aparecerá em todos os exemplos que fizermos. Para o retângulo superior e central, composto por uma

textura mais grossa, houve uma taxa maior de erros. Em especial, para esta área, obteve-se a tabela 5:

Res. (%)	Text. A	Text. B	Text. C	Text. D	Text. E
Text. B	22.63 (%)	65.39 (%)	7.33 (%)	2.38 (%)	2.27 (%)

tabela 5

Para o problema da figura 7 (molde figura 1(a)), existe um fator complicador que é a distribuição dos tons de cinza ao longo da imagem. Como na digitalização utilizamos uma resolução elevada, não capturamos toda a característica da distribuição dos níveis de cinza. Desta forma, a distribuição de manchas escuras e claras sobre a imagem se comporta como um processo estocástico não estacionário.




figura 7 - Em (b) observamos o resultado da segmentação sobre a imagem propota em (a).

Neste caso, utilizou-se as 4 máscaras 5x5 propostas por Laws e as 8 máscaras 5x5 propostas por Pietikäinen et al [1]. O vetor de características passou a ter dimensão 13 (12 das máscaras + 1 para a normalização). A janela de ABSAVE empregada possuía dimensões 19x19, para 32000 passos de treinamento. O tempo de processamento (classificação) aumentou consideravelmente (o tempo de treinamento da rede continuou da ordem de 2 minutos, para 80 padrões de testes). Os resultados obtidos são apresentados na figura 7(b), com a taxa de acertos dada pela tabela 6.

Dada a relação tom de cinza - textura, a propriedade que mais se evidenciou neste caso foi a textura. E isto era de se esperar pois a resolução com o qual a imagem foi obtida é elevada, fazendo com que as primitivas texturais se tornassem mais evidentes. Apesar das dimensões de ABSAVE, o sistema conseguiu detectar, com bons resultados, a fronteira presente entre as duas texturas.

Resultado	Textura A	Textura B
Textura A	95.61%	4.39%
Textura B	94.80%	5.20%

tabela 6

Um questionamento que pode ser feito neste momento se refere à característica das máscaras de Laws: sua detecção se baseia na trama ou em zonas com distribuição mais ou menos uniforme de tons de cinza? No conjunto de máscaras selecionado estão

embutidos operadores que detectam ambas as propriedades, mesmo porque esta é a própria essência da análise e segmentação de texturas. No caso da segmentação das texturas presentes na figura 3 (tipos diferentes de papelão), observa-se que as primitivas são menos definidas, prevalecendo a distribuição tonal. Entretanto, tentar segmentar as duas texturas usando-se somente a comparação dos tons de cinza com um decisor (*Threshold*) pode levar a resultados muito piores que os apresentados. Ainda que a textura (ou a trama) não esteja claramente definida, a própria distribuição dos tons de cinza se encarrega de definir uma interrelação que, apesar de aparentemente aleatória, guarda em si alguns tipos de características marcantes. São estas as características detectáveis pelas máscaras empregadas.

Com o próximo teste observa-se a robustez do sistema quanto à rotação. Na figura 8, duas regiões entre texturas foram giradas de 37° anti-horários e 54° horários, conforme se observa. Ensinou-se o sistemas apenas com exemplos referentes à região não rotacionada. Como se observa, os resultados obtidos revelam que as características extraídas são robustas à rotação. Empregou-se as 12 máscaras de dimensões 5x5 (Laws + Pietikäinen) e janelas de ABSAVE de dimensões 19x19.




figura 8 - Texturas rotacionadas

Como as máscaras detectam microcaracterísticas (pontos, pontos concêntricos, retas, etc, o que se assemelha ao proposto por [6]) e como não se mede interrelação entre *pixels*, obtemos medições absolutas (medimos a quantidade de energia de cada característica), o que favorece a robustez à rotação.

Para o caso da figura 9 [12], estamos utilizando o molde dado por 1(a).



figura 9 - Imagem contendo 4 tipos de texturas

Observe que a rede falha sobretudo ao tentar classificar as texturas B e C. Ambas possuem uma predominância de tons de cinza muito parecidos, diferenciando-se principalmente na textura propriamente dita (trama). A distribuição de tons de cinza produz um efeito similar ao apresentado na

figura 7, onde tons mais escuros destoam do resto da imagem. Isto nos leva a concluir que para melhorar a segmentação, neste caso, é necessário ater-nos na trama. Assim, o sistema exige uma melhor sintonia, devendo-se testá-lo para um número maior de iterações (utilizou-se a configuração básica dada pela tabela 5.1, porém 12 máscaras de dimensões 5x5 - Laws + Pietikäinen), com uma maior quantidade de exemplos de treinamento para cada textura. A tabela 7 mostra a taxa de acertos obtida.

Res.	Text. A	Text. B	Text. C	Text. D
Text. A	88.3%	10.3%	1.33%	0%
Text. B	15.2%	62.53%	22.27%	2.52%
Text. C	19.2%	36.45%	44.11%	0.27%
Text. D	1.42%	3.01%	23.8%	71.7%

tabela 7

No problema a seguir, figura 10, imprimiu-se, usando-se instrumentos metálicos, tipos diferentes de texturas sobre uma superfície de madeira. O molde utilizado é dado pela figura 1(f). Como se observa, a falta de definição nas bordas tornou-se bastante crítica (apesar das texturas não terem sido impressas segundo um molde retangular). O tamanho das máscaras de Laws e da janela de ABSAVE se mostram inadequadas (5x5 e 19x19 respectivamente) mas com elas se obteve os melhores resultados. Pode-se tentar aumentar a quantidade de iterações da CPN ou mesmo ajustá-la melhor. Neste caso, utilizou-se 15.000 iterações.




figura 10 - Texturas impressas sobre madeira.

Um outro problema se refere a pequenas regiões da textura de fundo que não foram detectadas como tal. A causa para isto pode ser devida a poucos exemplos de treinamento (foram usados 10) ou uma má seleção dos exemplos.

5. Conclusão

Uma escolha correta dos dados a serem usados no treinamento é fundamental. Em nosso caso, sempre buscamos treinar a CPN com aqueles representantes de uma classe que mais se distanciavam de seu padrão. Com isto, a rede teve chance de encontrar uma superfície de separação que melhor se adaptava ao problema. Neste sentido, uma rede do tipo LVQ pode apresentar resultados melhores.

A configuração inicial da rede, dada pela tabela 1, apresentou bons resultados. Alguns testes foram feitos utilizando-se 5000 iterações, porém só funcionaram para problemas onde a segmentação era simples de ser obtida. Para o problema mostrado na figura 2, 1000 iterações mostrou-se suficiente, dando inclusive taxas de acertos comparáveis às apresentadas pela tabela 2. Entretanto, problemas como os que se observam na figura 7 exigiram 32000 iterações. Não necessariamente o número de padrões a serem treinados devem ser iguais para cada textura. Existem texturas que exigem uma quantidade maior de padrões para treinamento, devido a sua complexidade.

Hsiao et al [13] sugere que seja utilizado um procedimento de relaxação espacial para melhorar a detecção de texturas. Acreditamos que tal mecanismo possa ser empregado utilizando-se uma rede neural.

Apêndice

$$\begin{array}{c}
 L_3^T \otimes L_3 \quad L_3^T \otimes E_3 \quad L_3^T \otimes S_3 \\
 \left| \begin{array}{ccc|ccc} 1 & 2 & 1 & -1 & 0 & 1 \\ 2 & 4 & 2 & -2 & 0 & 2 \\ 1 & 2 & 1 & -1 & 0 & 1 \end{array} \right| \quad \left| \begin{array}{ccc|ccc} -1 & 2 & -1 & -1 & 2 & -1 \\ -2 & 4 & -2 & -2 & 4 & -2 \\ -1 & 2 & -1 & -1 & 2 & -1 \end{array} \right| \\
 E_3^T \otimes L_3 \quad E_3^T \otimes E_3 \quad E_3^T \otimes S_3 \\
 \left| \begin{array}{ccc|ccc} -1 & -2 & -1 & 1 & 0 & -1 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 2 & 1 & -1 & 0 & 1 \end{array} \right| \quad \left| \begin{array}{ccc|ccc} 1 & -2 & 1 & 1 & -2 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ -1 & 2 & -1 & -1 & 2 & -1 \end{array} \right| \\
 S_3^T \otimes L_3 \quad S_3^T \otimes E_3 \quad S_3^T \otimes S_3 \\
 \left| \begin{array}{ccc|ccc} -1 & -2 & -1 & 1 & 0 & -1 \\ 2 & 4 & 2 & -2 & 0 & 2 \\ -1 & -2 & -1 & 1 & 0 & -1 \end{array} \right| \quad \left| \begin{array}{ccc|ccc} 1 & -2 & 1 & 1 & -2 & 1 \\ -2 & 4 & -2 & -2 & 4 & -2 \\ -1 & -2 & -1 & 1 & 0 & -1 \end{array} \right|
 \end{array}$$

$$\begin{array}{c}
 L_5 \otimes E_5 \quad E_5 \otimes S_5 \\
 \left| \begin{array}{ccc|ccc} -1 & -2 & 0 & 1 & 2 & -1 & 0 & 2 & 0 & -1 \\ -4 & -8 & 0 & 4 & 8 & -2 & 0 & 4 & 0 & -2 \\ -6 & -12 & 0 & 12 & 6 & 0 & 0 & 0 & 0 & 0 \\ -4 & -8 & 0 & 8 & 4 & 2 & 0 & 4 & 0 & 2 \\ -1 & -2 & 0 & 2 & 1 & 1 & 0 & -2 & 0 & 1 \end{array} \right| \\
 L_5 \otimes E_5 \quad E_5 \otimes S_5 \\
 \left| \begin{array}{ccc|ccc} -1 & 0 & 2 & 0 & -1 & -1 & -4 & 6 & -4 & 1 \\ -4 & 0 & 8 & 0 & -4 & -4 & 16 & -24 & 16 & -4 \\ -6 & 0 & 12 & 0 & -6 & 6 & -24 & 36 & -24 & 6 \\ -4 & 0 & 8 & 0 & -4 & -4 & 16 & -24 & 16 & -4 \\ -1 & 0 & 2 & 0 & -1 & 1 & -4 & 6 & -4 & 1 \end{array} \right|
 \end{array}$$

(b)

$R5\theta R5a$	$R5\theta R5e$
1 1 1 1 1	0 0 1 0 0
1 -4 -4 -4 1	0 0 -10 0 0
1 -4 16 -4 1	1 -10 36 -10 1
1 -4 -4 -4 1	0 0 -10 0 0
1 1 1 1 1	0 0 1 0 0
$R5\theta R5b$	$R5\theta R5f$
1 1 1 1 1	-1 -1 -2 -1 -1
1 -8 -8 -8 1	-1 -3 -4 -3 -1
1 -8 48 -8 1	-1 -4 48 -4 -1
1 -8 -8 -8 1	-1 -3 -4 -3 -1
1 1 1 1 1	-1 -1 -2 -1 -1
$R5\theta R5c$	$E5\theta L5a$
-1 -1 -1 -1 -1	-1 -1 -1 -1 -1
-1 -4 -4 -4 -1	-2 -2 -2 -2 -2
-1 -4 48 -4 -1	0 0 0 0 0
-1 -4 -4 -4 -1	2 2 2 2 2
-1 -1 -1 -1 -1	1 1 1 1 1
$R5\theta R5d$	$E5\theta L5b$
-2 -2 -2 -2 -2	-1 -1 -1 -1 -1
-2 0 0 0 -2	-8 -8 -8 -8 -8
-2 0 32 0 -2	0 0 0 0 0
-2 0 0 0 -2	8 8 8 8 8
-2 -2 -2 -2 -2	1 1 1 1 1

(c)

(a) Máscaras de Laws 3x3. (b) Máscaras de Laws 5x5. (c) Máscaras propostas por Pietikäinen et al [1]

Referências

[1] Experiments with Texture Classification Using Average of Local Pattern Matches
M. Pietikäinen, A. Rosenfeld, L. S. Davis - IEEE Transactions Systems, Mans, and Cybernetics - vol SMC-13, May/June , n. 3, 1983, pag 421~426

[2] Jerarquización de Estructuras de Nivel Bajo y Medio para Reociminto Visual. Aplicaciones a Texturas y Formas
J. A. Muñoz Blanco - Tesis Doctoral - Universidad Politécnica de Canarias - Facultad de Informática - Noviembre de 1987

[3] Identifying and Locating Surface Defects in Wood: Part of an Automated Lumber Processing System
R. W. Connors, C. W. McMillin, K. Lin, R. E. Vasquez-Espinosa - IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI -5, no. 6, November 1983

[4] Digital Image Processing
R. C. Gonzalez, Paul Wintz Addison-Wesley Publishing Company 1987

[5] Computer Perception of Repetitive Textures
L. G. C. Hamey - PhD Thesis - Carnigie Mellon, February 1988

[6] Textons, The Fundamental Elements in Preattentive Vision and Perception of Textures
B. Julesz. R. Bergen - Bell Sys. Tech. J., vol 62, no. 6, July/August 1983 pag 1619~1645

[7] Counterpropagation
R. Hecht-Nielsen - Aplied Optics, vol. 26, No. 23, December 1987

[8] Introduction to the Theory of Neural Computation
J. Herts, A. Krogh, R. G. Palmer - Addison-Wesley Publishing Company 1989

[9] Introdução à Computação Neuronal
L. P. Calôba - 9º CBA - UFES - minicurso - Setembro de 1992

[10] Segmentation of Textured Images and Gestalt Organization Using Spatial/Spatial-Frequency Representation
T. R. Reed, H. Wechsler - IEEE Pattern Analysis and Machine Intelligence - vol. 12 - no. 1 - January 1990, pag 1~12

[11] Local Linear Transforms for Textures Segmentation
M.I Unser - Signal Procecing , 11, (1986), pag 61 ~ 79

[12] Digital Image Processing
W. K. Pratt - A Willey Intercience Publication 1991 2nd edition

[13] Supervised Textured Image Segmentation Using Feature Smoothing and Probabilistic Relaxation Techniques
J. Y. Hisao, A. A. Sawchuk - IEEE Transactions On Pattern Analysis And Machine Intelligence - Vol. II No. 12 December 1989 - pag 1279 ~1292