

Análise de Textura em Imagens Microscópicas de Fungos Usando Método Auto-Regressivo e Uma Comparação com o Método Clássico de Estimação Espectral

RIBEIRO JR, ERALDO¹
MUCHERONI, MARCOS L.¹
CRUVINEL, PAULO E.²

¹ UFSCar - Universidade Federal de São Carlos
Programa de Pós-Graduação em Ciência da Computação
Grupo de Arquitetura, Processamento de Imagens e Sinais
Via Washington Luiz, Km 235, Caixa Postal 676,
13565-905- São Carlos, SP, Brasil
perj@iris.ufscar.br

² EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária
CNPDIA - Centro Nacional de Pesquisa e Desenvolvimento de Instrumentação Agropecuária
São Carlos - SP
cruvinel@npdia.embrapa.ansp.br

Abstract. This work presents a textural microscopic image analysis of fungus by using the auto-regressive estimation method. In addition it is presented a bi-dimensional comparative study between both the classical spectral estimation and the auto-regressive spectral estimation methods. Results show the suitability of the application of the auto-regressive spectra for analysis of roughness in natural images, as well as indicate the possibility of its use in determining the growth stage of the *Penicillium crysogenum*.

1 Introdução

A análise de texturas é uma importante técnica dentro de processamento de imagens digitais e visão computacional. Encontra diversas aplicações práticas em análise de imagens médicas, microscópicas e aéreas, entre outras. Uma aplicação particularmente importante é a análise de culturas de fungos *Penicillium crysogenum* [TUCK92].

As texturas naturais, geralmente, possuem comportamento aleatório quanto à distribuição de tons de cinza na imagem. Uma abordagem adequada para analisar tais texturas é a abordagem espectral [RIBE94a] [YUAN92].

Esse trabalho considera os métodos de estimação Blackman - Tukey (BT) e Auto - Regressivo (AR) verificando suas respostas em situações de análise de atributos visuais em imagens artificiais e naturais de modo a selecionar um estimador para uma aplicação que quantifica a irregularidade de superfícies numa cultura de fungos.

Todos os resultados apresentados foram produzidos pelo programa NVIPI [RIBE94b]. A figura 1 ilustra uma das telas no Núcleo de Visualização em Processamento de Imagens da UFSCar, PPG-CC-1994, implementado em estações de trabalho SUN-SPARC.

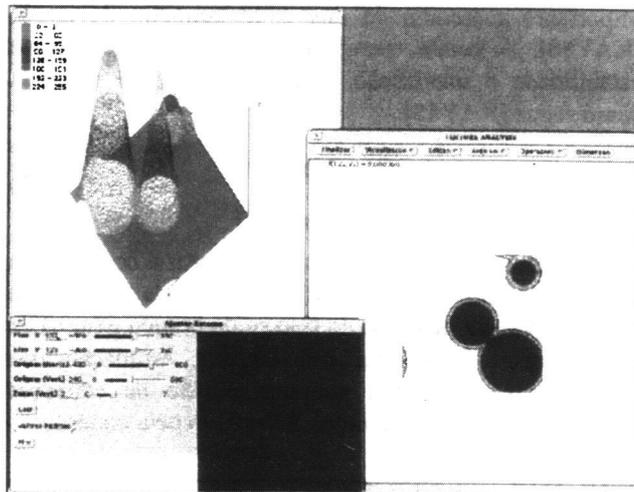


Figura 1 - NVIPI - Uma tela do Núcleo de Visualização em Processamento de Imagens.

2 A Análise Espectral de Texturas

A análise espectral de texturas é baseada na estimação da função de auto-correlação ou do espectro de potência de uma imagem, também chamado de função de densidade espectral de potência. Uma vez estimado o espectro, são feitas medidas sobre as informações de distribuição de

energia freqüencial por ele oferecido, para quantificar atributos visuais da imagem.

Um dos principais problemas nessa abordagem é a estimação do espectro, o qual pode ser realizado por vários métodos e está diretamente relacionado com o tipo de imagem e com a quantidade de dados disponíveis para análise. De forma geral, os métodos de estimação espectral são de dois tipos: clássicos e de alta resolução. Os métodos clássicos são baseados na Transformada de Fourier enquanto os de alta resolução são baseados em estimação paramétrica. Nesse trabalho são abordados o modelo clássico, representado pelo método Blackman-Tukey e o modelo de alta resolução, representado pelo método auto-regressivo de estimação espectral.

O método Blackman-Tukey consiste basicamente da transformada de Fourier da função de autocorrelação da imagem previamente multiplicada por uma janela escolhida [BLAC59]. O estimador para o caso bidimensional é dado pela equação a seguir:

$$P^{BT}(f_1, f_2) = \sum_{k=-K}^K \sum_{l=-L}^L r_{xx}[k, l] \cdot w[k, l] \exp(-j2\pi[f_1 k + f_2 l]) \quad (1)$$

onde $w[k, l]$ é a janela de correlação aplicada à seqüência de autocorrelação $r_{xx}[k, l]$. A janela de correlação $w[k, l]$ é responsável pela suavização da estimativa, sendo importante a escolha do tipo e do tamanho da janela [KAY88]. A janela triangular de Bartlett que oferece estabilidade e suavização bastante eficiente é formada como segue [KAY88]:

$$w(m) = \begin{cases} 1 - \frac{|m|}{M} & |m| \leq M \\ 0 & |m| > M \end{cases} \quad (2)$$

No modelo auto-regressivo, a imagem é considerada como um processo aleatório $y(n, m)$, saída de um sistema excitado por um processo do tipo ruído branco $w(m, n)$ de média zero e variância σ^2 , onde a estimação dos parâmetros reduz-se à simples solução de equações lineares [LIM90]. O estimador AR é dado pela equação:

$$P_x[f_1, f_2] = \frac{\sigma^2}{|1 + \sum_m \sum_n a[m, n] \exp(-j2\pi[f_1 m + f_2 n])|^2} \quad (3)$$

Os coeficientes $a[m, n]$ podem ser estimados através das equações de Yule-Walker ou equações normais cuja forma é indicada na equação:

$$R_x[l_1, l_2] = - \sum_{(k_1, k_2) \in A} a(k_1, k_2) \cdot R_x[l_1 - k_1, l_2 - k_2] \quad (4)$$

Onde A é a janela de predição que pode ter a forma meio plano não simétrico (MPNS) ou quarto de plano (QP). O tamanho da janela de predição A indica a ordem do modelo e, equivalentemente ao janelamento no

método Blackman-Tukey, variações na ordem suavizam a estimativa produzida.

3 Análise Comparativa entre os Métodos de Estimação Espectral Clássico e Auto-Regressivo

A partir dos métodos de estimação espectral apresentados foram feitas análises dos seus comportamentos face aos seguintes fatores: (1) quantidade de dados disponíveis para análise, (2) variação da ordem do modelo/tamanho da janela de correlação, (3) aumento da variância do ruído aditivo associado à imagem, (4) determinação da orientação em imagens, e (5) análise de atributos para imagens reais.

As informações oferecidas pelo espectro bidimensional da imagem podem ser, para efeito de análise, simplificadas com a utilização de histogramas unidimensionais que estão indicados nas equações (5), (6) e (7) [PITA93]. Considerando o espectro representado em coordenadas polares, tem-se:

Histograma de energia radial acumulada

$$P_r(r) = \int_0^{2\pi} P(r, \phi) d\phi \quad (5)$$

Histograma de energia angular acumulada

$$P_\phi(\phi) = \int_0^r P(r, \phi) dr \quad (6)$$

Histograma de energia por ângulo

$$P_\phi(r) = P(r, \phi) \quad (7)$$

Com o uso desses histogramas pode-se verificar a tendência de acúmulo de energia freqüencial no espectro como um todo. O histograma de energia radial acumulada indica a concentração de energia nas altas e nas baixas freqüências contidas no espectro, podendo ser utilizado para medir a rugosidade da imagem analisada, onde a rugosidade pode ser aproximada como a irregularidade na superfície analisada [TAMU78]. O histograma de energia angular acumulada indica a tendência de orientação θ da imagem analisada onde $\theta = \phi - \pi/2$. O histograma de energia por ângulo, por sua vez, proporciona uma secção unidimensional do espectro em dado ângulo direcional oferecendo a possibilidade de melhor visualização dos picos existentes.

Uma medida de tendência para a concentração de energia no histograma radial foi aproximada pela equação, que representa o centro de massa da distribuição radial:

$$\Gamma = \frac{\sum_{r=1}^{r_{\max}} P_r(r) \cdot r}{\sum_{r=1}^{r_{\max}} P_r(r)} \quad (8)$$

onde T varia de r=1 até r_max, e num espectro de dimensão NxN r_max é igual a N/2.

A utilização dessa tendência T proporciona uma forma de medir quantitativamente a rugosidade de uma dada imagem a partir do seu espectro de potência, sendo que, quanto maior o valor de T maior a rugosidade na imagem.

As imagens utilizadas para as análises são de dois tipos: geradas por computador e captadas por "scanner" de mesa em tons de cinza. Tais imagens foram selecionadas em função dos fatores descritos anteriormente, analisados a seguir.

Os histogramas apresentados exibem as respostas espectrais para os dois métodos, sendo que a cor indicada na legenda identifica o estimador utilizado bem como a escala numérica de amplitudes.

(1) Quantidade de dados disponíveis para análise

Nesta etapa foram analisadas imagens do tipo senóide, geradas inicialmente com frequência f = 0.125 onde a dimensão das imagens cresce até um limite máximo. Esse limite foi atribuído em função da capacidade de memória do sistema computacional utilizado e foi fixado em 256x256 pixels. Foram fixadas também o tamanho da janela para o estimador clássico como também a ordem do modelo para o estimador auto-regressivo, de modo que ambas características fossem máximas. Resultados foram obtidos para imagens que variam a dimensão a partir de 16x16 até 256x256 pixels. Com os resultados foi possível a observação da dificuldade de detectabilidade do sinal encontrada pelo estimador clássico quando existe pouca quantidade de dados, recuperando-se porém, com o aumento de dados. Por outro lado, o estimador auto-regressivo demonstrou sua capacidade de detecção mesmo frente a pouca quantidade de dados, porém, foi verificada uma tendência de realce de altas frequências não existentes que prejudicam a resposta espectral. Tal realce não ocorre no estimador clássico. Esse comportamento está indicado na figura 2.

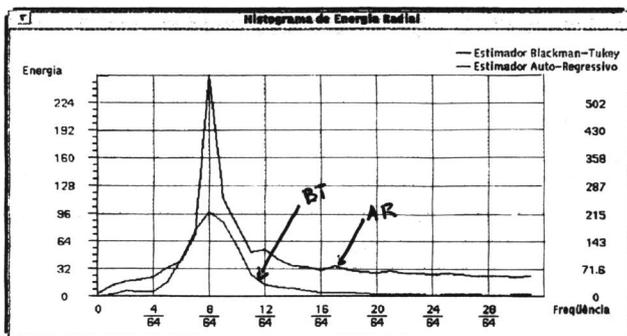


Figura 2 - Histogramas de energia radial acumulada dos espectros BT e AR. Imagem h(x,y) = sen(2πfx), f = 0.125, dim = 32x32.

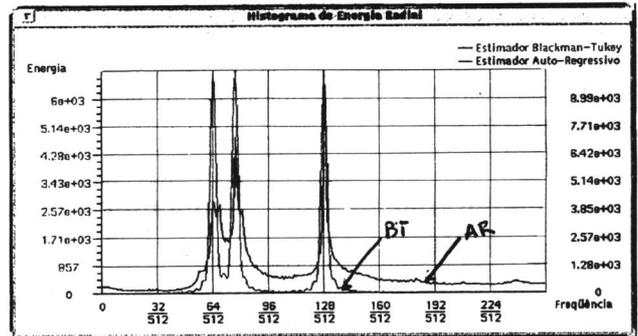


Figura 3 - Histogramas de energia radial acumulada dos espectros BT e AR. Imagem h(x,y) = sen(2πf1 x) + sen(2πf2 x) + sen(2πf3 x), f1 = 0.125, f2 = 0.15, f3 = 0.25, dim = 256x256.

Para imagens com mais de uma componente espectral, por exemplo f1 = 0.125, f2 = 0.15 e f3 = 0.25, o método clássico mostrou-se mais resolutivo do que o método AR mesmo com a máxima quantidade de dados oferecendo indicação satisfatória das componentes apresentadas na imagem, como indicado na figura 3.

(2) Aumento do tamanho da janela de correlação (BT) x Aumento da ordem do modelo (AR).

A detectabilidade para uma componente de frequência é realizada evidentemente melhor no modelo AR, mesmo com máxima suavização, isto é, mínima ordem. O método clássico, porém, com janela de correlação igual a quatro, considerada mínima no caso aqui indicado, não resolve a componente de frequência corretamente bem como produz um deslocamento considerável, como indicado na figura 4.

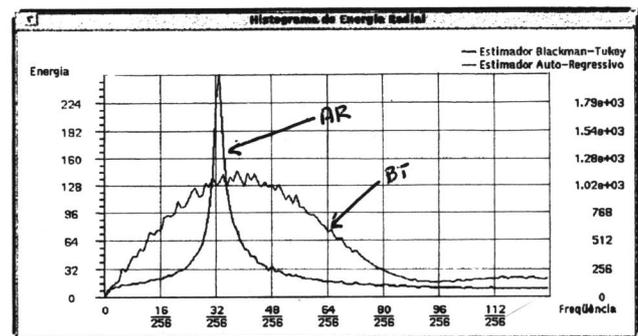


Figura 4 - Histogramas de energia radial acumulada para imagem h(x,y) = sen(2πfx), f = 0.125, dim = 128x128. Máxima suavização.

Em face à alta capacidade de detecção oferecida pelo estimador AR, este torna-se pouco sensível à suavização realizada pela diminuição da ordem do modelo. O estimador clássico possui maior sensibilidade à

suavização realizada pela diminuição do tamanho da janela de correlação.

(3) Comportamento do Estimador na Presença de Ruído

Outro fator analisado é a capacidade do estimador espectral de detectar a componente freqüencial em meio a existência de ruído aditivo à medida que a variância cresce. Existe um limite dessa capacidade nos estimadores e tal limite apresenta-se ser menor no modelo AR para detecção de senóides em ruído branco gaussiano. Foram feitas estimativas para senóides ruidosas de variâncias numa faixa de 1 até 300 e constatou-se a pouca influência do ruído sobre a resposta produzida pelo estimador clássico, como indicado na figura 5. Por outro lado o estimador AR mostrou-se muito sensível ao ruído e tal estimador parece não conseguir detectar componentes freqüenciais na presença de ruído aditivo com variância a partir de 250. A figura 6 indica esse comportamento.

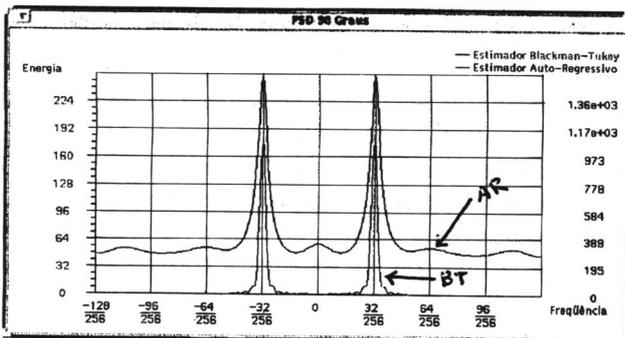


Figura 5 - Componentes senoidais de $h(x,y)=\text{sen}(2\pi fx)$, $f = 0.125$, $\text{dim} = 128 \times 128$, detectadas no estimador BT e no estimador AR na presença de ruído aditivo gaussiano de variância igual a 1.

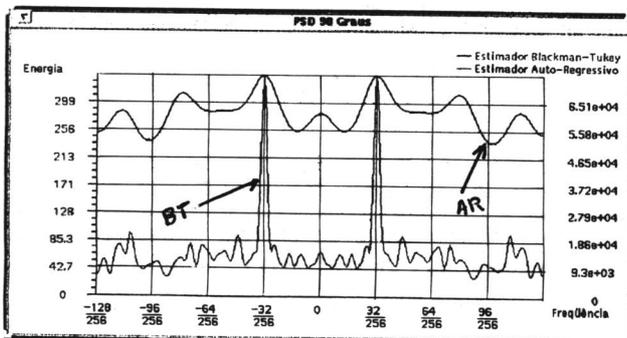


Figura 6 - Componentes senoidais de $h(x,y)=\text{sen}(2\pi fx)$, $f = 0.125$, $\text{dim} = 128 \times 128$, detectadas no estimador BT e no estimador AR na presença de ruído aditivo gaussiano de variância igual a 250.

Pode-se verificar a impossibilidade de detecção das componentes senóides para o modelo AR enquanto que o modelo clássico não sofre influência tão significativa.

(4) Determinação da Orientação em Imagens

Nesse ponto foram produzidos histogramas de energia angular acumulada a fim de verificar a capacidade de determinação de orientação a partir dos espectros estimados. Foram processadas imagens senóides em diferentes ângulos de orientação e imagens reais orientadas. Para as imagens senóides geradas, o estimador clássico produziu indicações angulares mais precisas e definidas do que o estimador AR. Esse comportamento está exemplificado nas figuras 7 e 8.

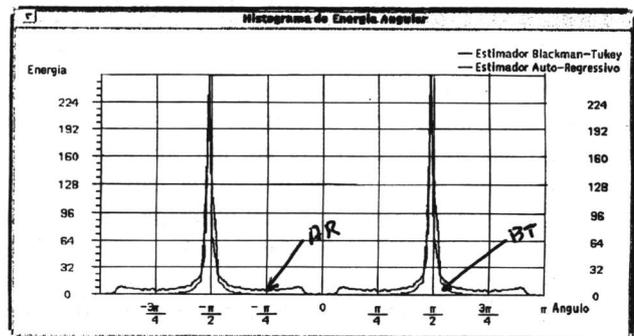


Figura 7 - Posição angular da concentração dos picos nos espectros BT e AR. Imagem senóide orientada a π radianos.

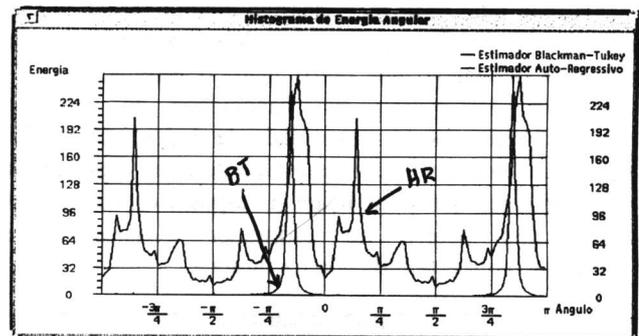


Figura 8 - Posição angular da concentração dos picos nos espectros BT e AR. Imagem senóide orientada a $5\pi/8$ radianos.

Por outro lado, com a utilização de imagens reais de barras em tons de cinza orientadas em determinado ângulo, o estimador AR resolveu mais precisamente as orientações indicadas nas imagens, como indicado nas figuras 9 e 10.

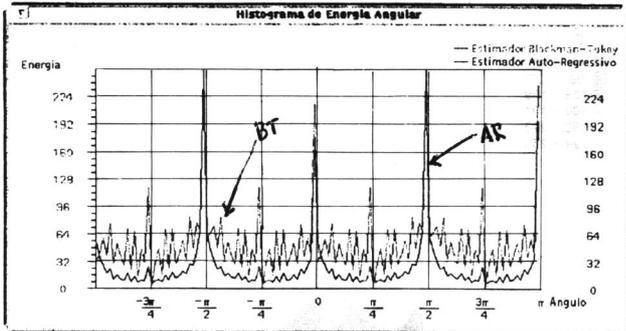


Figura 9 - Posição angular da concentração dos picos nos espectros BT e AR. Imagem real barras em tons de cinza orientada π radianos.

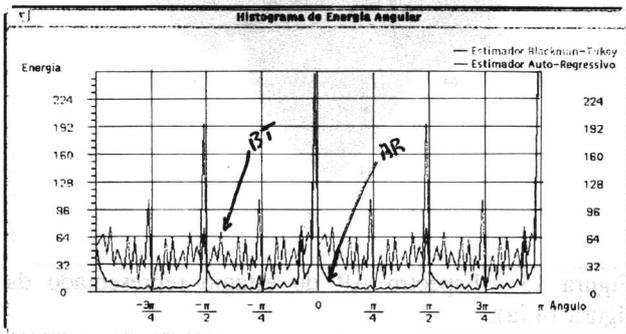


Figura 10 - Posição angular da concentração dos picos nos espectros BT e AR. Imagem real barras em tons de cinza orientada $\pi/2$ radianos.

(5) Análise de atributos para imagens reais

Considerando a utilização de imagens reais, o objetivo é a caracterização de atributos visuais pertencentes à imagem através do espectro de potência produzido. Sendo assim, o espectro gerado deve ser discriminante para cada diferente imagem e traduzir atributos nelas contidos.

Nas imagens reais analisadas, sejam elas compostas por primitivas que se distribuem espacialmente de forma regular ou mesmo aleatoriamente, o espectro produzido pelo modelo auto-regressivo utilizado mostrou maior capacidade de distinção dos espectros.

Utilizando-se o valor tendência T para aproximar a rugosidade das imagens, tem-se a seguir a análise das imagens apresentadas pela figura 11. Os histogramas radiais produzidos pelos métodos clássico e auto-regressivo são apresentados nas figuras 12 e 13 respectivamente.

A diferenciação nos espectros produzidos pelo modelo auto-regressivo torna-se clara no que diz respeito à concentração de energia nas baixas e altas frequências. Pela análise da tabela 1 pode-se verificar as variações na tendência de concentração para os dois casos. A imagem mostrada na figura 11.(a) apresenta uma irregularidade mais acentuada que a imagem mostrada na figura 11.(b).

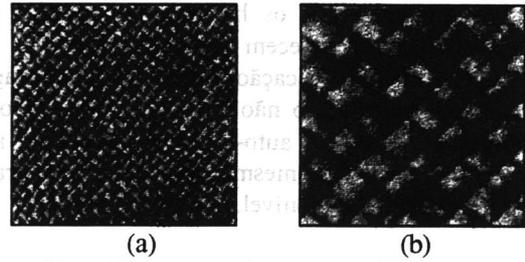


Figura 11 - Figuras reais para análise espectral de rugosidade. (a) esteira mais rugosa, (b) esteira menos rugosa

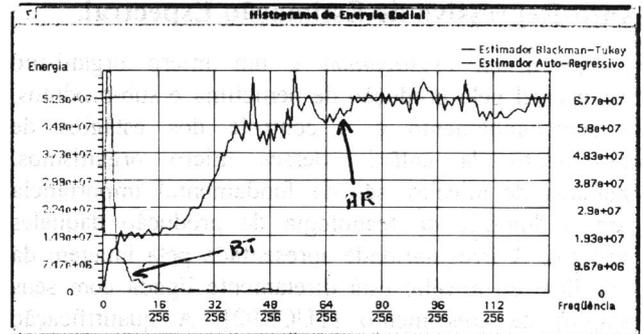


Figura 12 - Histograma de energia radial acumulada dos espectros BT e AR da imagem apresentada na figura 11.(a).

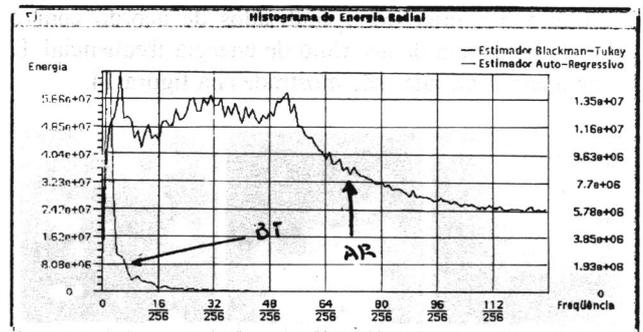


Figura 13 - Histograma de energia radial acumulada dos espectros BT e AR da imagem apresentada na figura 11.(b)

Tabela 1- Valores da tendência de concentração de energia T.

	B.T.	A.R.
Figura 11.(a)	9.36	70.50
Figura 11.(b)	7.09	54.19

A faixa de diferenciação gerada pelo espectro auto-regressivo é consideravelmente mais significativa que a do espectro clássico. Os valores de T indicam uma maior rugosidade na imagem mostrada na figura 11.(a). Isso verifica-se também pela análise das diferenças entre os histogramas de energia radial acumulada. Existem claras diferenças nos histogramas gerados pelo modelo auto-

regressivo, enquanto que os histogramas gerados pelo modelo clássico permanecem quase invariáveis. Isso sugere que para a quantificação de atributos em imagens reais com comportamento não determinístico o modelo de estimação espectral auto-regressivo seja o mais adequado entre os dois mesmo quando existe grande quantidade de dados disponível.

4 A Quantificação da Irregularidade da Superfície de Imagens Microscópicas do *Penicillium crysogenum* com o uso do Modelo Auto-Regressivo de Estimação Espectral.

O *Penicillium crysogenum* é um micro organismo responsável pela produção de penicilina e sub-produtos. O acompanhamento e o controle dos estágios de crescimento da colônia desses micro organismos, chamada de micélio, são de fundamental importância para o domínio da tecnologia de produção daqueles produtos. A irregularidade apresentada pela imagem da superfície do micélio está diretamente ligada com seus estágios de crescimento [TUCK92]. A quantificação dessa irregularidade é feita aqui com a utilização do espectro de potência auto-regressivo das imagens dos micélios.

Foram estimados os espectros para alguns estágios de cultura dos micélios e analisados de acordo com o valor da tendência de acúmulo de energia freqüencial T. As imagens analisadas são mostradas na figura 14.

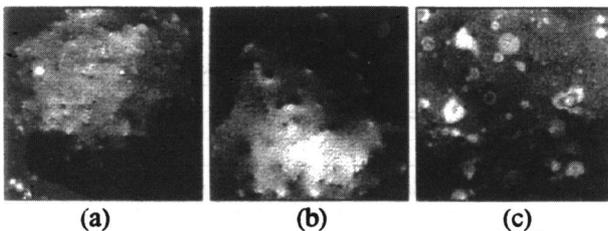


Figura 14 - Imagens do Micélio. Microscópio Ótico.

As imagens dos micélios apresentada na figura 14 possuem rugosidade visualmente decrescente de (a) até (c). Essa variação de rugosidade está refletida na distribuição de energia nos espectros mostrados nas figuras 15 a 16 respectivamente.

A tabela 2 apresenta a quantificação dessa rugosidade como resultado da tendência T de acúmulo de energia radial nos histogramas produzidos a partir dos respectivos espectros.

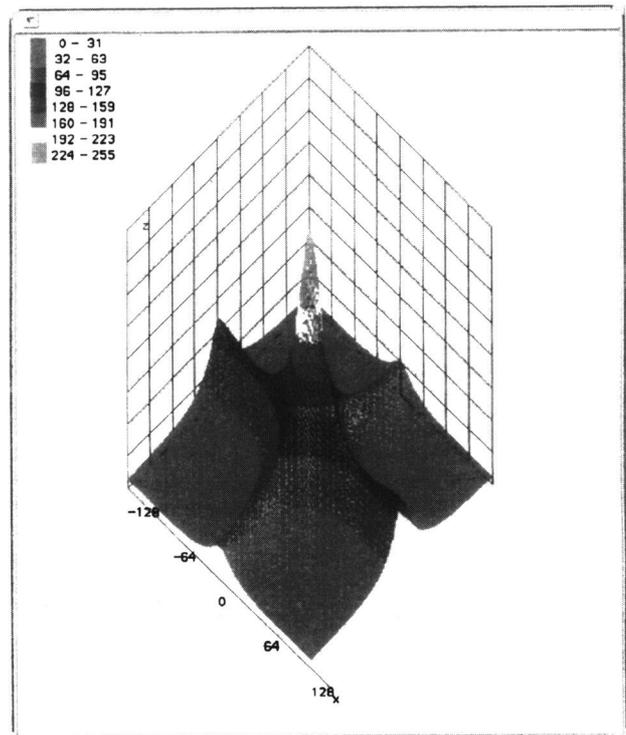


Figura 15 - Espectro AR do estágio representado da figura 14.(a).

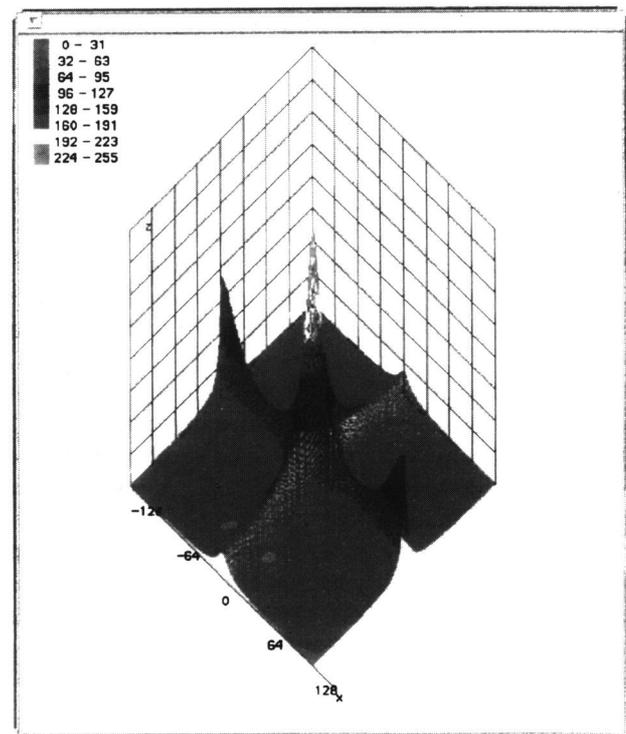


Figura 16 - Espectro AR do estágio representado da figura 14.(b).

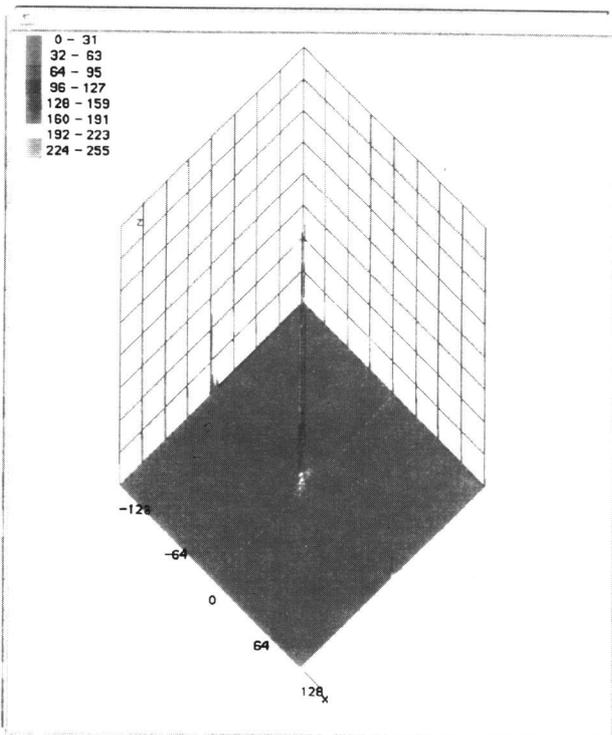


Figura 17 - Espectro AR do estágio representado da figura 14.(c).

Tabela 2- Valores da tendência de concentração de energia T.

	T
Figura 14.(a)	66.20
Figura 14.(b)	60.13
Figura 14.(c)	56.27

5 Conclusões

Foram analisados resultados da análise espectral realizadas tomando-se duas metodologias diferentes de estimação. O estimador clássico mostrou-se eficiente para a discriminação de imagens principalmente quando elas possuem comportamento regular e quando existe uma quantidade grande de dados para análise. Mostra-se principalmente aplicável para análise de imagens ruidosas devido pouca sensibilidade desse estimador ao ruído.

O estimador auto-regressivo, por sua vez, comporta-se muito bem para pequenos conjuntos de dados. Mostrou-se ser mais sensível ao ruído do que o estimador clássico porém muito mais eficiente para discriminação de imagens naturais onde o espectro clássico permanecia quase sem alterações.

Com o uso do estimador auto-regressivo foi realizada a análise de imagens microscópicas do *Penicillium crysogenum* e quantificada a rugosidade da superfície das imagens oferecendo a possibilidade de

controle e identificação dos estágios de produtividade da cultura.

6 Agradecimentos

Agradecemos:

A CAPES pelo apoio financeiro concedido.

Ao prof. Dr. Cláudio Suazo do DEQ-UFSCar.

Ao prof. Dr. Nelson D. A. Mascarenhas do DC-UFSCar.

7 Referências

- [BLAC59] BLACKMAN, R. B. & TUKEY, J. W. - Measurement of Power Spectra. New York, Dover, 1959.
- [KAY88] KAY, STEVEN M. - *Modern Spectral Estimation* - Prentice Hall, 1988, 544p.
- [LIM90] LIM, JAE S. - *Two-Dimensional Signal and Image Processing* - Prentice-Hall Ed., 1990, 694p.
- [PITA93] PITAS, IOANNIS - *Digital Image Processing Algorithms* - Prentice Hall, 1993, 362p.
- [RIBE94a] RIBEIRO JR., ERALDO ; MUCHERONI, MARCOS L. ; CRUVINEL, PAULO E. - Discriminação de Aspereza em Texturas Usando Medidas no Espectro de Potência - In: *Anais do Workshop sobre Visão Cibernética*, IFSC/USP, São Carlos - SP, Brasil, Agosto 1994, pp.87-93.
- [RIBE94b] RIBEIRO JR., ERALDO ; CRUVINEL, PAULO E. ; MUCHERONI, MARCOS L. ; - Implementação de Uma Ferramenta para Análise de Atributos Visuais em Imagens Texturais - In: *Anais do Congresso Nacional de Informática*, SUCESU-94, Salvador - BA, Novembro 1994.
- [TAMU78] TAMURA, HIDEYUKI ; MORI, SHUNJI ; YAMAWAKI, TAKASHI - Textural Features Corresponding to Visual Perception - *IEEE Trans. on Systems, Man, and Cyber.*, Vol. SMC-8, No.6, Jun. 1978, pp.460-473.
- [TUCK 92] Tucker R. & Tomas, C.R. - Micelial morphology, *Biotechnology Letters*, 14(1) : 1701-1704, 1992.
- [YUAN92] YUAN, J. & RAO, S. - Classification of Texture Using Second-Order Spectra - *J. of Times Series Analysis*, Vol.13, p.548-662, 1992.

