

Vermiculite ore classification by texture analysis

Raissa Tavares Vieira, Adilson Gonzaga

Departamento de Engenharia Elétrica
Escola de Engenharia de São Carlos – EESC/USP
São Carlos – SP, Brasil
raissa@ieee.org, agonzaga@sc.usp.br

Abstract— In this paper, two micro-patterns descriptors are evaluated in the vermiculite ore classification: the Local Binary Pattern (LBP) and the Local Fuzzy Pattern (LFP). A micro-pattern is the gray-level pixels' structure in an image neighborhood that describes the spatial specific context of various features, such as edges, lines, spots, blobs, corners or textures. In LBP approach is made a crisp comparison among the gray-levels values of the image pixel neighborhood and the LFP approach models the gray-level distribution of an image micro-pattern as a fuzzy set, and based on membership function generate fuzzy-codes that represents the membership degree of each neighborhood pixel to the central one. This is a quite appropriate alternative to deal with uncertainties by the acquisition process in digital images. The performance of the classification is evaluated using chi-square distance and the best result was obtained applying the LFP descriptor.

Keywords—texture analysis; fuzzy numbers; analysis of micro-patterns, vermiculite

I. INTRODUÇÃO

A textura fornece informações importantes sobre a constituição de cenas em geral. É um aspecto importante para análise de imagens na solução de problemas de segmentação [1], [2], reconhecimento [3], [4] e síntese [5], [6], mas também pelo fato de possibilitar a compreensão dos mecanismos básicos que fundamentam a percepção visual humana [7].

Devido a sua importância e ubiquidade em dados de imagem, a textura tem aplicações em vários campos na área de visão computacional. Uma potencial aplicação encontra-se na indústria de minérios com a classificação e separação do minério vermiculita (Fig. 1).



Fig. 1. Minério vermiculita

A vermiculita é um mineral do grupo das micas, com propriedade de alta expansividade, o que a torna de amplo uso na indústria e agricultura. A aplicação da vermiculita está intimamente ligada às suas propriedades físicas, decorrentes de sua estrutura cristalina. Quando expandida, o produto resultante apresenta baixas densidade e condutividades térmica, acústica e elétrica. Não se decompõe ou deteriora, sendo inodoro, não prejudicial à saúde e também lubrificante, bem como pode absorver normalmente até cinco vezes seu peso em água [8].

A amostra seca da vermiculita é peneirada em várias frações segundo a classificação granulométrica (grossa, média, fina, superfina e micron) e a sua aplicação em cada uso específico depende desta classificação. Aquelas com granulometria mais fina são aplicadas na produção de manufaturados para a construção civil, além de utilizadas como carreadoras na produção de fertilizantes e de alimentação para animais. As de granulometria mais grossa são utilizadas para fins de horticultura, cultivo e germinação de sementes, dentre outros. O valor comercial da vermiculita está ligado às impurezas contidas nos minérios e assim, também há a necessidade de classificação não só por tipo de granulometria do mineiro como também em relação à alta ou baixa concentração de fibras.

Uma maneira de realizar esta classificação de forma automática é a aplicação de técnicas para descrição de texturas, porém, devido à subjetividade inerente à textura, várias abordagens foram desenvolvidas e introduzidas ao longo dos anos e dependendo da perspectiva, há problemas para os quais alguns métodos funcionam adequadamente e outros não. Neste trabalho propõe-se o uso dos descritores de micropadrões locais para classificação do mineiro vermiculita. Estes descritores modelam a imagem analisando uma vizinhança de pixels codificando cada uma delas, computando assim, as relações das intensidades relativas entre os pixels em uma pequena vizinhança e não sobre os seus valores de intensidades absolutos.

Em 1990, He e Wang [9] deram os primeiros passos para análise local de imagens ao introduzir o *Texture Unit* (TU). Neste modelo a informação de textura é coletada de uma vizinhança 3 x 3, que representa a menor unidade da imagem, no sentido de se ter oito direções em torno dos pixels. Os valores deste micropadrão são divididos em três níveis (0, 1,2) de acordo com o valor do pixel central. Nesta metodologia é

possível gerar $3^8=6561$ códigos que caracterizam determinados micropadrões 3×3 da imagem. Baseados nesta metodologia, Ojala, Pietikäinen e Harwood [10] propuseram o *Local Binary Pattern* (LBP) que limiarizam os valores da vizinhança de um pixel em apenas dois níveis (0,1) reduzindo assim, a quantidade de códigos gerados para $2^8 = 256$ códigos. Nestas duas abordagens, os valores resultantes da limiarização são multiplicados pelos pesos dados para os pixels correspondentes e somados para se obter código de cada micropadrão da textura.

A desvantagem do descritor TU é a quantidade elevada de códigos gerados, há 6561 TU possíveis, cujos valores não são correlacionados. Como consequência, as regiões devem ter um tamanho relativamente grande para se obter as distribuições e que permita calcular medidas de dissimilaridade confiáveis e estáveis. Já o LBP reduz a quantidade de códigos gerados para 256. No entanto, com esta simplificação há perda de poder discriminatório e o torna sensível a ruído, visto que, é feita uma comparação *crisp* entre os pixels, perdendo assim, a informação relacionada com a quantidade real da diferença entre os valores dos pixels.

Uma possível solução para estes problemas é o uso da teoria *fuzzy*, capaz de gerenciar adequadamente informações vagas e ambíguas e tem sido aplicada no processamento de imagem [11]. Atualmente técnicas *fuzzy* estão em uso para descrição de textura como é o caso do *Fuzzy Local Binary Pattern* (FLPB) proposto em [12], e o *Local Fuzzy Pattern* (LFP) proposto em [13]. A Figura 2 exibe um exemplo de imagens reais de textura adquiridas por uma câmara a 4 fps. Ao selecionar uma vizinhança 3×3 observam-se valores diferentes de nível de cinza quando comparados com a vizinhança de mesmas coordenadas nas demais imagens.

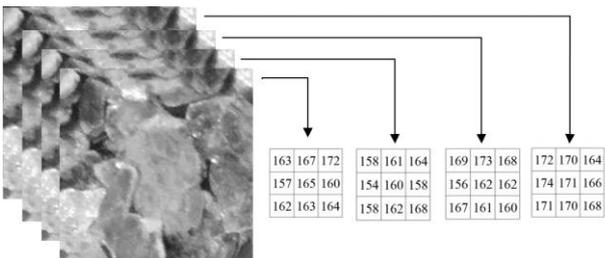


Fig. 2. Incerteza sobre os valores dos pixels em uma sequência da mesma imagem

Assim, as técnicas *fuzzy* se mostram com uma alternativa para tratar com essas incertezas e imprecisões nos valores dos pixels provenientes do processo de aquisição de imagens. Neste trabalho serão avaliados dois descritores de textura, um descritor *crisp*, o LBP, e um descritor *fuzzy*, o LFP e verificar a eficácia no processo classificatório do minério vermiculita.

O restante deste trabalho está organizado em quatro seções. Na Seção 2, é explicada a abordagem para descrição de micropadrão local *fuzzy*, o LFP. A Seção 3 explica a metodologia aplicada para análise de textura do minério. Os

resultados experimentais são exibidos na Seção 4, e na seção final, são apresentadas as conclusões.

II. LOCAL FUZZY PATTERN

Neste descritor o grau de pertinência do pixel central $g(i, j)$ para o micropadrão definido pela vizinhança $W \times W$ é determinado por (1):

$$\hat{\mu}_{g(i,j)} = \frac{\sum_{k=1}^W \sum_{l=1}^W [f_{g(i,j)} P(k,l)]}{\sum_{k=1}^W \sum_{l=1}^W P(k,l)} \quad (1)$$

na qual $f_{g(i,j)}$ é a função de pertinência que irá gerar os valores das pertinências em relação ao pixel central e $P(k,l)$ é uma matriz de pesos para a vizinhança com a mesma dimensão.

O grau de pertinência $\hat{\mu}_{g(i,j)}$ do pixel central à região definida pela janela $W \times W$ é então dado pela média ponderada dos valores de pertinências individuais de cada pixel. Como o LFP gera valores no intervalo $[0,1]$, é necessário convertê-los para um esquema de nível de cinza de 8-bit, cada valor do grau de pertinência é multiplicado por 255 e é arredondado o resultado final. Assim, o histograma LFP tem 256 bins (valores inteiros entre 0 e 255), da mesma forma que o LBP básico. Este grau de pertinência define o código LFP que reflete a estrutura do micropadrão dentro da vizinhança considerada, a Figura 3 ilustra o processo de geração do código LFP ao aplicar a função de pertinência sigmoide.

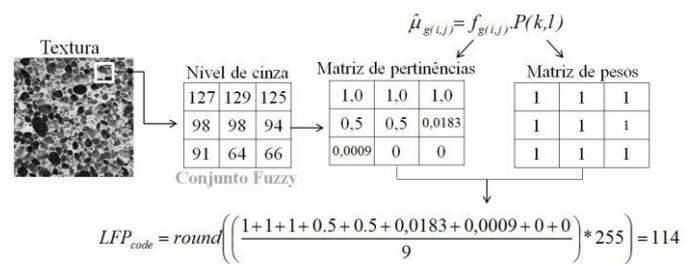


Fig. 3. Cálculo do código LFP

Em seguida, um histograma é criado para computar as ocorrências dos diferentes códigos LFP de todos os pixels da imagem. Este histograma forma o vetor de características LFP, que caracteriza cada imagem de textura avaliada.

A definição de uma função de pertinência apropriada é heurística e não única. Assim, a definição de diferentes funções de pertinência é baseada nas propriedades da vizinhança do

micropadrão $A(k,l)$ com dimensão $W \times W$ do pixel central $g(i,j)$ em uma imagem digital.

Neste trabalho é avaliado o descritor LFP-s que utiliza a função sigmoide (2) como função de pertinência.

$$f_{g(i,j)} = \frac{1}{1 + e^{-\frac{[A(k,l) - g(i,j)]}{\beta}}}, \quad (2)$$

em que β é o parâmetro que define a inclinação da curva.

E utiliza a seguinte matriz de pesos:

$$P(k,l) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

No trabalho [14] aplica-se também a função de pertinência triangular e simétrica (LFP-t), porém devido ao LFP-s obter melhor desempenho no processo de classificação, neste trabalho será apenas utilizada a função de pertinência sigmoide.

Conforme mostraram os autores do trabalho sobre o LFP [13], o LBP pode ser deduzido diretamente da equação geral do LFP ao aplicar uma função *crisp* como a função degrau de Heaviside (3):

$$f_{g(i,j)} = H[A(k,l) - g(i,j)], \quad (3)$$

em que,

$$H[A(k,l) - g(i,j)] = \begin{cases} 0, & \text{se } [A(k,l) - g(i,j)] < 0, \\ 1, & \text{se } [A(k,l) - g(i,j)] \geq 0. \end{cases}$$

Levando-se em consideração o LBP básico com uma vizinhança de pixels de 3×3 , a matriz de pesos será:

$$P(k,l) = \begin{bmatrix} 1 & 2 & 4 \\ 128 & 0 & 8 \\ 64 & 32 & 16 \end{bmatrix}$$

O N_{LBP} (valores entre 0 e 255) pode ser obtido por (4):

$$N_{LBP} = \hat{\mu}_{g(i,j)} \sum_{k=1}^W \sum_{l=1}^W P(k,l). \quad (4)$$

Como na abordagem LBP é feita uma comparação *crisp* (0 ou 1) entre os pixels, há uma perda de informação relacionada com a quantidade real da diferença entre os valores dos pixels. Assim, espera-se que com o uso da função sigmoide, dada por (2), seja possível captar nuances que abordagens com formulação analítica não são capazes.

III. METODOLOGIA

Para avaliação de desempenho dos descritores LBP e LFP-s foram realizados testes com imagens do banco de imagens do minério vermiculita. Esta base foi gerada em nossos laboratórios. Para o processo de captura e digitalização das imagens foram utilizados os seguintes dispositivos e equipamentos:

- Câmera fotográfica Sony DSC-W350, 14.1 Megapixels, Sensor super HAD CCD tipo 1/2.3 (7.76 mm), Lentes Carl Zeiss Vario-Tessar.
- Tripé universal Sony e mesa de apoio.
- Caixa de madeira para armazenamento do minério com dimensões 11 cm x 11 cm x 4 cm.
- Distância entre a lente da câmera fotográfica e o minério de 11 cm.
- Resolução de captura de 5 megapixels.

O processo de captura foi realizado em três condições de iluminação:

- Iluminação Tipo 1 (*Test Case 1*): lâmpada fluorescente.
- Iluminação Tipo 2 (*Test Case 2*): iluminação natural.
- Iluminação Tipo 3 (*Test Case 3*): iluminação com lâmpadas de LED, neste tipo de iluminação além dos equipamentos previamente mencionados também foram utilizadas duas lâmpadas de LED 9 W Luz Branca Bivolt Vision LED Philips como únicas fontes de iluminação em uma sala fechada.

O minério vermiculita foi separado por um especialista em mineração, em 8 classes, de acordo com a granulometria e a concentração de fibras:

Classe 1: Média com alta concentração de fibras

Classe 2: Média com baixa concentração de fibras

Classe 3: Fina com alta concentração de fibras

Classe 4: Fina com baixa concentração de fibras

Classe 5: Superfina com alta concentração de fibras

Classe 6: Superfina com baixa concentração de fibras

Classe 7: Mícron com alta concentração de fibras

Classe 8: Mícron com baixa concentração de fibras

A Figura 4 exibe um exemplo de imagem para cada classe.

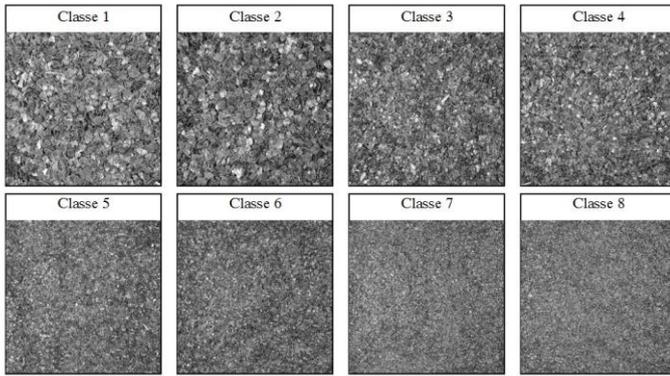


Fig. 4. Imagens do minério vermiculita

Para cada classe em cada tipo de iluminação foi realizada a captura de 10 imagens com tamanho 2592 x 1944 pixels. Após o processo de captura, as imagens foram transformadas em nível de cinza e recortadas, eliminando as bordas indesejadas, passando a ter o tamanho 1600 x 1600 pixels (Fig. 5).

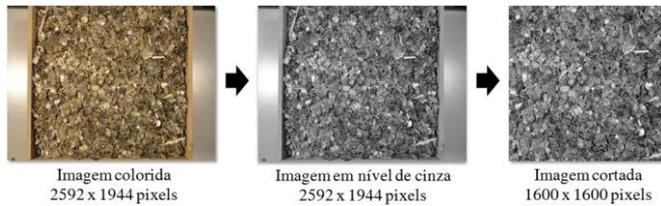


Fig. 5. Processo de formatação das imagens

Após o processo de formatação das imagens foram extraídas 20 amostras aleatórias de cada imagem com diversos tamanhos: 100 x 100 pixels, 160 x 160 pixels, 180 x 180 pixels, 190 x 190 pixels, 220 x 220 pixels, 250 x 250 pixels e 300 x 300 pixels.

De maneira resumida cada tipo de iluminação é dividido em 8 classes de acordo com a granulometria do minério e a concentração de fibras. Para cada classe foram capturadas 10 imagens das quais foram extraídas 20 amostras aleatórias. No total, cada tipo de iluminação possui 1600 amostras.

Para cada banco de imagem de cada tipo de iluminação foram aplicados os descritores LBP básico e o LFP-s gerando seus histogramas correspondentes a partir da distribuição das probabilidades dos códigos provenientes de cada descritor. Utilizando-se validação cruzada *leave-one-out*, foram comparados estes histogramas de cada amostra com o restante das amostras do conjunto, usando-se a distância Chi-quadrado (5) [15]:

$$\chi^2(P_i, Q_i) = \frac{1}{2} \sum_{i=0}^{255} \frac{(P_i - Q_i)^2}{(P_i + Q_i)}, \quad (5)$$

sendo, Q_i a frequência do nível de cinza da amostra que está sendo avaliada e P_i a frequência do nível de cinza da amostra do conjunto que está sendo comparada com a amostra avaliada.

Uma amostra é considerada corretamente classificada se pertencer à mesma classe da amostra de teste para qual obteve a menor distância, ou seja, se o menor valor de distância Chi-quadrado for encontrado quando a amostra avaliada for comparada com as demais amostras da mesma classe.

Os resultados das classificações são armazenados em uma matriz de confusão e é feito o cálculo da sensibilidade (6), alcançada para cada descritor.

$$S = \frac{VP}{VP + FN}, \quad (6)$$

em que VP são os verdadeiros positivos e FN os falsos negativos.

IV. RESULTADOS EXPERIMENTAIS

O descritor LFP-s é paramétrico por natureza, assim, se faz necessário a definição do parâmetro β a fim de se alcançar o melhor desempenho do processo classificatório. Assim, neste trabalho serão exibidos os melhores valores de sensibilidades alcançados com a otimização deste parâmetro para o descritor LFP-s. A Tabela 1 exibe os valores de sensibilidade obtidos pelos descritores LBP e LFP-s, usando-se diferentes tamanhos de amostras para os três tipos de iluminação.

TABELA 1 SENSIBILIDADE OBTIDA PARA DIFERENTES TAMANHOS DE AMOSTRAS

		Tamanho da amostra (pixels)						
		100x100	160x160	180x180	190x190	220x220	250x250	300x300
TC1	LBP	58,7%	79,3%	86,4%	87,6%	92,3%	94,6%	96,8%
	LFPs	60,4%	80,8%	87,2%	89,7%	92,5%	94,9%	98,3%
TC2	LBP	56,8%	82,3%	86,0%	89,4%	93,6%	95,9%	97,4%
	LFPs	59,4%	84,8%	88,9%	91,3%	94,9%	96,2%	98,7%
TC3	LBP	58,7%	82,8%	85,8%	88,8%	92,6%	95,3%	96,8%
	LFPs	62,9%	84,1%	89,9%	90,0%	94,5%	96,7%	98,3%

A Tabela 2 exibe os valores otimizados do parâmetro β utilizados no descritor LFP-s.

TABELA 2 PARÂMETROS OTIMIZADOS PARA DIFERENTES TAMANHOS DE AMOSTRAS

	Tamanho da amostra (pixels)						
	100x100	160x160	180x180	190x190	220x220	250x250	300x300
TC1	0,710	0,500	0,800	0,600	0,500	0,500	0,820
TC2	0,620	0,722	0,750	0,600	0,740	0,700	0,745
TC3	0,727	0,800	0,700	0,996	0,700	0,700	0,820

Analisando os resultados para cada tipo de iluminação observa-se que o descritor LFP-s supera o LBP em todos os testes. Isto ocorre devido ao fato de o LBP fazer a comparação entre os pixels de maneira *crisp* e o LFP-s de maneira *fuzzy*, mais flexível e desta forma, a textura pôde ser melhor representada pela abordagem LFP-s.

O melhor desempenho foi apresentado na iluminação natural com amostras de tamanho 300 x 300 pixels, com 98,7% de sensibilidade para o descritor LFP-s com parâmetro beta igual a 0,745. A Tabela 3 exibe a matriz de confusão gerada para este caso

TABELA 3 MATRIZ DE CONFUSÃO LFP-S

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8
Classe 1	196	2	2	0	0	0	0	0
Classe 2	4	197	0	0	0	0	0	0
Classe 3	0	0	194	1	0	0	0	0
Classe 4	0	1	4	199	1	0	0	0
Classe 5	0	0	0	0	198	1	0	0
Classe 6	0	0	0	0	1	199	0	0
Classe 7	0	0	0	0	0	0	198	2
Classe 8	0	0	0	0	0	0	2	198

Na diagonal principal têm-se os verdadeiros positivos, ou seja, das 200 amostras de cada classe quantas foram classificadas corretamente como pertencentes à mesma classe. É importante ressaltar que a Classe 1 e a Classe 2 contém imagens de minério com a mesma granulometria, assim como Classe 3 e 4, Classe 5 e 6 e Classe 7 e 8 também representam minérios com mesma granulometria e o que as diferencia é apenas a concentração de fibras. Isto explica o fato de a maioria das amostras que foram classificadas erroneamente estarem na classe do mesmo tipo da sua classe de origem. Por exemplo, para a Classe 1 algumas amostras são confundidas, 4 delas são classificadas como pertencentes a Classe 2 (com o minério de mesma granulometria). Mas há também o caso em que a mostra é classificada como pertencente a uma classe de tipo diferente da sua classe de origem, isto ocorre na Classe 3 que classifica 2 amostras como sendo da Classe 1.

Observando a matriz de confusão para o mesmo tipo de iluminação e tamanho de amostra agora analisando o descritor LBP (Tabela 4), mais amostras são confundidas em outras classes e inclusive classes com o minério de granulometrias diferentes. Na Classe 1, por exemplo, 3 de suas amostras são classificadas como Classe 2, 3 amostras como classe 3 e 2 amostras como Classe 4.

TABELA 4 MATRIZ DE CONFUSÃO LBP

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6	Classe 7	Classe 8
Classe 1	192	3	0	0	0	0	0	0
Classe 2	3	193	1	1	0	0	0	0
Classe 3	3	4	193	3	0	0	0	0
Classe 4	2	0	3	194	0	0	0	0
Classe 5	0	0	2	2	195	2	1	0
Classe 6	0	0	1	0	3	198	1	0
Classe 7	0	0	0	0	0	0	196	3
Classe 8	0	0	0	0	2	0	2	197

A fim de realizar uma avaliação quantitativa do processo de classificação é selecionada aleatoriamente uma amostra com tamanho 250 x 250 pixels. A Figura 6 exibe a avaliação ao aplicar o LFP-s (beta = 0,95) na oitava amostra extraída da imagem 1 da classe 1 sob iluminação fluorescente. Já a Figura 7 exibe a avaliação ao aplicar o descritor LBP na mesma amostra sob o mesmo tipo de iluminação. Ao lado da amostra escolhida para a análise estão dispostas as 10 amostras que apresentaram menor distância em relação à amostra em análise no processo classificatório.

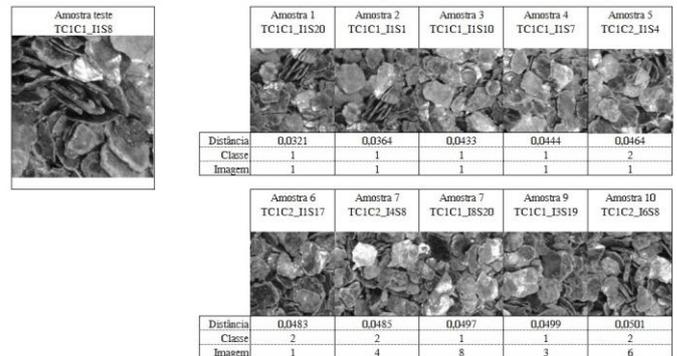


Fig. 6. Avaliação qualitativa da iluminação natural para o descritor LFP-s

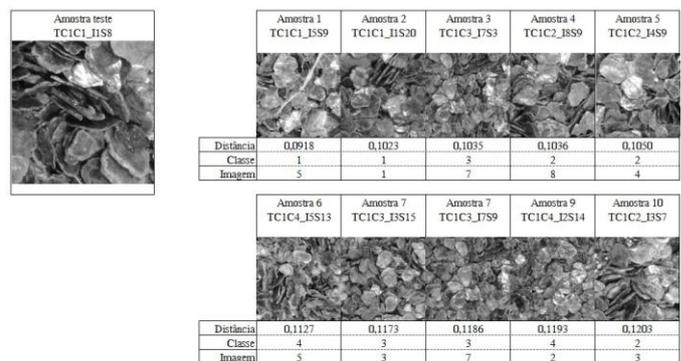


Fig. 7. Avaliação qualitativa da iluminação natural para o descritor LBP

Ao aplicar o LFP-s nas amostras 5, 6, 7 e 10 da Classe 2 as mesmas foram classificadas como semelhantes a amostra em análise. Visualmente estas amostras apresentam grande semelhança com a amostra teste, visto que representam o mesmo tipo de minério, no caso, granulometria média. Mas já no caso do LBP além de retornar amostras da Classe 2 também retorna amostras de classes de granulometrias diferentes como é o caso das amostras 3, 6 e 9 todas com granulometria fina, isto pode ser comprovado visualmente ao observar os minérios de tamanhos diferentes da amostra original.

Dentre as 10 amostras com menor distância retornadas pelo LBP apenas 2 pertencem a mesma classe da amostra analisada, já o LFP-s é capaz de retornar 6 amostras da mesma classe. As distâncias calculadas para o LBP apresentam valores maiores em todas as amostras que os valores calculados para o LFP-s. Isto explica o fato do LBP ter retornado tantas amostras de imagens diferentes do que a

imagem a qual foi extraída a amostra em análise, como por exemplo, a amostra 4 foi extraída da imagem 8.

É possível observar que através do uso do descritor LFP-s as amostras são classificadas mais corretamente e que, quando são classificadas como pertencentes à outra classe, retornam imagens do mesmo tipo de minério. Outro ponto importante é o fato das distâncias entre a amostra teste e as amostras retornadas para o LFP-s são sempre menores que as calculadas para o LBP, aumentando assim a confiabilidade do descritor.

V. CONCLUSÕES

Este trabalho apresentou a avaliação do processo classificatório do minério vermiculita ao aplicar duas abordagens para descrição de micropadrões locais, o LBP básico e o LFP-s. As duas abordagens diferem substancialmente na sua formulação do código para cada unidade de textura. A primeira realiza uma limiarização e obtém valores binários para geração de códigos já a segunda, tem seus códigos gerados a partir do grau de pertinência da vizinhança em relação ao pixel central do micropadrão. A segunda abordagem se mostrou mais robusta ao tratar as informações incertas e imprecisas inerentes aos valores dos pixels e foi possível classificar eficientemente as diferentes granulometrias e concentrações de fibras.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) e da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior).

REFERÊNCIAS

- [1] A. Zuliang, Z. Limin, Z. Jianting, "A practical method of texture segmentation and transformation for radar image simulation". IEEE International Conference on Computer Science and Automation Engineering, vol.3, no., pp.311,317, 25-27 May 2012
- [2] A. Khanna, M. Shrivastava, "Unsupervised techniques of segmentation on texture images: A comparison", IEEE International Conference on Signal Processing, Computing and Control, pp.1,6, 15-17 March 2012.
- [3] T. Ahonen, A. Hadid, M. Pietikainen, "Face Description with Local Binary Patterns: Application to Face Recognition", IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 26, n. 12, p. 2037-2041, 2006.
- [4] G. Zhao, M. Pietikainen, "Dynamic Texture Recognition Using Local Binary Patterns with an Application to Facial Expressions", IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 29, n. 6, p. 915-928, 2007.
- [5] W. Xin, J. Huawei, Y. T. Fei, "Study on constraint-based texture synthesis", International Conference on Education Technology and Computer, vol.1, pp.V1-172, V1-175, 22-24 June 2010.
- [6] G. Xu, S. Ma, "Robust tile-based texture synthesis using texture element", International Conference on Electronics and Information Engineering, vol. 2, pp.V2-179, V2-183, 2010,
- [7] H. Tamura, S. Mori, T. Yamawaki, "Textural Features Corresponding to Visual Perception", IEEE Transactions on Systems, Man and Cybernetics, v. 8, n. 6, pp. 460-473, 1978.
- [8] P. Daniel, "Vermiculita", Sumário Mineral, DNPM, pp. 121-122, 2012.
- [9] D. C. He, L. Wang, "Texture Unit, Texture Spectrum, and Texture Analysis", IEEE Transactions On Geoscience And Remote Sensing. vol. 28, pp. 509-512, 1990.
- [10] T. Ojala, M. Pietikäinen, D. Harwood, "A comparative study of texture measures with classification based on feature distributions". Pattern Recognition. v.29, n.1, p.51-59, 1996.
- [11] K. K. George, M. G. Madan, "Fuzzy uncertainty measures in image processing". Journal of Electronic Imaging, v.3, n.2, p.142-153, 1994.
- [12] D. K. Iakovidis, E. G. Keramidis, D. Maroulis, "Fuzzy Local Binary Patterns for Ultrasound Texture Characterization". In Campilho, A.; Kamel, M. (Ed.). Lecture Notes in Computer Science. Springer-Verlag Berlin Heidelberg, v. 5112, p. 750-759, 2008.
- [13] R. T. Vieira, C.E.O. Chierici, C.T. Ferraz, A. Gonzaga, "Image micro-pattern analysis using fuzzy numbers", SIBGRAPI 2012 - XXV Conference on Graphics, Patterns and Images, Ouro Preto, MG, August 22-25, pp. 87-93, 2012
- [14] R. T. Vieira, C.E.O. Chierici, C.T. Ferraz, A. Gonzaga, "Local Fuzzy Pattern: A New Way for Micro-pattern Analysis", IDEAL 2012, H. Yin et al. (Eds.): LNCS 7435, Springer-Verlag Berlin Heidelberg 2012, pp. 602-611.
- [15] O. Pele, M. Werman. The quadratic-chi histogram distance family. In Proceedings of the 11th European conference on Computer vision Part II (ECCV'10), pages 749-762, Berlin, Heidelberg, 2010. Springer-Verlag.