

# Classificação de Imagens de Satélite Utilizando Descritores de Textura

Weiner E. B. Oliveira, Sandro R. Fernandes

Departamento Acadêmico de Educação e Tecnologia – Núcleo de Informática  
Instituto Federal do Sudeste de Minas Gerais, *Campus* Juiz de Fora (IF Sudeste MG JF)  
Caixa Postal 15.064 – 36.080-001 – Juiz de Fora, MG – Brasil

woliveira82@gmail.com, sandro.fernandes@ifsudestemg.edu.br

**Abstract.** *This paper aims to create a computer system to classify satellite images, testing the efficiency of the texture descriptors selected and implemented for this work. The texture descriptors were tested with artificial images and then used to classify satellite images. The classification was performed by a neural network that achieved 95% accuracy in the tests. The texture descriptors shown to be a powerful tool for the classification of these images and may be used in other applications.*

**Resumo.** *Este artigo visa a elaboração de um sistema computacional para classificar imagens de satélite, testando a eficiência dos descritores de textura selecionados e implementados para esse trabalho. Os descritores de textura foram testados com imagens artificiais e depois utilizados para classificar imagens aéreas obtidas por satélites. A classificação foi realizada através de uma rede neural que obteve 95% de acerto nos testes realizados. Os descritores de textura mostraram ser uma ferramenta poderosa para a classificação destas imagens, podendo ser utilizados em outras aplicações.*

## 1. Introdução

Classificar padrões em imagens é uma das etapas mais complexas no processamento de imagens digitais. Abordagens diferentes são utilizadas visando diminuir o custo computacional e que permitam utilizar os dados extraídos em diferentes domínios de aplicação [Pedrini e Schwartz, 2008].

O diagnóstico por imagem é uma importante técnica de investigação. As informações extraídas dos padrões existentes em uma imagem podem auxiliar a tomada de decisão em várias áreas [Nascimento, 2003]. Dessa forma, o ajuste adequado das técnicas e o aprimoramento de uma metodologia de classificação é de fundamental importância para que o diagnóstico por imagem se torne um instrumento auxiliar significativo para a tomada de decisão.

Pelo apresentado observa-se a necessidade de uma técnica computacional que permita a classificação de padrões em uma imagem e que não tenha um grande custo computacional. Observa-se ainda que os resultados fornecidos possam ser utilizados em áreas diversas. Uma solução é recorrer a uma característica natural dos seres humanos para interpretação de informações visuais: a textura. Os padrões de textura encontrados em imagens possuem informações sobre a distribuição espacial, luminosidade e arranjo estrutural da superfície em relação às regiões vizinhas [Oliveira et al., 2014].

A análise das texturas de uma imagem fornece uma classificação que permite

identificar uma região na imagem sem depender da acuidade visual humana. Informações extraídas da análise de texturas podem auxiliar o diagnóstico de identificação de calcificações em mamografias [Fernandes et al., 2008], sensoriamento remoto [Nascimento, Madeira e Pedrini, 2003], padrões de folhas em plantações [Santos, 2009], caracterização de imagens de micro tomografia de raio-X [Fernandes, 2012 e Oliveira, 2014] entre outras aplicações [Pedrini e Schwartz, 2008].

Um dos processos de classificação de imagens através da textura foi iniciado em 1973 por Robert M. Harallick e K. Shanmugan no trabalho intitulado “Descritores de Textura para Classificação de Imagens” (*Textural Features for Image Classification*, no original). Em seu trabalho, Harallick apresentou quatorze descritores de texturas, deixando claro a existência de outros descritores possíveis de extrair em imagens. Realmente, os trabalhos posteriores aumentaram o número dos descritores, mas Andrea Baraldi e Flavio Parmiggiani (1995) estudaram a correlação entre eles e identificaram os mais relevantes. Dos mais relevantes, seis descritores de textura são utilizados neste artigo para a classificação das imagens de satélite: segundo momento angular, entropia, contraste, variância, correlação e homogeneidade [Pedrini e Schwartz, 2008].

O presente artigo é dividido da seguinte forma: na seção 2 são apresentados os descritores de textura utilizados e como são calculados; na seção 3 é mostrado como as imagens de satélite foram selecionadas e capturadas; na seção 4 os descritores das imagens são calculados e analisados; na seção 5 os resultados são analisados e finalmente na seção 6 é apresentado as conclusões finais.

## 2. Descritores de Textura

A representação de imagens em meios computacionais requer a definição de um modelo matemático adequado. Como um exemplo podemos definir uma função  $f(x, y)$ , onde os valores das coordenadas  $x$  e  $y$  fornece o brilho da imagem naquele ponto [Pedrini & Schwartz, 2008]. Nas imagens em tons de cinza, como é o caso desse trabalho, quanto maior os valores apresentados nas coordenadas  $(x, y)$ , mais perto do branco e quanto menor o valor, mais perto do preto. A Figura 1 mostra uma imagem em tons de cinza com a ampliação de uma região onde é destacado o valor de dois tons de cinza. A Figura 1 foi adquirida pelo link <[www.flickr.com/photos/fantasy-art-and-portraits/5567326551/](http://www.flickr.com/photos/fantasy-art-and-portraits/5567326551/)> e transformada em tons de cinza para esse exemplo.

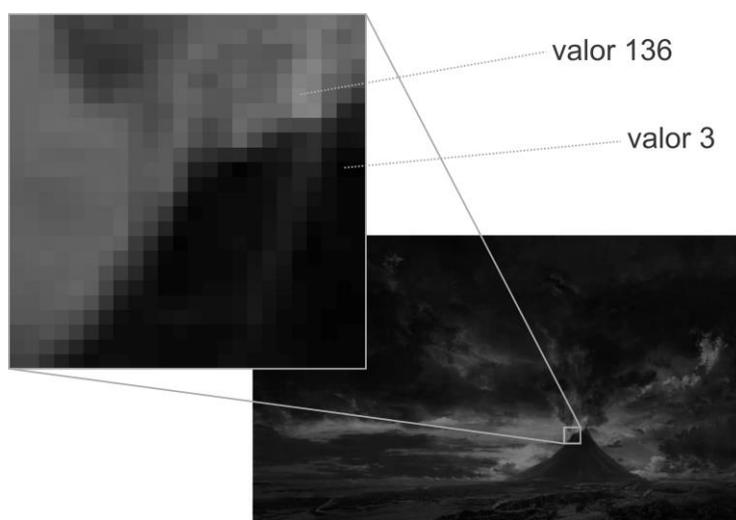


Figura 1. Imagem ampliada e valor dos pixels.

Na Figura 1 o quadro a esquerda possui dois pixels em destaque para mostrar seus valores: o mais escuro tem valor 3, bem perto do preto; o acinzentado tem valor 136, ou seja, um cinza médio. A codificação dessa imagem utiliza os valores de 0 a 255 para representar os tons de cinza, onde 255 exibe o branco e 0 representa o preto.

Robert M. Harallick em 1973 introduziu a matriz de co-ocorrência e quatorze diferentes descritores de textura para a classificação de forma automatizada de imagens em tons de cinza. Cada descritor é um valor numérico, calculado a partir da matriz de co-ocorrência e que representa uma característica da textura, como por exemplo a rugosidade ou o contraste. Como foi bem identificado por Harallick, os descritores possuem uma larga capacidade de aplicação para classificar imagens digitais em vários campos de atuação. De fato, os descritores foram aplicados, seu número foi ampliado e posteriormente identificados os mais relevantes.

Para obter os descritores de textura é necessário a construção da matriz de co-ocorrência, que se baseia no relacionamento espacial entre os níveis de cinza dos pixels que compõem a imagem. Considerando que uma imagem é representada por uma função  $f(x, y)$ , temos uma matriz de pixels contendo cada um seus valores de nível de cinza, podemos afirmar que cada elemento que constitui a matriz de co-ocorrência representa a frequência com que um pixel de nível de cinza  $x$  e outro de nível de cinza  $y$  ocorrem na imagem, separados por uma distância  $dx$  de linhas e  $dy$  de colunas. Essa abordagem se baseia na suposição de que a informação sobre a textura da imagem está contida na relação de distribuição espacial média ou global dos níveis de cinza na imagem. Leva-se em conta, também, que a descrição de uma textura é baseada na ocorrência repetida de um nível de cinza. Essa informação da textura da imagem pode ser especificada usando matrizes de dependência espacial dos níveis de cinza computadas em vários ângulos ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ) e distâncias  $dx$  e  $dy$ . A Figura 2, abaixo, mostra as posições dos ângulos referentes ao pixel localizado na posição central.

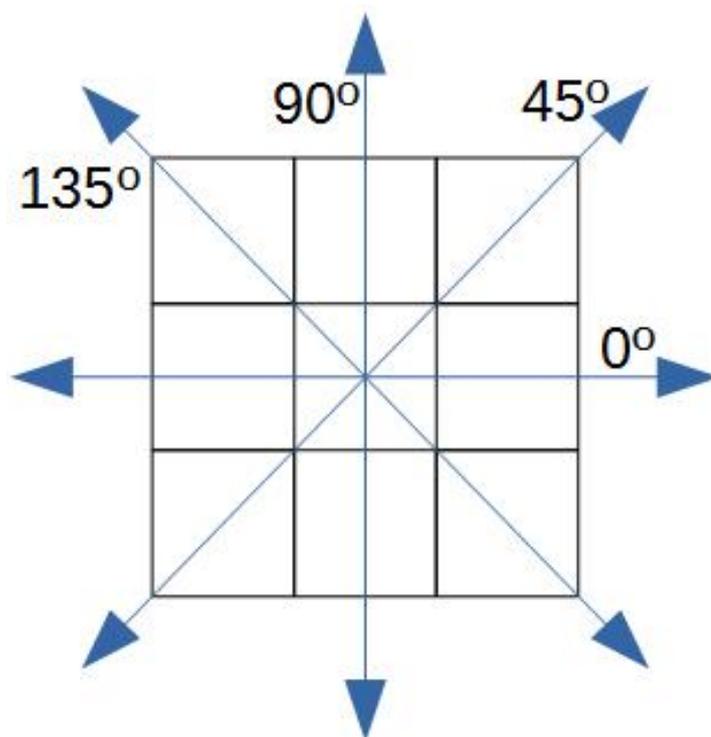
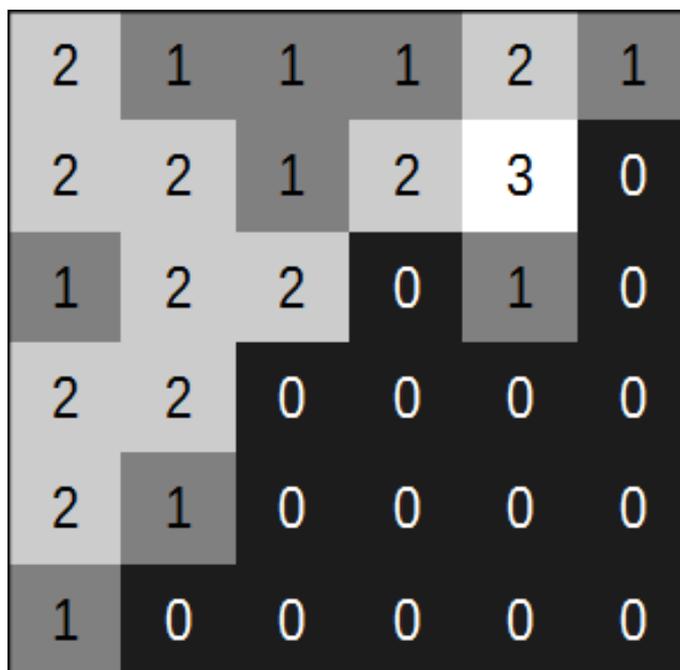


Figura 2. Ângulos utilizados para o cálculo da matriz de co-ocorrência.

Para demonstrar como a matriz de co-ocorrência, e posteriormente os descritores, são calculados, é apresentado abaixo a Figura 3, contendo o valor do tom de cinza em cada pixel. Para facilitar o entendimento do cálculo, foi utilizado uma imagem simples, com apenas quatro níveis de cinza (0, 1, 2, 3), e 6 x 6 pixels. Os cálculos foram realizados com o operador “um pixel à direita e um pixel abaixo”, ou seja, o operador de 135° com um pixel de distância ( $dx$  e  $dy$  igual a 1).



**Figura 3. Imagem de exemplo com valores de cinza em cada pixel.**

Para calcular a matriz de co-ocorrência é preciso calcular uma matriz intermediária, criando uma matriz quadrada com a dimensão igual à quantidade de tons de cinza utilizados na imagem. Como a Figura 3 possui quatro tons de cinza será criado uma matriz 4 x 4. A coluna 0 da matriz representa o tom de cinza 0, para preencher essa coluna, é preciso determinar, a partir de cada pixel de tom de cinza 0, quantos pixels de tom de cinza 3 estão posicionados no ângulo utilizado (135°), em um dos sentidos, esse número é colocado na coluna 0 e linha 3, posição (0, 3). O mesmo é feito para os tons 2, 1 e 0 colocando-os nas posições (0, 2), (0, 1) e (0, 0), respectivamente. Conta-se a partir dos outros tons de cinza e completa-se a matriz intermediária. A primeira matriz apresentada na Figura 4 é a matriz intermediária, com a contagem de todos os pixels da Figura 3, utilizando o ângulo de 135°, ou seja, um pixel à direita e um pixel abaixo.

A matriz de co-ocorrência é calculada a partir da matriz intermediária, representando a probabilidade de determinado valor de cinza ocorrer na posição indicada (135°) de outro valor, ou seja, tomando o total  $n$  de ocorrências da matriz intermediária cada novo valor da matriz será ele mesmo sobre  $n$ . Assim a matriz intermediária é transformada na matriz de co-ocorrência. A Figura 4 apresenta a matriz intermediária à esquerda e a matriz de co-ocorrência gerada por ela, à direita.

	0	1	2	3		0	1	2	3
0	7	3	5	1	0	0,28	0,12	0,2	0,04
1	0	1	2	0	1	0	0,04	0,08	0
2	0	2	3	0	2	0	0,08	0,12	0
3	0	1	0	0	3	0	0,04	0	0

Figura 4. Matriz intermediária e matriz de co-ocorrência, respectivamente.

A matriz de co-ocorrência pode ser utilizada para diversos cálculos estatísticos de segunda ordem, como no caso da extração de características [Haralick et al., 1973]. Essas características, além de serem eficientes para a análise e classificação de imagens também são utilizadas como diferenciação de uma região para outra, mostrando ser uma assinatura de um padrão definido pela região em estudo. Os seis cálculos de segunda ordem mais relevantes são: segundo momento angular, entropia, contraste, variância, correlação e homogeneidade [Baraldi e Parmiggiani, 1995 e Pedrini e Schwartz, 2008]. Nas equações abaixo a posição  $(i, j)$  da matriz de co-ocorrência é chamada de  $p_{i,j}$ .

O Segundo Momento Angular (SMA) ou energia, definido na equação (1), expressa a uniformidade da textura. Quanto mais a textura é uniforme, maior é o valor calculado para o SMA.

$$\sum_{i=0}^{H_g} \sum_{j=0}^{H_g} p_{i,j}^2 \quad (1)$$

A equação (2) mostra a Entropia que mede a desordem contida na textura. É normalmente denominada como uma medida de primeiro grau. Para evitar valores inexistentes, como não existe definição da função logarítmica para zero, considera-se  $\log(0) = 0$ .

$$-\sum_{i=0}^{H_g} \sum_{j=0}^{H_g} p_{i,j} \log(p_{i,j}) \quad (2)$$

O Contraste, equação (3), demonstra a diferença ou variação local entre os tons de cinza. Também conhecido como quadrado da variância. Quando  $i$  e  $j$  são iguais, ou seja, possuem o mesmo valor de tom de cinza, o contraste não é alterado, quanto maior a diferença entre  $i$  e  $j$  maior a influência nesse descritor.

$$\sum_{i=0}^{H_g} \sum_{j=0}^{H_g} (i - j)^2 p_{i,j} \quad (3)$$

A Variância é uma medida de heterogeneidade, apresenta valores altos quando os níveis de cinza de cada pixel comparado com seu vizinho desviam da média. A equação (4) exibe a variância em X e a equação (5) em Y.

$$\sum_{i=0}^{H_g} \sum_{j=0}^{H_g} (i - \mu_i)^2 p_{i,j} \quad (4)$$

ou

$$\sum_{i=0}^{H_g} \sum_{j=0}^{H_g} (j - \mu_j)^2 p_{i,j} \quad (5)$$

A correlação, expressa na equação (6), mede a dependência linear entre os tons de cinza de um pixel em relação à sua vizinhança.

$$\frac{1}{\sigma_i \sigma_j} \sum_{i=0}^{H_g} \sum_{j=0}^{H_g} (i - \mu_i) (j - \mu_j) p_{i,j} \quad (6)$$

Finalmente, a Homogeneidade apresenta valores altos com pequenas variações dos tons de cinza na textura e é definida na equação (7). A Homogeneidade é inversamente proporcional ao contraste.

$$\sum_{i=0}^{H_g} \sum_{j=0}^{H_g} \frac{1}{1+(i-j)^2} p_{i,j} \quad (7)$$

Nas equações (2), (3), (4), (5), (6) e (7)  $H_g$  representa o nível de cinza máximo presente na imagem analisada, nas equações (4), (5) e (6)  $\mu_i$  e  $\mu_j$  indica os valores médios das distribuições em  $i$  e em  $j$ , respectivamente; já na equação (6)  $\sigma_i$  e  $\sigma_j$  representa o desvio padrão das distribuições calculado em  $i$  e em  $j$ , respectivamente.

### 3. Imagens de Satélite

As imagens de satélite utilizadas nesse trabalho foram adquiridas com o programa ArcGIS da empresa Esri. O ArcGIS é um sistema que une mapas, aplicativos e informações e é utilizado por governos, indústrias, ONGs e mais de 500 empresas através do mundo [Esri, 2014]. O Sistema foi acessado de sua página web ([www.arcgis.com](http://www.arcgis.com)) onde o serviço é parcialmente disponibilizado de forma gratuita em sua versão online.

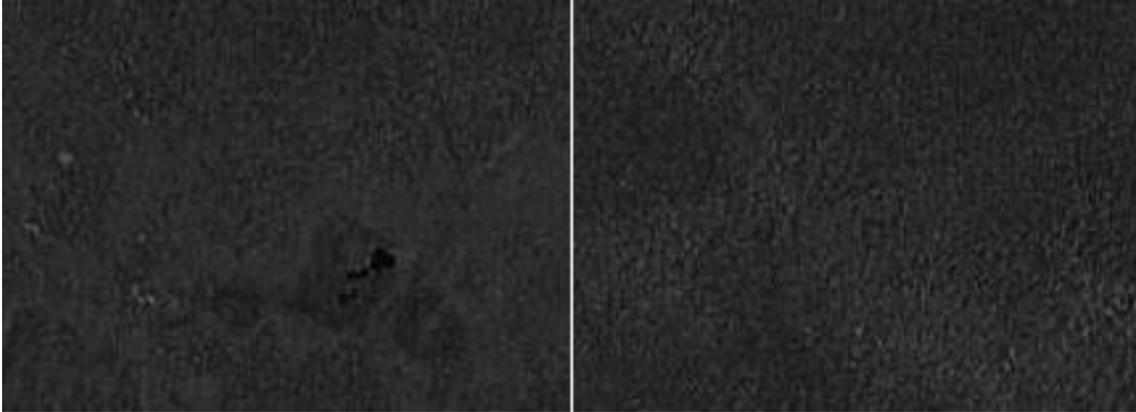
O ArcGIS foi configurado para a capturar todas as imagens. O mapa base utilizado para capturar os terrenos não possui rótulos como nome de ruas, rios e regiões, pois esses podem atrapalhar o cálculo dos descritores. Esse mapa base mostra apenas as imagens de satélite. A altura das capturas também foi padronizada, foi utilizado o 12º nível de zoom do programa, aonde 23 pixels equivalem aproximadamente a 1 km. Cinco regiões distintas do Brasil foram selecionadas para a retirada das imagens, cada região formou um grupo e a intenção desse trabalho é verificar se a utilização dos descritores pode ser utilizada para identificar o grupo, ou região de cada imagem, sem a intervenção humana. As regiões estão localizadas na Figura 5 abaixo.



**Figura 5. Regiões de origem dos grupos de imagens. 1 – Amazonas; 2 – Ceará; 3 – São Paulo; 4 – Mato Grosso e 5 – São Paulo.**

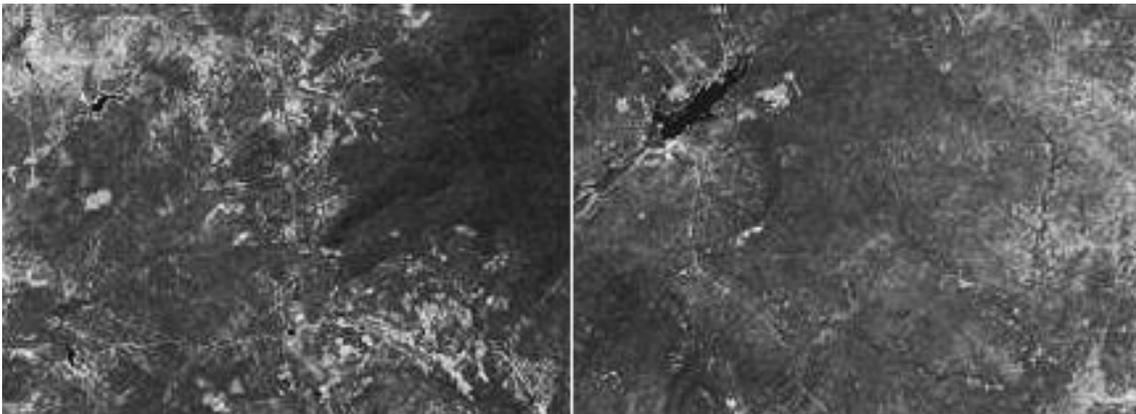
Foram retiradas 24 imagens de cada região, totalizando 120 imagens, cada uma possui o nome do grupo que pertence e uma sequência numérica de 01 a 24. O grupo 1 foi nomeado de “Amazonas”; o grupo 2 de “Ceará”; o grupo 3 de “MataAtlantica”, pertence a uma região de Mata Atlântica a sudoeste da cidade de São Paulo; o grupo 4 de “MatoGrosso” e finalmente o grupo 5 de “SaoPaulo”, refere-se a cidade de São Paulo.

Todas as imagens possuem o mesmo tamanho (215 x 257 pixels), elas foram salvas no formato bitmap (extensão .bmp) e em tons de cinza (*grayscale*). As imagens do grupo 3 e 5 foram retiradas do estado de São Paulo, mas o grupo 3 apresenta imagens da Mata Atlântica enquanto o grupo 5 apresenta a área urbana da cidade de São Paulo. A Figura 6 abaixo apresenta imagens do grupo 1 nomeado “Amazonas”:



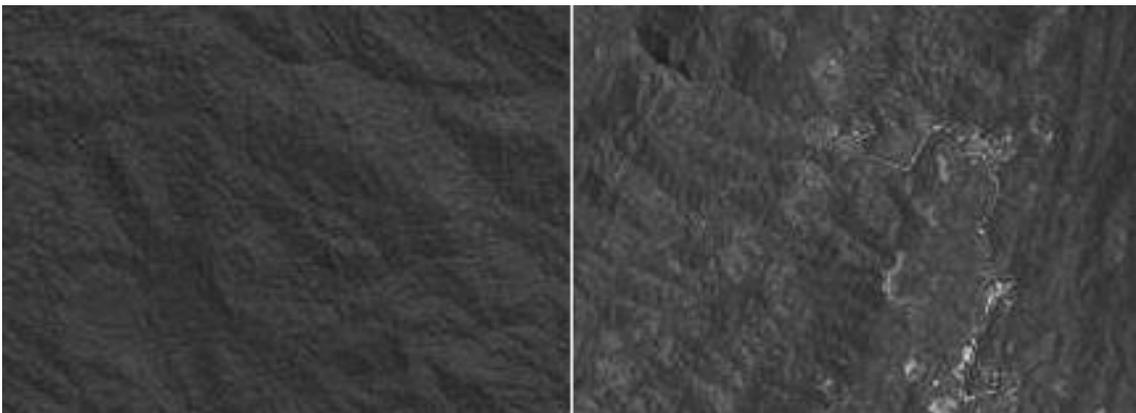
**Figura 6. Dois exemplos do grupo 1 Amazonas**

A Figura 7 abaixo apresenta imagens do grupo 2 nomeado “Ceará”:



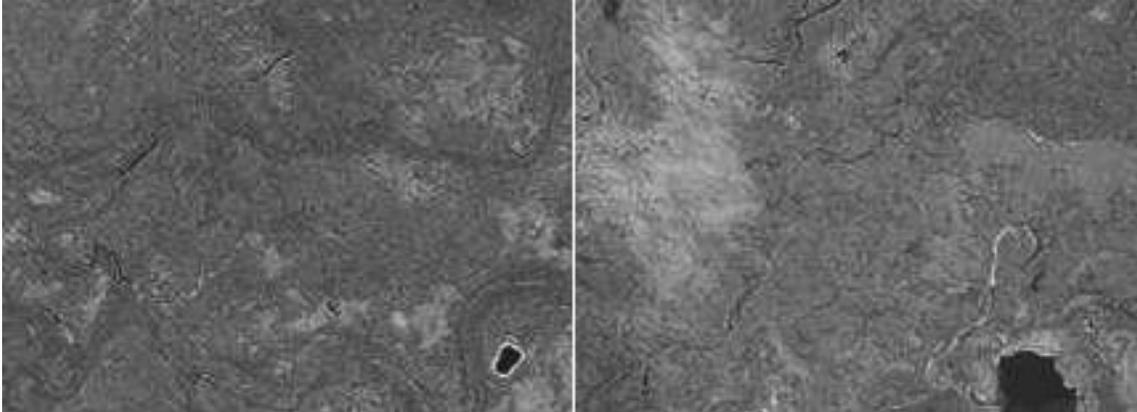
**Figura 7. Dois exemplos do grupo 2 Ceará**

A Figura 8 abaixo apresenta imagens do grupo 3 nomeado “MataAtlantica”:



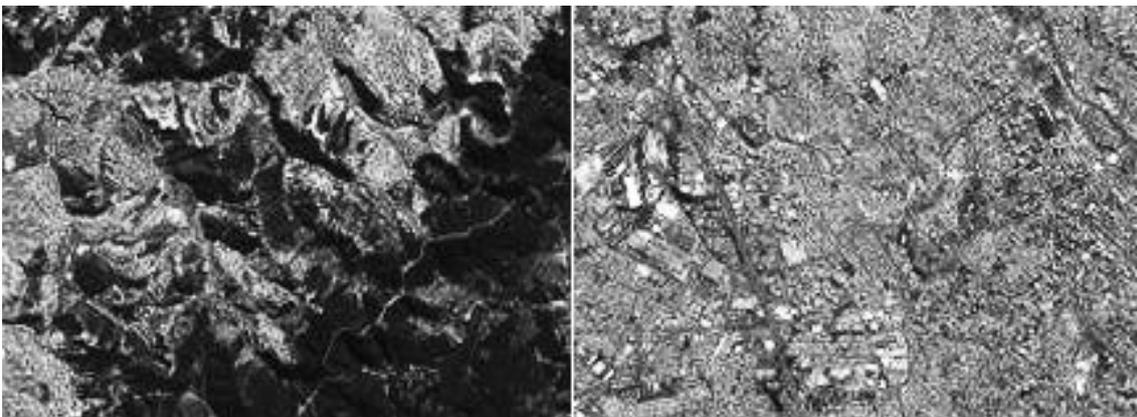
**Figura 8. Dois exemplos do grupo 3 Mata Atlântica**

A Figura 9 abaixo apresenta imagens do grupo 1 nomeado “MatoGrosso”:



**Figura 9. Dois exemplos do grupo 4 Mato Grosso**

A Figura 10 abaixo apresenta imagens do grupo 5 nomeado “SaoPaulo”:



**Figura 10. Três exemplos do grupo 5 cidade de São Paulo**

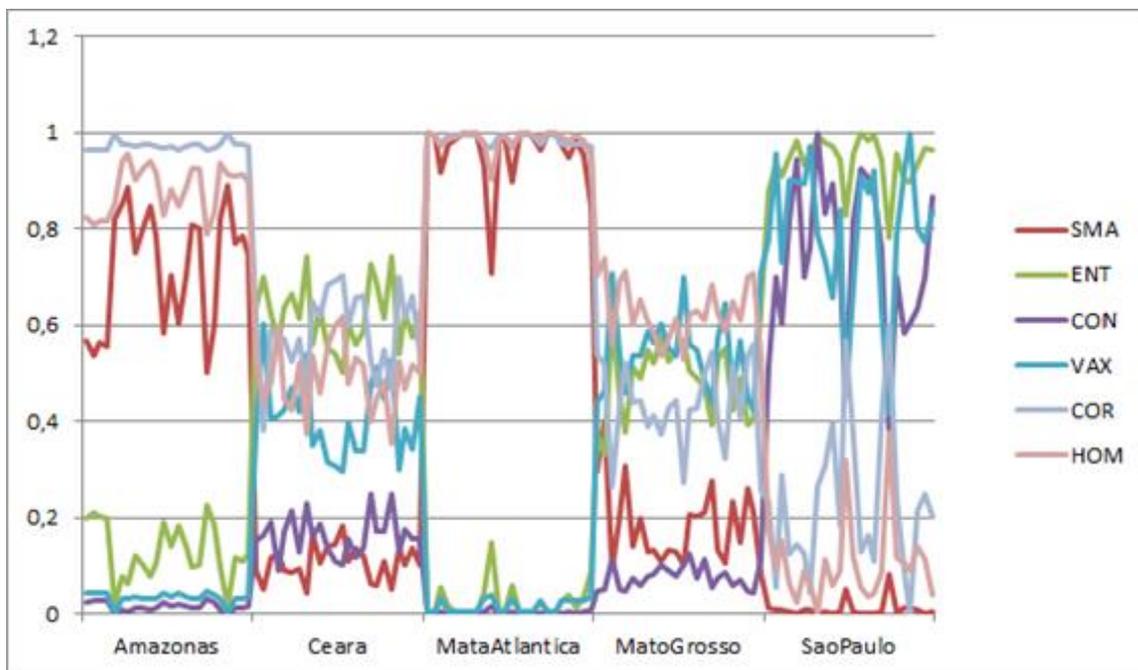
#### **4. Calculo dos Descritores**

Todos os seis descritores foram implementados em um trabalho anterior [Oliveira et al., 2014], onde o potencial dos descritores na classificação de imagens foi identificado e testado com dois conjuntos de imagens criadas pelos autores: um com padrão geométrico e o outro simbolizando o crescimento de uma área semelhante a um desmatamento. O sistema sofreu modificações e foi reutilizado nesse trabalho.

Os seis descritores foram calculados de todas as imagens. Os resultados foram parametrizados entre 0 e 1, realizando uma regra de três simples. A parametrização permitiu uma melhor análise gráfica e contribuiu com o equilíbrio do peso dos descritores dentro da rede neural, já que alguns descritores que normalmente possuem valores muito altos poderiam ter mais peso na decisão da rede.

Os cálculos foram separados em dois grupos: o grupo de treino com o resultado de 100 imagens, contendo 20 de cada grupo; e o grupo de teste com o resultado de 20 imagens, contendo 4 de cada grupo. As imagens foram selecionadas de maneira aleatória dentro dos grupos. Os resultados dos descritores do grupo de treino geraram uma matriz 100x6 que foi chamada de *InputTreino*, já os resultados do grupo de teste geraram uma matriz 20x6 e foi chamada de *InputTeste*.

Os cálculos dos descritores parametrizados foram dispostos no Gráfico 1 abaixo. As imagens foram ordenadas por grupo antes da geração do gráfico. Na legenda, a sigla SMA é Segundo Momento Angular; a sigla ENT representa a Entropia; A sigla CON representa o Contraste; a sigla VAX representa a Variância em x; A sigla COR representa a Correlação e a sigla HOM representa a Homogeneidade.



**Gráfico 1. Resultados agrupados dos descritores do *InputTreino***

O resultado do treino identificou todas as 100 imagens com sucesso. A menor precisão do treino foi de 69,837%, referente a uma imagem do grupo 3 (Mata Atlântica), confundida com o grupo 1 (Amazonas) com 26,321%.

As médias de identificação de todos os grupos ficaram superiores à 95%, como mostra a Tabela 1.

**Tabela 1. Porcentagem de identificação do treinamento da rede neural**

	IDENTIFICAÇÕES CORRETAS		
	MENOR	MÉDIA	MAIOR
<b>GRUPO 1</b>	85,814%	96,247%	99,999%
<b>GRUPO 2</b>	98,667%	99,620%	99,815%
<b>GRUPO 3</b>	69,837%	95,883%	99,679%
<b>GRUPO 4</b>	98,668%	99,511%	99,754%
<b>GRUPO 5</b>	98,723%	99,770%	99,929%

Após o treinamento da rede neural a matriz *InputTeste* foi utilizada para testar a rede, os resultados estão dispostos na Tabela 2 abaixo. Cada linha da tabela representa uma imagem testada na rede neural. A primeira coluna apresenta o grupo de origem da

imagem, as demais apresentam a porcentagem de chance, calculada pela rede neural, da imagem pertencer para cada grupo. Cada porcentagem possui um destaque em verde: quanto maior o valor (mais provável), mais escuro é a cor do preenchimento da célula. Dessa forma, é mais fácil identificar na tabela qual é o grupo inferido pela rede neural. Como a maior parte dos valores está perto de 0% eles aparecem com o preenchimento muito próximo do branco.

**Tabela 2. Resultados inferidos no grupo de treino**

GRUPO ORIGINL	GRUPO INFERIDO				
	1	2	3	4	5
1	98,351%	0,001%	1,784%	0,025%	0,003%
2	0,983%	99,812%	0,000%	0,083%	0,189%
4	0,000%	0,369%	0,381%	99,703%	0,151%
3	0,267%	0,000%	99,288%	1,052%	0,003%
3	0,377%	0,000%	98,997%	0,972%	0,003%
4	0,000%	0,357%	0,455%	99,658%	0,143%
4	0,000%	0,578%	0,305%	99,775%	0,163%
3	0,224%	0,000%	99,398%	1,086%	0,003%
5	0,467%	0,280%	0,000%	0,099%	99,914%
1	36,462%	0,000%	48,569%	0,275%	0,003%
5	0,915%	22,445%	0,000%	0,049%	75,070%
1	97,159%	2,160%	0,321%	0,002%	0,015%
2	0,730%	99,711%	0,000%	0,084%	0,187%
2	0,962%	99,729%	0,000%	0,087%	0,320%
5	0,768%	0,477%	0,000%	0,050%	99,749%
3	0,319%	0,000%	99,187%	0,965%	0,003%
2	1,097%	99,687%	0,000%	0,086%	0,562%
1	97,463%	1,323%	0,607%	0,002%	0,013%
4	0,000%	0,236%	0,515%	99,650%	0,152%
5	0,100%	0,186%	0,000%	0,275%	99,877%

Os resultados mostram uma precisão de 95% da rede neural, a imagem inferida erroneamente é do grupo 1 (Amazonas), apontada como sendo do grupo 3 (Mata Atlântica) com 48,569%. Esse resultado reflete o menor valor obtido no treinamento.

A Tabela 3 abaixo mostra a menor, a média e a maior porcentagem de identificação, tanto do treinamento, quanto do teste.

**Tabela 3. Porcentagem de identificação do treinamento e do teste da rede neural**

	IDENTIFICAÇÕES CORRETAS NO TREINAMENTO			IDENTIFICAÇÕES CORRETAS NO TESTE		
	MENOR	MÉDIA	MAIOR	MENOR	MÉDIA	MAIOR
GRUPO 1	85,814%	96,247%	99,999%	36,462%	82,359%	98,351%
GRUPO 2	98,667%	99,620%	99,815%	99,687%	99,735%	99,812%
GRUPO 3	69,837%	95,883%	99,679%	98,997%	99,218%	99,398%
GRUPO 4	98,668%	99,511%	99,754%	99,650%	99,697%	99,775%
GRUPO 5	98,723%	99,770%	99,929%	75,070%	93,653%	99,914%

Na tabela 3 observa-se a boa média de identificação em todos os grupos, exceto no grupo 1 (Amazonas), onde houve o erro de identificação do teste. Devido ao erro, a menor identificação ficou no grupo 1 com 36,462% seguido pelo grupo 5 (São Paulo) com 75,070%, ao contrário do grupo de treinamento que teve as menores identificações no grupo 3 (Mata Atlântica) com 69,837% e 1 (Amazonas) com 85,814%.

Todos os descritores foram implementados no programa MATLAB da empresa MathWorks. O MATLAB é um ambiente interativo que utiliza uma linguagem de alto nível para programação, cálculos ou visualização de dados [The MathWorks Inc., 2014]. O alto nível da linguagem permite uma codificação rápida e as ferramentas presentes no ambiente auxiliam a manipulação de estruturas complexas ou grandes como as imagens. Por isso o MATLAB foi utilizado para implementar os descritores, manipulando as imagens e formatando os dados de saída que serviram de entrada para a rede neural.

## 5. Análise dos Resultados

O sistema se apresentou lento no cálculo dos descritores, o que já era esperado com a utilização do MATLAB. O MATLAB se mostrou importante na prototipação do sistema que calcula os descritores, mas, o tempo ganho na codificação foi compensado com um cálculo mais lento. Com o protótipo pronto, uma nova implementação dos mesmos descritores em outra linguagem de mais baixo nível, promete ser muito mais rápida e também é esperado menos tempo para calcular os descritores.

O grupo de treinamento se mostrou promissor pois identificou corretamente todas as 100 imagens obtendo uma média acima de 95% nos cinco grupos. O menor resultado do treinamento é de 69,837%, referente ao grupo 3 (Mata Atlântica), o que ainda sim, supera o acerto aleatório de 20% (1 chance em 5 grupos) e a metade das possibilidades com uma boa margem. Já considerando os resultados gráficos, é perceptível um padrão diferenciado entre os grupos de imagens apresentados no Gráfico 1. Uma análise humana pode identificar visualmente a diferença entre os grupos, tanto das imagens, como no gráfico.

Analisando o grupo de teste, a rede neural obteve um bom desempenho na classificação com precisão de 95%, representando o acerto de 19 das 20 imagens testadas. Duas das imagens tiveram sua porcentagem de inferência abaixo de 97%: uma do grupo 5 (São Paulo) identificada com 75,070% de chance de pertencer ao grupo 5 e 22,445% de pertencer ao grupo 2; a outra do grupo 1 (Amazonas) identificada erroneamente com 48,569% de chance de pertencer ao grupo 3 e 36,462% de pertencer ao grupo 1. Também é notável a média das identificações corretas da rede neural mostradas na Tabela 3: no grupo de treino todas ficaram acima de 95% e no grupo de teste, mesmo com o erro do grupo 1, que ficou com média 82,359%, as restantes ficaram acima de 99%.

Durante os cálculos, foi identificado que o valor das variâncias em  $x$  e  $y$  não variavam mais de 1% em todas as imagens, considerando os valores interdependentes. Por esta razão, apenas uma delas deveria ser utilizada para treinar e testar as imagens, foi escolhido o valor calculado em  $x$ .

## 6. Conclusões e Trabalhos Futuros

Considerando a interdependência das variâncias, caso a matriz de co-ocorrência fosse simétrica, as variâncias em  $x$  e  $y$  seriam idênticas. Foi observado que somente alguns valores tiram a forma simétrica da matriz, assim, a diferença entre as variâncias  $X$

e Y são próximas a zero.

O alto índice de acerto da rede neural, ao identificar as imagens retiradas por satélite mostraram que a classificação de imagens utilizando os descritores de textura é um processo poderoso e reduz a quantidade de dados de entrada da rede neural: em vez de 55.255 valores de inserção por imagem (o total de pixels das imagens testadas com 215x257 pixels) apenas seis valores foram inseridos, após o pré-processamento que gerou os descritores.

O sistema empregado também mostrou-se capaz de, futuramente, ser implementado sem a dependência da análise visual ou interferência humana, que podem sofrer subjetividades. Mesmo considerando a intervenção humana indispensável em certas aplicações, como no diagnóstico de doenças, os descritores podem auxiliar no processamento da maior parte dos valores e entregar para a análise humana apenas os resultados mais duvidosos, ou com um limite mínimo no valor de inferência.

Mais sobre os descritores precisa ser testado, como por exemplo a relação, se existir, entre os valores utilizando diferentes ângulos como operadores e o mesmo em relação as distâncias dos pixels dos operadores. A rede neural também precisa ser testada com um novo banco de imagens, maior e mais diversificado para provar sua eficácia e auxiliar no treinamento e precisão dos resultados. Este processo, como visto, pode ser utilizado em outras classificações como identificação de calcificações em mamografias, localizações de áreas desmatadas em aerofotografias e determinação de padrões em plantações.

Concluindo, os autores consideram a utilização dos descritores uma excelente estratégia para classificar imagens, reduzindo o processamento e acelerando a análise humana ou de máquina.

Em trabalhos futuros visamos desenvolver uma ferramenta computacional para automatizar a obtenção dos Descritores de Textura. A ferramenta deve ser desenvolvida visando o cálculo dos descritores utilizados neste trabalho. Uma opção que deve constar na ferramenta é o cálculo de uma única imagem ou de um grupo de imagens fornecida pelo usuário. Os resultados obtidos devem estar em um formato que facilite seu uso em aplicações diversas.

Uma implementação desejada é uma ferramenta que possua uma RNA para a análise dos Descritores de Textura. Uma única ferramenta computacional que possua também esta opção deixa amplo o uso de análise de imagens através dos Descritores de Textura.

### **Agradecimentos**

Os autores agradecem o apoio do IF Sudeste MG – Campus Juiz de Fora e a UERJ – Instituto Politécnico na realização desse trabalho, junto com o financiamento da FAPEMIG.

## Referências

- Baraldi, A., e Parmiggiani, F. (1995). “An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters”. *Geoscience and Remote Sensing, IEEE Transactions on*, v. 33, n.2, p. 293-304.
- de Oliveira, W. E. B., do Prado, A. F., Roberto, S., Fernandes, S. T. F., & de Assis, J. T. (2014) “Classificação de padrões utilizando descritores de textura”. In *Simpósio de Mecânica Computacional e Encontro Mineiro de Modelagem Computacional*.
- do Nascimento, J. P. R. (2003). *Análise e classificação de imagens baseadas em características de textura utilizando matrizes de co-ocorrência* (Tese de Doutorado, Universidade Federal do Paraná).
- ESRI. (2014) “ArcGIS”. Disponível em: <[www.arcgis.com/features/](http://www.arcgis.com/features/)>. Acesso em 21 nov. 2014.
- Fernandes, S. R., de Assis, J. T., Lima, I. C. B., & de Carvalho, G. (2012). *Caracterização de imagens de microtomografia de raios X baseada em descritores de textura* (Tese de Doutorado, UERJ).
- Fernandes, S., Leite, C. A. F. T., Cleber de Almeida, C., & de Assis, J. T. (2008). “Diagnóstico Auxiliado Por Computador Para Detecção, Identificação E Classificação De Microcalcificações Em Mamogramas Digitais”. In *XI Latin American Seminar of Analysis by X-Ray Techniques*. p. 16-20.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). “Textural features for image classification”. *Systems, Man and Cybernetics, IEEE Transactions on*, n. 6, p. 610-621.
- Nascimento, J. P. R., Madeira, H. M. F., & Pedrini, H. (2003). “Classificação de imagens utilizando descritores estatísticos de textura”. *XI Simpósio Brasileiro de Sensoriamento Remoto*.

The MathWorks Inc. (2014). “MATLAB The Language of Technical Computing”.

Disponível em: <[www.mathworks.com/products/matlab/](http://www.mathworks.com/products/matlab/)>. Acesso em: 21 nov. 2014.

Pedrini, H., & Schwartz, W. R. (2008). *Análise de imagens digitais: princípios, algoritmos e aplicações*. Thomson Learning.

SANTOS, A. D. O. (2009). *Desenvolvimento de descritores de imagens para reconhecimento de padrões de plantas invasoras (folhas largas e folhas estreitas)* (Doctoral dissertation, Dissertação de mestrado, Programa de Pós Graduação em Ciência da Computação, Universidade Federal de São Carlos).