

Classificação de texturas a partir de vetores de atributos e função de distribuição de probabilidades

Anderson de Rezende Rocha
Prof. Neucimar Jerônimo Leite

¹Universidade Estadual de Campinas (Unicamp)
Instituto de Computação
Caixa Postal 6176 – CEP 13084-971, Campinas, SP
(anderson.rocha,neucimar)@ic.unicamp.br

Resumo. Os métodos de classificação de imagens baseados em características texturais têm sido amplamente utilizados no meio científico e industrial, possuindo aplicações na medicina, microscopia, sensoriamento remoto, controle de qualidade, recuperação de dados em bases gráficas, dentre outras. A característica de textura é uma importante fonte de informações para o processo de análise e interpretação de imagens. Neste trabalho, a textura é definida através de um conjunto de medidas estatísticas descrevendo as variações espaciais de intensidade ou como uma função de distribuição de probabilidades. As medidas espaciais são calculadas utilizando-se histogramas de somas e diferenças. As comparações a partir das funções de distribuição de probabilidades são feitas a partir de métricas como distância de Minkowsky, distância de Bhattacharyya e o teste Chi-Square. Os métodos de classificação implementados ainda não possuem a etapa de treinamento.

1. Introdução

A análise de imagens é uma das principais tarefas envolvidas em um sistema de classificação. Seu objetivo é obter informações suficientes para distinguir entre diferentes regiões de interesse. Normalmente, o processo de classificação é baseado nos níveis de cinza ou cores, características de forma e textura. Diversas aplicações utilizam técnicas de classificação para reconhecimento de objetos em imagens, tais como análise de imagens multiespectrais e interpretação de fotografias aéreas [Gonzalez and Woods, 2000].

A textura é uma das características mais importantes para classificação e reconhecimento, e pode ser caracterizada por variações locais dos valores de *pixels* que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem. Textura pode também ser definida como um arranjo repetitivo de padrões sobre uma área, com o objetivo de medir a sua aspereza, observando fatores como as dependências de níveis de cinza, auto-correlação, entre outros. Vários métodos para classificação de imagens utilizando características de textura têm sido propostos na literatura [Gonzalez and Woods, 2000], [Marceau et al., 1990], [Haralick, 1973] entre outros. Entretanto, não há um método genérico ou uma abordagem formal que seja válida para uma grande variedade de imagens.

O processo de classificação de texturas, em geral, envolve duas fases, a **etapa de treinamento** e a **etapa de reconhecimento**. Na **fase de treinamento**, o objetivo é construir um modelo para o conteúdo de textura de cada classe presente nos dados de treinamento, o qual normalmente é realizado através de rótulos de classes conhecidas. Na **fase de reconhecimento**, o conteúdo de textura das amostras desconhecidas é primeiro descrito através do método de análise utilizado na etapa de treinamento. Desse modo, as características de textura das amostras são comparadas com aquelas das imagens de treinamento e a amostra é atribuída àquela categoria que apresenta maior similaridade.

Neste trabalho, no entanto, não houve a fase de treinamento. Foi montado um banco de texturas com cerca de trinta imagens de texturas para comparação. Assim, quando qualquer imagem submetida à classificação possui algum padrão conhecido ele é classificado de acordo com o banco de texturas. Futuramente, pode-se acrescentar a fase de aprendizado de modo que o sistema passe a ser o mais independente possível.

A seção 2 apresenta os principais conceitos abordados ao longo do texto. A seção refresultados apresenta os dois métodos de classificação implementados e os resultados obtidos. A seção 5 apresenta as principais conclusões obtidas.

2. Revisão

2.1. Texturas

Textura é uma das características mais importantes para classificar e reconhecer objetos e cenas, e pode ser caracterizada por variações locais em valores de *pixels* que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem.

De acordo com [Haralick, 1973], as texturas definem uniformidade, densidade, aspereza, regularidade, intensidade, entre outras características em uma imagem. No trabalho citado, os autores caracterizam textura como um conceito bidimensional, onde uma dimensão contém as propriedades primitivas da tonalidade e a outra corresponde aos relacionamentos espaciais entre elas. Eles indicaram que os conceitos de tonalidade e textura não são independentes, tal que em algumas imagens a tonalidade é dominante e, em outras, a textura é dominante.

2.2. Classificação

As três abordagens principais usadas em classificação de imagens para a descrição de texturas são a estatística, a estrutural e a espectral.

- **Abordagens estatísticas:** a textura é definida por um conjunto de medidas locais extraídas do padrão. Medidas estatísticas comuns incluem entropia, correlação, contraste e variância, média;
- **Abordagens estruturais:** utilizam a idéia de que texturas são compostas de primitivas dispostas de forma aproximadamente regular e repetitiva, de acordo com regras bem definidas. Como exemplo, pode-se citar a descrição da textura baseada em linhas paralelas regularmente espaçadas;
- **Abordagens espectrais:** baseiam-se em propriedades do espectro de *Fourier*, sendo principalmente utilizadas na detecção de periodicidade

As análises realizadas neste trabalho são abordagens estatísticas.

Para proceder a classificação, é necessário realizar inferências sobre os padrões presentes em uma imagem. De acordo com [Gonzalez and Woods, 2000], a habilidade de realizar o reconhecimento de padrões em um determinado nível é fundamental em análise de imagens. Desta forma, pode-se definir um *padrão* como uma descrição quantitativa ou estrutural de um objeto ou alguma outra entidade de interesse em uma imagem. Em geral, um padrão é formado por um ou mais descritores. Entre outras palavras, um padrão é um arranjo de descritores.

Uma classe de padrões é uma família de padrões que compartilham algumas propriedades comuns. Os três principais arranjos de padrões utilizados na prática são *vetores* (para descrições quantitativas), *cadeias* e *árvores* (para descrições estruturais). Neste trabalho utilizou-se o arranjo por vetores de descritores e comparação de funções de distribuição de probabilidades (histogramas).

2.3. Matrizes de co-ocorrências

A primitiva mais simples que pode ser definida em uma imagem digital em níveis de cinza é um *pixel*, que tem como propriedade seu nível de cinza. Conseqüentemente, a distribuição dos níveis de cinza dos *pixels* pode ser descrita por estatísticas de primeira ordem, como média, variância, desvio padrão, inclinação *skewness* ou estatísticas de segunda ordem como a probabilidade de dois *pixels* terem um determinado nível de cinza ocorrendo com um relacionamento espacial particular. Essa informação pode ser resumida em matrizes de co-ocorrência bidimensionais, calculadas para diferentes distâncias e orientações.

A matriz de co-ocorrência é uma tabulação de quantas combinações diferentes de valores de intensidade dos pixels (níveis de cinza) ocorrem em uma imagem. A idéia principal da matriz de co-ocorrência é descrever textura através de um conjunto de características para as ocorrências de cada nível de cinza nos pixels da imagem considerando múltiplas direções.

As matrizes de coocorrência são uma poderosa ferramenta na classificação de imagens. No entanto, elas são de custo muito alto para a computação e alternativas precisam ser encontradas, como pode ser visto na seção 2.4.

2.4. Histogramas de somas e diferenças

O histograma de uma imagem digital, representa, para cada nível de intensidade (cinza), o número de *pixels* com aquele nível. O histograma indica se a imagem está distribuída adequadamente dentro dos possíveis níveis. De forma geral, o histograma H pode ser definido como:

$$H_g(k) = \frac{nk}{MxN} \quad (1)$$

onde nk é o número de vezes que o *pixel* k aparece na imagem e M e N são as dimensões da imagem.

O histograma pode ser muito útil na classificação de imagens uma vez que ele representa uma função de distribuição de probabilidades. De acordo com [Unser, 1986], podemos utilizar o histograma das somas e diferenças de uma dada amostragem para descrever texturas ao invés da tradicional utilização de matrizes de coocorrência. Os ganhos computacionais são relevantes. Defina-se I como a imagem sendo analisada, hs como sendo o histograma das somas e hd como sendo o histograma das diferenças. Desta forma, temos que:

$$hs[I(i, j) + I(i + t_1, j + t_2)]_+ = 1, \quad (2)$$

$$hd[I(i, j) - I(i + t_1, j + t_2)]_+ = 1. \quad (3)$$

Note que (t_1, t_2) representa o vetor direção (sentido) no espaço Z^2 que estamos considerando. A primitiva $I(i, j)$ acessa o *pixel* localizado na linha i e coluna j da imagem.

Temos que o histograma hs está definido para o intervalo onde $hs[i]/i \in [0, 2(L-1)]$ L representa o máximo nível de cinza da imagem. De forma similar, temos que hd está definido para o intervalo $hd[j]/j \in [-(L-1), (L-1)]$.

2.5. Descritores utilizados

A classificação correta de qualquer textura depende muito dos descritores utilizados para caracterizá-la da melhor forma possível. Neste trabalho foram utilizados os descritores: média, contraste, homogeneidade, energia, variância, correlação e entropia.

Média

$$\mu = \sum_{i=0}^{2*(L-1)} hs[i] \quad (4)$$

Contraste

$$C = \sum_{j=-L}^L j^2 hd[j] \quad (5)$$

Homogeneidade

$$H = \sum_{j=-L}^L \frac{1}{1 + j^2} hd[j] \quad (6)$$

Energia

$$En = \sum_{i=0}^{2L-1} hs[i] \sum_{j=-(L-1)}^{L-1} hd[j] \quad (7)$$

Variância

$$\sigma^2 = \frac{1}{2} \sum_{i=0}^{2L-1} (i - 2\mu)^2 hs[i] + \sum_{j=-(L-1)}^{L-1} j^2 hd[j] \quad (8)$$

Correlação

$$Cr = \frac{1}{2} \sum_{i=0}^{2L-1} (i - 2\mu)^2 hs[i] - \sum_{j=-(L-1)}^{L-1} j^2 hd[j] \quad (9)$$

Entropia

$$Et = - \sum_{i=0}^{2L-1} hs[i] \log hs[i] - \sum_{j=-(L-1)}^{L-1} hd[j] \log(hd[j]) \quad (10)$$

2.6. Métricas para comparação de histogramas

Outra forma possível de se fazer classificação de imagens é através da utilização do histograma diretamente. Desta forma, dado um histograma de uma amostra de imagem e de vários protótipos de comparação podemos classificar tal amostra como sendo de um dos protótipos simplesmente definindo alguma métrica que prove que tal amostragem está mais próxima deste ou daquele protótipo.

Algumas métricas para comparação de histogramas podem ser: distância de *Minkowsky*, *Chi-Square* e de *Bhattacharyya*.

Distância de Minkowsky

$$M = \sum_{i=0}^L |h_1[i] - h_2[i]|^f \quad (11)$$

onde f é uma função a ser definida. Quando $f = 1$ temos a *Norma L1*, quando $f = 2$ temos a *Norma L2* também conhecida como distância Euclidiana.

Distância χ^2

$$\chi^2 = \sum_{i=0}^L \frac{(h_1[i] - h_2[i])^2}{h_1[i] + h_2[i]} \quad (12)$$

Distância de Bhattacharyya

$$B = -\ln \sum_{i=0}^L \sqrt{(h_1[i]h_2[i])} \quad (13)$$

3. Abordagens utilizadas

Para obter a classificação de imagens, este trabalho aplicou duas abordagens diferentes. Na primeira abordagem, utilizou-se protótipos caracterizados por vetores de padrões montando uma base de referência. A partir desta base de referência, uma imagem de entrada é classificada pelo critério de menor distância Euclidiana a partir de seu vetor de padrões aos protótipos da base de referência. Na segunda abordagem, foi utilizada a comparação direta das funções de distribuição de probabilidades das imagens protótipo com a imagem sendo analisada. Para selecionar a qual padrão uma textura da amostra pertence foram utilizadas as métricas de comparação de histogramas apresentadas na seção 2.6.

3.1. Abordagem com vetores de descritores

Nesta abordagem, cada textura passada é representada a partir dos sete descritores apresentados na seção 2.5. Um banco de imagens é montado e, a partir dele, monta-se um vetor característico para cada protótipo passado para a base de conhecimentos. Cada posição do vetor característico identifica um dos descritores apresentados na seção 2.5.

Para tornar a classificação robusta à transformações de rotação e translação na imagem, são consideradas as vizinhanças de uma malha 8-conexa para o *pixel* tratado. Desta forma, ao analisar o *pixel* p centrado em i , é construído um histograma de somas e um histograma de diferenças para cada direção t_1, t_2 possível em relação ao *pixel* p_i para uma abordagem 8-conexa. Estas direções são apresentadas na figura 1.

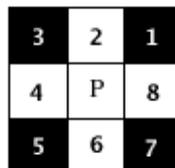


Figura 1: Direções consideradas relevantes para um *pixel* p centralizado em i

onde $1 = 45^\circ$, $2 = 90^\circ$, $3 = 135^\circ$, $4 = 180^\circ$, $5 = 225^\circ$, $6 = 270^\circ$, $7 = 315^\circ$ e $8 = 360^\circ$. Ao computar os histogramas para todas estas direções os descritores são avaliados para cada uma delas e o descritor médio de todas as direções é retornado.

Os passos para classificar uma imagem são:

1. Enumerar todos os protótipos que servirão de comparação.
2. A partir dos protótipos passados será montado a base de protótipos que servirá de referência. Para cada protótipo analisado é feito seu histograma de somas e diferenças em todas as direções consideradas. Em seguida, é feita a avaliação de cada descritor. Ao final, cada protótipo passa a ser representado por um vetor de descritores.
3. Uma amostra (imagem) a ser classificada é passada. Para cada padrão encontrado na imagem sendo analisada este será comparado aos padrões da base de referências (protótipos). O padrão será classificado segundo o critério da menor distância Euclidiana entre ele e todos os protótipos disponíveis para análise.
4. A imagem de saída terá uma região setada para uma cor de acordo com a classificação feita. Cada protótipo tem um nível de cinza diferente representando a classificação. Essa cor é definida pela divisão $COR = (\text{Máximo nível de cinza}) / (\text{número de protótipos}) * (\text{índice do protótipo})$. Ex.: O máximo nível de cinza na imagem é 255 e o número de protótipos disponíveis na base de conhecimentos é 10. Assim o protótipo com identificação 0 terá a cor 0 de saída, o protótipo 1 terá 25, o protótipo 2 terá 50 e assim até o último protótipo. Obviamente, este tipo de abordagem é limitado pois com mais de 20 protótipos a classificação cria uma imagem de saída tão complexa quanto à imagem de entrada. No entanto, esta é uma abordagem didática. Uma melhor solução poderia produzir imagens coloridas na saída, onde cada cor representaria uma região classificada.

É importante observar que o índice de um protótipo na base de referência é dado pela sua linha no arquivo de protótipos passado. Assim, se o nome do protótipo está na quinta linha do arquivo então ele terá o índice 5 na base de referência.

3.2. Abordagem com classificação por comparação de histogramas

Nesta abordagem, cada textura passada é representada a partir de seu histograma. Um banco de imagens é montado e, a partir dele, monta-se um vetor onde cada posição é o histograma de uma imagem protótipo da base de conhecimentos. Quando uma classificação deve ser feita, uma janela de tamanho definido nos parâmetros passeia pela imagem comparando o histograma da janela com o histograma de todos os protótipos. Obviamente, estes histogramas são normalizados. A janela será classificada pela melhor métrica encontrada entre os histogramas. Neste caso, uma cor é atribuída à janela classificada e a janela é deslocada uma coluna à direita.

As métricas utilizadas para comparar os histogramas e assim classificar uma textura foram *distância de Minkowsky*, *distância de Bhattacharyya* e o *teste Chi-Square*. Os melhores resultados foram obtidos com a combinação das métricas. No entanto, quando se utiliza apenas a *distância de Minkowsky* e/ou o *teste Chi-Square* as classificações são muito próximas da classificação dessas métricas combinadas. Assim, o usuário pode escolher qual forma utilizar.

4. Resultados

De acordo com [Marceau et al., 1990], 90% da variabilidade na precisão de classificação usando texturas dependem do tamanho da janela usado para calcular texturas, enquanto os algoritmos particulares de textura determinam somente 10%. Essa é uma particularidade importante, pois a maioria dos estudos envolvendo textura abordam o desenvolvimento e a avaliação de algoritmos sem considerar o efeito do tamanho da janela. Foi avaliado que o tamanho da janela, em *pixels*, depende da textura em questão para realizar uma classificação satisfatória. Janelas de tamanho pequeno não capturam o padrão particular da maioria das classes, enquanto janelas maiores podem incluir *pixels* de mais de uma classe, resultando em classificações mais pobres. O tamanho ideal de janela seria aquele que produz a menor variabilidade na textura. Nos testes realizados os melhores resultados foram obtidos com janelas de tamanho 21×21 *pixels*.

Para poder comparar os resultados de uma e outra abordagem vamos aos resultados.

4.1. A base de protótipos

Os protótipos utilizados nos testes estão listados nas figuras 2 a 31.

4.2. Imagens analisadas

As imagens submetidas à classificação são apresentadas nas figuras 32 a 41.



Figura 2: Protótipo 1



Figura 3: Protótipo 2

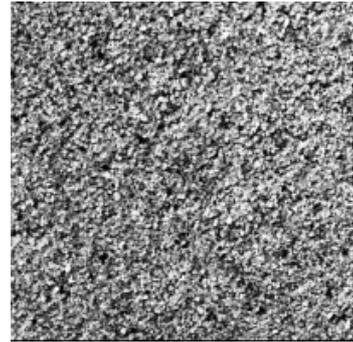


Figura 4: Protótipo 3

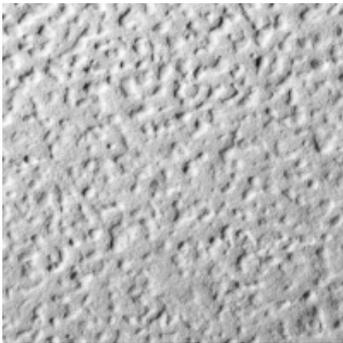


Figura 5: Protótipo 4

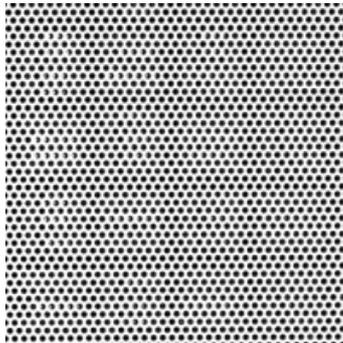


Figura 6: Protótipo 5

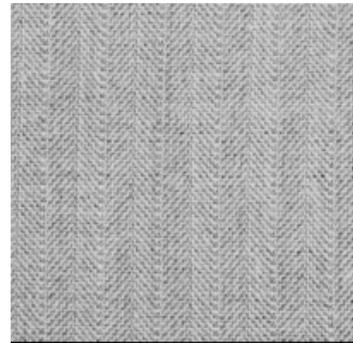


Figura 7: Protótipo 6

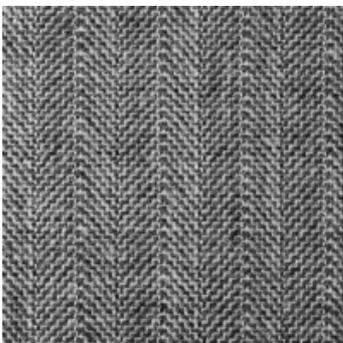


Figura 8: Protótipo 7

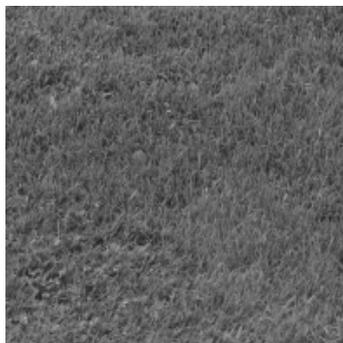


Figura 9: Protótipo 8

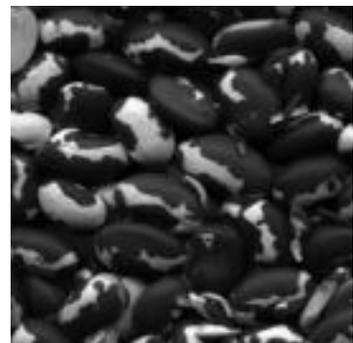


Figura 10: Protótipo 9

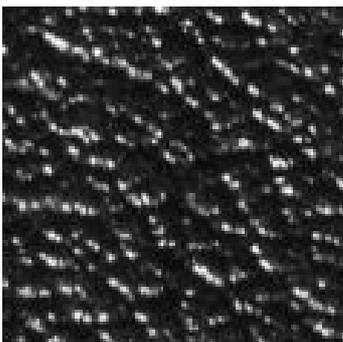


Figura 11: Protótipo 10

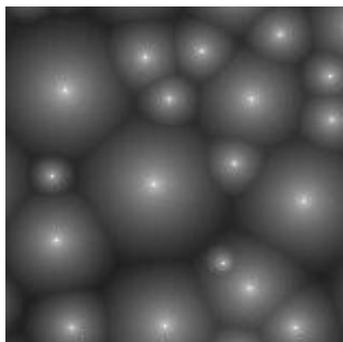


Figura 12: Protótipo 11

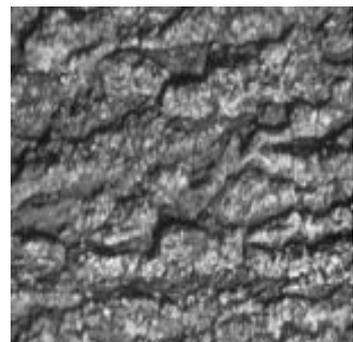


Figura 13: Protótipo 12

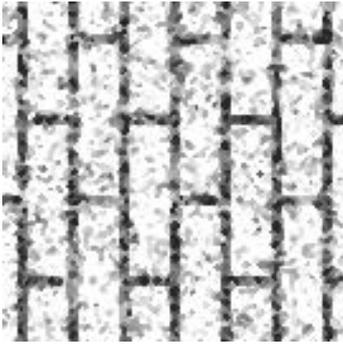


Figura 14: Protótipo 13

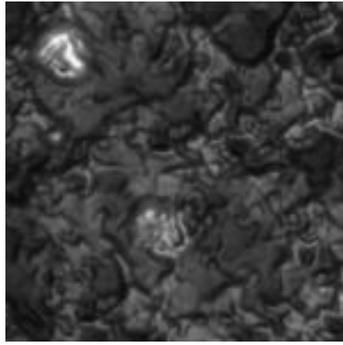


Figura 15: Protótipo 14

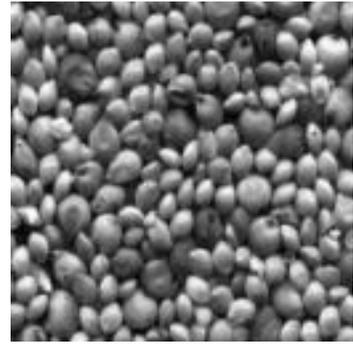


Figura 16: Protótipo 15

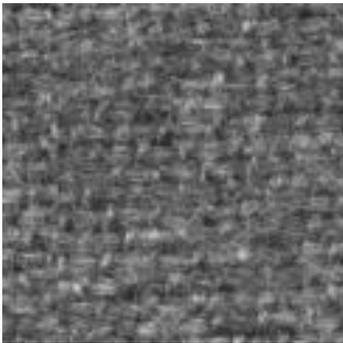


Figura 17: Protótipo 16



Figura 18: Protótipo 17

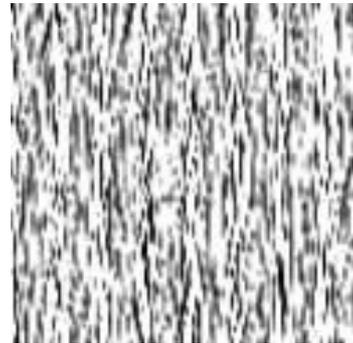


Figura 19: Protótipo 18



Figura 20: Protótipo 19

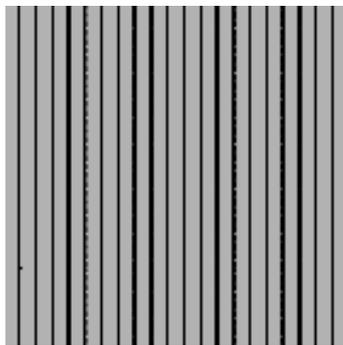


Figura 21: Protótipo 20

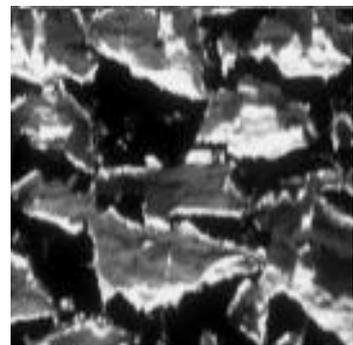


Figura 22: Protótipo 21



Figura 23: Protótipo 22



Figura 24: Protótipo 23

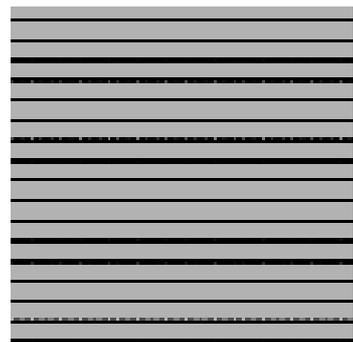


Figura 25: Protótipo 24

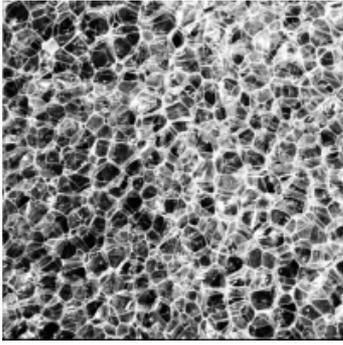


Figura 26: Protótipo 25

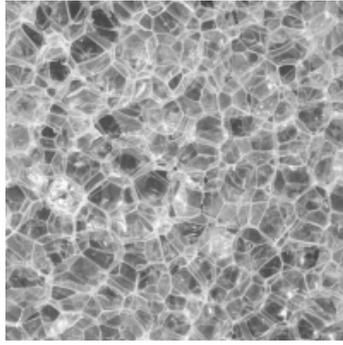


Figura 27: Protótipo 26

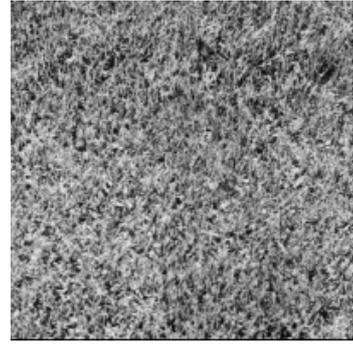


Figura 28: Protótipo 27

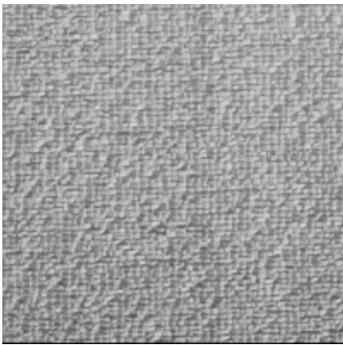


Figura 29: Protótipo 28

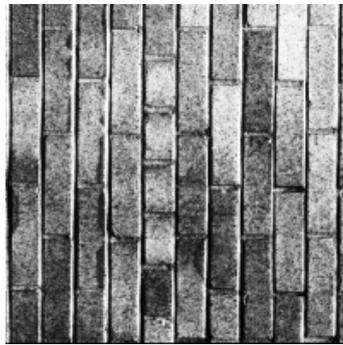


Figura 30: Protótipo 29

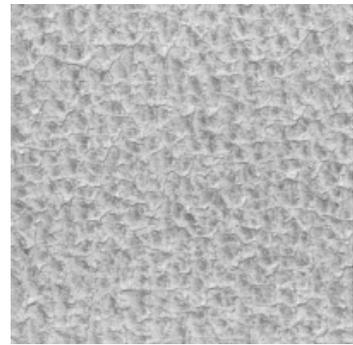


Figura 31: Protótipo 30

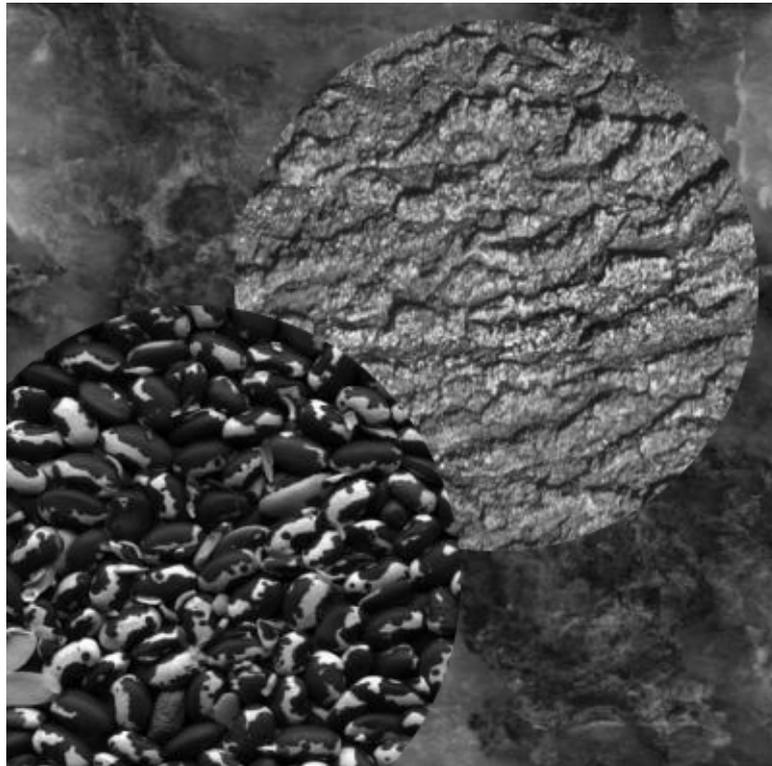


Figura 32: Imagem de teste 1



Figura 33: Imagem de teste 2

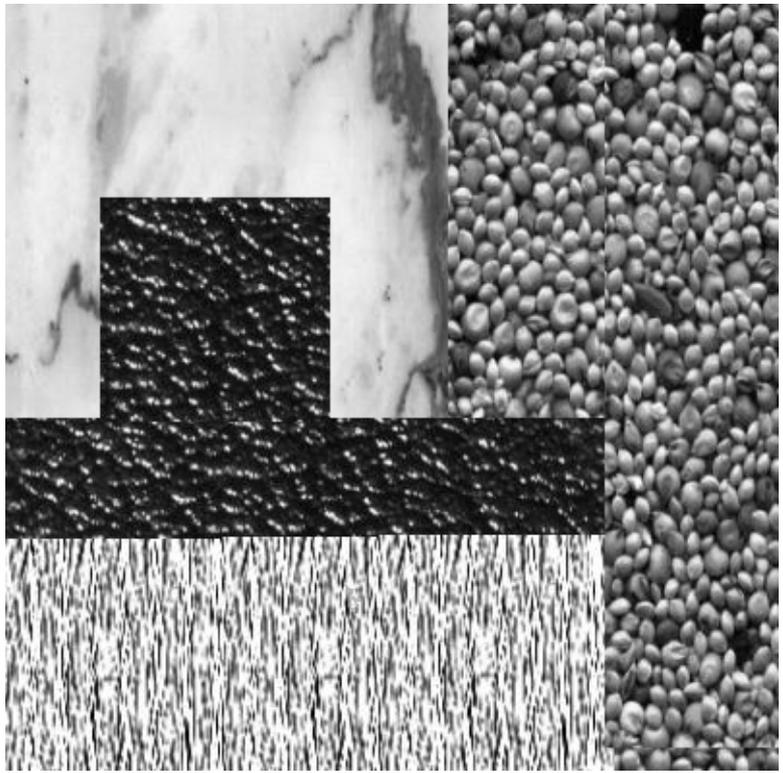


Figura 34: Imagem de teste 3

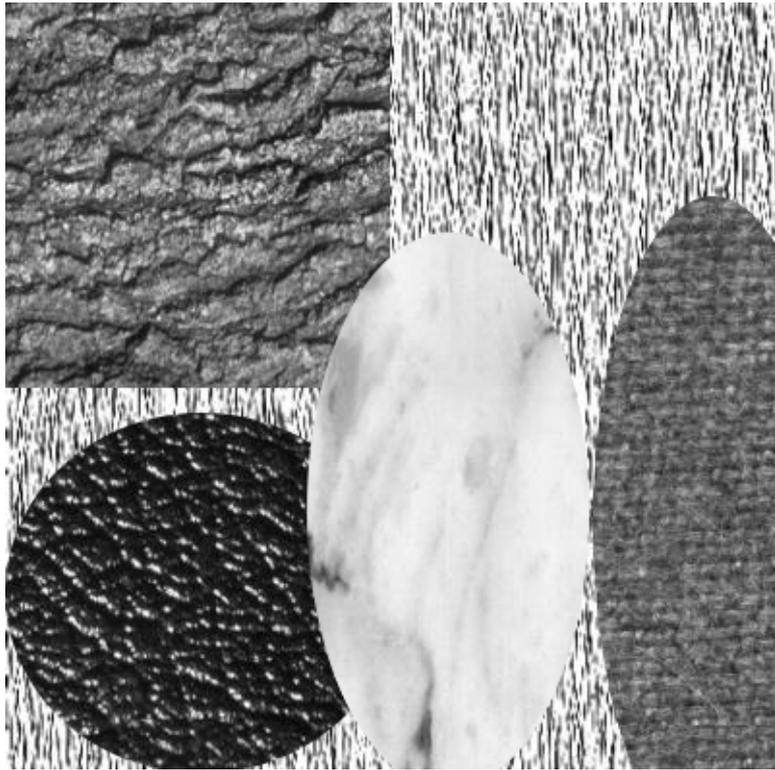


Figura 35: Imagem de teste 4

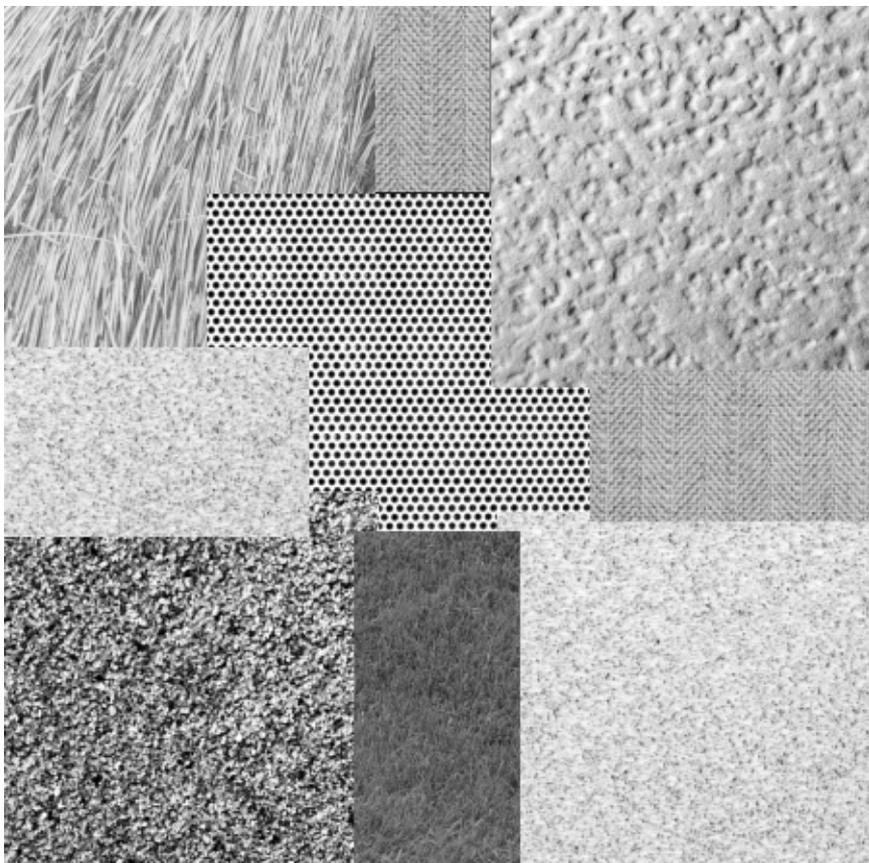


Figura 36: Imagem de teste 5

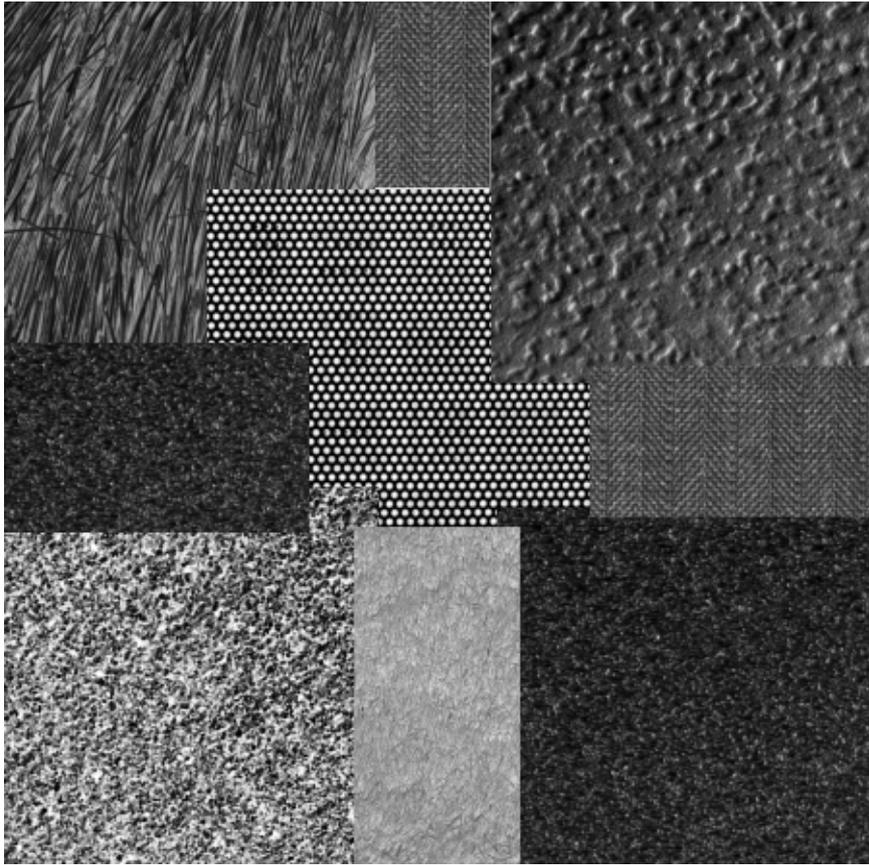


Figura 37: Imagem de teste 6

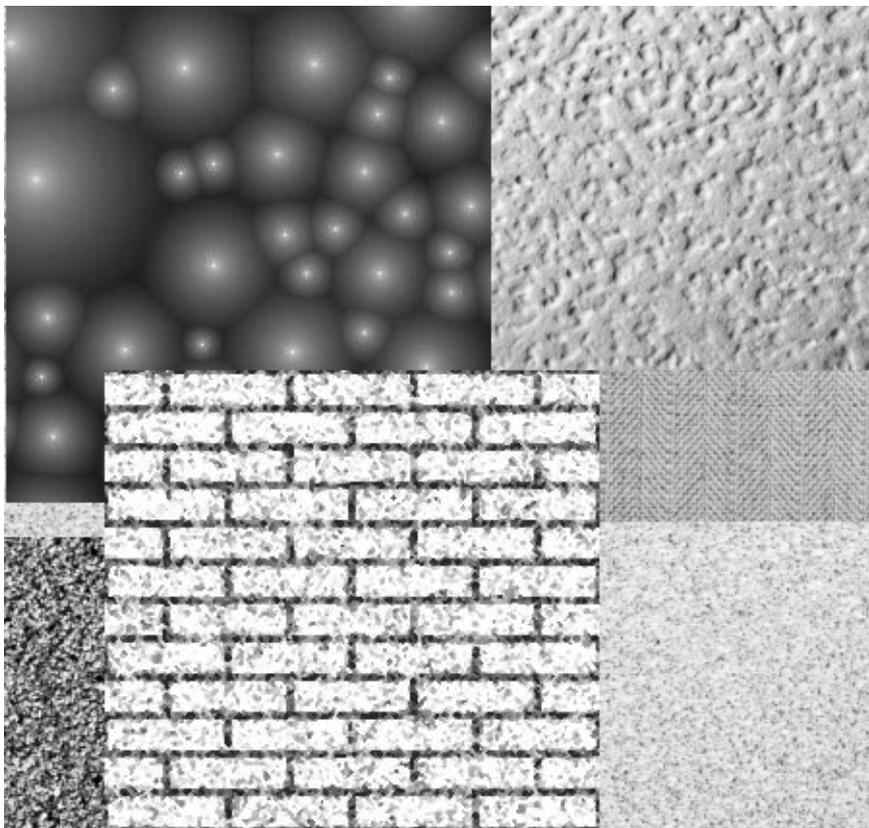


Figura 38: Imagem de teste 7

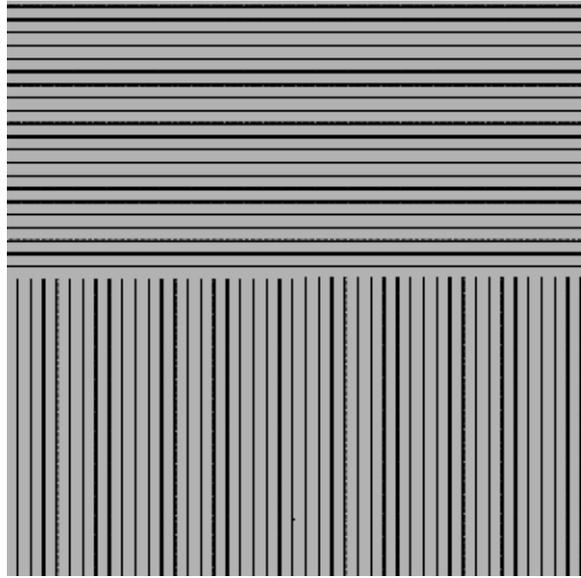


Figura 39: Imagem de teste 8

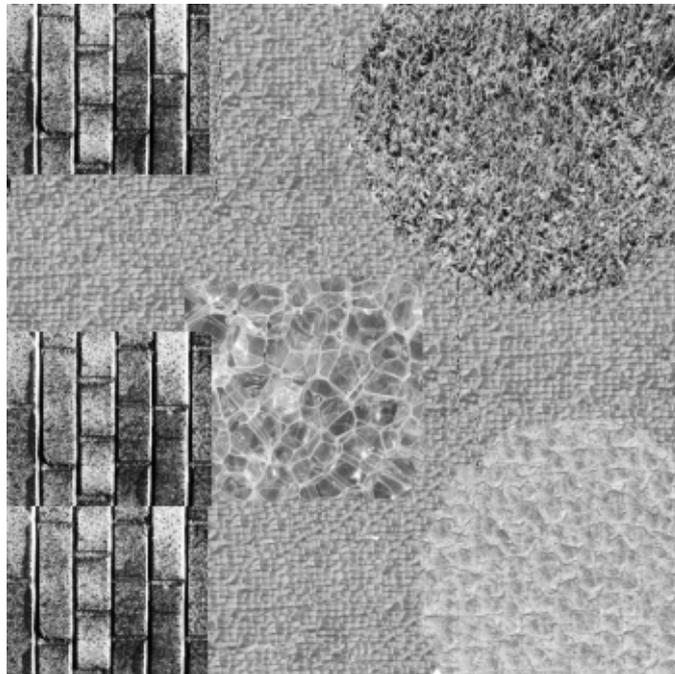


Figura 40: Imagem de teste 9

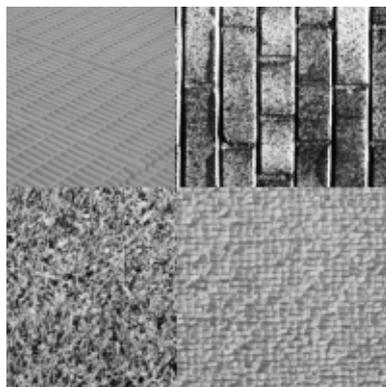


Figura 41: Imagem de teste 10

4.3. Análise por descritores

A partir do momento em que se gera todos os descritores para cada um dos protótipos, tem-se uma base de referência que irá permitir a classificação de uma imagem qualquer de entrada que apresente padrões descritos pela base de referência.

Foram feitos 10 testes com esta abordagem. As respectivas imagens resultantes da classificação são mostradas nas figuras 42 a 51.

O **teste 1** é um teste difícil pois contém três texturas complexas. O fundo é uma textura de mármore e é entrecortado por dois círculos. O primeiro é uma textura de casca de árvore e o segundo é um grupo de feijões. O grupo de feijões por si apresenta padrões de várias texturas presentes na base de protótipos e por isso não é bem classificado.

O **teste 2** é um teste mais simples. A textura superior esquerda e inferior direita são as mais complexas. As outras são mais simples e apresentam padrões bem definidos. O classificador se comportou bem neste teste. Destaque apenas para os pequenos erros cometidos na classificação da textura superior esquerda devido à confusão do classificador com alguma outra textura da base de referência dos protótipos.

No **teste 3**, a textura mais complexa é a dos grãos de soja. No entanto, o classificador se comportou bem. Destaque para os pequenos erros na zona de transferência entre as duas texturas superiores. Note que o classificador chega a confundir a parte escura do mármore da textura superior esquerda com outra textura presente mais abaixo na imagem.

No **teste 4**, a textura inferior esquerda é a mais complexa. As outras são: textura de lã, mármore branco, casca de árvore e o fundo tem uma textura salpicada. O classificador se perde um pouco na classificação da textura inferior esquerda. Além disso, o classificador chega a cometer alguns deslizamentos na classificação da textura superior esquerda.

O **teste 5** é um teste completo. Há 7 texturas a serem classificadas. A textura de *capim* na parte superior esquerda e a textura caracterizando a superfície lunar na parte superior direita são as mais complexas. O classificador se comporta bem exceto para a classificação da superfície lunar onde fica praticamente perdido. A explicação é que esta textura está muito próxima de outras presentes tanto na base de referência quanto na própria imagem sendo analisada. Além disso, há informações de buracos (pequenas crateras) na textura que dificultam a sua classificação.

O **teste 6** é semelhante ao teste 5 com a diferença de que a imagem está com suas cores invertidas. Nota-se que a base de referência não é boa o suficiente para representar a mesma textura com a cor invertida. Isto quer dizer que, se houver uma textura I na base de referência e for necessário classificar uma imagem que contenha uma textura I' que seja o inverso de I (presente na base de referência) o resultado não será muito bom.

O **teste 7** é um teste complexo dado que as texturas das bolhas, do muro e da superfície lunar são difíceis de classificar. O classificador fica perdido na classificação das bolhas e comete alguns erros na textura da superfície lunar. **Observação:** este teste foi realizado levando em consideração apenas as texturas presentes na imagem e não toda a base de texturas de referência.

O **teste 8** é simples com apenas duas texturas. O objetivo é mostrar o comportamento do classificador em relação a alterações na direções das texturas. A textura de cima é a mesma textura de baixo exceto pela variação de 90° . O classificador se comportou bem neste caso. Isto é devido à análise espacial do classificador que leva em conta as variações de rotação mais comuns.

O **teste 9** contém uma textura de muro. O classificador se comportou bem exceto para a textura de muro, como era de se esperar dado que este tipo de textura não apresenta um padrão bem definido.

O **teste 10** contém uma textura de muro como a mais complexa. O classificador se comportou bem exceto para a textura de muro. O classificador chega a se confundir em algumas das bordas. A base de texturas utilizada aqui foi apenas as texturas presentes na imagem e não toda a base de referência.

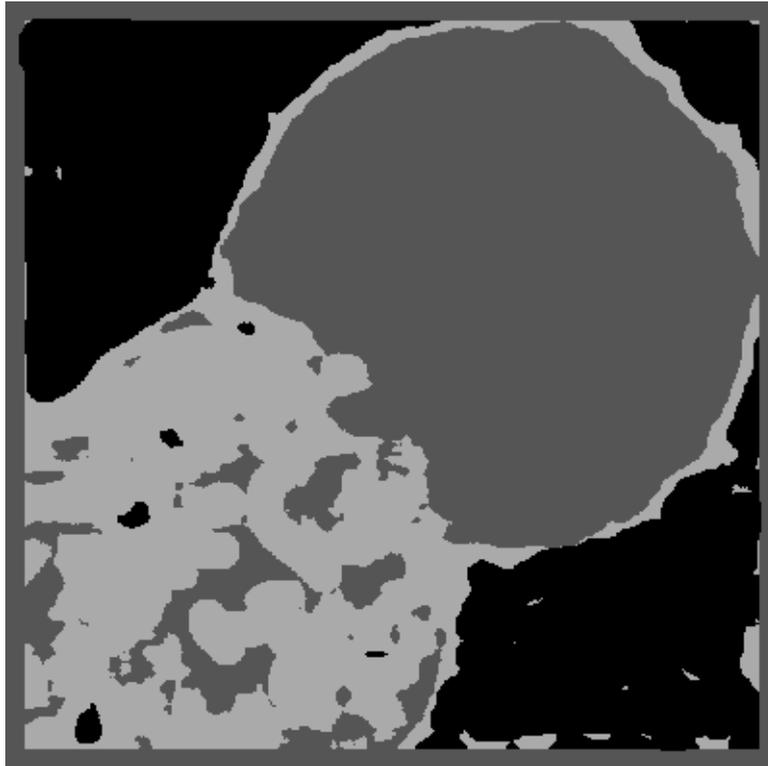


Figura 42: Resultado para o teste 1



Figura 43: Resultado para o teste 2



Figura 44: Resultado para o teste 3

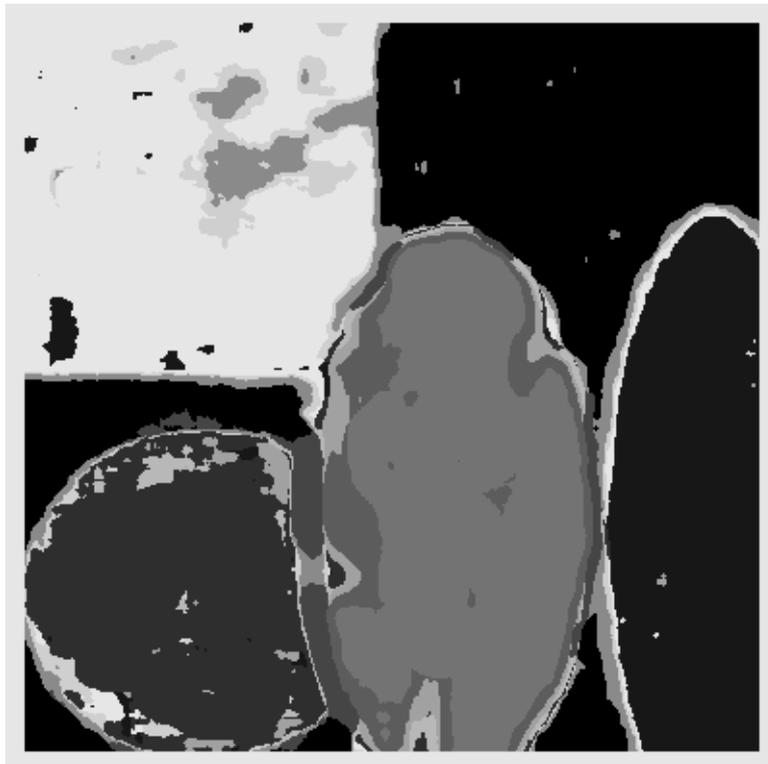


Figura 45: Resultado para o teste 4

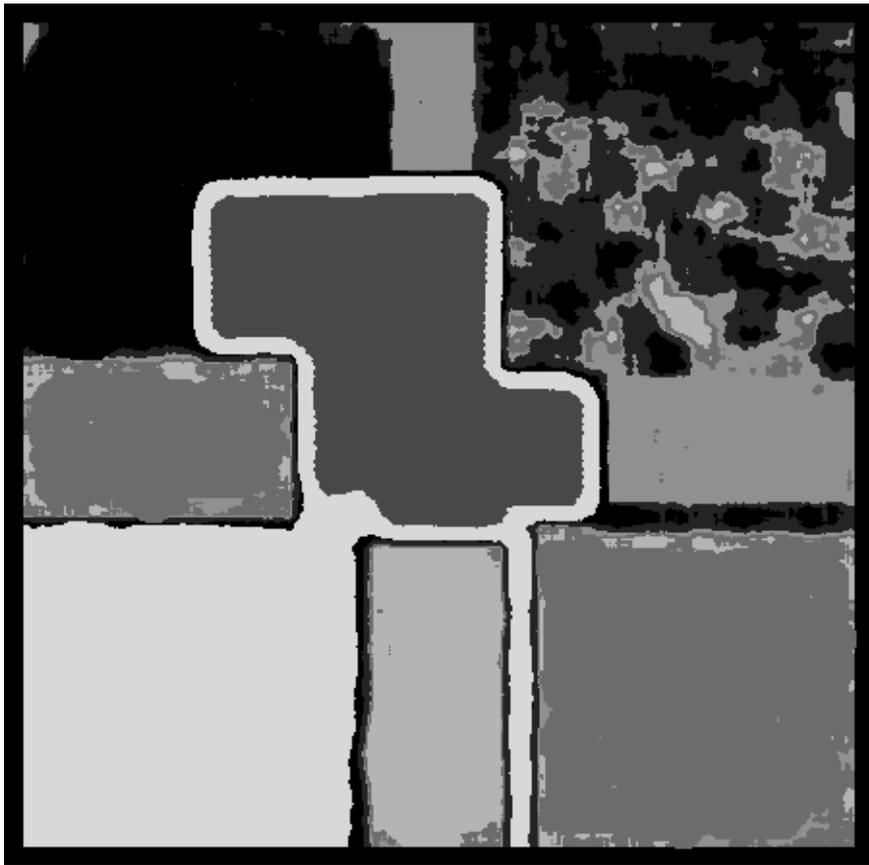


Figura 46: Resultado para o teste 5

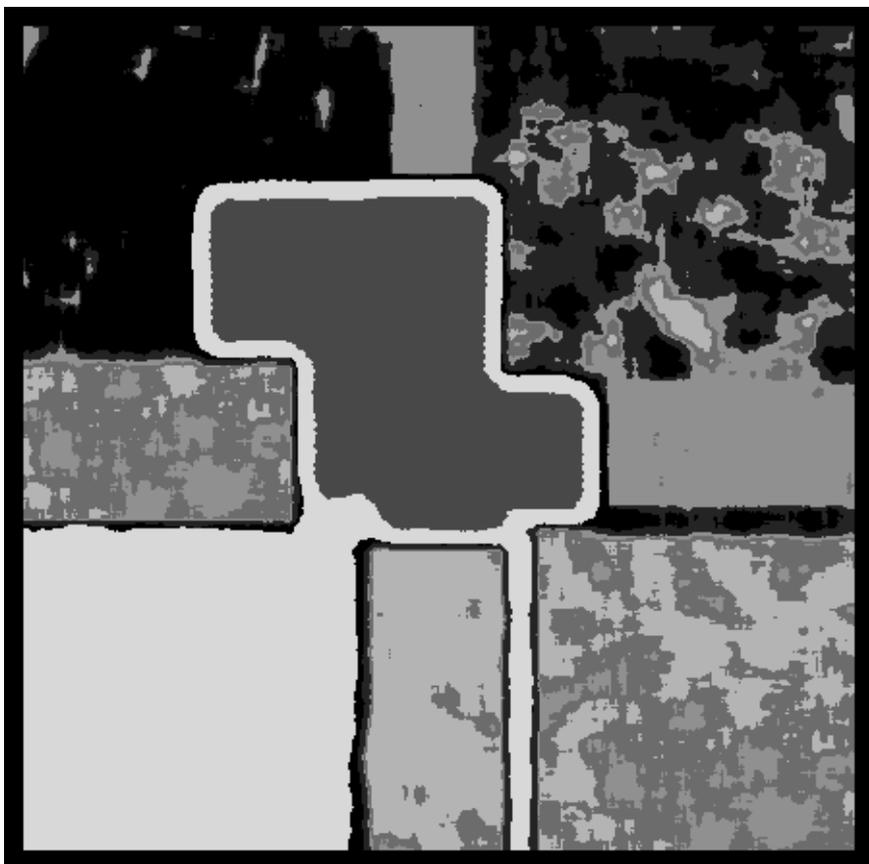


Figura 47: Resultado para o teste 6

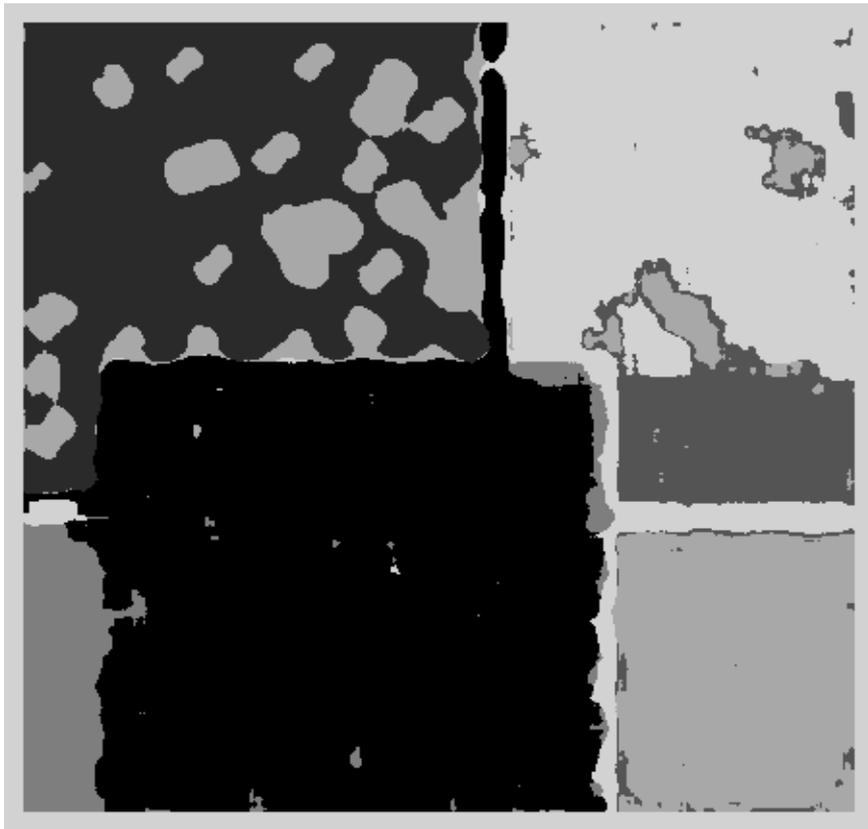


Figura 48: Resultado para o teste 7

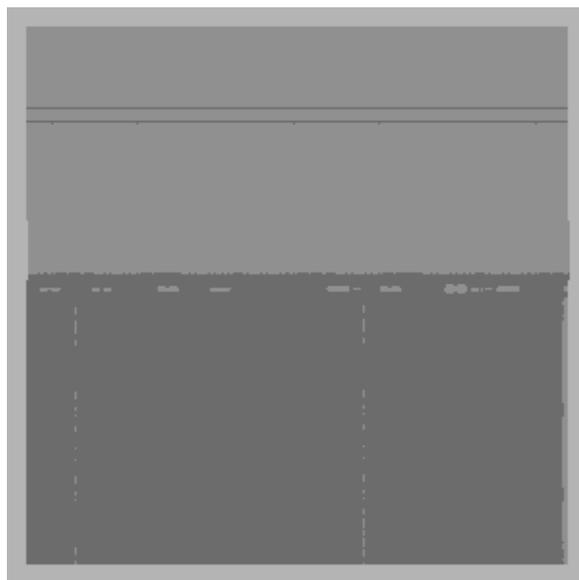


Figura 49: Resultado para o teste 8

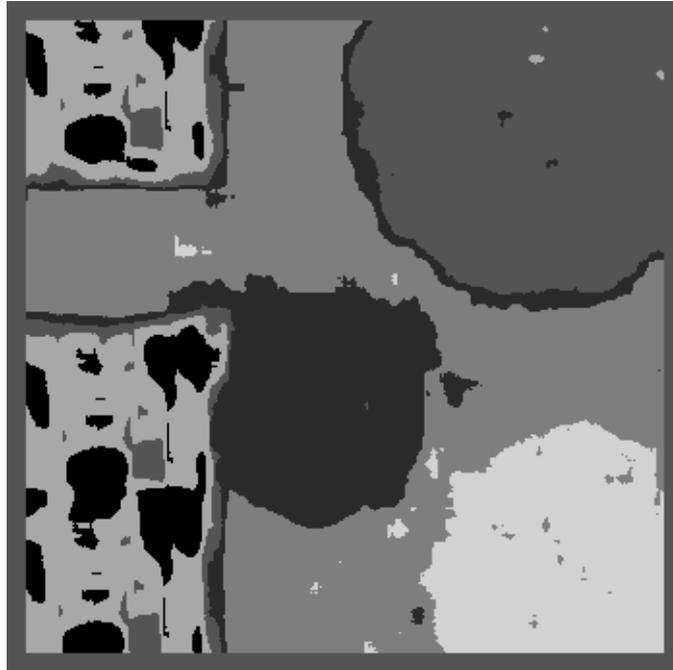


Figura 50: Resultado para o teste 9



Figura 51: Resultado para o teste 10

4.4. Análise por comparação de histogramas

A partir do momento em que se gera um histograma para cada um dos protótipos, tem-se uma base de referência que irá permitir a classificação de uma imagem qualquer de entrada que apresente um histograma que tenha intersecção com algum histograma da base de referência. Para isso, foram usadas as métricas de intersecção de histogramas apresentadas na seção 2.6. Em todos os testes foram calculadas todas as métricas e montado um vetor para elas. Ao analisar uma janela centrada no *pixel* p , por exemplo, faz-se a distância Euclidiana para as métricas desta janela em relação às métricas da base de referência. O vetor de métricas de menor distância é selecionado e o *pixel* é então classificado de acordo com este vetor. De acordo com os resultados, a abordagem de se levar em conta todas as métricas descritas em 2.6 não é muito vantajosa. Os resultados obtidos utilizando apenas uma das métricas é praticamente o mesmo. A única exceção é para a métrica de *Bhattacharyya* cujos resultados são um pouco piores.

Foram feitos 10 testes com esta abordagem. As respectivas imagens resultantes da classificação são mostradas nas figuras 52 a 61.

O **teste 1** apresenta texturas cujos histogramas não são muito diferentes. O resultado é que as métricas de intersecção dos histogramas não consegue classificar a imagem. A resultado é a bagunça presente na figura 52.

No **teste 2** os histogramas das texturas inferior esquerdo que é o mesmo da superior direito e da textura central são bem diferentes e são bem classificados. As texturas inferior direita e superior esquerda possuem uma classificação bastante pobre.

No **teste 3** o classificador se perde na textura dos feijões. A classificação das texturas restantes é bem feita.

O **teste 4** apresenta uma boa classificação baseado em métricas do histograma. Isto acontece porque as texturas presentes na imagem têm histogramas bastante diferentes e portanto, são capazes de bem caracterizar cada textura.

O mesmo acontece com as texturas presentes no **teste 5**. Os histogramas são bons representantes das texturas. O classificador comete pequenos erros nas zonas limítrofes mas no geral o resultado é satisfatório.

Já no **teste 6** que é o inverso de cores da imagem do **teste 5**, o classificador se perde e não produz um resultado bom. Ao inverter as cores da imagem de entrada os histogramas passam a ser bem diferentes dos histogramas presentes na base de referência. Logo, o classificador fica inconsistente. Seria ideal que o classificador fosse robusto a isto.

O resultado do **teste 7** é bastante bom. Salvo a classificação com erros da textura de bolhas que já sabemos ser problemática por não ser bem representada por seu histograma. Além disso, há alguns pequenos defeitos nas zonas limítrofes.

O **teste 8** serve para provar que os classificadores baseados em métricas de intersecção de histogramas não são muito robustos pois são sensíveis a alterações de rotação. O classificador implementado não observa a direção da textura. Uma possível melhoria neste tipo de classificador baseado em histogramas é analisar além do histograma a direção de contorno o que poderia resolver este problema.

O **teste 9** apresenta uma classificação boa para as texturas superior direita e inferior direita. A textura 9 central não é bem classificada como acontecia na abordagem de classificação por descritores. A textura de muros continua não sendo bem classificada.

No **teste 10**, a textura de muro também não foi bem classificada. As outras texturas apresentam um resultado razoável.

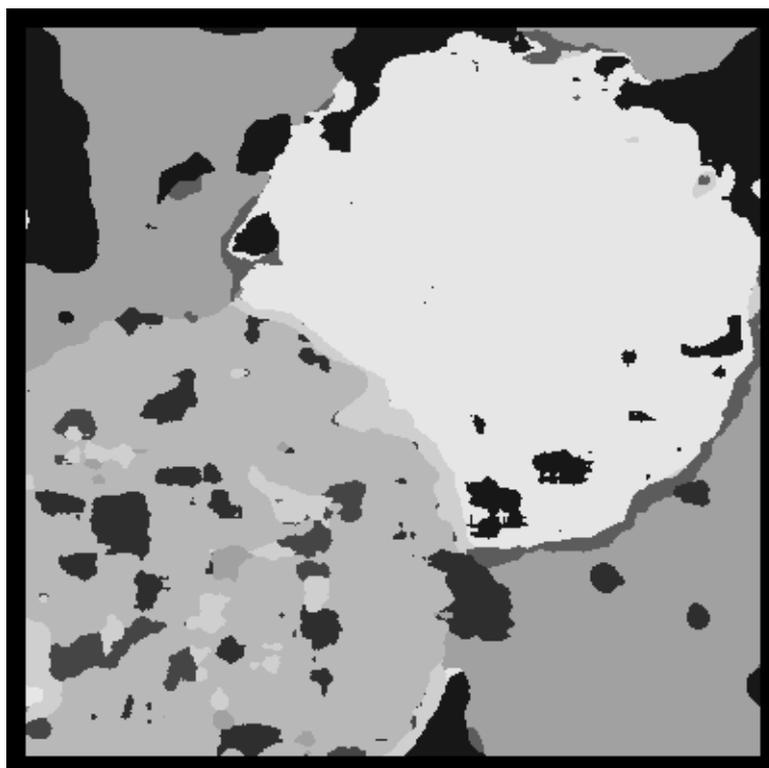


Figura 52: Resultado para o teste 1



Figura 53: Resultado para o teste 2



Figura 54: Resultado para o teste 3

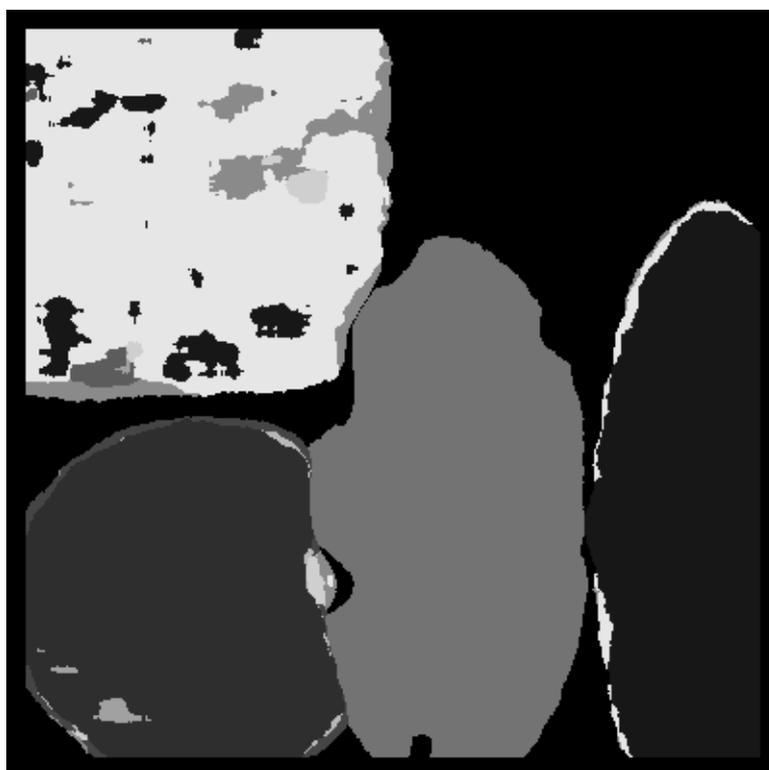


Figura 55: Resultado para o teste 4

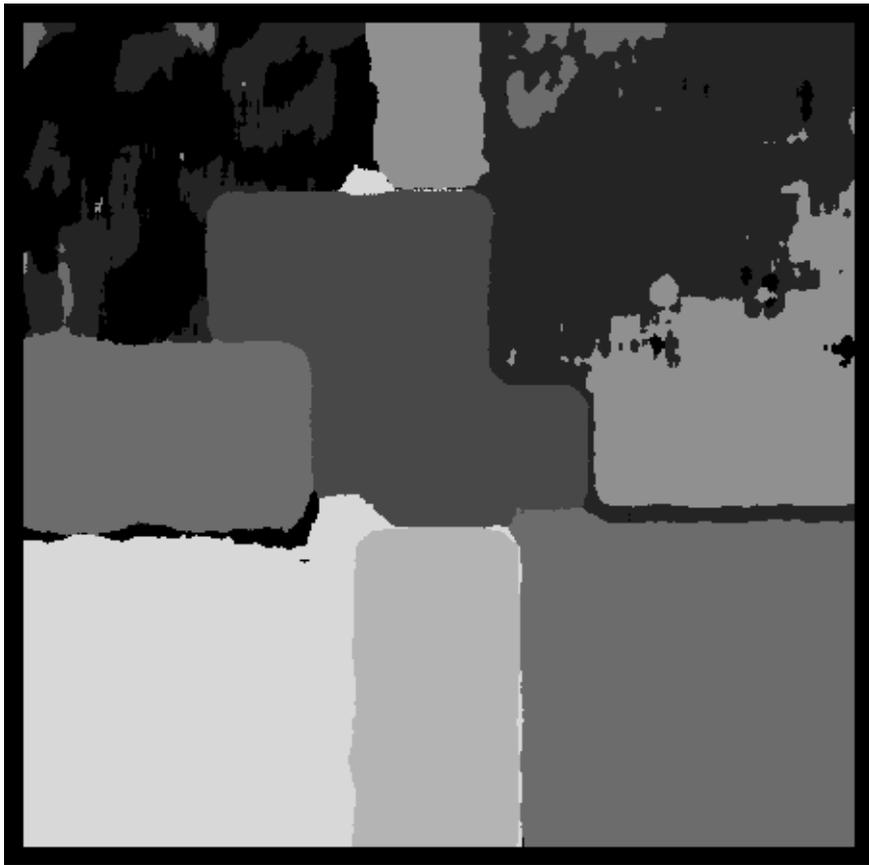


Figura 56: Resultado para o teste 5



Figura 57: Resultado para o teste 6

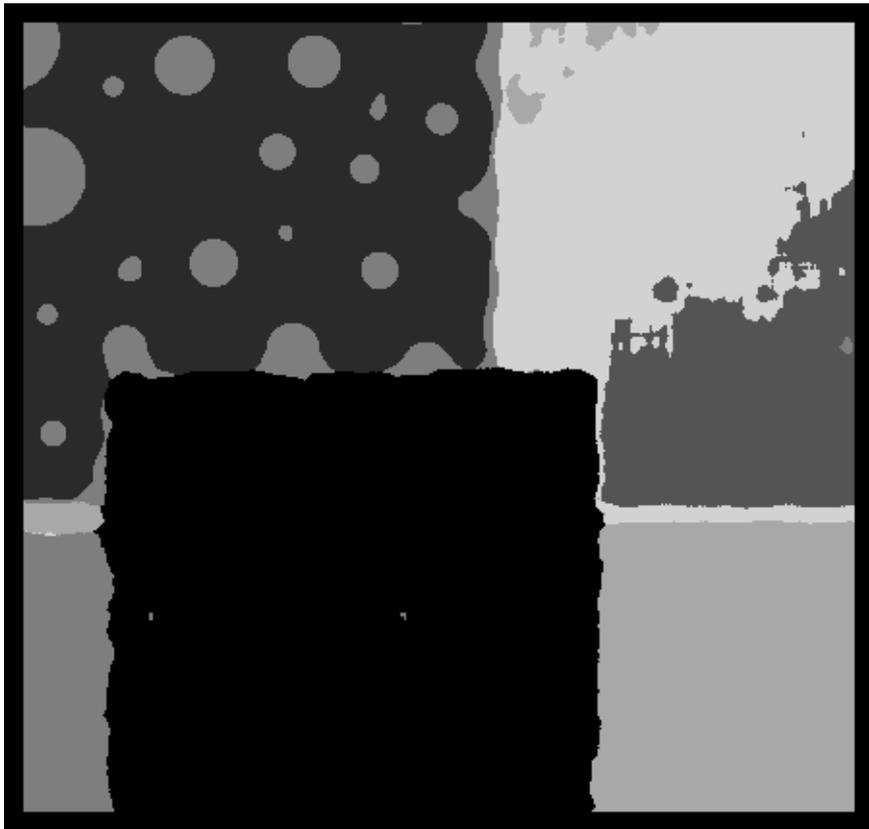


Figura 58: Resultado para o teste 7



Figura 59: Resultado para o teste 8

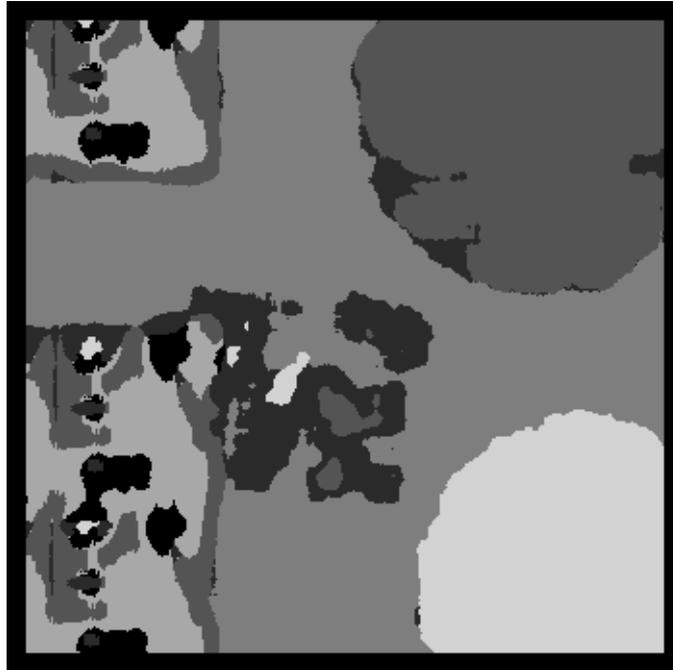


Figura 60: Resultado para o teste 9

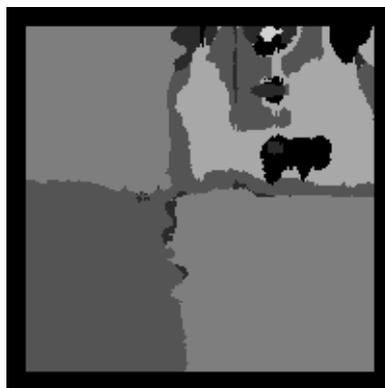


Figura 61: Resultado para o teste 10

5. Conclusões

A partir dos testes realizados, conclui-se que realmente o tipo de classificação empregado neste trabalho é um dos mais simples possíveis. Os resultados das classificações são extremamente relacionados às texturas sendo analisadas. Muitas outras abordagens mais eficientes são descritas na literatura. Uma das mais comuns é o emprego de redes neurais com aprendizado. No entanto, este trabalho tem fins didáticos de comparação entre os classificadores por descritores estatísticos e por intersecção de histogramas.

A abordagem utilizando descritores estatísticos apresenta resultados melhores que a abordagem por intersecção de histogramas. A classificação baseada em métrica de intersecção de histogramas não é muito robusta uma vez que é sensível à transformações de rotação e translação. Por outro lado, por fazer uma boa abordagem espacial considerando várias direções diferentes no cômputo de uma vizinhança, os descritores estatísticos conseguem ser um pouco mais robustos a estas transformações.

Outro ponto muito importante é a relação entre o tamanho da janela utilizada e a resposta produzida. Nos testes realizados a melhor relação *custo computacional por melhor classificação* foi encontrada com janelas de tamanho 21×21 . Janelas menores podem não reproduzir o padrão de textura sendo analisado. Janelas muito maiores podem englobar mais de uma textura ao mesmo tempo. O tamanho da janela está extremamente ligado com a qualidade da resposta produzida.

Quanto mais complexa a textura utilizada, mais difícil a classificação. Ao encontrar uma textura que não pode ser muito bem caracterizada pelos descritores estatísticos utilizados, o classificador fica sem uma base confiável para comparação. Desta forma, o classificador irá encontrar dentro de uma mesma textura, pequenos padrões referentes às outras texturas disponíveis na base de referência. Isto é o que acontece com as texturas de feijões, muro de tijolos, solo lunar e bolhas. O mesmo pode ser dito quando o classificador é baseado nas métricas de intersecção de histogramas. Quando os histogramas são muito próximos, as texturas não são bem classificadas. Este tipo de abordagem funciona bem para texturas com histogramas bem diferentes.

As imagens produzidas como saída não foram submetidas a uma etapa posterior de **suavização / filtragem**. Os resultados aqui apresentados são brutos. Uma possível melhoria seria então, tomar os resultados produzidos a fazer uma filtragem de modo a eliminar pequenos falhas. Uma possível abordagem seria através de filtros morfológicos levando em conta erosões e dilatações sucessivas de modo a eliminar pequenas perturbações não desejadas.

Referências

- [Gonzalez and Woods, 2000] Gonzalez, R. C. and Woods, R. E. (2000). *Processamento de imagens digitais*. Editora Edgard Blucher, São Paulo. ISBN 85-212-0264-4.
- [Haralick, 1973] Haralick, R. M. (1973). Texture features for image classification. In *IEEE Transactions on Systems, Man and Cybernetics*. vol. SMC-3, número 6,.
- [Marceau et al., 1990] Marceau, D. J., Howarth, P. J., Dubois, J. M., and Gratton, D. J. (1990). Evaluation of the grey-level co-occurrence matrix method for land-cover classification using spot imagery. In *IEEE Transactions on Geosciences and Remote Sensing*, Waterloo, Canadá. pgs. 513-519.
- [Unser, 1986] Unser, M. (1986). Sum and difference histograms for texture classification. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*. vol. PAMI-8, número 1.