



**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

*Inspeção Visual Automática Baseada na Análise de
Texturas*

**DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE FEDERAL DE SANTA CATARINA
PARA OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA**

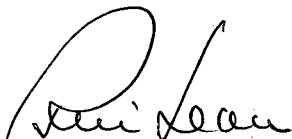
Orlando José Tobias

FLORIANÓPOLIS, AGOSTO DE 1995

INSPEÇÃO VISUAL AUTOMÁTICA BASEADA NA ANÁLISE DE TEXTURAS

CANDIDATO: ORLANDO JOSÉ TOBIAS

Esta dissertação foi julgada para obtenção do título de **MESTRE EM ENGENHARIA - ESPECIALIDADE ENGENHARIA ELÉTRICA** e aprovada em sua forma final pelo Curso de Pós-Graduação.



Prof. RUI SEARA, Dr.

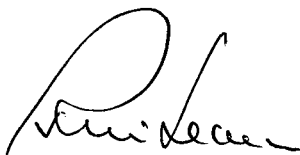
ORIENTADOR



Prof. ENIO VALMOR KASSICK, Dr.

COORDENADOR DO CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

BANCA EXAMINADORA:



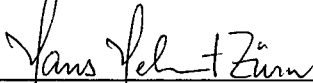
Prof. RUI SEARA, Dr.

PRESIDENTE

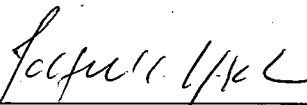


Prof. JOSÉ CARLOS MOREIRA BERMUDEZ, Ph.D.

CO-ORIENTADOR



Prof. HANS HELMUT ZÜRN, Ph.D.



Prof. JACQUES SZCZUPAK, Ph.D.



DIEGO PINTO DE GARRIDO, Ph.D.

*Caminante son tus huellas el camino
y nada mas....
caminante no hay camino
se hace camino al andar.
Al andar se hace camino
y al volver la vista atrás
se vé la senda que nunca más se ha de volver a pisar
caminante no hay camino sino estelas en la mar.....*

*Caminante no hay camino.....
se hace camino al andar...*

Joan Manuel Serrat

*À Patrícia,
que com sua força e alegria
me estimula à vida.*

AGRADECIMENTOS

Ao Laboratório de Instrumentação Eletrônica (LINSE) e aos professores que o integram, pelo suporte que, sem o qual, não seria possível a realização desta dissertação. Em especial aos professores Dr. Rui Seara e Dr. José Carlos Moreira Bermudez pela sua confiança e orientação dedicada a este trabalho.

Aos grandes amigos, Elton (*O Secretário*) e Ricardo (*Japonés*) pela agradável convivência (passada, presente e futura).

Ao grande Anderson (*Consultor especial*) pelas inestimáveis dicas na construção dos programas.

A todos aqueles integrantes do LINSE que, embora não mencionados nominalmente, colaboraram para a realização deste trabalho.

À sociedade brasileira, representada pelo CNPq, pela concessão de uma bolsa de estudos, permitindo assim a realização deste trabalho.

A meus pais Catalina e Orlando que, com enorme amor e sacrifício, fizeram com que eu possa chegar aonde cheguei. A Carolina.

RESUMO

A indústria, na última década, vem ampliando a utilização da visão artificial. Os principais fatores de contribuição são: os grandes avanços da microeletrônica e a disponibilidade no mercado de sistemas dedicados ao processamento de imagens com custo acessível. Desta forma é possível que os tempos envolvidos na execução dos algoritmos de análise de imagens sejam compatíveis com os exigidos pelos processos de manufatura. Em algumas indústrias, como por exemplo a indústria cerâmica, é necessário a inspeção visual da superfície do produto em suas diversas etapas de fabricação, resultando em um esforço tão importante quanto o processo de transformação do produto. O controle visual do produto se realiza em diferentes etapas do processo produtivo:

- a) *Etapas intermediárias*: nestas etapas o objetivo é eliminar do processo as peças com defeitos. Aqui a inspeção visual é de fundamental importância, uma vez que está relacionada diretamente com o custo de fabricação.
- b) *Controle de qualidade*: nesta etapa tem-se o produto final. Aqui a finalidade do controle visual é detectar e separar peças com defeitos, a fim de manter a qualidade exigida por um mercado cada vez mais competitivo.

Tradicionalmente a tarefa de inspeção visual depende fundamentalmente de inspetores humanos, cujo desempenho é variável e inadequado, especialmente para linhas de produção com grandes volumes de itens por unidade de tempo. Deve-se mencionar que na indústria cerâmica, o produto apresenta um alto índice de uniformidade, exigindo por parte do operador, uma grande concentração, que segundo estudos realizados não é possível ser mantida por longos períodos de tempo. Este último fato, inerente ao modo de como o ser humano trata texturas repetidas por longos períodos de tempo, associado a um ambiente de trabalho em geral não adequado (ruídos, alta temperatura, poluição, etc.), fazem com que seja vantajoso o emprego de um sistema de inspeção visual automático. Dentre outras vantagens deste sistema

pode-se citar: compatibilização das altas velocidades de produção com as altas velocidades de inspeção; evitar que tarefas rotineiras e monótonas sejam realizadas por operadores humanos; uniformizar critérios para determinar a conformidade ou não do produto; possibilitar de emitir relatórios e estatísticas de produção, a fim de atingir a máxima eficiência no processo produtivo. O presente trabalho aborda o emprego da inspeção visual utilizando a análise de textura como ferramenta. A metodologia de análise foi desenvolvida para ser utilizada pela indústria cerâmica. Descreve-se uma aplicação de matrizes de co-ocorrências na detecção de defeitos em peças cerâmicas.

ABSTRACT

Machine-vision systems are increasingly being applied in industrial processes. The main reasons are the recent advances in the fields of sensors, processors, memory, hardware components, etc., which are becoming both inexpensive and commercially available. It is therefore already possible to design cost-effective fast machine-vision systems that meet the high-speed requirements of an industrial process. In some industries (for example, the ceramic tiles industry), there exists a need for 100% on-line visual inspection of the surfaces. In these cases, the inspection task plays a role as important as the productive process itself. Traditionally, industrial visual inspection depends mainly on human inspectors whose performance is generally variable and inadequate to most modern high-speed industrial processes. An important example is the ceramic tiles industry. In the ceramic tiles industry, the product presents a high degree of uniformity. Thus, the visual inspection requires high concentration for observing the same type of texture repeatedly to detect anomalies. Several studies demonstrate the inability of humans to perform monotonous and endlessly routine jobs. Furthermore, there exist inappropriate or hazardous environments that make human presence dangerous. These factors favor the use of automated visual inspection systems. There are many benefits which accrue from using such a system. Some of these benefits are increased productivity, improved product quality, no human inspectors performing dull and monotonous tasks, high-speed inspection (matched with high-speed production), reduced human labor costs, etc. These have been key factors on the increasing use of machine-vision systems in industry. A natural approach to solve the problem of detecting defects is to use of co-occurrence matrices. Co-occurrence matrices can single pixel values that do not belong to a known texture. This paper describes an algorithm which uses machine-vision techniques to perform visual inspection tasks in the ceramic industry. This algorithm uses *difference statistics* to analyze images of ceramic tiles from the point of view of their texture content.

SUMÁRIO

AGRADECIMENTOS	iii
RESUMO	v
ABSTRACT	vii
SUMÁRIO	viii
LISTA DE FIGURAS	xii

INTRODUÇÃO. INSPEÇÃO VISUAL AUTOMÁTICA.

CONCEITOS BÁSICOS. APLICAÇÕES 1

CAPÍTULO I. APRESENTAÇÃO DOS OBJETOS SOB

ANÁLISE 15

INTRODUÇÃO 15

TIPOS DE DEFEITOS 15

CONCLUSÕES 21

CAPÍTULO II. TEXTURA 22

INTRODUÇÃO 22

ANÁLISE DA TEXTURA	25
AUTOCORRELAÇÃO E TEXTURA	27
MÉTODO ESPECTRAL	28
MODELO AUTO-REGRESSIVO	31
ESTATÍSTICAS DE SEGUNDA ORDEM	32
ESTATÍSTICAS DE DIFERENÇAS	33
RELAÇÕES ENTRE OS MÉTODOS DE ANÁLISE DE TEXTURAS	34
CAPÍTULO III. ESTATÍSTICA DE CO-OCORRÊNCIAS	35
INTRODUÇÃO	35
MATRIZES DE CO-OCORRÊNCIAS	35
APLICAÇÃO DAS MATRIZES DE CO-OCORRÊNCIAS À DETECÇÃO DE DEFEITOS COSMÉTICOS	41
ESTATÍSTICAS DE DIFERENÇAS 1	49
ESTATÍSTICAS DE DIFERENÇAS 2	53
DETECÇÃO DE DEFEITOS COSMÉTICOS	56
CONCLUSÕES	63
CAPÍTULO IV. DESCRIÇÃO DO SISTEMA	64
INTRODUÇÃO	64
SISTEMA AUTOMÁTICO DE INSPEÇÃO	64

AQUISIÇÃO.....	65
SEGMENTAÇÃO.....	66
LOCALIZAÇÃO.....	70
DETECÇÃO DE DEFEITOS EM BORDAS.....	75
DETECÇÃO DE DEFEITOS COSMÉTICOS.....	77
CAPÍTULO V. RESULTADOS EXPERIMENTAIS.....	78
INTRODUÇÃO.....	78
EXTRAÇÃO DAS CARACTERÍSTICAS.....	79
PROJETO DOS CLASSIFICADORES.....	79
MÉTODO 1: CLASSIFICADOR DE FISHER.....	84
MÉTODO 2: CLASSIFICADOR DE BAYES.....	86
MÉTODO 3: MÉTODO PROPOSTO.....	92
ANÁLISE DA COMPLEXIDADE COMPUTACIONAL.....	93
ANÁLISE DOS RESULTADOS.....	95
CAPÍTULO VI. CONCLUSÕES E SUGESTÕES.....	98
APÊNDICE.....	101
MÉTODO DE OTSU.....	101
MÉTODO PARAMÉTRICO.....	105

MÉTODO DE RIDLER-CALVARD	107
MÉTODO DE LLOYD	108
REFERÊNCIAS BIBLIOGRÁFICAS	109

LISTA DE FIGURAS

Fig. I.1.	Estrutura geral de um sistema de inspeção automático	7
Fig. I.2.	Mapeamento da imagem para o espaço de características	10
Fig. I.3.	Espaço de características: (a) caso ideal sem sobreposição entre classes; (b) caso com sobreposição	11
Fig. 1.1.	(a) e (b) Cerâmicas lisas de boa qualidade	19
Fig. 1.2.	Cerâmica lisa com defeito	21
Fig. 1.3.	a) e b) Cerâmicas decoradas sem defeito	22
Fig. 1.4.	Tipos de defeitos em cerâmicas decoradas: (a) mancha, (b) risco	23
Fig. 1.5.	Outros defeitos em cerâmicas decoradas: (a) mancha, (b) risco	24
Fig. 2.1.	Diferentes tipos de textura: (a) fina, (b) grossa, (c) periódica	29
Fig. 2.2.	Análise estrutural de texturas: imagem composta de texturas elementares	31
Fig. 2.3.	Espectro de potência. (a) Região anelar, (b) setor circular	34
Fig. 2.4.	(a) Textura periódica. (b) Espectro. (c) Gráfico de $P(r)$. (d) Gráfico de $P(\theta)$. (e) Imagem com outro tipo de textura periódica. (f) Gráfico de $P(\theta)$	36
Fig. 2.5.	Interrelações entre os diferentes métodos propostos para análise de texturas	39
Fig. 3.1.	Operador de posição \mathfrak{R} representando a relação “dois pixels à direita e um pixel para cima” na determinação da matriz \mathbf{P}	41
Fig. 3.2.	Relação de vizinhança entre dois níveis de cinza para um dado vetor \mathbf{d}	42
Fig. 3.3.	Obtenção da estatística de diferença a partir da matriz de co-ocorrências	55
Fig. 3.4.	Vetores ortogonais para o cálculo da matriz de co-ocorrências : (a) 0° (b) 90°	58
Fig. 3.5.	Estatísticas de primeira ordem correspondentes a duas peças com defeito e uma sem defeito	63
Fig. 3.6.	Comparação dos vetores \mathbf{h} entre uma peça com defeito e outra de referência; (a) região de diferenças $\{0, \dots, 14\}$; (b) ampliação da região de diferenças $\{10, \dots, 90\}$	67

Fig. 4.1. Diagrama em blocos do sistema de análise e classificação de peças cerâmicas	71
Fig. 4.2. Histograma dos níveis de cinza: (a) Aquisição efetuada incorretamente, (b) variáveis de aquisição corretamente fixadas.....	75
Fig. 4.3. Áreas de ação das máscaras para a detecção dos cantos da peça	77
Fig. 4.4. Máscara de detecção do canto superior esquerdo	78
Fig. 4.5. Canto superior esquerdo da imagem de peça binarizada. (a) Caso ideal; (b) caso real.....	80
Fig. 4.6. Regiões de análise. (a) Região de procura de defeitos em bordas; (b) região de procura de defeitos cosméticos	82
Fig. 4.7. (a) Rampa; (b) derivada da rampa, segundo o operador $D[.]$	83
Fig. 4.8. Derivada da imagem	84
Fig. 5.1. (a), (b) e (c) Três perspectivas do gráfico tridimensional das características (MEAN,CON,STD)	92
Fig. 5.2. Gráfico tridimensional das características (CON,ENT,STD)	93
Fig. 5.3. Classificador para o conjunto 1. Características: (a) CON,MEAN; (b) CON,STD ; (c) MEAN,STD.....	100
Fig. 5.4. Classificador para o conjunto 2. Características: (a) CON,ENT; (b) CON,STD; (c) ENT,STD	103
Fig. A.1. Fixação do limiar de binarização	116

INTRODUÇÃO.

**INSPEÇÃO VISUAL AUTOMÁTICA.
CONCEITOS BÁSICOS.
APLICAÇÕES.**

INTRODUÇÃO

OS AVANÇOS tecnológicos que as técnicas da visão por computador tem experimentado nos últimos anos, favoreceram sua utilização em várias aplicações industriais [1]. No início essas técnicas eram empregadas para resolver problemas de pouca complexidade, como operações simples de medição ou verificação da presença, posição e orientação de objetos [2]. Com o decorrer do tempo foi possível compreender melhor o processamento da informação visual feita pelos seres humanos. Este fato importante permitiu a construção de máquinas que possam analisar a informação visual de forma mais eficiente [3]. O conjunto de técnicas de visão por computador empregadas em aplicações industriais originou uma nova área de conhecimento denominada de *visão industrial* [4].

Essa nova área compreende o estudo dos processos que permitem às máquinas verem e atuarem em função do que estão vendo. Aqui se faz uso de praticamente todo o repertório de técnicas disponíveis de processamento de imagens [5]. A visão industrial é também utilizada em *robótica* [6]. É possível distinguir duas classes de robótica dependendo da sua aplicação: ativa e passiva.

Em *robótica ativa* realizam-se tarefas complexas de manipulação de materiais e/ou objetos. Aqui, requer-se que o sistema seja capaz de perceber a posição e a orientação de um objeto em três dimensões. A utilização da informação visual como realimentação torna-se muito atrativa, já que esse fato diminui significativamente os requisitos na malha de controle das partes mecânicas, permitindo um controle mais eficiente dos robôs destinados à manipulação de objetos [5].

Em *robótica passiva*, diferentemente da anterior, as imagens dos objetos são adquiridas e a informação obtida é usada para caracterizar e/ou classificar tais objetos (por exemplo: nas tarefas de inspeção visual automática).

A *visão industrial* é utilizada pela indústria para melhorar a *qualidade* e a *produtividade*, podendo ser aplicada com sucesso em uma ampla gama de processos industriais, tais como:

- 1) *Verificação* de itens, como na detecção de produtos incorretamente classificados;
- 2) *Medição* de dimensões críticas e detecção de peças com dimensões fora das especificações;
- 3) *Controle*, como no ajuste de posição de um objeto durante a tarefa de montagem;
- 4) *Reconhecimento* de itens a partir de um grupo de alternativas conhecidas;
- 5) *Orientação e posicionamento de objetos*. Essa tarefa representa uma etapa intermediária no processo de montagem;
- 6) *Inspeção* de itens na procura de amostras defeituosas;
- 7) *Leitura* de caracteres, indicadores, etc.

As tarefas de montagem, por exemplo, pertencem à robótica ativa. Entretanto, as tarefas de medição, inspeção, leitura são classificadas dentro da robótica passiva. Nesse último caso, a atuação física envolvida é mínima, normalmente consistindo em desviar os objetos a diferentes destinos em função da classe em que foram classificados pelo sistema.

Com a introdução deste tipo de sistemas é possível obter uma substancial melhoria no desempenho do resto das instalações. Às vezes, é possível realizar tarefas que de outro modo seriam impraticáveis ou economicamente onerosas. O atual estado do mercado requer a fabricação de pequenos lotes de diferentes produtos, com a possibilidade da introdução de futuros novos produtos. A flexibilidade introduzida pelos sistemas de visão industrial permite que um mesmo sistema projetado para realizar uma tarefa específica, adapte-se perfeitamente para tratar outros produtos sem perda de eficiência. Em síntese, com a incorporação da visão industrial, obtém-se um ganho imediato em velocidade, exatidão, consistência e relação custo-benefício. O aumento de flexibilidade representa às vezes um benefício secundário. Quando o produto é modificado, o sistema de visão pode ser perfeitamente adaptado para tratar com o novo produto mediante sua reprogramação.

A aplicação industrial das técnicas de visão por computador requer um metuculoso equilíbrio de quatro áreas:

- i) *algoritmos*
- ii) *arquiteturas de processamento*
- iii) *mecânica*
- iv) *sensores*

De fato, a integração dessas áreas é o que diferencia a visão industrial das técnicas comuns de processamento de imagem. Nessas últimas não existe uma preocupação, por exemplo, com a complexidade dos algoritmos ou com os cuidados necessários para a iluminação da cena na hora de adquirir uma imagem.

Quando se menciona visão *industrial*, invariavelmente imaginamos os olhos de robôs, encarregados de guiá-los em complexas tarefas tais como montagem ou

manipulação de materiais. Mas a atividade mais comum desempenhada pelos sistemas de visão industrial é na área de inspeção visual e/ou medição. As opções de inspeção visual automática podem ser agrupadas nas seguintes quatro áreas gerais [7]: metrologia determinística, medição *on-line*, inspeção *on-line* e controle de qualidade. Nas três primeiras opções a peça encontra-se ainda em processo de transformação.

A metrologia determinística (disciplina ainda em desenvolvimento) tem por objetivo antecipar possíveis problemas com a utilização de algoritmos preventivos. A inspeção por medição *on-line* é realizada durante o processo de fabricação, com a peça situada na máquina, e tem a vantagem da correção imediata do processo. Esse tipo de inspeção encontra-se limitado a poucas aplicações. No caso da inspeção *on-line*, tem-se a vantagem de evitar que peças com defeitos continuem no processo produtivo ocupando tempo de máquina e evitando desperdício de matéria-prima. Por último, a inspeção visual automática aplicada ao controle de qualidade tem por objetivo inspecionar 100% dos produtos manufaturados [8].

As quatro áreas anteriormente mencionadas incluem as mais variadas aplicações [9], desde inspeção de dimensões críticas, medição de contornos de peças manufaturadas, inspeção de superfícies, inspeção de soldas em placas eletrônicas, até inspeção de frutas. Nos últimos anos, um crescente número de estudos discutiu as vantagens e desvantagens das diferentes aplicações da visão industrial. Embora essa tecnologia possa ser potencialmente aplicável em inúmeras áreas, somente o reconhecimento de caracteres (OCR) atingiu a realidade comercial em grande escala [10]. Algumas atividades produtivas em que sistemas de inspeção visual, projetados para realizar tarefas específicas, encontram-se operando com sucesso, são:

- *Inspeção visual na indústria automobilística*: aplicações nessa área incluem inspeção de freios, pintura, eixos e uma grande variedade de outras partes e peças. Em [11-13] pode-se

encontrar uma grande variedade de tarefas onde a visão artificial é empregada nesta atividade industrial.

- *Inspeção visual na indústria de metais laminados* : as velocidades da maioria dos processos que produzem metais laminados são usualmente da ordem de 25 m/s sendo que um inspetor humano consegue inspecionar corretamente até velocidades de 3 m/s. Para esse tipo de aplicação a superfície é iluminada com luz coerente, onde a luz refletida e/ou dispersada é coletada e processada eletronicamente para efetuar a detecção e identificação dos defeitos. Em [14-17] detalha-se um sistema de inspeção automática aplicado à indústria de aço laminado.
- *Inspeção visual em outras indústrias* : a inspeção do produto nas diferentes etapas do processo produtivo, como também o controle de qualidade do produto terminado, tem uma significativa importância em várias indústrias. Sistemas automáticos de inspeção são atualmente usados na inspeção de diferentes processos. Alguns exemplos são: indústria têxtil, produtos farmacêuticos, indústria militar, papel, cerâmica, circuitos impressos, etc. Em [18-21] são apresentadas diversas aplicações do emprego dos sistemas de visão para estas indústrias.

Em [22] encontram-se listadas mais de 600 publicações em congressos e periódicos na área de inspeção visual automática.

Na indústria, a inspeção do produto é uma importante tarefa dentro do processo produtivo. Em alguns casos, requer-se atualmente que 100% das peças fabricadas sejam inspecionadas. Nesses casos, o processo de inspeção chega a ser tão importante quanto o processo de transformação da matéria-prima.

A tarefa mais difícil de inspeção é aquela na qual julga-se a aparência visual de um objeto. Atualmente, a inspeção visual depende principalmente de inspetores humanos, cujo desempenho é em geral variável e inadequado. O sistema visual humano está especialmente adaptado para as situações apresentadas pela vida cotidiana. No processo de inspeção visual é necessária a observação de um mesmo tipo de cena repetidas vezes, a fim de detectar anomalias em relação a um padrão. Também deve-se considerar a pressão cada vez maior exercida pelo mercado com o objetivo de obter produtos de qualidade. As dimensões dos defeitos que são considerados significativos encontram-se, às vezes, longe dos limites de percepção de um inspetor humano em um ambiente com razoáveis condições de trabalho. Condições ideais de trabalho são raras dentro de ambientes fabris. Além disso, estudos realizados [23-24] demonstram que o desempenho do sistema visual humano declina com as tarefas monótonas e rotineiras, permitindo que peças defeituosas não sejam percebidas. Como resultado, a tarefa de inspeção passa a ser custosa e errônea. É aqui que um sistema de inspeção visual automático representa uma alternativa vantajosa frente ao inspetor humano.

No mundo industrial, justificar a necessidade de um sistema de inspeção visual representa, às vezes, um difícil problema. A principal justificativa para a utilização desse tipo de sistema é a economia a médio e longo prazos, pois as máquinas oferecem uma relação custo-benefício melhor do que um inspetor humano. Outros objetivos importantes a serem considerados na automação de uma atividade visual, são:

- a) maior produtividade: os inspetores humanos são lentos quando comparados com as atuais velocidades de produção,

obtendo-se uma elevada taxa de erros; por outro lado, os sistemas automáticos possuem velocidade e capacidade de diagnóstico;

- b) dispensar operadores humanos de tarefas rotineiras;
- c) realizar tarefas de inspeção em ambientes perigosos;
- d) reduzir a demanda de inspetores humanos altamente qualificados;
- e) compatibilizar as velocidades de inspeção com as altas velocidades de fabricação.

Na Fig. I.1 mostra-se a estrutura geral de um sistema de inspeção visual automático aplicado à classificação de itens.

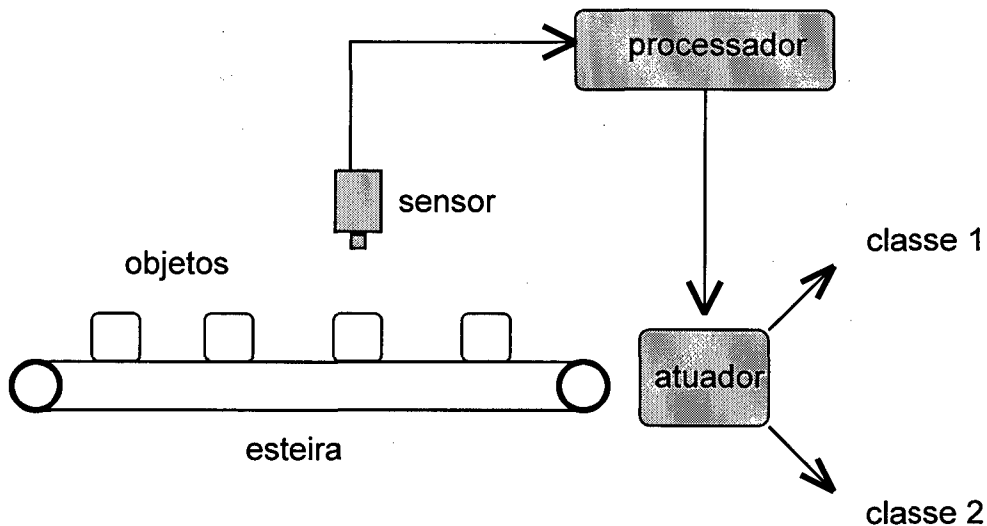


Fig. I.1 Estrutura geral de um sistema de inspeção automático.

No sistema ilustrado pela Fig. I.1, um sensor adquire a informação proveniente do mundo real. Tal informação é usualmente adquirida na forma de uma imagem do objeto que se quer analisar. Portanto, o tipo de sensor mais comum utilizado na área de automação inteligente é uma câmera que gera um sinal eletrônico como saída. Dependendo do tipo de tarefa, podem ser encontrados sensores de diversos tipos, como sensores de pressão, força, posição ou aceleração. O sinal é transportado a um processador, geralmente um computador digital. O tipo de processador utilizado depende fortemente da aplicação em questão. Para processamento "on-line", é preciso utilizar processadores com arquiteturas dedicadas. Geralmente são utilizados dois ou mais processadores em paralelo, objetivando principalmente processar a informação em tempo real. Além de um processador adequado, o algoritmo utilizado deve ser de complexidade mínima. O principal objetivo é atingir um equilíbrio entre as partes que constituem o sistema total.

A estrutura mostrada na Fig. I.1 pode substituir e melhorar as atuais operações de inspeção visual. A câmera e o processador "substituem" o inspetor humano numa típica linha de produção. A esteira leva os objetos a serem inspecionados até a câmera, a qual digitaliza a imagem da cena contendo um objeto. Tal imagem é enviada ao processador para ser analisada. Após esse processo, é tomada a decisão sobre a classe a que pertence o objeto em análise. Em função da classe determinada, deve-se acionar um mecanismo a fim de separar os objetos segundo sua classificação.

Numerosos métodos de reconhecimento de padrões orientados para a separação em classes têm sido propostos [25-27]. A subtração de imagens foi um dos primeiros métodos empregados para realizar a inspeção automática. Neste método, realiza-se uma simples operação *OU EXCLUSIVO* entre a imagem de uma peça sem defeito (considerada de referência) e a imagem da peça a ser inspecionada. A vantagem deste método é sua simplicidade de implementação, com a conseguinte alta velocidade de operação. Porém, este método apresenta algumas desvantagens:

- a) variações normais na produção de peças do mesmo tipo são suficientemente significativas para criar diferenças entre peças sem defeito, as quais não são toleradas pelo método. Como conseqüência, muitos falsos alarmes são originados por esta técnica;
- b) a necessidade de coincidência entre a posição da peça a ser inspecionada e a posição em que foi tomada a imagem da peça de referência. Isto requer um dispositivo mecânico de alta precisão ou um algoritmo de pré-processamento. Tais ferramentas de correção seriam encarregadas de rotacionar e/ou deslocar a peça ou sua imagem para colocá-la na posição correta. A utilização de qualquer uma das soluções representa um grau de complexidade adicional, que, às vezes não é admitido pelo processo;
- c) para aplicações em que se deseja verificar dimensões, torna-se muito difícil expressar as tolerâncias de medição. Portanto, este método é muito pouco utilizado para tal.

Atualmente os métodos mais utilizados para inspeção automática são baseados em mapeamentos da informação da imagem adquirida para um espaço de características (Fig. I.2). O volume de informações contidas em uma imagem é muito grande. Usualmente uma imagem é armazenada na forma de uma matriz numérica podendo ter dimensões de até 2048×2048 pixels. O objetivo da função de mapeamento $F(I)$ é caracterizar a informação visual contida na imagem I mediante um número reduzido de parâmetros. O número m de características extraídas de uma imagem define a dimensão deste espaço ($P \in \mathcal{R}^m$). A classificação das amostras é realizada pela comparação entre as características de uma peça padrão e as respectivas características da peça em estudo.




Fig. I.2 Mapeamento da imagem para o espaço de características.

A seleção das características mais apropriadas para representar a imagem de uma peça é de fundamental importância no desempenho do algoritmo de classificação. Se as características forem corretamente escolhidas, os grupos que representam as diferentes classes (classes com defeito e sem defeito) não devem se sobrepor (Fig. I.3a). Como não se conhece a priori a localização das duas classes dentro do espaço de características, utiliza-se um grupo de amostras com identificação conhecida denominado de conjunto de treinamento ou conjunto de projeto. A análise deste conjunto permite determinar os limites de separação entre os grupos. Uma vez que as classes foram identificadas, uma amostra arbitrária pode ser classificada em relação à sua localização no espaço de características. Na prática, normalmente obtém-se alguma sobreposição entre as diferentes classes (Fig. I.3b). Esse último fato terá como resultado eventuais classificações incorretas de algumas amostras de entrada. Um dos objetivos da função de mapeamento é a obtenção de uma taxa mínima de classificações incorretas.

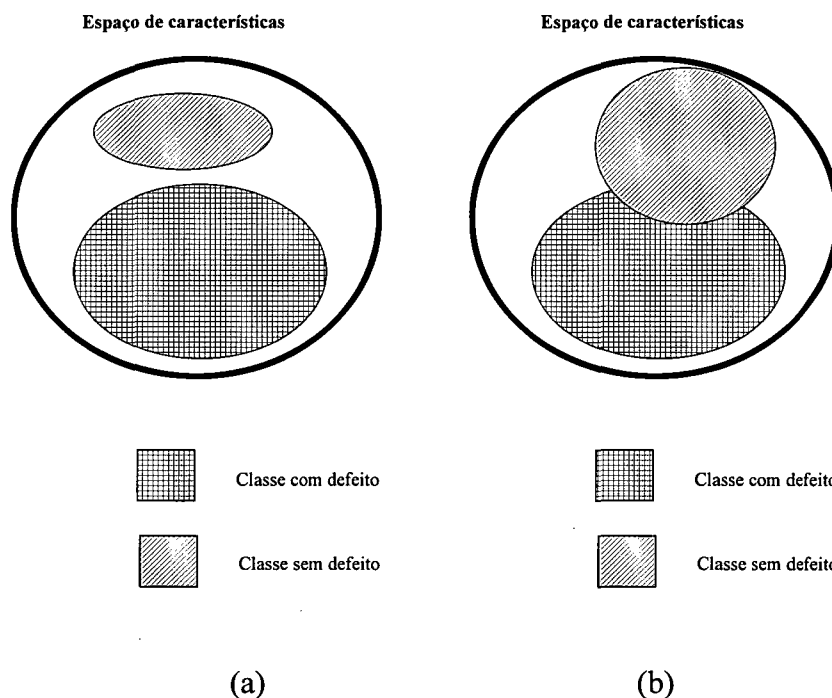


Fig. I.3 Espaço de características: (a) caso ideal sem sobreposição entre classes; (b) caso com sobreposição.

Considerando o exposto anteriormente, fica evidenciado que uma das etapas críticas no projeto de um sistema de inspeção industrial reside nas definições do espaço de características e da função de mapeamento a serem utilizados. Uma das características mais utilizadas atualmente na inspeção de imagens é a textura. A textura dos diversos materiais ou produtos manufaturados formam uma base de informações de onde diversas propriedades importantes podem ser extraídas. A análise de texturas tem sido reconhecida como um dos mais importantes critérios na definição das funções de mapeamento.

A análise de texturas pode ser efetuada utilizando-se diferentes pontos de vista [28]. Do ponto de vista analítico, a textura caracteriza a distribuição espacial dos níveis de cinza da imagem. A análise de texturas resulta numa representação concisa (modelo) da região da imagem que estamos analisando. Em alguns casos a textura pode ser decomposta em duas componentes básicas: a primeira delas chamada de primitiva e a

segunda constituída pelas regras de alocação espacial das primitivas. Nestes casos, o tipo de análise é conhecido como análise estrutural [29-30]. Dentro do contexto da análise estrutural, o interesse principal encontra-se na extração das primitivas ou texturas elementares. Wang [31] comparou três métodos destinados à extração de primitivas.

Quando as primitivas e suas regras de alocação espacial não são facilmente separáveis, a textura é analisada estatisticamente. Julesz [32] mostrou a importância da estatística de segunda ordem para descrever e discriminar visualmente as texturas. Haralick [33] introduziu matrizes que levam em consideração a dependência espacial dos níveis de cinza de uma imagem. Estas matrizes são denominadas matrizes de co-ocorrências. Cada matriz é obtida percorrendo-se a imagem com uma janela (retangular ou quadrada) de observação. Cada elemento destas matrizes representa a frequência relativa entre dois níveis de cinza dentro da janela, separados por uma distância pré-definida. Para cada matriz são calculadas algumas medidas básicas de textura (média, desvio padrão, momento angular, momento angular de segunda ordem, correlação, etc.). Inicialmente este método foi utilizado na classificação automática de texturas em imagens de satélite [34-35].

Outro método empregado baseia-se na procura de parâmetros que são utilizados pelo sistema visual humano na tarefa de discriminação de texturas. Tamura [36], definiu alguns parâmetros de textura que correspondem ao sistema visual humano, sendo rugosidade, contraste e direcionalidade os parâmetros globais mais importantes.

O presente trabalho aborda o emprego da inspeção visual automática utilizando a análise de textura como ferramenta. A metodologia de análise foi desenvolvida para ser utilizada pela indústria cerâmica. Este tipo de indústria requer atualmente que 100% dos produtos sejam visualmente inspecionados. O controle visual do produto é realizado em diferentes etapas do processo produtivo:

- a) *etapas intermediárias*: etapas cujo objetivo é eliminar do processo as peças com defeitos. Aqui a inspeção visual é de fundamental importância, uma vez que está relacionada diretamente com o custo de fabricação;
- b) *controle de qualidade*: nessa etapa tem-se o produto final. Aqui a finalidade do controle visual é detectar e separar peças com defeitos, a fim de manter a qualidade exigida por um mercado cada vez mais competitivo.

A tarefa de inspeção visual na indústria cerâmica é, ainda hoje, fortemente dependente de inspetores humanos. Nas linhas de produção modernas existem grandes volumes de itens por unidade de tempo. Considerando que nesta indústria os produtos apresentam um alto índice de uniformidade, exige-se uma grande concentração por parte do operador. Essa conjunção de fatores torna errática a tarefa de inspeção manual. Outro fator que também deve ser considerado é o modo como o ser humano trata texturas repetidas por longos períodos de tempo, associado a um ambiente de trabalho que é em geral inadequado (ruídos, alta temperatura, poluição, iluminação inadequada, etc.). Estes fatores fazem com que seja vantajoso o emprego de um sistema de inspeção visual automático. Dentre as vantagens já citadas pode-se incluir também a uniformização de critérios para determinar a conformidade ou não do produto, a possibilidade de emitir relatórios e estatísticas de produção, a fim de atingir-se a máxima eficiência no processo produtivo.

Os tipos de defeitos que devem ser detectados estão relacionados com a aparência da peça. Estes defeitos são conhecidos na literatura como *defeitos cosméticos*. Os tipos mais comuns de defeitos podem acontecer em duas regiões da peça cerâmica: no perímetro e/ou na superfície. Os defeitos no perímetro ocorrem sob a forma de cantos quebrados e/ou lascados. Os defeitos na superfície podem pertencer a duas classes: modificação na topologia da superfície da peça e defeitos no desenho decorativo.

Neste trabalho propõe-se um algoritmo de inspeção visual automático baseado na análise de texturas com o objetivo da detecção dos defeitos cosméticos. O algoritmo desenvolvido para o problema da inspeção automática de cerâmicas utiliza um subconjunto da estatística de co-ocorrências [33], a estatística de diferenças [37]. Baseado nesta última técnica de análise, foi desenvolvida uma nova metodologia de análise de texturas capaz de tratar com as duas classes de defeitos anteriormente apresentadas.

No Capítulo I são apresentados os tipos de objetos que vamos tratar e os defeitos que eles apresentam. No Capítulo II, são apresentadas as abordagens clássicas usadas na classificação automática de texturas. No Capítulo III é abordada uma revisão da teoria referente às matrizes de co-ocorrências junto com o algoritmo proposto de classificação. O Capítulo IV aborda o diagrama em blocos do sistema de inspeção visual proposto, apresentando-se as funções de cada um deles. No Capítulo V veremos os resultados experimentais, que indicam a habilidade do algoritmo para a detecção de defeitos. Finalmente, na Conclusão são apresentadas as conclusões e sugestões tiradas deste trabalho.

CAPÍTULO I.

APRESENTAÇÃO DOS OBJETOS SOB

ANÁLISE

APRESENTAÇÃO DOS OBJETOS SOB ANÁLISE

I.1 INTRODUÇÃO

ATÉ o presente não foi desenvolvido um sistema de visão artificial de propósito geral que se iguale em desempenho ao sistema visual dos seres humanos. Portanto, um sistema destinado a realizar uma tarefa de inspeção visual automática deve operar sobre objetos específicos ou classes de objetos. Esta operação deve ocorrer em condições cuidadosamente controladas para maximizar seu desempenho. Assim, quanto maior for o conhecimento dos objetos a serem analisados e os tipos de defeitos que eles podem conter, melhor e mais precisamente será definida uma abordagem para a solução do problema.

Em geral, defeito é a falta de conformidade de alguma característica de um produto quando comparado com seu respectivo padrão. O conceito de defeito encontra-se intimamente relacionado com a definição de peça padrão. Uma definição clara e objetiva de padrões possibilitará a criação de bases robustas de análise que permitam a avaliação da qualidade da peça. Neste capítulo são apresentados os objetos sob análise juntamente com os defeitos que eles apresentam.

I.2 TIPOS DE DEFEITOS

Antes de apresentar os diferentes tipos de defeitos devemos conhecer o processo de decoração das cerâmicas.

Existem basicamente três tipos de processos que permitem decorar a superfície de uma cerâmica: pintura, litografia e texturização.

O conjunto de cerâmicas ilustradas pelas fotografias mostradas na Fig.1.1 é decorado por pintura. Neste caso, as peças são pintadas por meio de um jato de tinta de uma única cor. As cerâmicas assim manufaturadas pertencem ao conjunto das cerâmicas lisas. A seguir definimos o que consideramos uma cerâmica de boa qualidade (cerâmica aceitável), em termos de qualidade superficial:

Cerâmica aceitável: não existe cerâmica que possa ser considerada perfeita do ponto de vista de "não possuir defeito". Uma cerâmica é considerada de boa qualidade quando o número de defeitos cosméticos é considerado aceitável pelo controle de qualidade. Na Fig. 1.1, pode-se observar o que foi dito anteriormente sobre a qualidade superficial típica considerada aceitável. Nessa figura observa-se, por exemplo, que a presença de pequenos pontos escuros espalhados pela superfície das cerâmicas não chegam a inutilizar a peça. Por outro lado, uma cerâmica com a mesma quantidade de pontos escuros agrupados numa pequena área, deverá ser considerada agora defeituosa. Tal situação é ilustrada pela Fig.1.2. A classe de defeito representada por essa figura ilustra o tipo de defeito mais comum encontrado em cerâmicas decoradas por pintura.

As cerâmicas decoradas por litografia têm como característica um alto índice de uniformidade no desenho decorativo. Tal característica pode ser observada na Fig. 1.3 onde se ilustram cerâmicas sem defeito com desenho obtido a partir deste procedimento. Nas imagens desta classe de cerâmicas estes vários possíveis defeitos [18] podem ser classificados em duas categorias básicas:


- i) Defeitos caracterizados pela alteração de níveis de cinza em alguma região, em relação aos existentes na imagem da peça padrão. Na

imagem da peça, esses defeitos têm o aspecto de uma mancha ou risco. Alguns exemplos típicos destes defeitos são apresentados na Fig. 1.4. A Fig.1.4a ilustra um defeito sob a forma de mancha e a Fig.1.4b um defeito na forma de risco.


ii) Defeitos oriundos de uma má colocação da placa litográfica na peça a ser decorada. O resultado final deste tipo de defeito é um deslocamento do desenho decorativo da peça em relação ao da peça padrão.

No caso de decoração da peça empregando a técnica de texturização é possível obter superfícies cujas texturas não apresentam variações relevantes entre as peças assim decoradas. Este fato pode ser observado nas fotografias da Fig. 1.6. Os únicos tipos de defeitos presentes nesta classe de cerâmicas são nas formas de manchas ou riscos, tal como é ilustrado pela Fig. 1.5.

Outros tipos de defeitos, comuns a todas as classes de peças cerâmicas, são aqueles que ocorrem nas bordas ou cantos. Tais defeitos apresentam-se sob a forma de bordas lascadas e/ou cantos quebrados.



(a)



(b)

Fig. 1.1. Cerâmicas lisas de boa qualidade.






Fig. 1.2. Cerâmica lisa com defeito.




(a)




(b)

Fig. 1.3. Cerâmicas decoradas sem defeito.



(a)



(b)

Fig. 1.4. Tipos de defeitos em cerâmicas decoradas. (a) mancha, (b) risco.




Fig. 1.5. Outros defeitos em cerâmicas decoradas: (a) mancha, (b) risco.

I.3 CONCLUSÕES

A noção da estrutura do defeito e o conhecimento preciso dos objetos são essenciais para a precisa determinação da abordagem do problema em questão. Devemos lembrar também que tal abordagem deve ser compatível com a filosofia de projeto de um sistema que possa ser utilizado pela indústria. Como foi mencionado no capítulo anterior, o algoritmo de análise de textura inclui como pré-requisito de projeto apresentar a mínima complexidade possível. Isto implicará em um menor custo para o restante dos sub-sistemas requeridos para implementar o sistema de inspeção visual automática.

CAPÍTULO II.

TEXTURA

TEXTURA

II.1 INTRODUÇÃO

NA ÁREA de visão computacional, a textura é uma característica muito importante na análise de imagens. A textura permite caracterizar e descrever uma ampla gama de tramas e estruturas, desde imagens de satélite até imagens médicas. Tal característica é amplamente empregada para a segmentação de imagens [21]. Pode também ser usada como elemento de informação de classificação e no reconhecimento de objetos [38]. Apesar da sua grande importância, ainda não existe uma definição formal de textura [39]. Técnicas *ad-hoc* são utilizadas para a discriminação de texturas na maioria dos casos práticos. O objetivo principal desta técnica de análise é extrair da imagem informações que permitam caracterizar sua textura por meio das variações dos níveis de cinza. Quando a textura pode ser decomposta, esta decomposição é feita em duas dimensões básicas. A primeira dimensão descreve as primitivas ou texturas elementares com que a textura é composta. A segunda dimensão descreve a dependência espacial ou a relação entre as primitivas. A descrição das primitivas está relacionada com as propriedades locais, também chamadas de primitivas tonais. Primitivas tonais são regiões com propriedades tonais bem estabelecidas. Essas podem ser descritas em termos do tom médio de uma região específica [31], ou também pelo valor máximo-mínimo do tom de cinza nessa região [40]. Por região considera-se um conjunto conexo de pixels com uma determinada propriedade tonal. Às vezes tem-se interesse em avaliar a região tonal em termos de sua área e/ou sua forma [41].

A textura de uma imagem é descrita tanto pelo número quanto pelo tipo de primitivas, assim como pela organização espacial das mesmas. A organização espacial pode ser aleatória, ou pode existir uma dependência espacial entre duas ou mais primitivas. Tal dependência pode ser estrutural, probabilística ou funcional.


A textura pode ser avaliada como sendo fina, grossa, periódica, etc. (Fig. 2.1). Cada um destes adjetivos traduz alguma propriedade das primitivas tonais e de sua relação espacial. Infelizmente, existem poucas técnicas orientadas a mapear o conteúdo semântico destas características (usadas na avaliação de texturas) em propriedades precisas das primitivas tonais e de sua distribuição espacial [43].



(a)



(b)



(c)

Fig. 2.1: Diferentes tipos de textura : (a) fina, (b) grossa, (c) periódica.

A análise de texturas está baseada na utilização de dois conceitos fundamentais, o *tom* e o *tipo de textura*. Se dentro de uma região os níveis de cinza não apresentam variações significativas, a propriedade presente é o tom. Caso contrário, se os níveis de cinza apresentam uma ampla variação, a propriedade que descreve a região é o tipo de textura.

Para utilizar objetivamente o conceito de tom e textura, ambos devem ser explicitamente definidos. Uma vez definidos, constata-se que eles não são conceitos independentes [33]. Estes compartilham uma intrincada relação, da mesma forma que o conceito de *onda-partícula*, onde dependendo da situação, um deles pode predominar sobre o outro. Similarmente, numa imagem, o tom e a textura encontram-se sempre presentes, porém em determinadas situações uma propriedade pode predominar sobre a outra.

Os conceitos de tom e textura são definidos para uma região. Portanto, devemos considerar o tamanho da região em relação ao tamanho das primitivas tonais, assim como o número de primitivas distinguíveis dentro desta região. Quando o número de primitivas

diminui, as propriedades tonais predominam. De fato, quando se considera uma região do tamanho de um pixel, a única característica presente é o tom. Se o número de primitivas tonais aumenta dentro da região, a propriedade dominante é a textura.

Em relação ao anteriormente discutido, uma textura fina é caracterizada por uma distribuição espacial aleatória das primitivas tonais e com uma ampla variação entre as mesmas (Fig. 2.1a). Se a distribuição espacial é definida e as regiões tonais compreendem grandes quantidades de pixels, teremos uma textura grossa (Fig. 2.1b).

Resumindo, para caracterizar uma textura, devemos caracterizar as propriedades das primitivas tonais e as relações espaciais entre elas. Isto implica em que o conceito *tom-textura* é uma estrutura de duas camadas. A primeira está relacionada com a especificação das propriedades locais que se manifestam por meio das primitivas tonais. A segunda especifica sua organização espacial.

II.2 ANÁLISE DA TEXTURA

A textura pode ser analisada de vários pontos de vista, mas os principais são o *estatístico* [10, 23-24, 33, 42], o *estrutural* [29-30, 37, 44-45] e o *espectral* [29]. No nível estatístico, as características locais são computadas paralelamente para cada ponto ou região de uma imagem. Depois, deriva-se um conjunto de estatísticas globais a partir das distribuições das características locais. Em função do número de pontos que foram considerados na definição das características locais, a estatística é classificada como sendo de primeira ordem, segunda ordem, etc. As estatísticas não necessariamente devem ser tomadas só para as intensidades. Também podem ser consideradas outras características locais, como bordas, manchas, etc., visando avaliar alguma propriedade específica da textura. No nível estrutural, a textura é considerada como sendo composta de texturas elementares, Fig. 2.2.




Fig. 2.2: Análise estrutural de texturas: imagem composta de texturas elementares.

As propriedades das texturas elementares e as regras de distribuição espacial das mesmas definem a textura. A diferença em relação ao caso estatístico é que a análise estrutural é mais complexa, sendo necessária uma quantidade de informações maior e mais detalhada. Com tais informações sempre será possível reconstruir a textura original a partir da descrição das texturas elementares e de suas regras de distribuição espacial. No tratamento estrutural, a idéia é agrupar regiões com propriedades similares e formadas pela mesma regra de distribuição espacial das texturas elementares. Finalmente, as

técnicas espectrais são utilizadas para análise, principalmente quando se deseja detectar uma periodicidade global dentro da imagem.

A seguir apresentamos um resumo dos principais métodos de caracterização da textura.

II.2.1 AUTOCORRELAÇÃO E TEXTURA

Na seção anterior, vimos que a textura encontra-se intimamente relacionada com as primitivas tonais da imagem. Amplas regiões de primitivas tonais são indicativos de uma textura grossa. Primitivas tonais com pequenas dimensões caracterizam uma textura fina. Mediante a utilização da função de autocorrelação, é possível obter informações acerca do tamanho das primitivas tonais. A expressão matemática da função de autocorrelação normalizada [28] para uma função bidimensional é:

$$\rho(u,v) = \frac{\frac{1}{(N_x - |u|)(N_y - |v|)} \int \int_{-\infty}^{+\infty} \mathbf{I}(x,y) \mathbf{I}(u+x, v+y) dx dy}{\frac{1}{N_x N_y} \int \int_{-\infty}^{+\infty} \mathbf{I}^2(x,y) dx dy}, \quad \begin{cases} |u| < N_x \\ |v| < N_y \end{cases} \quad (2.1)$$

onde $\mathbf{I}(x,y)$ é a intensidade do pixel (x,y) em uma imagem de dimensões $N_y \times N_x$.

Se as primitivas tonais existentes na imagem apresentam elementos com dimensões relativamente grandes, a função de autocorrelação decrescerá suavemente com a distância. Se, por outro lado, as primitivas tonais apresentam elementos com dimensões pequenas, a função de autocorrelação decairá mais rapidamente. No caso em que as primitivas tonais possuam um padrão periódico na distribuição espacial, a função de autocorrelação será periódica com o mesmo período de repetição das primitivas tonais. A função de autocorrelação e a função densidade espectral de potência, são a transformada de Fourier do outro.

II.2.2 MÉTODO ESPECTRAL

A textura pode ser analisada no domínio da transformada de Fourier. Seja uma imagem de dimensões $N_y \times N_x$ com intensidade $I(x, y)$. A transformada discreta de Fourier de I , é definida por:

$$F(u, v) = \sum_{x=0}^{N_x-1} \sum_{y=0}^{N_y-1} I(x, y) e^{(-2\pi j(\frac{ux}{N_x} + \frac{vy}{N_y}))} \quad (2.2)$$

A densidade espectral de energia é dada por:


$$P(u, v) = |F(u, v)|^2 \quad (2.3)$$

Bajcsy [34], propôs as seguintes funções de distribuição de energia a partir da potência espectral em coordenadas polares $P(r, \theta)$.


$$P(r) = 2 \sum_{\theta=0}^{\pi} P(r, \theta) \quad (2.4)$$

$$P(\theta) = \sum_{r=0}^{n/2} P(r, \theta) \quad (2.5)$$

onde $P(r)$ é a soma das potências numa região anelar (Fig. 2.3a) e $P(\theta)$ representa a soma das potências em uma região com forma de um setor circular como mostrado na Fig. 2.3b.



(a)




(b)


Fig. 2.3: Espectro de potência. (a) Região anelar, (b) setor circular.

Um pico na função $P(r)$ indica o tamanho da textura elementar dominante, enquanto que um pico em $P(\theta)$ indica a direção dominante das texturas elementares. Na Fig. 2.4a, mostra-se a imagem de uma textura periódica e na Fig. 2.4b seu espectro. Nas Figs. 2.4c e 2.4d estão representadas as funções $P(r)$ e $P(\theta)$, respectivamente. Do gráfico


de $P(\theta)$ observa-se que existem picos a cada 45° , indicando a periodicidade angular da imagem. É interessante comparar com outra imagem contendo uma textura diferente, ilustrada na Fig. 2.4e, onde se observa a periodicidade existente em intervalos de 90° . Tal como pode ser observado na correspondente função $P(\theta)$ na Fig. 2.4f. Em [35] é feita uma comparação da eficácia de algumas técnicas de classificação de texturas de imagens de satélite. A conclusão tirada desse trabalho foi que a frequência espacial não é tão eficiente para um processo de classificação quanto os métodos que utilizam as estatísticas de primeira e de segunda ordens. A utilidade da análise espectral, nesta aplicação, reside na possibilidade de filtrar as componentes periódicas da imagem para permitir uma análise mais eficiente das componentes não periódicas usando métodos estatísticos.



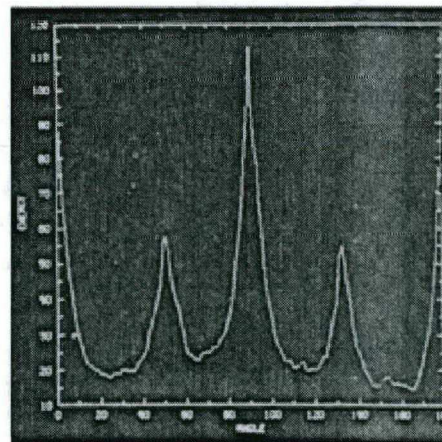
(a)



(b)



(c)



(d)




Fig. 2.4: a) Textura periódica. (b) Espectro. (c) Gráfico de $P(r)$. (d) Gráfico de $P(\theta)$. (e) Imagem com outro tipo de textura periódica. (f) Gráfico de $P(\theta)$.

II.2.3 MODELO AUTO-REGRESSIVO

A análise de séries temporais é bem conhecida no estudo de sinais unidimensionais. Um de seus principais empregos é na estimação de valores futuros (predição) de um sinal a partir de valores referentes a instantes de tempo passados. Para aplicar estes conceitos ao caso de processamento de imagens, devemos estender o método de autorregressão para o caso bidimensional [46, 48].

Seja $I(x,y)$ o tom de cinza no ponto (x,y) da imagem, gerada pela combinação linear de uma região definida por $I(x-p,y-q)$ de dimensões $N \times N$ pixels afetada por um ruído branco aditivo, $w(x,y)$, dada por:

$$\mathbf{I}(x,y) = \sum_{p=-N}^N \sum_{\substack{q=-N \\ (p,q) \neq (0,0)}}^N a_{pq} \mathbf{I}(x-p, y-q) + \mathbf{w}(x,y) \quad (2.6)$$

Os coeficientes a_{pq} são os parâmetros utilizados para caracterizar o tipo de textura contida na imagem. O modelo autorregressivo é utilizado, principalmente, tanto para a geração de texturas sintéticas, quanto para as aplicações de segmentação de imagens. A limitação deste método está ligada, basicamente, às classes de texturas que podem ser caracterizadas sendo que são as microtexturas as que melhor se adaptam às técnicas que utilizam métodos de autorregressão.

II.2.4 ESTATÍSTICAS DE SEGUNDA ORDEM

Seja $\mathbf{d}=(\rho\Delta x, \nu\Delta y)$ um vetor definido no plano (x,y) . Para qualquer imagem \mathbf{I} e qualquer vetor \mathbf{d} é possível calcular a densidade de probabilidade conjunta de pares de níveis de cinza que ocorrem numa imagem separados por uma distância \mathbf{d} . Se cada ponto da imagem é quantizado em N_g níveis, essa densidade de probabilidade pode ser expressa na forma de uma matriz $\mathbf{P}(i,j,\mathbf{d})$, onde o elemento p_{ij} da matriz representa a probabilidade de que o par de níveis de cinza (i,j) ocorra com uma separação dada por \mathbf{d} . A matriz $\mathbf{P}(i,j,\mathbf{d})$, assim formada, terá dimensões $N_g \times N_g$. $\mathbf{P}(i,j,\mathbf{d})$ é usualmente conhecida como *matriz de co-ocorrências* [42, 47].

Se a textura da imagem é grossa, e \mathbf{d} é pequeno em relação ao tamanho dos elementos da textura elementar, os pares de pontos separados por \mathbf{d} terão aproximadamente o mesmo nível de cinza. Isto significa que as grandezas maiores se concentraram na ou muito próxima da diagonal principal da matriz $\mathbf{P}(i,j,\mathbf{d})$. No caso de uma textura fina os valores em $\mathbf{P}(i,j,\mathbf{d})$ se encontrarão mais uniformemente distribuídos.

Se a textura for direcional o grau de dispersão dos valores ao redor da diagonal principal variará em função das diferentes direções do vetor \mathbf{d} . A direcionalidade da textura numa imagem pode ser avaliada pela comparação da dispersão entre as matrizes $P(i,j,\mathbf{d})$ obtidas para cada \mathbf{d} . Haralick [33] propôs um conjunto de medidas com o objetivo de extrair informação de textura a partir das matrizes de co-ocorrências.

II.2.5 ESTATÍSTICAS DE DIFERENÇAS

Um outro tipo de estatística que pode ser empregada para a análise de texturas são as estatísticas (ou estatísticas de primeira ordem) de propriedades locais tais como média, variância, etc. Neste caso, estamos interessados nas propriedades locais baseadas nas diferenças absolutas entre pares de níveis de cinza. Dado um vetor \mathbf{d} calcula-se a matriz $\mathbf{D}(x,y,\mathbf{d})=|I(x,y)-I(x+\rho\Delta x,y+v\Delta y)|$. A partir do histograma da matriz $\mathbf{D}(x,y,\mathbf{d})$ é possível extrair uma série de parâmetros para caracterizar a textura de uma imagem. Em [35] é demonstrado que a estatística de diferenças se constitui num subconjunto da matriz de co-ocorrência.

Existem outros métodos de análise de texturas baseados em transformadas óticas, número de bordas por unidade de área, etc.

A escolha de um método de análise depende fundamentalmente do problema a ser resolvido. Cada um desses métodos possui suas vantagens e desvantagens. O presente trabalho, por ser uma aplicação industrial, requer que o algoritmo de análise empregado seja de mínima complexidade computacional. Dentre os métodos anteriormente apresentados o que satisfaz o pré-requisito de apresentar uma baixa complexidade computacional é aquele baseado no subconjunto da matriz de co-ocorrências (estatísticas de diferenças). A escolha deste método é também motivada pela conjectura de Julesz [32]

a qual preconiza que as estatísticas de segunda ordem são suficientes para a discriminação de texturas pelos seres humanos.

II.2.6 RELAÇÕES ENTRE OS MÉTODOS DE ANÁLISE DE TEXTURAS

No diagrama em blocos (Fig. 2.5) são ilustradas as relações existentes entre os diferentes métodos de análise de texturas apresentados neste capítulo e no seguinte [37].

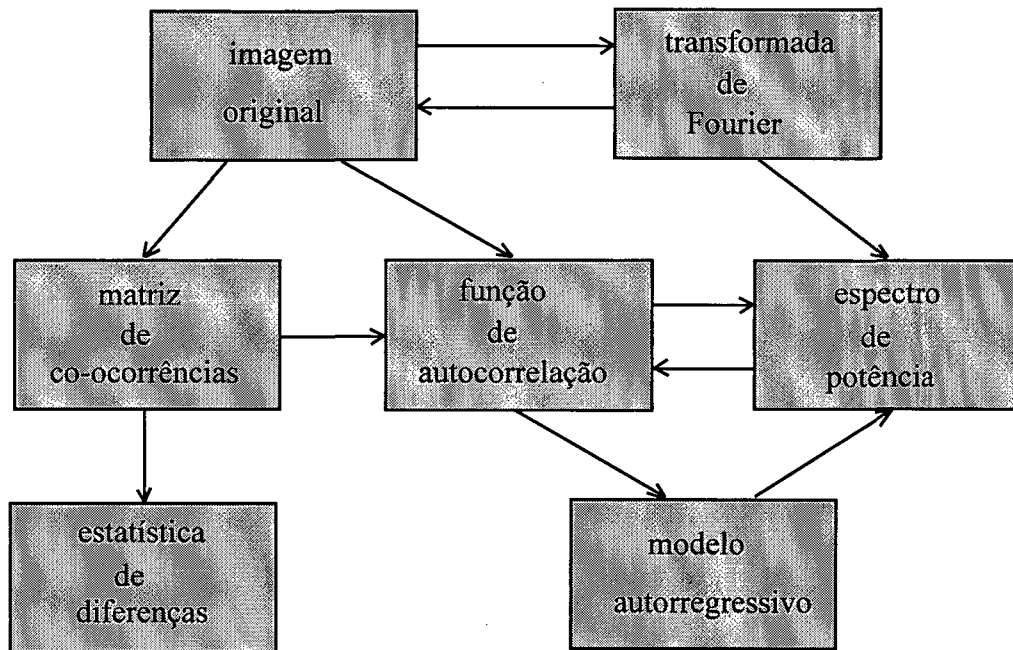


Fig. 2.5: Inter-relações entre os diferentes métodos propostos para análise de texturas.

CAPÍTULO III.

ESTATÍSTICA DE CO-OCORRÊNCIAS

ESTATÍSTICA DE CO-OCORRÊNCIAS

III.1 INTRODUÇÃO

NESTE Capítulo são apresentados, primeiramente, os conceitos teóricos das matrizes de co-ocorrência. Na Seção III.2, essa teoria é utilizada como ferramenta na solução ao problema de detecção de defeitos em cerâmicas. Também nessa seção, são obtidas as regras para a classificação das peças como sendo defeituosas ou não. Entretanto, a utilização direta das matrizes de co-ocorrência acarreta uma série de problemas (capacidade de armazenamento, complexidade computacional, etc.). Tais problemas impossibilitam sua utilização direta numa aplicação industrial. Deve-se portanto utilizar uma outra ferramenta disponível dentro dessa mesma teoria, mas que contorne esses problemas. Nas Seções III.3 e III.4 é apresentada a estatística de diferenças, que é um subconjunto das matrizes de co-ocorrência. Através do emprego desta estatística é possível desenvolver um algoritmo que utilize os conceitos da estatística de co-ocorrência em uma aplicação industrial. A seção III.5 apresenta o método proposto, que viabiliza o emprego da teoria das matrizes de co-ocorrência no desenvolvimento de um algoritmo de inspeção visual automática.

III.2 MATRIZES DE CO-OCORRÊNCIAS

A utilização de matrizes de co-ocorrências no estudo das propriedades estatísticas das imagens, do ponto de vista da textura, é bem conhecida [49-52]. Julesz [53] foi o primeiro a utilizar o conceito de co-ocorrência em experimentos de discriminação de texturas. Mais tarde, Haralick [33] sugeriu a utilização de uma matriz

em que cada elemento qualificaria a ocorrência entre dois tons de cinza caracterizados por uma determinada relação espacial.

Com base em uma imagem, o processo clássico de determinação das matrizes de co-ocorrências consiste em contabilizar as ocorrências conjuntas de certas características, normalmente os tons de cinza, separadas por um operador de posição \mathfrak{R} .

Suponhamos que a imagem a analisar seja de dimensão $N_x \times N_y$, e que os tons de cinza estejam quantizados em N_g níveis. Sejam $\mathbf{X} = \{1, \dots, N_x\}$ o domínio da coordenada horizontal, $\mathbf{Y} = \{1, \dots, N_y\}$ o domínio da coordenada vertical e $\mathbf{G} = \{0, \dots, N_g - 1\}$ o conjunto de níveis de cinza em que será quantizada a imagem. Sendo n o número de bits por pixel, $N_g = 2^n$. Assim, uma imagem \mathbf{I} pode ser representada por uma função que assume um valor pertencente a \mathbf{G} para cada par (x, y) pertencente a $\mathbf{X} \times \mathbf{Y}$. Portanto, a função imagem pode ser expressa por:

$$\mathbf{I} : \mathbf{X} \times \mathbf{Y} \rightarrow \mathbf{G} \quad (3.1)$$

A co-ocorrência dos tons de cinza pode ser especificada numa matriz \mathbf{P} de freqüências relativas. Os elementos p_{ij} desta matriz representam o número de vezes que dois pixels, um com tom de cinza i e outro com tom de cinza j (i e $j \in \mathbf{G}$), ocorrem numa imagem relacionados por \mathfrak{R} (Fig. 3.1).




Fig. 3.1- Operador de posição \mathfrak{R} representando a relação "dois pixels à direita e um pixel para cima" na determinação da matriz \mathbf{P} .

Seja $\Delta x, \Delta y$ a dimensão de um pixel. A forma clássica de representar a relação espacial entre os níveis de cinza é mediante um vetor [33] dado por $\mathbf{d}=(\rho \Delta x, v\Delta y)$, conforme mostrado na Fig. 3.2.




Fig. 3.2 - Relação de vizinhança entre dois níveis de cinza para um dado vetor \mathbf{d} .

Representando \mathbf{d} em coordenadas polares, temos:

$$\mathbf{d} = (r, \theta) \quad (3.2)$$

onde,

$$r = \sqrt{(\rho \Delta x)^2 + (v \Delta y)^2} \quad (3.3a)$$

$$\theta = \arctg\left(\frac{v \Delta y}{\rho \Delta x}\right) \quad (3.3b)$$

Tipicamente, determina-se o número de ocorrências conjuntas dos níveis de cinza segundo as direções 0° , 90° , 45° e 135° para a obtenção da matriz de co-ocorrências. Portanto, no método clássico obtém-se quatro grupos de matrizes espacialmente dependentes, um para cada um dos seguintes vetores \mathbf{d} :

$$\mathbf{d}_1 = (r, 0^\circ); \quad \mathbf{d}_2 = (r, 90^\circ); \quad \mathbf{d}_3 = (r, 45^\circ); \quad \mathbf{d}_4 = (r, 135^\circ) \quad (3.4)$$

O número de matrizes dentro de cada grupo dependerá do número de separações (valores de r) distintas entre pixels que se considere. Em [33] foram utilizados os seguintes valores para r : 1, 2, 4 e 8. A escolha dos valores de r depende do tipo de textura que está sendo analisada, principalmente quando o objetivo for a classificação de texturas.

As matrizes $\mathbf{P}(i, j, \mathbf{d}_e)$, de dimensão $N_g \times N_g$, para, $e = \{1, \dots, 4\}$, especificam frequências não normalizadas. Formalmente essas frequências são definidas para cada \mathbf{d}_e da seguinte maneira:

$$\begin{aligned} \mathbf{P}(i, j, \mathbf{d}_1) = \aleph\{((k, l); (m, n)) \in (\mathbf{X}, \mathbf{Y}) \times (\mathbf{X}, \mathbf{Y}) \\ | |k - m| = r; l - n = 0; \\ \mathbf{I}(k, l) = i; \mathbf{I}(m, n) = j\} \quad , \quad \mathbf{d}_1 = (r, 0^\circ) \end{aligned} \quad (3.5)$$

$$\begin{aligned} \mathbf{P}(i, j, \mathbf{d}_2) = \aleph\{((k, l); (m, n)) \in (\mathbf{X}, \mathbf{Y}) \times (\mathbf{X}, \mathbf{Y}) \\ | |l - n| = r; k - m = 0; \\ \mathbf{I}(k, l) = i; \mathbf{I}(m, n) = j\} \quad , \quad \mathbf{d}_2 = (r, 90^\circ) \end{aligned} \quad (3.6)$$

$$\begin{aligned} \mathbf{P}(i, j, \mathbf{d}_3) = \aleph\{((k, l); (m, n)) \in (\mathbf{X}, \mathbf{Y}) \times (\mathbf{X}, \mathbf{Y}) \\ | (k - m = r, l - n = +r) \text{ ou} \\ (k - m = -r, l - n = -r) \\ \mathbf{I}(k, l) = i, \mathbf{I}(m, n) = j\} \quad , \quad \mathbf{d}_3 = (r, 45^\circ) \end{aligned} \quad (3.7)$$

$$\begin{aligned} \mathbf{P}(i, j, \mathbf{d}_4) = \aleph\{((k, l); (m, n)) \in (\mathbf{X}, \mathbf{Y}) \times (\mathbf{X}, \mathbf{Y}) \\ | (k - m = r, l - n = -r) \text{ ou} \\ (k - m = -r, l - n = +r) \\ \mathbf{I}(k, l) = i, \mathbf{I}(m, n) = j\} \quad , \quad \mathbf{d}_4 = (r, 135^\circ) \end{aligned} \quad (3.8)$$

onde $\aleph\{A\}$ representa o número de elementos do conjunto A .

Em geral, é mais simples trabalhar com a matriz de co-ocorrências normalizada, $P_n(i,j,\mathbf{d}_e)$. Para isto, deve-se calcular o número total de pares de pixels que satisfazem a relação dada pelo vetor \mathbf{d}_e . No caso de uma imagem de 4×4 , o número total de pixels que satisfazem $\mathbf{d}=(1,0^\circ)$ está definido por:

$$\mathbf{R}_{\mathbf{d}_1} = \{((k,l);(m,n)) \in (\mathbf{X}, \mathbf{Y}) \times (\mathbf{X}, \mathbf{Y}) \mid l-n=0; |k-m|=1\} \quad (3.9a)$$

sendo o número de elementos do conjunto $\mathbf{R}_{\mathbf{d}_1}$ dado por :

$$R_1 = 2(Nx-r)Ny \quad (3.9b)$$

Para esta imagem e $\mathbf{d} = (1, 0^\circ)$, $\mathbf{R}_{\mathbf{d}_1}$ possui 24 elementos. Para os vetores \mathbf{d}_e restantes tem-se:

$$\mathbf{d}_2 = (r, 90^\circ) \Rightarrow R_2 = 2(Ny-r)Nx \quad (3.10)$$

$$\mathbf{d}_3 = (r, 45^\circ) \Rightarrow R_3 = 2(Nx-r)(Ny-1) \quad (3.11)$$

$$\mathbf{d}_4 = (r, 135^\circ) \Rightarrow R_4 = 2(Ny-r)(Nx-1) \quad (3.12)$$

uma vez determinado o valor de R_e , dividimos cada elemento de $P(i,j,\mathbf{d}_e)$ pelo correspondente valor R_e para obtermos a matriz normalizada, $P_n(i,j,\mathbf{d}_e)$.

A partir das matrizes de co-ocorrências, é possível extrair um conjunto de parâmetros que permitem obter informações sobre a textura [33]. Os principais parâmetros são:

1) Momento angular de segunda ordem:

$$f_1 = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} \mathbf{P}_n^2(i, j, \mathbf{d}_e), \quad e = 1, \dots, 4 \quad (3.13)$$

2) Contraste:

$$f_2 = \sum_{m=0}^{Ng-1} m^2 \left\{ \sum_{|i-j|=m} \mathbf{P}_n(i, j, \mathbf{d}_e) \right\}, \quad e = 1, \dots, 4 \quad (3.14)$$

3) Correlação:

$$f_3 = \frac{\sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} ij \mathbf{P}_n(i, j, \mathbf{d}_e) - \mu_x \mu_y}{\sigma_x \sigma_y}, \quad e = 1, \dots, 4 \quad (3.15)$$

onde μ_x , σ_x , μ_y e σ_y são as médias e os desvios-padrão das distribuições marginais associadas à matriz $\mathbf{P}_n(i, j, \mathbf{d}_e)$.

As informações de textura que estes parâmetros traduzem são as seguintes:

1) *Momento angular de segunda ordem*: é uma medida da homogeneidade da imagem. Em uma imagem homogênea, ou seja, com poucas variações nos tons de cinza, a matriz de co-ocorrências terá poucos elementos diferentes de zero e com valores elevados concentrados em torno da diagonal principal. No caso de uma imagem com uma ampla variação nos tons de cinza, a matriz de co-ocorrências terá muitos elementos diferentes de zero, porém de baixos valores e mais

uniformemente distribuídos. Portanto, o valor deste parâmetro será menor quando os elementos da matriz forem aproximadamente do mesmo valor.

2) *Contraste*: é uma medida da quantidade de variações locais presentes na imagem. Em uma imagem homogênea, o valor deste parâmetro será menor do que no caso de uma imagem com importantes variações nos tons de cinza. Este parâmetro representa o momento de inércia da matriz de co-ocorrências em torno da diagonal principal. Portanto, fornece uma medida do grau de dispersão nos valores da matriz.

3) *Correlação*: este parâmetro fornece uma medida da semelhança entre as linhas (ou colunas) da matriz de co-ocorrências. Este parâmetro apresenta valores elevados quando os elementos da matriz estão uniformemente distribuídos. Assim, fornecendo uma noção da distribuição dos níveis de cinza na imagem.

Os parâmetros anteriormente apresentados são utilizados nas referências [20-21, 31, 33, 35, 38, 54] para a classificação de texturas. As áreas de aplicação incluem desde a classificação de texturas em imagens aéreas até o reconhecimento de objetos através da textura.

III.3 APLICAÇÃO DAS MATRIZES DE CO-OCORRÊNCIAS À DETECÇÃO DE DEFEITOS COSMÉTICOS

Nesta seção, a teoria de matrizes de co-ocorrências será utilizada como ferramenta na detecção de defeitos cosméticos em cerâmicas [67]. Evidenciaremos, a partir de simples exemplos, a capacidade de detecção de defeitos. Em função dos resultados

obtidos, obteremos então as regras que determinarão a presença ou não de defeitos numa peça cerâmica, quando comparada com seu correspondente padrão.

Como primeiro exemplo, consideremos uma matriz \mathbf{I} de dimensão 4×4 , que representa uma *imagem ideal* de uma *cerâmica perfeita* de padrão liso. Assim, sua imagem possui um único tom de cinza de valor 2. Cada pixel é quantizado com 2 bits. Com isto o conjunto, $\mathbf{G}=\{0,1,2,3\}$ contém todos os valores possíveis que um pixel $\mathbf{I}(x,y)$ pode assumir. Então,

$$\mathbf{I} = \begin{pmatrix} 2 & 2 & 2 & 2 \\ 2 & 2 & 2 & 2 \\ 2 & 2 & 2 & 2 \\ 2 & 2 & 2 & 2 \end{pmatrix} \quad (3.16a)$$

$$\mathbf{X} = \mathbf{Y} = \{1,2,3,4\} \quad ; \quad \mathbf{G} = \{0,1,2,3\} \quad (3.16b)$$

Definiremos agora o conjunto $\mathbf{C}_p \subset \mathbf{G}$ como o conjunto de valores de pixels de uma cerâmica sem defeito, de um determinado tipo de textura. No caso do presente exemplo, o conjunto \mathbf{C}_p é constituído por um único elemento ($\mathbf{C}_p=\{2\}$). Considere por exemplo $r=1$. As matrizes de co-ocorrências calculadas para os quatro vetores \mathbf{d}_e da equação (3.4) a partir de (3.5), (3.6), (3.7) e (3.8) são:

$$\mathbf{P}(i, j, \mathbf{d}_1) = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 24 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \quad (3.17a)$$

$$\mathbf{P}(i, j, \mathbf{d}_2) = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 24 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \quad (3.17b)$$

$$\mathbf{P}(i, j, \mathbf{d}_3) = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 18 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \quad (3.17c)$$

$$\mathbf{P}(i, j, \mathbf{d}_4) = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 18 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \quad (3.17d)$$

as correspondentes matrizes normalizadas são:

$$\mathbf{P}_n(i, j, \mathbf{d}_1) = \frac{1}{24} \mathbf{P}(i, j, \mathbf{d}_1) = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} = \mathbf{P}_n(i, j, \mathbf{d}_2) \quad (3.18a)$$

$$\mathbf{P}_n(i, j, \mathbf{d}_3) = \frac{1}{18} \mathbf{P}(i, j, \mathbf{d}_3) = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} = \mathbf{P}_n(i, j, \mathbf{d}_4) \quad (3.18b)$$

Da análise das matrizes de $P(i,j,d_e)$ ou $P_n(i,j,d_e)$, observa-se que o único elemento diferente de zero corresponde ao elemento (2,2). Isto ocorre por ser 2 o único nível de cinza presente na imagem. Consideremos agora uma matriz imagem I' de uma cerâmica com defeito representada por:

$$I' = \begin{pmatrix} 2 & 2 & 2 & 2 \\ 2 & 2 & 3 & 2 \\ 2 & 2 & 3 & 2 \\ 2 & 2 & 2 & 2 \end{pmatrix} \quad (3.19a)$$

$$X = Y = \{1,2,3,4\} \quad ; \quad G = \{0,1,2,3\} \quad (3.19b)$$

Da análise da matriz imagem I' , observa-se a existência de valores de pixels em $I(x,y) \notin C_p$. Vejamos como este tipo de defeito se reflete nas matrizes de co-ocorrências da imagem I' . As respectivas matrizes P'_n são:

$$P'_n(i,j,d_1) = \frac{1}{24} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 16 & 4 \\ 0 & 0 & 4 & 0 \end{pmatrix} \quad (3.20)$$

$$P'_n(i,j,d_2) = \frac{1}{24} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 18 & 2 \\ 0 & 0 & 2 & 2 \end{pmatrix} \quad (3.21)$$

$$P'_n(i,j,d_3) = \frac{1}{18} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 10 & 4 \\ 0 & 0 & 4 & 0 \end{pmatrix} \quad (3.22)$$

$$\mathbf{P}'_n(i, j, \mathbf{d}_4) = \frac{1}{18} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 10 & 4 \\ 0 & 0 & 4 & 0 \end{pmatrix} \quad (3.23)$$

Comparando as matrizes \mathbf{P}_n e \mathbf{P}'_n correspondentes às peças sem defeito e com defeito, respectivamente, vemos que a presença de níveis de cinza em \mathbf{I}' que não pertencem ao conjunto \mathbf{C}_p alteram os elementos da matriz \mathbf{P}'_n , quando comparada com \mathbf{P}_n . Portanto, é possível estabelecer um critério relacionando os elementos das duas matrizes, visando determinar a presença de defeitos na peça que está sendo confrontada com o padrão. Dado que a presença de algum tipo de defeito modifica as matrizes de co-ocorrências, a estratégia a seguir é a comparação entre elementos correspondentes da matriz \mathbf{I} da imagem padrão e da matriz \mathbf{I}' da imagem a ser classificada. Então, a condição sobre os elementos p'_{ij} para que não exista defeito na peça analisada é:

$$p'_{ij} = p_{ij} \quad \forall i \in \mathbf{X} \text{ e } \forall j \in \mathbf{Y} \quad (3.24)$$

onde:

p_{ij} = elemento (i, j) da matriz $\mathbf{P}_n(i, j, \mathbf{d}_e)$ (padrão)

p'_{ij} = elemento (i, j) da matriz $\mathbf{P}'_n(i, j, \mathbf{d}_e)$ (amostra a classificar)

Por exemplo, pode-se observar que os elementos (2,3) e (3,2) em (3.20) e os elementos (3,2), (3,3) e (2,3) em (3.21) não satisfazem à regra (3.24), o que indica a presença de defeitos em \mathbf{I}' .

No exemplo anterior, a existência de valores de pixels em $\mathbf{I}(x, y) \notin \mathbf{C}_p$ determinavam a presença de defeitos na peça sob análise. Consideremos agora uma

situação na qual \mathbf{I}' possui um defeito porém $\mathbf{I}'(x,y) \in \mathbf{Cp} \forall x \in \mathbf{X} \text{ e } \forall y \in \mathbf{Y}$. Para isto consideremos as seguintes matrizes imagem sem defeito \mathbf{I} e com defeito \mathbf{I}' :

$$\mathbf{I} = \begin{pmatrix} 2 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \\ 2 & 2 & 3 & 3 \\ 2 & 2 & 3 & 3 \end{pmatrix} \quad (3.25a)$$

$$\mathbf{I}' = \begin{pmatrix} 2 & 2 & 2 & 2 \\ 2 & 3 & 3 & 3 \\ 2 & 2 & 3 & 3 \\ 2 & 2 & 3 & 3 \end{pmatrix} \quad (3.25b)$$

onde:

$$\mathbf{X} = \mathbf{Y} = \{1,2,3,4\}$$

$$\mathbf{G} = \{0,1,2,3\}$$

$$\mathbf{Cp} = \{2,3\}$$

as matrizes de co-ocorrências para \mathbf{I} são:

$$\mathbf{P}_n(i,j,\mathbf{d}_1) = \frac{1}{24} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 12 & 3 \\ 0 & 0 & 3 & 6 \end{pmatrix} \quad (3.26a)$$

$$\mathbf{P}_n(i,j,\mathbf{d}_2) = \frac{1}{24} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 12 & 2 \\ 0 & 0 & 2 & 8 \end{pmatrix} \quad (3.26b)$$

$$\mathbf{P}_n(i, j, \mathbf{d}_3) = \frac{1}{18} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 8 & 3 \\ 0 & 0 & 3 & 4 \end{pmatrix} \quad (3.26c)$$

$$\mathbf{P}_n(i, j, \mathbf{d}_4) = \frac{1}{18} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 6 & 4 \\ 0 & 0 & 4 & 4 \end{pmatrix} \quad (3.26d)$$

e as matrizes de co-ocorrências para Γ' são:

$$\mathbf{P}'_n(i, j, \mathbf{d}_1) = \frac{1}{24} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 10 & 3 \\ 0 & 0 & 3 & 8 \end{pmatrix} \quad (3.27a)$$

$$\mathbf{P}'_n(i, j, \mathbf{d}_2) = \frac{1}{24} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 8 & 4 \\ 0 & 0 & 4 & 8 \end{pmatrix} \quad (3.27b)$$

$$\mathbf{P}'_n(i, j, \mathbf{d}_3) = \frac{1}{18} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 4 & 5 \\ 0 & 0 & 5 & 4 \end{pmatrix} \quad (3.27c)$$

$$\mathbf{P}'_n(i, j, \mathbf{d}_4) = \frac{1}{18} \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 4 & 4 \\ 0 & 0 & 4 & 6 \end{pmatrix} \quad (3.27d)$$

Novamente, aplicando a regra em que os elementos p'_{ij} devem ser iguais aos correspondentes p_{ij} , observa-se que o elemento (3,3) de $\mathbf{P}'_n(i, j, \mathbf{d}_1)$, os elementos (2,3) e (3,2) em $\mathbf{P}'_n(i, j, \mathbf{d}_2)$ e $\mathbf{P}'_n(i, j, \mathbf{d}_3)$ e o elemento (3,3) em $\mathbf{P}'_n(i, j, \mathbf{d}_4)$ são maiores do que os correspondentes nas respectivas matrizes $\mathbf{P}(i, j, \mathbf{d}_e)$. Portanto, a partir de simples exemplos, pode-se observar que com a utilização das matrizes de co-ocorrências é possível realizar a detecção de duas categorias de defeitos. Uma delas corresponde aos defeitos que originam da existência de valores de pixels $\mathbf{I}'(x, y) \notin \mathbf{Cp}$. A outra categoria representa aqueles pixels que não satisfazem à função

$$f = \xi(\mathbf{I}(x, y)) \quad (3.28)$$

onde f representa a função textura da cerâmica considerada e ξ representa a regra de distribuição espacial dos níveis de cinza da imagem padrão \mathbf{I} .

Resumindo, os tipos de defeitos que podem ser detectados numa imagem \mathbf{I}' , quando comparada com \mathbf{I} , correspondem aos valores de pixels que satisfazem a uma das seguintes regras:

$$\begin{aligned} & i) \mathbf{I}'(x, y) \notin \mathbf{Cp}, \text{ para algum } x \in \mathbf{X} \text{ e/ou } y \in \mathbf{Y} \\ & ii) \mathbf{I}'(x, y) \in \mathbf{Cp} \quad \forall x \in \mathbf{X}, \forall y \in \mathbf{Y}, \text{ mas } \xi'(\mathbf{I}'(x, y)) \neq \xi(\mathbf{I}(x, y)) \end{aligned} \quad (3.29)$$

III.4 ESTATÍSTICAS DE DIFERENÇAS 1

Um dos problemas associados com a utilização das matrizes de co-ocorrências é a capacidade de armazenamento requerida para sua determinação. Para cada par distância-orientação a matriz terá dimensão $N_g \times N_g$, onde N_g é o número de diferentes níveis de quantização da intensidade $I(x,y)$. No caso de utilizarmos L valores de separação, e as 4 orientações usuais (0° , 90° , 45° , 135°), a quantidade de dados que devemos armazenar é de $4 \times L \times N_g \times N_g$. Com o objetivo de diminuir o volume de dados a serem armazenados, podemos trabalhar com a *estatística de diferenças*. Essa estatística é um subconjunto da matriz de co-ocorrências e representa a probabilidade de ocorrência Ω_{d_e} de níveis de cinza separados por d_e e com diferença de intensidades igual a k (Fig. 3.3). Neste caso a quantidade de dados a ser armazenado é $4 \times L \times N_g$, o que representa uma importante redução quando comparada às necessidades do procedimento anterior. O vetor Ω_{d_e} é derivado da matriz $P(i,j,d_e)$ pela seguinte expressão:

$$\Omega_{d_e}(k) = \sum_{i=0}^{N_g-1} \sum_{\substack{j=0 \\ |i-j|=k}}^{N_g-1} P(i,j,d_e) \quad (3.30)$$

isto equivale a somar os elementos da matriz $P(i,j,d_e)$ ao longo de linhas paralelas à diagonal principal (Fig. 3.3).

As características da imagem obtidas a partir das matrizes $P(i,j,d_e)$ são similares às que podem ser obtidas a partir dos vetores Ω_{d_e} . Por exemplo, através destes vetores pode-se determinar entropia, contraste, momento angular de segunda ordem, etc. Em [35] foi demonstrado que a utilização da estatística de diferenças é tão efetiva na tarefa de classificação de texturas quanto à utilização das matrizes de co-ocorrências.




Fig. 3.3- Obtenção da estatística de diferenças a partir da matriz de co-ocorrências.

A fim de determinar o poder de discriminação de defeitos da estatística de diferenças no caso de aplicação em classificação de peças cerâmicas, consideremos novamente as matrizes imagem (3.25a) e (3.25b). Usando as matrizes de co-ocorrências já calculadas e aplicando a equação (3.30) calcularemos as estatísticas de diferenças para as matrizes **I** e **I'**.

Usando a notação

$$\Omega_{d_e} = \{ \Omega_{d_e}(0), \Omega_{d_e}(1), \dots, \Omega_{d_e}(3) \}$$

ou

$$\Omega_{d_e} = \{ \Omega_{d_e}(k), k=0,1,2,3 \}$$

temos:

matriz **I** :

$$\mathbf{P}(i, j, \mathbf{d}_1) \Rightarrow \Omega_{\mathbf{d}_1} = \frac{1}{24} \{18, 6, 0, 0\} \quad 0^\circ \quad (3.31a)$$

$$\mathbf{P}(i, j, \mathbf{d}_2) \Rightarrow \Omega_{\mathbf{d}_2} = \frac{1}{24} \{20, 4, 0, 0\} \quad 90^\circ \quad (3.31b)$$

$$\mathbf{P}(i, j, \mathbf{d}_3) \Rightarrow \Omega_{\mathbf{d}_3} = \frac{1}{18} \{12, 6, 0, 0\} \quad 45^\circ \quad (3.31c)$$

$$\mathbf{P}(i, j, \mathbf{d}_4) \Rightarrow \Omega_{\mathbf{d}_4} = \frac{1}{18} \{10, 8, 0, 0\} \quad 135^\circ \quad (3.31d)$$

matriz \mathbf{I}' :

$$\mathbf{P}'(i, j, \mathbf{d}_1) \Rightarrow \Omega'_{\mathbf{d}_1} = \frac{1}{24} \{18, 6, 0, 0\} \quad 0^\circ \quad (3.32a)$$

$$\mathbf{P}'(i, j, \mathbf{d}_2) \Rightarrow \Omega'_{\mathbf{d}_2} = \frac{1}{24} \{16, 8, 0, 0\} \quad 90^\circ \quad (3.32b)$$

$$\mathbf{P}'(i, j, \mathbf{d}_3) \Rightarrow \Omega'_{\mathbf{d}_3} = \frac{1}{18} \{8, 10, 0, 0\} \quad 45^\circ \quad (3.32c)$$

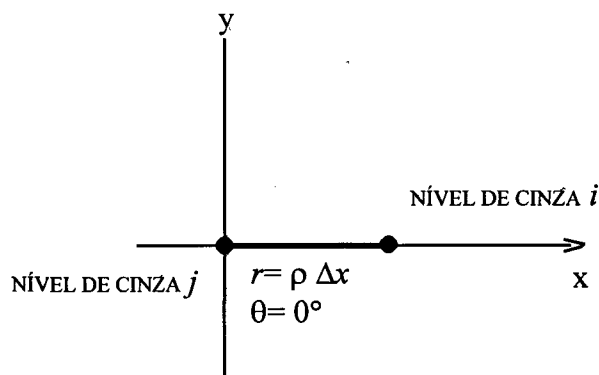
$$\mathbf{P}'(i, j, \mathbf{d}_4) \Rightarrow \Omega'_{\mathbf{d}_4} = \frac{1}{18} \{10, 8, 0, 0\} \quad 135^\circ \quad (3.32d)$$

Da mesma forma que com as matrizes de co-ocorrências, o critério para determinar a presença ou não de defeitos é obtido a partir da comparação entre os resultados das expressões (3.31) e (3.32). Observando $\Omega_{\mathbf{d}_1}$ e $\Omega'_{\mathbf{d}_1}$ constata-se que são iguais. Entretanto, as matrizes de co-ocorrência que originam tais vetores tinham seus elementos correspondentes diferentes. Ou seja, do ponto de vista da estatística de diferenças, para o vetor $\mathbf{d}_1=(1,0^\circ)$, a matriz \mathbf{I}' não apresenta nenhuma diferença em

relação à imagem padrão **I**. A mesma situação acontece para os vetores Ω_{d_4} e Ω'_{d_4} . Este exemplo mostra claramente que alguma informação é perdida ao utilizarmos a estatística de diferenças ao invés das matrizes de co-ocorrências. No entanto, ainda assim o defeito fica evidenciado pela comparação entre Ω_{d_2} e Ω'_{d_2} e Ω_{d_3} e Ω'_{d_3} . Neste caso, o critério a ser aplicado para a detecção das peças defeituosas é a comparação entre elementos correspondentes dos vetores Ω_{d_e} e Ω'_{d_e} , ou seja:

$$\Omega_{d_e}(k) = \Omega'_{d_e}(k) \quad , \quad e = 1, \dots, 4 \quad \text{e} \quad k = 0, \dots, Ng - 1 \quad (3.33)$$

Como queremos determinar apenas a existência de defeitos; sem a necessidade de quantificação, este procedimento pode ser simplificado ainda mais. Como a imagem em análise é bidimensional, basta utilizarmos 2 direções ortogonais. Assim, a detecção de defeitos pode ser feita utilizando apenas dois vetores Ω_{d_e} , correspondentes a direções ortogonais. Tais vetores poderiam ser, por exemplo, os ilustrados na Fig. 3.4.



(a)

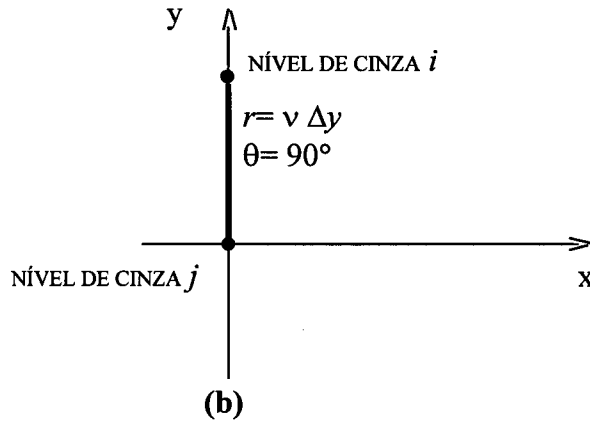


Fig. 3.4: Vetores ortogonais para a determinação da matriz de co-ocorrências:
(a) 0° e (b) 90° .

III.5 ESTATÍSTICA DE DIFERENÇAS 2

Um segundo problema das matrizes de co-ocorrências, além da necessidade de uma grande capacidade de armazenamento de dados, é esforço computacional requerido para a sua determinação. Uma das principais restrições que deve atender um algoritmo, para ser empregado numa aplicação industrial, é uma complexidade computacional reduzida. Na seção anterior, vimos que é possível contornar o problema de necessidade de memória requerida, mediante a utilização da estatística de diferenças. Porém, o problema relacionado ao esforço computacional ainda persiste, já que devemos primeiramente determinar as matrizes de co-ocorrências para depois obter a estatística de diferenças pela aplicação da equação (3.30).

Em [28] é demonstrado que é possível obter a estatística de diferenças $\Omega_{\mathbf{d}_e}$ sem a necessidade de calcular previamente as matrizes de co-ocorrências $\mathbf{P}(i,j,\mathbf{d}_e)$. Com isto, pode-se diminuir a quantidade de processamento requerido. Para se obter $\Omega_{\mathbf{d}_e}$ deve-se, a partir da escolha do vetor \mathbf{d}_e , determinar as diferenças entre os pixels relacionados por \mathbf{d}_e . Através de um operador diferença $\mathbf{D}_{\mathbf{d}_e}[\cdot]$ pode-se obter as diferenças diretamente a partir da imagem.

Considerando o vetor \mathbf{d}_e representado em coordenadas retangulares dado por: $\mathbf{d}_e = (\rho \Delta x, \nu \Delta y)$, determinam-se os elementos da matriz $\mathbf{D}_{\mathbf{d}_e}(x, y)$ associada, da seguinte forma:

$$\mathbf{D}_{\mathbf{d}_e}(x, y) = \left| \mathbf{I}(x, y) - \mathbf{I}(x + \rho \Delta x, y + \nu \Delta y) \right| \quad (3.34)$$

Em seguida, determina-se a função distribuição de probabilidades, que pode ser estimada pelo vetor histograma normalizado $\mathbf{h}_{\mathbf{d}_e}$ da matriz $\mathbf{D}_{\mathbf{d}_e}$, onde $\mathbf{h}_{\mathbf{d}_e}$ é determinado por:

$$\mathbf{h}_{\mathbf{d}_e} = \frac{\Phi}{\eta} \quad (3.35)$$

Na equação (3.35) a função Φ contabiliza o número de vezes que elementos de valor k ocorrem em $\mathbf{D}_{\mathbf{d}_e}$ e η representa o número total de elementos de $\mathbf{D}_{\mathbf{d}_e}$. Assim, aplicando-se o procedimento apresentado, chega-se aos mesmos resultados anteriores para $\Omega_{\mathbf{d}_e}$. Esta é, portanto, uma simplificação sem perdas. Consideremos novamente, para um exemplo as matrizes (3.25a) e (3.25b).

A partir da matriz \mathbf{I} (3.25a) determinam-se as matrizes $\mathbf{D}_{\mathbf{d}_1}$ e $\mathbf{D}_{\mathbf{d}_2}$ para os vetores em coordenadas retangulares $\mathbf{d}_1 = (1, 0)$ e $\mathbf{d}_2 = (0, 1)$, e com o auxílio das seguintes expressões:

$$\mathbf{D}_{\mathbf{d}_1}(x, y) = \left| \mathbf{I}(x, y) - \mathbf{I}(x + 1, y) \right| \quad (3.36a)$$

$$\mathbf{D}_{\mathbf{d}_2}(x, y) = \left| \mathbf{I}(x, y) - \mathbf{I}(x, y + 1) \right| \quad (3.36b)$$

Assim, tem-se:

$$\mathbf{D}_{d_1}(x, y) = \begin{pmatrix} 0 & 0 & 0 & \emptyset \\ 0 & 1 & 0 & \emptyset \\ 0 & 1 & 0 & \emptyset \\ 0 & 1 & 0 & \emptyset \end{pmatrix}$$

$$\mathbf{D}_{d_2}(x, y) = \begin{pmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ \emptyset & \emptyset & \emptyset & \emptyset \end{pmatrix}$$

Os histogramas normalizados de cada matriz são:

$$\mathbf{h}_{d_1}(k) = \frac{1}{12} \{9, 3, 0, 0\}, \quad k = \{0, 1, 2, 3\} \quad (3.37a)$$

$$\mathbf{h}_{d_2}(k) = \frac{1}{12} \{10, 2, 0, 0\}, \quad k = \{0, 1, 2, 3\} \quad (3.37b)$$

realizando o mesmo procedimento de cálculos para a matriz \mathbf{I}' , tem-se:

$$\mathbf{D}'_{d_1}(x, y) = \begin{pmatrix} 0 & 0 & 0 & \emptyset \\ 1 & 0 & 0 & \emptyset \\ 0 & 1 & 0 & \emptyset \\ 0 & 1 & 0 & \emptyset \end{pmatrix}$$

$$\mathbf{D}'_{\mathbf{d}_2}(x,y) = \begin{pmatrix} 0 & 1 & 1 & 1 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ \emptyset & \emptyset & \emptyset & \emptyset \end{pmatrix}$$

Os histogramas das matrizes $\mathbf{D}'_{\mathbf{d}_1}$ e $\mathbf{D}'_{\mathbf{d}_2}$ são:

$$\mathbf{h}'_{\mathbf{d}_1}(k) = \frac{1}{12} \{9,3,0,0\}, \quad k = \{0,1,2,3\} \quad (3.38a)$$

$$\mathbf{h}'_{\mathbf{d}_2}(k) = \frac{1}{12} \{8,4,0,0\}, \quad k = \{0,1,2,3\} \quad (3.38b)$$

Comparando-se os vetores $\mathbf{h}_{\mathbf{d}_e}$ obtidos por este método, observa-se que são idênticos aos vetores $\Omega_{\mathbf{d}_e}$ obtidos na seção anterior, que utilizaram as matrizes de co-ocorrência. Deve-se observar que a matriz $\mathbf{D}_{\mathbf{d}_e}$ resultante possui uma coluna ou uma linha a menos do que a matriz imagem \mathbf{I} , com isto o número de pixels efetivos η de $\mathbf{D}_{\mathbf{d}_e}$ é de $\eta=(N_x-1)N_y$ para $e=1$ e $\eta=(N_y-1)N_x$ para $e=2$.

III.6 DETECÇÃO DE DEFEITOS COSMÉTICOS

Nesta seção são abordados alguns aspectos práticos da detecção de defeitos cosméticos [68]. Esta é implementada utilizando os conceitos da teoria de matrizes de co-ocorrência apresentados nas Seções III.2 até III.4. Para aplicar tais conceitos aos processos reais teremos que substituir as definições de *imagens ideais* e *cerâmicas perfeitas*, respectivamente por:

- a) *imagens reais*: Geralmente considerado linear [55], o processo de aquisição de imagens possui várias fontes de não-

linearidades e de ruído, tais como: variações na iluminação, variações na reflectância da superfície da peça em função do ângulo de incidência da luz, erro nas lentes, ruído de digitalização, etc. Isto produzirá, na imagem real, uma alteração nos valores dos pixels. No caso de uma cerâmica lisa tal alteração aparece na forma de uma dispersão dos valores dos pixels em torno do valor do nível de cinza ideal, sendo que esse valor ideal corresponde a um tom de cinza dentro do intervalo [0-255] e determinado pela cor da cerâmica. Na Fig. 3.5 são apresentados os histogramas correspondentes a duas peças com defeitos e outra sem defeito. Nessa figura, pode-se observar que a estatística de primeira ordem não oferece um espaço de características onde possam ser identificadas as amostras defeituosas.

b) *cerâmicas aceitáveis*: não existe cerâmica que possa ser considerada perfeita, do ponto de vista de "não possuir defeito". Uma cerâmica é considerada de boa qualidade quando o número de defeitos cosméticos é considerado aceitável pelo controle de qualidade. Nas figuras apresentadas no Capítulo I, pode-se observar o que foi dito anteriormente sobre a qualidade superficial típica ser considerada aceitável. Nas figuras das cerâmicas sem defeito observa-se que a presença de pequenos pontos escuros espalhados pela superfície das cerâmicas não invalida a peça. Por outro lado, no caso de uma cerâmica com a mesma quantidade de pontos escuros, mas agora agrupados numa pequena área, a mesma deverá ser considerada como sendo defeituosa. Portanto, o método de detecção de defeitos cosméticos deverá ser capaz de considerar este tipo de situações.

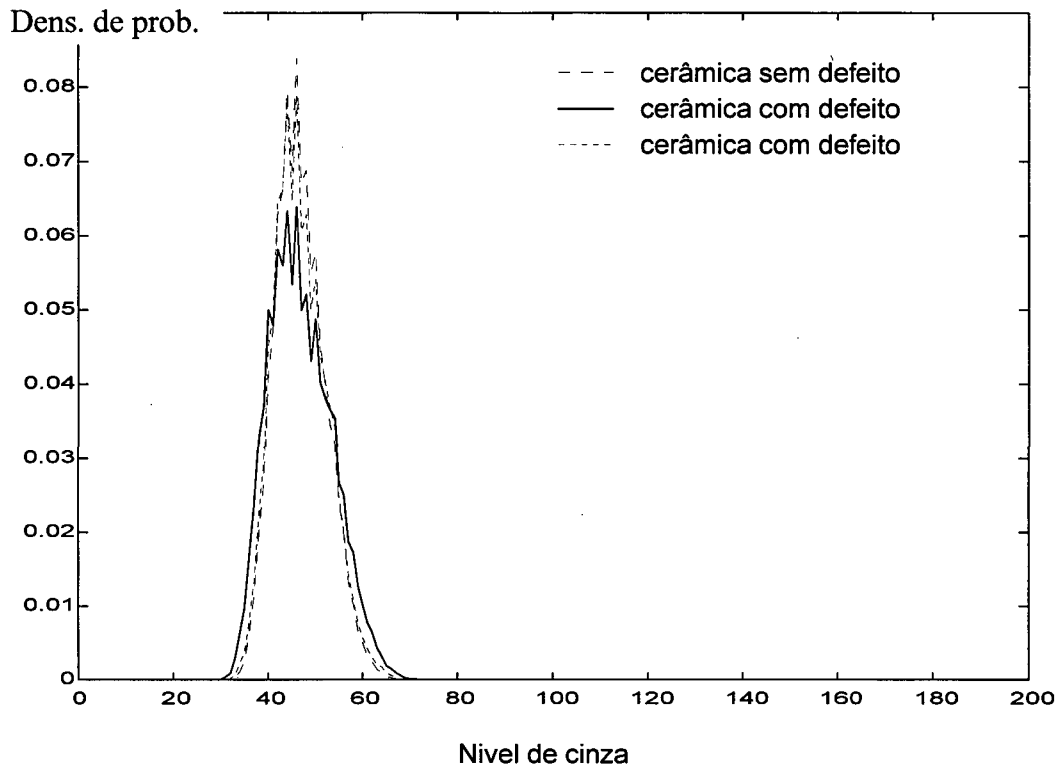


Fig. 3.5 - Estatísticas de primeira ordem correspondentes a duas peças com defeito e uma sem defeito.

Deve-se notar que a definição de defeito foi estabelecida considerando a imagem da peça em estudo e não a peça real. Isto é importante mencionar devido à existência de alguns tipos de defeitos que não são detectáveis na imagem para as condições de iluminação em que foi examinada a peça. Para abranger uma ampla gama de defeitos, as peças devem ser analisadas em diversas condições de iluminação. Esta opção requer, evidentemente, um maior tempo de processamento por peça, em contra-partida, aumenta-se a quantidade de defeitos detectáveis. A adoção de um esquema de multi-análise por peça envolve tanto um sistema de iluminação de maior custo quanto um aumento no tempo de processamento. Ficará, então, como opção do usuário a escolha da configuração mais adequada, considerando a relação de compromisso *capacidade de detecção* \times *custo e tempo de processamento*.

O método proposto está baseado no método alternativo de determinação da estatística de diferenças (Seção III.4). Em nosso trabalho, no entanto, foram introduzidas algumas modificações em relação ao procedimento convencional na determinação desses vetores. Tais modificações são:

- i) utilização de apenas um único valor de r na equação (3.2).
Usualmente são utilizados vários valores para cada uma das orientações 0° , 45° , 90° e 135° ;
- ii) utilização de somente duas orientações com a condição destas serem ortogonais. No nosso caso são utilizadas as orientações 0° e 90° .

Uma outra diferença é que os dois vetores ortogonais são combinados numa única matriz diferença dada por \mathbf{D} , para em seguida se extrair um único vetor \mathbf{h} .

A seqüência de passos a serem seguidos para obtenção do vetor \mathbf{h} de uma imagem é:

- i) adotar um valor de ρ e v para o vetor $\mathbf{d}_e = (\rho\Delta x, v\Delta y)$
- ii) adotar um valor para ρ' e v' para $\mathbf{d}'_e = (\rho'\Delta x, v'\Delta y)$ de maneira que se verifique a relação,

$$\mathbf{d}_e \perp \mathbf{d}'_e$$

- iii) calcular a matriz de diferenças absolutas dada por:

$$\mathbf{D} = \mathbf{D}_{\mathbf{d}_e} + \mathbf{D}_{\mathbf{d}'_e}, \quad e=\{1,2\}$$

onde:


$$\mathbf{D}_{d_e}(x, y) = |\mathbf{I}(x, y) - \mathbf{I}(x + \rho \Delta x, y + \upsilon \Delta y)|, \quad e = \{1, 2\}$$

$$\mathbf{D}_{d'_e}(x, y) = |\mathbf{I}(x, y) - \mathbf{I}(x + \rho' \Delta x, y + \upsilon' \Delta y)|, \quad e = \{1, 2\}$$


iv) calcular o vetor \mathbf{h} como sendo o histograma normalizado da matriz \mathbf{D} .

Na Fig. 3.5 nota-se que é difícil discernir entre uma cerâmica com defeito e outra sem defeito a partir de medições realizadas sobre o histograma de níveis de cinza.

Na Fig. 3.6 são mostrados os vetores \mathbf{h} de uma cerâmica com defeito e de outra, do mesmo padrão, considerada de boa qualidade. A Fig. 3.6a, mostra que na região de diferenças entre pares de níveis de cinza na faixa entre $\{0, \dots, 14\}$ praticamente não existem diferenças entre os elementos dos histogramas. Já, a partir análise da faixa entre $\{0, \dots, 90\}$, Fig. 3.6b, nota-se que o último valor diferente de zero, para a peça considerada de boa qualidade, é de **22**. Entretanto, para a peça defeituosa, existem ocorrências de diferenças que ultrapassam o valor anterior. Essas ocorrências indicam a presença de níveis de cinza (na imagem em análise) estranhos ao tipo de textura do padrão de referência.



(a)



(b)

Fig. 3.6 - Comparação dos vetores h entre uma peça com defeito e outra de referência, (a) região de diferenças $\{0, \dots, 14\}$; (b) região de diferenças $\{10, \dots, 90\}$.

Até este ponto, apresentamos o algoritmo proposto para a determinação do vetor \mathbf{h} , onde evidenciamos que através deste, é possível diferenciar entre uma amostra de boa qualidade e uma amostra defeituosa. No entanto, persiste ainda um problema devido às variações inerentes (dispersão) entre cerâmicas de mesma textura consideradas sem defeito. Para acomodar esta situação no cálculo do vetor \mathbf{h} , que será o classificador para cada determinado tipo de cerâmica, utiliza-se uma quantidade M de amostras consideradas padrão. A partir destas M amostras são calculados os vetores \mathbf{h}_τ , $\tau=1, \dots, M$.

$$\begin{array}{ll}
 \text{amostra padrão 1:} & \mathbf{h}_1 = \mathbf{h}_1(0), \mathbf{h}_1(1), \dots, \mathbf{h}_1(\omega+1), \dots, \mathbf{h}_1(N_{max}) \\
 \text{amostra padrão 2:} & \mathbf{h}_2 = \mathbf{h}_2(0), \mathbf{h}_2(1), \dots, \mathbf{h}_2(\omega+1), \dots, \mathbf{h}_2(N_{max}) \\
 & \cdot \\
 & \cdot \\
 \text{amostra padrão } \tau: & \mathbf{h}_\tau = \mathbf{h}_\tau(0), \mathbf{h}_\tau(1), \dots, \mathbf{h}_\tau(\omega+1), \dots, \mathbf{h}_\tau(N_{max}) \\
 & \cdot \\
 \text{amostra padrão } M: & \mathbf{h}_M = \mathbf{h}_M(0), \mathbf{h}_M(1), \dots, \mathbf{h}_M(\omega+1), \dots, \mathbf{h}_M(N_{max})
 \end{array}$$

onde N_{max} é o número máximo de elementos de algum dos vetores \mathbf{h}_τ , no caso em que um vetor tenha um número de elementos inferior a N_{max} este é preenchido com zeros de maneira que todos os vetores \mathbf{h}_τ possuam a mesma quantidade de elementos.

O classificador resultante é um vetor, onde cada elemento ω é obtido pela seguinte expressão:

$$\text{elemento: } \omega = \mu_\omega + \kappa \cdot \sigma_\omega, \quad \omega = 1, \dots, N_{max} \quad (3.39)$$

onde:

$$\mu_{\omega} = \frac{1}{M} \sum_{\tau=1}^M h_{\tau}(\omega) \quad (3.40)$$

e

$$\sigma_{\omega} = \sqrt{\frac{\sum_{\tau=1}^M (h_{\tau}(\omega) - \mu_{\tau})^2}{M-1}} \quad (3.41)$$

sendo κ uma constante que assume um valor entre 2 e 5. O efeito de se utilizar valores diferentes de κ é modificar a sensibilidade do classificador.

III.7 CONCLUSÕES

Do apresentado nas Seções III.2 e III.3 se observou que a capacidade de detecção de defeitos é comparável quando se utilizam as matrizes de co-ocorrências ou um subconjunto delas, a estatística de diferenças. O método alternativo de cálculo da estatística de diferenças, apresentado na Seção III.4, possui a grande vantagem de não ser necessário o cálculo prévio das matrizes de co-ocorrências, este fato muito importante, permitiu a utilização dos conceitos da teoria referente às matrizes de co-ocorrência para desenvolver um algoritmo de inspeção visual automático de peças cerâmicas que possua mínima complexidade computacional.

CAPÍTULO IV.

DESCRIÇÃO DO SISTEMA

DESCRIÇÃO DO SISTEMA

IV.1 INTRODUÇÃO

NESTE Capítulo é apresentada a estrutura do sistema de inspeção visual automática proposto. O sistema é apresentado pelo seu diagrama em blocos. Descreveremos o objetivo de cada um dos blocos junto com as considerações práticas necessárias para seu adequado funcionamento. Tais considerações têm dois objetivos principais: diminuir os requisitos dos subsistemas envolvidos e a complexidade dos algoritmos implementados em cada bloco. Satisfazendo essas condições a tarefa a ser efetuada por cada um deles será realizada no menor tempo possível.

IV.2 SISTEMA AUTOMÁTICO DE INSPEÇÃO

O sistema de inspeção visual automático de cerâmicas proposto consta da seqüência de operações mostrada no diagrama em blocos da Fig. 4.1:

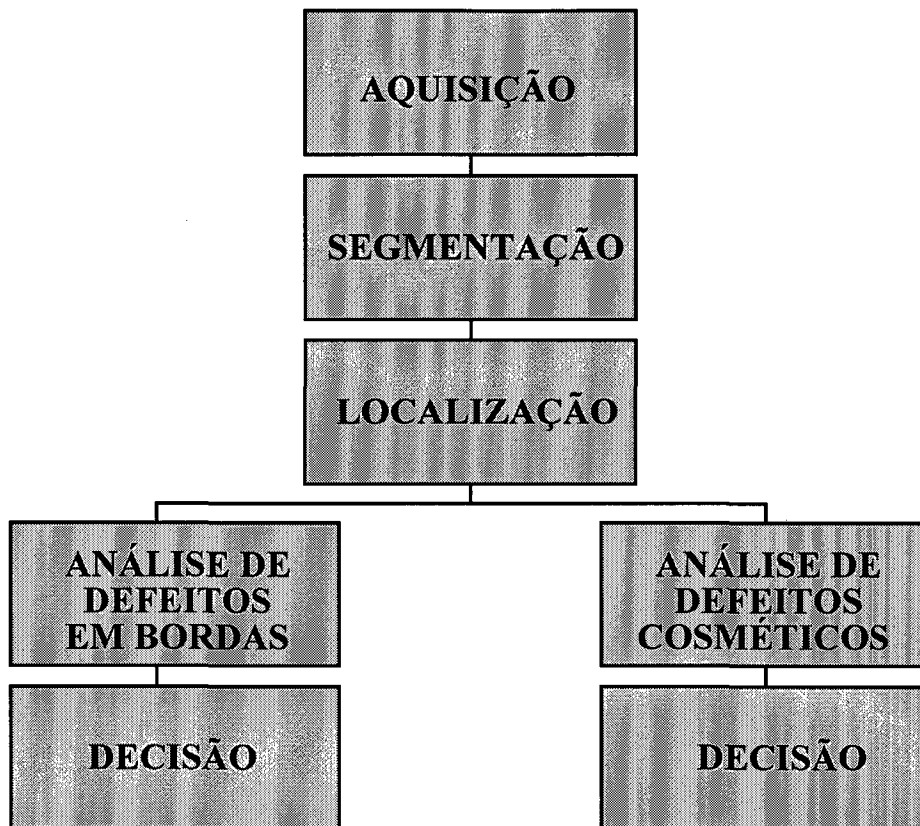


Fig. 4.1- Diagrama em blocos do sistema de análise e classificação de peças cerâmicas.

A seguir é descrito cada um dos blocos contituíntes do sistema de inspeção:

a) AQUISIÇÃO

A aquisição das imagens utilizadas no processo de inspeção é realizada através de uma câmera de estado sólido acoplada a um sistema computadorizado, que adquire e armazena as imagens das peças cerâmicas a serem analisadas. A imagem adquirida é composta pelo objeto em estudo (a peça cerâmica) mais o fundo. Se quizéssemos digitalizar somente a área correspondente ao objeto seria necessário um complexo sistema para controlar o campo visual da câmera junto com um dispositivo mecânico de

posicionamento do objeto de alta precisão. Estes requisitos, no entanto, além de incrementar desnecessariamente o custo dos subsistemas envolvidos dificilmente poderiam ser realizados em tempo real num sistema automático de inspeção.

b) SEGMENTAÇÃO

Pelos motivos mencionados anteriormente, a imagem adquirida é composta pelo objeto mais o fundo, sendo que a posição do objeto (ou objetos) dentro da imagem é, a priori, desconhecida. Por esta razão, é necessário determinar e caracterizar a posição dos objetos dentro da imagem. As técnicas de processamento de imagem que se encarregam dessa tarefa são as técnicas de segmentação. A segmentação de uma imagem é o processo de particionar a imagem em regiões disjuntas.


Quando um ser humano observa uma cena, o cérebro realiza um complexo processamento (uma depurada decomposição e análise), de maneira que o que está se vendo não representa uma cena estruturalmente complexa mas sim, uma coleção de objetos elementares. Quando a mesma cena é analisada por um instrumento, devemos explicitamente prover o mesmo de uma seqüência de instruções, a fim de que este possa isolar do fundo os objetos contidos na imagem.

Um dos métodos de segmentação mais utilizados é obtido através do estabelecimento de níveis limiares no histograma de tons de cinza da imagem [56-57]. Esta técnica é adequada se a cena em questão contém objetos que apresentem um nível alto de contraste com relação ao fundo. Uma imagem que contenha objetos que contrastem com o fundo terá um histograma de níveis de cinza do tipo bimodal como esse mostrado na Fig.4.2a. Na Fig.4.2b apresenta-se o histograma correspondente a uma cerâmica cuja imagem possui um nível baixo de contraste com relação ao fundo. Dentre as causas que originam um baixo nível de contraste em uma imagem, pode-se destacar a incorreta iluminação, fundo e objeto com tons de cinza similares ou ainda um muito


baixo nível de luz incidindo sobre o sensor ótico da câmera, este último caso decorrente normalmente de uma deficiente abertura da íris da câmera.

Como pode ser observado pela Fig. 4.2b, um nível baixo de contraste faz com que não se aproveite inteiramente a faixa dinâmica do sistema (no caso 256 níveis de cinza) e, portanto, o histograma cobrirá apenas uma restrita região deslocada para um dos extremos (0 ou 255). Neste caso, os pixels com nível de cinza de 255 são oriundos do efeito de saturação. Ou seja, aos pixels cujos valores estão muito próximos de 255, é atribuído, devido ao inerente ruído de medição do processo, o valor de 255. Um fenômeno similar acontece no caso de excesso de iluminação. Neste caso, teremos uma acumulação de ocorrências para o valor zero de nível de cinza. Em síntese, a excessiva ocorrência de valores de cinza em zero ou 255 é um indicativo de problemas relacionados com a iluminação da peça e/ou a fixação dos parâmetros (controles) da câmera. O não adequado aproveitamento da faixa dinâmica implica na perda de detalhes na imagem adquirida. Assim, os defeitos na peça sob análise podem ser mascarados ou atenuados fazendo com que seja muito difícil a sua detecção.

A condição de um nível alto de contraste entre objeto e fundo é garantida mediante ao uso de um nível de cinza de fundo diferente do nível de cinza da peça inspecionada. Isto fato dará origem a histogramas de níveis de cinza do tipo bimodal (Fig.4.2a).



(a)



(b)

Fig. 4.2 - Histograma dos níveis de cinza. (a) Aquisição efetuada incorretamente, (b) aquisição com as variáveis corretamente fixadas.

Assim, a segmentação de uma imagem com base nesse tipo de histograma é possível ser realizada mediante o emprego de técnicas simples. O principal objetivo das técnicas de segmentação de imagens, neste caso, consiste em determinar a posição do vale. No Apêndice 1 são descritos três métodos que foram empregados para realizar esta tarefa, são eles os seguintes: método de Otsu [58], o de Ridler-Calvard [59] e o de Lloyd [60]. Estes dois últimos estão baseados na obtenção de um erro mínimo de classificação dos pixels (pixels fundo ou pixels objeto).

Assim, seja T um determinado valor limiar, que divide o histograma de níveis de cinza, Φ , em duas regiões $\Phi(i)$: $0 \leq i < T$ e $T \leq i \leq 255$. Portanto, obtêm-se dois conjuntos de pixels:

$$\mathbf{O} = \{((x, y); \mathbf{I}(x, y)) \mid \mathbf{I}(x, y) \geq T\} \quad (4.1)$$

$$\mathbf{F} = \{((x, y); \mathbf{I}(x, y)) \mid \mathbf{I}(x, y) < T\}$$

onde \mathbf{O} é o conjunto de pixels objeto e \mathbf{F} o conjunto de pixels fundo. Tais conjuntos devem satisfazer a seguinte condição:

$$\mathbf{O} \cap \mathbf{F} = \emptyset \quad (4.2)$$

Na Tabela 4.1 são mostrados os limiares obtidos com cada um destes, anteriormente mencionados, métodos de segmentação (para as imagens das cerâmicas do conjunto 1). Essencialmente, os três métodos produzem uma correta segmentação quando a cena é adequadamente iluminada.

TABELA 4.1 - Comparação dos valores limiares obtidos.

MÉTODO	VALOR DO LIMIAR
Otsu	142
Ridler-Calvard	138
Lloyd	140

c) LOCALIZAÇÃO

Considerando que a posição da cerâmica a ser analisada, dentro do campo visual da câmera, pode ser variável, antes de proceder qualquer análise, deve-se localizar com precisão na imagem a peça em questão. Assim, com base no resultado da segmentação, agruparam-se os pixels da imagem nos dois conjuntos anteriormente mencionados, **O** e **F**, respectivamente. Para os pixels pertencentes ao objeto, assume-se (a imagem segmentada) $I_s(x,y)=1$, caso contrário, $I_s(x,y)=0$.

Na detecção da posição da peça são utilizadas 4 máscaras, cada uma especializada em detectar um canto em particular. Na Fig. 4.3 são mostradas as áreas de ação de cada máscara.




Fig. 4.3 - Área de ação das máscaras para a detecção dos cantos da peça.

Quanto menor for a área de busca, menor será o tempo despendido para executar esta tarefa. Idealmente, a área de busca é zero pixels. Isto ocorre quando é possível assegurar que as peças a serem analisadas estejam sempre numa mesma posição pré-definida. Nessa situação, poder-se-ia descartar as etapas de segmentação e localização.

Para ilustrar tal procedimento, é mostrada na Fig. 4.4 uma máscara utilizada para realizar a detecção do canto superior esquerdo.

	i	i+1	i+2	i+3	i+4	i+5	i+6	i+7
j								
j+1			X					
j+2	0							
j+3								
j+4								

Fig. 4.4 - Máscara de detecção do canto superior esquerdo.

Na Fig. 4.5 são ilustradas regiões da imagem destacando o canto superior esquerdo. Para efetuar a detecção desse canto por meio da máscara mostrada na Fig. 4.4, vejamos as condições simultâneas que o pixel, marcado com X, na posição $(j+1, i+2)$ deve satisfazer para ser considerado como sendo um canto:

$$\text{condição 1:} \quad \mathbf{I}(j+2, i) = 0 \quad (4.3)$$

$$\text{condição 2:} \quad \sum_{x=i+3}^{i+7} \sum_{y=j+1}^{j+3} \mathbf{I}(x, y) \geq \alpha \quad (4.4)$$

$$\text{condição 3: } \left\{ \sum_{\substack{x=i+3 \\ y=j}}^{i+7} \mathbf{I}(x, y) + \sum_{\substack{y=j \\ x=i+2}}^{j+3} \mathbf{I}(x, y) \right\} \leq \beta \quad (4.5)$$

Com o objetivo de trabalhar com a máxima eficiência com relação ao tempo de processamento, as somatórias são calculadas somente no caso que $\mathbf{I}(j+2, i)$ seja igual a zero. Esta condição é para não permitir que a máscara entre dentro da peça e, portanto, se efetuem cálculos desnecessários. O valor das constantes α e β para o caso ideal é de 24 e 0, respectivamente. Entretanto, estas constantes devem ser escolhidas em função da qualidade da iluminação. Valores aceitáveis, obtidos experimentalmente, de tais constantes podem estar dentro de alguns dos seguintes intervalos:

$$20 \leq \alpha \leq 24 \quad (4.6)$$

$$0 \leq \beta \leq 5 \quad (4.7)$$

Na prática, mesmo contando com uma adequada iluminação, a imagem segmentada tende a ser da forma apresentada pela Fig. 4.5b, devido aos seguintes fatores:

i) as bordas da peça, na maior parte das vezes, são do tipo rampa;

ii) a peça pode estar levemente rotacionada.

Idealmente a imagem \mathbf{I}_s apresenta cantos do tipo mostrado na Fig. 4.5a. Para o caso real, onde a peça pode estar levemente rotacionada, a imagem \mathbf{I}_s é do tipo dado pela Fig. 4.5b.

```

0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0
0 0 1 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1

```

(a)

```

0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0
0 0 0 0 1 0 1 1 1 1
0 0 1 1 0 1 1 1 1 1
0 0 0 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1
0 0 0 1 1 1 1 1 1 1
0 0 0 1 0 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1
0 0 1 1 1 1 1 1 1 1

```


(b)

Fig. 4.5 - Canto superior esquerdo da imagem da peça binarizada. (a) Caso ideal, (b) caso real.


Para esta última situação, as constantes α e β devem assumir algum valor pertencente ao intervalo dado anteriormente. Com o objetivo de não detectar uma quantidade excessiva de pixels candidatos a "pixel de canto", o valor escolhido deve inicialmente estar mais perto do valor ideal.

As outras duas máscaras para localizar os outros cantos, exigem o mesmo princípio discutido anteriormente para o caso do canto superior esquerdo.

Após serem localizados os 4 cantos da peça cerâmica, a etapa seguinte consiste na individualização das duas áreas que serão submetidas a um tipo particular de análise dependendo se estas correspondem a uma região de bordas ou a uma região interna da cerâmica. Na Fig. 4.7 são mostradas as áreas (regiões) onde são realizadas cada uma destas análises.



(a)



(b)

Fig. 4.6 - Regiões de análise. (a) Região de procura de defeitos em bordas; (b) região de procura de defeitos cosméticos.

d) DETECÇÃO DE DEFEITOS EM BORDAS

Para efetuar a detecção de defeitos nas bordas da peça sob análise será utilizado o operador diferença $D[.]$ [61]. A região de ação deste operador é a região hachurada da Fig. 4.6a, já que os pixels pertencentes a essa região correspondem apenas a "pixels de borda", evitando-se, assim, cálculos desnecessários. O modelo de borda que mais se adapta para imagens reais é o do tipo rampa [57], Fig. 4.7a.

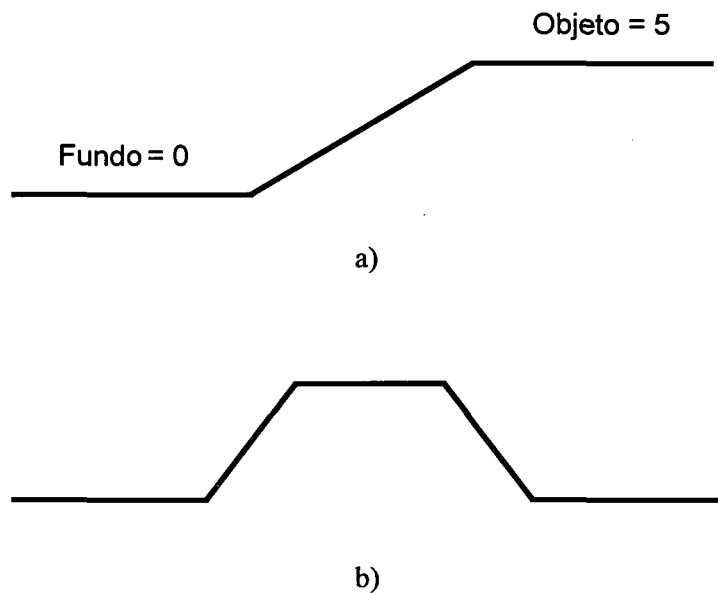


Fig. 4.7 (a) Rampa; (b) derivada da rampa, segundo o operador $D[.]$.

Na Fig. 4.7b é esboçado o resultado da aplicação do operador $D[.]$ (equação 4.8) à rampa da Fig. 4.7a.

$$D[.] = |f(x+1) - f(x-1)| \quad (5.8)$$

Na Fig. 4.8 é mostrado o resultado do operador $D[.]$ aplicado a uma imagem real. Pode-se observar que tal operador produz a máxima resposta na região de transição, regiões indicadas por \\\ e /// na Fig. 4.6a. Os máximos valores da derivada devem se encontrar, idealmente, numa mesma coluna ou numa mesma linha. Portanto, um deslocamento de Δx em relação à coluna ou Δy em relação à linha dos máximos indica que a peça sob análise possui uma borda defeituosa. Para o caso ideal, ou seja, modelo de bordas tipo degrau, perfeitas condições de iluminação e a peça corretamente centrada, um Δx ou Δy igual a 1 deve ser estipulado como critério de detecção de borda com defeito. No caso real, a peça pode não estar corretamente centrada tal como está ilustrado na Fig. 4.8. Nessa figura são mostrados ainda, através das linhas pontilhadas, a posição correta da peça sob análise. Note que a posição levemente rotacionada da peça, caso trivial na prática, pode levar a se obter um Δx de até 10 pixels do início ao fim de uma linha (ou coluna). Para-se evitar que este problema de posicionamento produza falsos “alarmes”, utiliza-se como regra analisar o desvio Δx em trechos de no máximo 20 linhas (ou colunas). A cerâmica da Fig. 4.8 apresenta um defeito na borda horizontal superior. Na região do defeito temos um Δy de três pixels, indicando nesse caso a presença de uma borda lascada.




Fig. 4.8 - Derivada da imagem.

e) DETECÇÃO DE DEFEITOS COSMÉTICOS

Neste bloco é implementado o algoritmo descrito na Seção III.5 do Capítulo III.

CAPÍTULO V.

RESULTADOS EXPERIMENTAIS

RESULTADOS EXPERIMENTAIS

V.1 INTRODUÇÃO

NO PRESENTE Capítulo são apresentados e analisados os principais resultados obtidos nesta dissertação. Estes resultados são comparados com os obtidos por outros algoritmos extraídos da literatura e utilizados nas referências [62, 33, 35] para a classificação de texturas. A fim de testar o algoritmo proposto, foram utilizados três conjuntos de cerâmicas. Dois conjuntos correspondem a cerâmicas texturizadas e o terceiro a cerâmicas lisas. Na Tabela 5.1, detalha-se o número de amostras com defeito e sem defeito em cada conjunto.

TABELA 5.1. Conjuntos de peças testes para avaliação dos algoritmos.

CONJUNTO	PEÇAS BOAS	PEÇAS COM DEFEITO
conjunto 1	150	20
conjunto 2	80	15
conjunto 3	30	10

Os métodos clássicos de classificação de texturas (referenciados em [62], [33] e [35]), como os baseados na matriz de co-ocorrências ou na estatística de diferenças, consistem na extração a partir dessas estatísticas de um conjunto de medidas (ou também chamadas de características, por exemplo MAS, ENT, CON, STD, etc.) que representam pontos num espaço de características. Posteriormente, sobre esse espaço serão identificadas as regiões que correspondem às classes com defeito e sem defeito (Fig. I.3 da Introdução). Portanto, uma amostra desconhecida será classificada em função da região a que correspondem suas coordenadas. As fronteiras que delimitam estas regiões são chamadas de classificadores.

O desempenho dos classificadores, tanto no método proposto quanto nos implementados a partir da literatura, são obtidos pelo método "Leave-One-Sample-Out" (LOSO) [63]. Seja S o número de amostras no conjunto que está sendo avaliado; o método LOSO consiste em treinar o classificador com $S-1$ amostras e classificar o restante. Este método possui a desvantagem de que deve-se calcular S classificadores, portanto, é um método que demanda tempo importante de processamento. Por outro lado, apresenta resultados mais próximos para a estimação do futuro desempenho do classificador.

V.2 EXTRAÇÃO DAS CARACTERÍSTICAS

Os métodos utilizados para a comparação com o algoritmo proposto estão baseados na extração de características a partir da estatística de diferenças. Algumas dessas características freqüentemente utilizadas são [28]:

Momento angular de segunda ordem (MAS):

$$\text{MAS} = \sum_{k=0}^{\text{Nbins}} h^2(k) \quad (5.1)$$

Entropia (ENT):

$$\text{ENT} = \sum_{k=0}^{\text{Nbins}} h(k) \log[h(k)] \quad (5.2)$$

Desvio padrão (STD):

$$\text{STD} = \sqrt{\sum_{k=0}^{\text{Nbins}} k^2 h(k) - \mu^2} \quad (5.3)$$

Contraste (CON):

$$\text{CON} = \sum_{k=0}^{\text{Nbins}} k^2 h(k) \quad (5.4)$$

Valor médio (MEAN):

$$\text{MEAN} = \sum_{k=0}^{N_{bins}} k h(k) \quad (5.5)$$

onde \mathbf{h} com $k = 1, \dots, N_{bins}$ representa o vetor estatística de diferenças da matriz imagem e N_{bins} é seu número de elementos.

Dentre as características possíveis a serem extraídas devemos escolher a característica, ou combinação delas, que melhor se ajuste com a qualidade previamente julgada da amostra em questão [62]. A figura de mérito utilizada para avaliar a qualidade da peça em função da característica selecionada é a covariância, dada por:

$$\text{COV}\{F, Q\} = \frac{\frac{1}{n} \sum_{i=1}^n [F(m_i) Q(m_i)] - \mu_F \mu_Q}{\sigma_F \sigma_Q} \quad (5.6)$$

onde $F(m_i)$ é o valor da característica F para a amostra m_i e $Q(m_i)$ é a qualidade julgada da peça. O vetor \mathbf{Q} assume valor 1 se a peça não tem defeito e valor zero se for uma peça defeituosa; μ_F e μ_Q são os valores médios dos vetores \mathbf{F} e \mathbf{Q} , respectivamente; σ_F e σ_Q são os desvios padrão. Os valores obtidos da figura de mérito para os conjuntos de amostras 1 e 2, são dados nas Tabelas 5.2 e 5.3, respectivamente:

TABELA 5.2 - Avaliação do conjunto 1

CARACTERÍSTICA	VALOR OBTIDO
CON	0.1907
MEAN	0.5616
MAS	0.0082
ENT	0.0079
STD	0.4003

TABELA 5.3 - Avaliação do conjunto 2


CARACTERÍSTICA	VALOR OBTIDO
CON	0.5912
MEAN	0.5530
MAS	0.5169
ENT	0.5683
STD	0.6248

Com o objetivo de maximizar a separação entre classes, é utilizado um espaço de três dimensões onde cada ponto (x,y,z) desse espaço é determinado pelo valor das seguintes características:


conjunto 1: (MEAN,STD,CON)

conjunto 2: (CON,ENT,STD)


Para esta representação foram aplicadas, as características de cada conjunto (conjunto 1 e conjunto 2) que obtiveram os maiores valores de figuras de mérito apresentados nas Tabelas 5.2 e 5.3. Na Fig. 5.1 é apresentado o gráfico tridimensional correspondente às cerâmicas do conjunto 1 e, na Fig. 5.2, é apresentado o correspondente ao conjunto 2.



(a)



(b)



(c)

Fig. 5.1. (a), (b) e (c): Três perspectivas do gráfico tridimensional das características (MEAN,CON,STD)




Fig. 5.2. Gráfico tridimensional das características (CON,ENT,STD)

V.3 PROJETO DOS CLASSIFICADORES

Nesta seção veremos os métodos mais utilizados na literatura (métodos clássicos) para o projeto de classificadores. Em seguida, vamos comparar o desempenho do método proposto em relação aos métodos clássicos apresentados.

a) MÉTODO 1: CLASSIFICADOR DE FISHER

Neste método é utilizada a técnica do discriminante linear de Fisher [64-65] para projetar o classificador. Geralmente, trabalha-se com duas classes a fim de simplificar os cálculos no projeto do classificador. Este método fornece uma direção no plano, onde a

projeção das características sobre essa direção possui máxima separação entre classes. O vetor direção de Fisher α é obtido a partir da otimização da seguinte função:

$$\Gamma(\mathbf{r}) = \frac{\alpha' \mathbf{B} \mathbf{r}}{\mathbf{r}' \mathbf{S}_x \mathbf{r}} \quad (5.7)$$

onde

$$\mathbf{B} = (\mu_p - \mu_d)(\mu_p - \mu_d)^T \quad (5.8)$$

e

$$\mathbf{S} = \mathbf{S}_p + \mathbf{S}_d \quad (5.9)$$

sendo μ_p , μ_d , \mathbf{S}_p e \mathbf{S}_d as estimações dos valores médios e as matrizes de covariância das duas classes, respectivamente. A matriz \mathbf{B} é conhecida como a matriz de covariância *entre-classes*. O vetor que maximiza a função $\Gamma(\mathbf{r})$ é dado pela seguinte expressão [65]:

$$\alpha = \mathbf{S}^{-1}(\mu_p - \mu_d) \quad (5.10)$$

Seja \mathbf{Z} o vetor de características e sejam C_d e C_p as duas classes, correspondendo a peças com defeito e sem defeito, respectivamente. Seja o conjunto de vetores $\mathbf{Z}_{d_1}, \mathbf{Z}_{d_2}, \dots, \mathbf{Z}_{d_k}$ e $\mathbf{Z}_{p_1}, \mathbf{Z}_{p_2}, \dots, \mathbf{Z}_{p_k}$ onde os elementos destes vetores são as características extraídas das imagens pertencentes aos conjuntos C_d e C_p , respectivamente. Utilizando a equação (5.10) tem-se a direção ótima de separação de classes. Para decidir a classe a que pertence uma amostra desconhecida \mathbf{Z}_x devemos calcular o produto $\alpha^T \mathbf{Z}_x$ e comparar com o limiar dado pela seguinte expressão:

$$\text{limiar} = \frac{(\mu_p \sigma_d + \mu_d \sigma_p)}{(\sigma_d + \sigma_p)} \quad (5.11)$$

onde, σ_d e σ_p são as variâncias das classes sem defeito e com defeito, respectivamente.

Como foram utilizadas três características: MEAN, STD e CON (no caso do conjunto 1), foi projetado um classificador em cada um dos planos (MEAN,STD), (MEAN,CON) e (STD,CON) do espaço tridimensional da Fig. 5.1. Uma amostra desconhecida é classificada como sendo pertencente à classe que recebe maior quantidade de votos, a partir dos classificadores em cada um dos três planos. Para avaliar os classificadores foi utilizada a técnica LOSO, estando os resultados representados na Tabela 5.4,

TABELA 5.4. Resultados experimentais do método de Fisher

CONJUNTO	TAXA DE REJEIÇÃO	TAXA DE DETECÇÃO
1	37.33%	59.00%
2	22.22%	65.30%
3	47.30%	57.50%

b) MÉTODO 2: CLASSIFICADOR DE BAYES [61]

Neste método, o projeto do classificador está baseado no teorema de Bayes. Este supõe que a probabilidade de ocorrência das amostras pertencentes a uma determinada classe exibe função densidade de probabilidades gaussianas. No caso considerado, teremos duas classes possíveis, C_d e C_p . Então, a expressão da função densidade para este caso é:

$$p(\mathbf{Z}/C_i) = \frac{1}{2\pi\sqrt{|Cov_i|}} \exp\left[-\frac{1}{2}(\mathbf{Z}-\mu_i)^T Cov_i^{-1}(\mathbf{Z}-\mu_i)\right] \quad (5.12)$$

onde \mathbf{Z} é o vetor de características pertencente à classe C_l , μ_l e Cov_l são as estimações do vetor de média e a matriz de covariância, obtidas pelas seguintes expressões:

$$\mu_l = \frac{1}{N_l} \sum_{\mathbf{Z} \in C_l} \mathbf{Z} \quad (5.13)$$

e

$$Cov_l = \frac{1}{N_l} \sum_{\mathbf{Z} \in C_l} \mathbf{Z}\mathbf{Z}^T - \mu_l \mu_l^T \quad (5.14)$$

A função de decisão para a classe C_l é:

$$d_l(\mathbf{Z}) = p\left(\frac{\mathbf{Z}}{C_l}\right) P(C_l) \quad , \quad l = \{d, p\} \quad (5.15)$$

Devido à forma exponencial das funções gaussianas, é mais conveniente trabalhar com o logaritmo natural da função densidade. Assumindo que as probabilidades de ocorrência das classes são iguais ($P(C_d)=P(C_p)$), temos que a função de decisão é:

$$d_d(\mathbf{Z}) = \mathbf{Z}^T Cov_d^{-1} \mu_d - \frac{1}{2} \mu_d^T \mu_d \quad (5.16a)$$

e

$$d_p(\mathbf{Z}) = \mathbf{Z}^T Cov_p^{-1} \mu_p - \frac{1}{2} \mu_p^T \mu_p \quad (5.16b)$$

A superfície de decisão é dada pela seguinte expressão:


$$d(\mathbf{Z}) = d_d(\mathbf{Z}) - d_p(\mathbf{Z}) \quad (5.17)$$

onde a regra para classificar uma amostra desconhecida \mathbf{Z}_x é:



$$\begin{aligned} \mathbf{Z}_x \in C_d &\Rightarrow d(\mathbf{Z}_x) > 0 \\ \mathbf{Z}_x \in C_p &\Rightarrow d(\mathbf{Z}_x) < 0 \end{aligned}$$

Na Fig. 5.3 são apresentados os gráficos bidimensionais das características MEAN, CON e STD junto com a superfície de decisão obtida, a partir da equação (5.17),

para o conjunto 1. Na Fig. 5.4 são apresentadas as regiões de decisão para as características ENT, CON e STD representativas do conjunto 2.




(a)




(c)


Fig. 5.3 Classificador para o conjunto 1. Características: (a) CON,MEAN; (b) CON,STD e (c) MEAN,STD.



(a)



(b)



(c)

Fig. 5.4 Classificador para o conjunto 2. Características: (a) CON,ENT; (b) CON,STD e (c) ENT,STD.

Na Tabela 5.5 são apresentados os resultados obtidos na classificação, através do método de Bayes, dos três conjuntos de amostras.

TABELA 5.5. Resultados experimentais do método de Bayes

CONJUNTO	TAXA DE REJEIÇÃO	TAXA DE DETECÇÃO
1	16.44%	78.76%
2	15,30%	71.20%
3	42.60%	69.80%

c) MÉTODO 3: MÉTODO PROPOSTO

No Capítulo III foi apresentado o algoritmo de extração do vetor h , onde demonstrou-se que, com sua utilização, é possível diferenciar uma amostra de boa qualidade de outra com defeito (ver Fig. 4.13). Como foi colocado anteriormente (Seção III.6), para contornar o problema de variações inerentes ao processo de fabricação na obtenção de cerâmicas da mesma textura (dispersão), a determinação do classificador é obtida utilizando-se uma quantidade M de amostras consideradas padrão. A partir dessas amostras são obtidos os vetores h que são utilizados para a determinação do classificador. Experimentalmente, comprovou-se que os valores de κ que apresentam melhores resultados são: 2 e 3. Tais resultados são apresentados nas Tabelas 5.6 e 5.7.

Para avaliar o classificador foi utilizado também o método LOSO de forma idêntica à usada na avaliação dos outros classificadores apresentados anteriormente.

TABELA 5.6 - Resultados experimentais para $\kappa=2$

CONJUNTO	TAXA DE REJEIÇÃO	TAXA DE DETECÇÃO
1	6.67%	85.00%
2	6.35%	84.62%
3	5.20%	83.00%

TABELA 5.7 - Resultados experimentais para $\kappa=3$

CONJUNTO	TAXA DE REJEIÇÃO	TAXA DE DETECÇÃO
1	4.00%	85.00%
2	4.76%	84.62%
3	4.81%	83.00%

V.4 ANÁLISE DA COMPLEXIDADE COMPUTACIONAL

A complexidade computacional é associada com o número de operações. Estas operações envolvem o cálculo das características que serão utilizadas para determinar se a peça possui defeito ou não. Na avaliação desta complexidade será utilizada uma medida de complexidade (C) [69] dada por:

$$\text{Complexidade (C)} = \text{Operações Aritméticas (O)}$$

O valor total de operações O é uma soma ponderada das operações aritméticas envolvidas. O peso associado a cada tipo de operação é dado na Tabela 5.8.

TABELA 5.8. Pesos associados às operações aritméticas.

OPERAÇÃO	EXEMPLO	PESO
Adições (AD)	$() = () + ()$	1
Multiplicações (MUL)	$() = () * ()$	1
Multipl. e acumulação (MAC)	$() = () * () + ()$	1
Transferência de dados	float, int.	1
Operações lógicas	shift, AND, OR	1
Divisões (DIV)	$() = () / ()$	18
Raízes quadradas (SQRT)	$() = \text{sqrt}()$	25
Funções transcendentais (FT)	seno, log	25
Testes aritméticos	if, if then else	2
Adiciona-compara-seleciona	decodificação Viterbi	6

O cálculo da complexidade computacional para a determinação da estatística de diferenças (ED), segundo o método proposto e para uma imagem de dimensão $N \times N$, é obtido pela seguinte expressão:

$$\text{Complex. (ED)} = N \times N \times 2 \times \text{AD} + \text{Complex. Histograma}$$

onde a complexidade para o cálculo do histograma é dada por:

$$\text{Complex. Histograma} = N \times N \times \text{AD} + \text{DIV}$$

No caso do método clássico, devem ser calculadas as características que representam a textura da imagem (MAS, ENT, STD, CON, e MEAN). A complexidade computacional destes parâmetros característicos é obtida a partir das seguintes expressões:

$$\text{Complex. (MAS)} = N_g \times (\text{MULT} + \text{AD})$$

$$\text{Complex. (ENT)} = N_g \times (\text{MULT} + \text{LOG} + \text{AD})$$

$$\text{Complex. (CON)} = N_g \times (3 \times \text{MULT} + \text{AD})$$

$$\text{Complex. (MEAN)} = 2 \times N_g \times \text{MULT}$$

$$\text{Complex. (STD)} = N_g \times (3 \times \text{MULT} + 2 \times \text{AD}) + 2 \times \text{MULT} + \text{SQRT}$$

Considerando uma imagem de dimensão 400×400 e cada pixel quantizado com 256 níveis de cinza, a complexidade computacional dos métodos clássico e proposto é resumida na Tabela 5.9. Neste caso o método clássico é avaliado utilizando a ED do método proposto. Aqui utiliza-se um único vetor estatística de diferenças.

TABELA 5.9. Comparação da complexidade computacional.

MÉTODO	COMPLEXIDADE/PIXEL
Clássico	3.04
Proposto	3

No caso de se utilizar as 4 direções principais, a comparação da complexidade computacional é dada na Tabela 5.10.

TABELA 5.10. Comparação da complexidade computacional.

MÉTODO	COMPLEXIDADE/PIXEL
Clássico	8
Proposto	3

V.5 ANÁLISE DOS RESULTADOS

Neste capítulo é apresentada uma comparação do desempenho do método proposto em relação a métodos tradicionais largamente utilizados na classificação de texturas. Através da análise das Tabelas 5.4, 5.5, 5.6 e 5.7, pode-se avaliar o desempenho do método proposto em relação aos outros métodos com respeito à taxa de rejeição de amostras sem defeito como também relativo à taxa de detecção de cerâmicas defeituosas. Pode-se constatar a nítida vantagem do classificador proposto sobre os outros dois classificadores tradicionais. Outras vantagens que o novo classificador apresenta são:

- a) menor complexidade computacional. Não é preciso efetuar nenhum cálculo adicional além da determinação dos vetores \mathbf{h} , como é o caso nos métodos 1 e 2 (métodos clássicos), onde se deve determinar as características CON, ENT, ASM, etc. Da Tabela 5.9 pode se observar que a complexidade computacional por pixel é levemente menor do que no caso do método clássico. Isto é porque as características consideradas foram obtidas a partir da estatística de diferenças do método proposto. Entretanto, da análise das Tabelas 5.11 e 5.12 pode-se observar o melhor desempenho em relação ao método clássico. Se são utilizadas as quatro direções, a complexidade computacional por pixel aumentou em quase 90% em relação ao método proposto. A partir

destes resultados pode-se observar uma menor complexidade do método proposto em relação ao método clássico.

- b) o treinamento do classificador é feito apenas com amostras padrão. Nos outros métodos é preciso treinar com amostras padrão e amostras com defeito, aumentando, assim, o tempo e os cuidados necessários dispensados na etapa de treinamento.
- c) da análise das Tabelas 5.2. e 5.3, pode-se observar que, dependendo do tipo de textura da peça, as características que melhor descrevem a peça não são sempre as mesmas. Este fato obriga à realização de uma análise particular em cada caso, introduzindo, portanto, uma complicação adicional na etapa de treinamento do sistema. Isto não acontece quando são utilizados os vetores \mathbf{h} , tal como no método proposto.

A partir da análise das Figs. 5.1, 5.2, 5.3 e 5.4 pode-se observar que a separação das classes "sem defeito" e "defeituosa" não é bem definida, ou seja, as características normalmente utilizadas na classificação de texturas não produzem neste caso resultados aceitáveis. Tanto as taxas de detecção de peças com defeito quanto às de rejeição de peças sem defeito obtidas (métodos 1 e 2) não são devidas ao método de projeto do classificador, mas sim à superposição existente entre classes. Outro fato a se considerar é que, nos métodos 1 e 2, foram utilizadas as amostras defeituosas que foram corretamente classificadas pelo método proposto, ou seja, as percentagens das taxas de detecção são em relação a 100% das taxas de detecção obtidas no método proposto. As taxas de rejeição são, em todos os casos, em relação ao total de amostras sem defeito de cada conjunto. Nas Tabelas seguintes são mostradas as taxas de detecção dos métodos utilizados na comparação em relação ao método proposto.

TABELA 5.11 - Resultados experimentais do método de Fisher em relação ao método proposto

CONJUNTO	κ	TAXA DE DETECÇÃO
1	2	69.41%
2	2	77.71%
3	2	69.28%
1	3	69.41%
2	3	77.71%
3	3	69.28%

TABELA 5.12 - Resultados experimentais do método de Bayes em relação ao método proposto

CONJUNTO	κ	TAXA DE DETECÇÃO
1	2	92.66%
2	2	90.10%
3	2	84.10%
1	3	92.66%
2	3	90.10%
3	3	84.10%

Pode-se observar, a partir das Tabelas 5.11 e 5.12, o melhor desempenho do método proposto com relação aos métodos de análise de texturas existentes. A escolha dos métodos de análise de texturas para efetuar a comparação baseou-se na sua complexidade computacional na hora da implementação do algoritmo de processamento. Métodos de grande complexidade não foram considerados, já que seria inviável sua aplicação na solução de um problema real.

CAPÍTULO VI.

CONCLUSÕES E SUGESTÕES

CONCLUSÕES E SUGESTÕES

O OBJETIVO deste trabalho foi o desenvolvimento de novas técnicas de processamento de imagens que, quando utilizadas em uma aplicação industrial podem ajudar sensivelmente o aumento de produtividade como também, possibilitar um mais rigoroso controle de qualidade no produto final. Atualmente, na maior parte das indústrias no Brasil, a inspeção visual do produto é efetuada por inspetores humanos. Por outro lado, diversos estudos realizados têm concluído que o desempenho de inspetores humanos, em certas atividades, é eficiente apenas em curtos períodos de tempo durante a jornada de trabalho. O período de tempo em que um inspetor humano consegue inspecionar corretamente um determinado produto é função das características do produto, da velocidade do processo e do ambiente de trabalho. As razões apresentadas têm representado uma justificativa suficientemente convincente para se procurar empregar sistemas de inspeção visual automática nos processos industriais.

O domínio das técnicas de processamento de imagens, atualmente, já permitem o desenvolvimento de algoritmos para operação em tempo real que possibilitem a manipulação das informações contidas na imagem de uma peça cerâmica para realizar a sua inspeção visual, permitindo assim, a detecção de defeitos superficiais. Um requisito fundamental a ser cumprido pelo algoritmo de inspeção é quanto à sua complexidade computacional. Devido ao fato da complexidade computacional requerida estar intimamente relacionada ao tempo de processamento, a simplicidade de implementação e a precisão do algoritmo tornam-se fatores decisivos para o sucesso de um sistema automático de inspeção.

O algoritmo desenvolvido neste trabalho está baseado na teoria das matrizes de co-ocorrências. A utilização destas matrizes é bem conhecida quando se deseja estudar as

propriedades estatísticas de imagens com algum tipo característico de textura, podendo-se citar da literatura diversas aplicações desta teoria. O objetivo principal dos métodos de classificação até então existentes era a classificação de texturas a partir de um conjunto de alternativas conhecidas. Geralmente, esses métodos consistem de duas fases, a fase de treinamento e a fase de classificação. Na fase de treinamento se extrai, a partir de texturas conhecidas, um conjunto de características da estatística de co-ocorrência que representam a “identidade” dessas texturas. Na fase de classificação, são extraídas as mesmas características de uma imagem com uma textura desconhecida, porém pertencente a alguma textura do conjunto de treinamento, para ser classificada pela sua proximidade a um determinado padrão. Quando tenta-se aplicar este tipo de procedimento na tarefa de classificação de cerâmicas, as características que melhor representam os diferentes tipos de cerâmicas não são as mesmas. Este fato representa uma grande desvantagem devido que a extração do padrão precisa ser feito por um operador qualificado. Entretanto, a técnica proposta sugere um outro ponto de vista para o emprego destas matrizes. Como o interesse não é direcionado para a classificação das peças cerâmicas pela sua textura, através da extração de determinadas características a partir da estatística de co-ocorrência (ou estatística de diferenças), neste caso propõe-se o emprego direto das matrizes de co-ocorrência (ou estatística de diferenças) para determinar se a peça é defeituosa ou não. Assim, o algoritmo desenvolvido possui os requisitos básicos de fácil treinamento e de complexidade mínima.

Os resultados apresentados no presente trabalho foram obtidos através da simulação em estações de trabalho. Entretanto, provêm uma ampla justificação para a aplicação do método na automação da tarefa de inspeção visual na indústria cerâmica. Abrem-se, então, novas linhas de pesquisas que podem ser exploradas para o desenvolvimento do trabalho aqui apresentado, destacando-se como sugestão:

- a) Utilização de técnicas de Reconhecimento de Padrões no projeto do classificador, visando otimizar seu desempenho;

- b) Aplicação do método em outras áreas, como por exemplo indústria têxtil, onde se requer o mesmo tipo de análise a fim de se determinar a presença de defeitos no produto que está sendo manufaturado.

APÊNDICE

APÊNDICE

A seguir, serão apresentadas as técnicas de segmentação de imagens, baseadas no histograma, utilizadas neste trabalho.

A.1 MÉTODO DE OTSU [58]

Consideremos uma imagem quantizada com N_g níveis de cinza pertencentes ao conjunto $\mathbf{G}=\{0,\dots,N_g-1\}$; seja n_i o número de pixels de nível de cinza i . O número total de pixels é então dado por:

$$N = \sum_{i=0}^{N_g-1} n_i \quad (\text{A.1})$$

Considerando que o histograma normalizado \mathbf{h} da imagem corresponde à função densidade de probabilidade da imagem, tem-se que:

- 1) $h_i = \frac{n_i}{N}$
- 2) $h_i \geq 0$
- 3) $\sum_{i=0}^{N_g-1} h_i = 1$

A partir da suposição de que na imagem só existem duas classes, C_O e C_F , e considerando que os pixels pertencentes a cada uma destas classes se agrupam ao redor de cada pico do histograma \mathbf{h} , a separação entre uma classe e a outra é dada pelo limiar T . Com isto, tem-se:

Conjunto de pixels objeto: $C_O=\{0,\dots,T\}$

, $T \in \mathbf{G}$

Conjunto de pixels fundo: $C_F = \{T+1, \dots, 255\}$

As probabilidades de ocorrência e o valor médio da classe para cada conjunto são dados, respectivamente, por:

$$w_o = P(C_o) = \sum_{i=0}^T h_i = w(T) \quad (\text{A.2})$$

$$w_F = P(C_F) = \sum_{i=T+1}^{Ng-1} h_i = 1 - w(T) \quad (\text{A.3})$$

e,

$$\mu_o = \sum_{i=0}^T i P(i / C_o) = \sum_{i=0}^T \frac{i p_i}{w_o} = \frac{\mu(T)}{w(T)} \quad (\text{A.4})$$

$$\mu_F = \sum_{i=T+1}^{Ng-1} i P(i / C_F) = \sum_{i=0}^T \frac{i p_i}{w_F} = \frac{\mu_T - \mu(T)}{1 - w(T)} \quad (\text{A.5})$$

onde:

$$P(i / C_o) = \frac{P(i \cap C_o)}{P(C_o)} = \frac{h_i}{w_o} \quad (\text{A.6})$$

$$w(T) = \sum_{i=0}^T h_i \quad \text{: momento cumulativo de ordem zero} \quad (\text{A.7})$$

$$\mu(T) = \sum_{i=0}^T i h_i \quad \text{momento cumulativo de ordem 1} \quad (\text{A.8})$$

$$\mu_T = \mu(Ng - 1) = \sum_{i=0}^{Ng-1} i h_i \quad (\text{A.9})$$

onde, μ_T representa o nível médio de cinza da imagem.

Para qualquer valor de $T \in \mathbf{G}$, tem-se que:

$$w_0 \mu_0 + w_1 \mu_1 = \mu_T \quad (\text{A.10})$$

$$w_0 + w_1 = 1 \quad (\text{A.11})$$

as variâncias de classe são dadas por:

$$\sigma_O^2 = \sum_{i=0}^T (i - \mu_0)^2 P(i / C_O) = \sum_{i=0}^T (i - \mu_0)^2 \frac{h_i}{w_0} \quad (\text{A.12})$$

$$\sigma_F^2 = \sum_{i=T+1}^{Ng-1} (i - \mu_F)^2 P(i / C_F) = \sum_{i=0}^T (i - \mu_F)^2 \frac{h_i}{w_F} \quad (\text{A.14})$$

A fim de determinar o valor ótimo de T , tal que este maximize a separação de classes, deve-se utilizar algum critério ou função de maneira que o máximo desta função corresponda a este valor ótimo. De [66] pode-se extrair as seguintes funções a maximizar:

$$\lambda = \frac{\sigma_B^2}{\sigma_w^2} \quad ; \quad \kappa = \frac{\sigma_T^2}{\sigma_w^2} \quad ; \quad \eta = \frac{\sigma_B^2}{\sigma_T^2} \quad (\text{A.15})$$

onde,

$$\sigma_w^2 = w_0 \sigma_O^2 + w_F \sigma_F^2 \quad (\text{A.16})$$

$$\sigma_B^2 = w_0 (\mu_0 - \mu_T)^2 + w_1 (\mu_1 - \mu_T)^2 \quad (\text{A.17})$$

$$\sigma_T^2 = \sum_{i=0}^{Ng-1} (i - \mu_T)^2 h_i \quad (\text{A.18})$$

com:

σ_w : variância de classe

σ_B : variância entre classes

σ_T : variância total

também, tem-se que:

$$\sigma_T^2 = \sigma_w^2 + \sigma_B^2 \quad (\text{A.19})$$

Escolhendo a função $\eta = \frac{\sigma_B^2}{\sigma_T^2}$, vemos que σ_B^2 é uma função que depende de T .

Portanto, para achar o valor ótimo de T basta só achar o máximo de $\sigma_B^2(T)$. Substituindo as expressões de w_o , σ_o , w_1 e σ_1 em (A.17) e (A.18) obtém-se:

$$\sigma_B^2(k) = \frac{[\mu_T w(k) - \mu(k)]^2}{w(k)[1 - w(k)]} \quad (\text{a.20})$$

Chamando T^* ao valor que maximiza (a.20), tem-se:

$$\sigma_B^2(T^*) = \max_{0 \leq T < N_g - 1} \sigma_B^2(T) \quad (\text{a.21})$$

Na Fig. A.1 é mostrado o histograma da imagem junto com a função $\sigma_B^2(T)$, onde observa-se que o valor máximo de $\sigma_B^2(T)$ corresponde ao vale do histograma.




Fig. A.1. Fixação do limiar de binarização.

A.2 MÉTODO PARAMÉTRICO

Outro método utilizado no problema de segmentação é o método paramétrico. Segundo essa suposição, o histograma bimodal da imagem é obtido a partir da soma de duas funções densidade de probabilidades unimodais. Cada densidade unimodal representa objeto e fundo, respectivamente. Modelando cada função densidade de probabilidade, segundo os parâmetros média e variância de uma distribuição gaussiana $N(\alpha, \sigma)$, a função densidade de probabilidade da soma será:

$$p(z) = P_1 p_1(z) + P_2 p_2(z) \quad (\text{A.22})$$

onde,

$$p_1(z) : N(\mu_1; \sigma_1^2) \quad (\text{A.23})$$

$$p_2(z) : N(\mu_2; \sigma_2^2) \quad (\text{A.24})$$

sendo P_1 e P_2 as probabilidades a priori dos níveis de cinza correspondentes ao objeto e fundo, respectivamente, admitindo que:

$$P_1 + P_2 = 1 \quad (\text{A.25})$$

Para calcular o limiar ótimo consideremos $\mu_1 < \mu_2$, e que os conjuntos de pixels que pertencem ao objeto e fundo, são definidos por:

$$\mathbf{O}: \{((x, y); \mathbf{I}(x, y)) / \mathbf{I}(x, y) \geq T\} \quad (\text{A.26})$$

$$\mathbf{F}: \{((x, y); \mathbf{I}(x, y)) / \mathbf{I}(x, y) < T\}$$

O valor do limiar ótimo pode ser obtido a partir da minimização da probabilidade de erro. A probabilidade de classificar erradamente um pixel pertencente ao objeto como pertencendo ao fundo está dada por:

$$E_1(T) = \int_{-\infty}^T p_2(z) dz \quad (\text{A.27})$$

Similarmente, a probabilidade de classificar um pixel pertencente ao fundo como sendo um pixel do objeto é:

$$E_2(T) = \int_T^{\infty} p_1(z) dz \quad (\text{A.28})$$

Portanto, a probabilidade total de erro será:

$$E(T) = P_2 E_1(T) + P_1 E_2(T) \quad (\text{A.29})$$

Para achar o T ótimo, faz-se $\frac{dE(T)}{dT} = 0$, obtendo-se a seguinte expressão:

$$P_1 p_1(T) = P_2 p_2(T) \quad (\text{A.30})$$

resolvendo a expressão anterior para T e assumindo que $\sigma_1 = \sigma_2 = \sigma$, obtém-se o limiar que minimiza (A.29), assim:

$$T = \frac{\mu_1 + \mu_2}{2} + \frac{\sigma^2}{\mu_1 - \mu_2} \log\left(\frac{P_2}{P_1}\right) \quad (\text{A.31})$$

Em seguida, são apresentadas duas variantes deste método; ambos são métodos iterativos e utilizados para imagens contendo duas classes, ou seja com histogramas do tipo bimodal.

A.2.1 MÉTODO DE RIDLER- CALVARD: [59]

A regra de segmentação é obtida a partir da consideração que $P_1 = P_2$ na equação (A.31). O limiar resultante é dado pela seguinte expressão:

$$T = \frac{1}{2}(\mu_1 + \mu_2) \quad (\text{A.32})$$

onde μ_1 e μ_2 são os valores médios de classe.

A.2.2 MÉTODO DE LLOYD: [60]

Para este caso as probabilidades a priori P_1 e P_2 são estimadas por:

$$P_1 = \frac{n_1}{N} \quad ; \quad P_2 = \frac{n_2}{N} \quad (\text{A.33})$$

com n_1 e n_2 número de pixels pertencentes ao objeto e ao fundo, respectivamente, e sendo N o número total de pixels da imagem. Substituindo (A.33) em (A.31), o limiar resultante é dado por:

$$T = \frac{1}{2}(\mu_1 + \mu_2) + \frac{\sigma^2}{(\mu_1 - \mu_2)} \log\left(\frac{n_2}{n_1}\right) \quad (\text{A.34})$$

Por não se conhecer o valor de σ este é estimado, a partir da imagem, pela seguinte expressão:

$$\sigma_{est}^2 = \frac{1}{2} \frac{(\mu_1 - \mu_2)^2}{\log(n_1 + n_2)} \quad (\text{A.35})$$

substituindo (A.35) na expressão (A.34), tem-se o limiar proposto por Lloyd como sendo:

$$T = \frac{1}{2} \left[(\mu_1 + \mu_2) + \frac{(\mu_1 - \mu_2) \log\left(\frac{n_2}{n_1}\right)}{\log(n_1 + n_2)} \right] \quad (\text{A.35})$$

REFERÊNCIAS BIBLIOGRÁFICAS

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] H.M. Morris, " Industry Begins to Apply vision Systems Widely ", Control Engineering, pp.68-70, jan-85.
- [2] D. Petkovic and J. Wilder, " Machine Vision in the 1990s: Applications and how to get there ", Machine Vision and Applications 4, pp. 113-115, 1991.
- [3] M. Eijiri, " Machine Vision in the 1990s", Machine Vision and Applications 4, pp. 116-119, 1991.
- [4] J.L.C. Sanz, A.K. Jain, " Machine-vision techniques for inspection of printed wiring boards and thick-film circuits ", J.Opt.Soc.Am., vol.3, no.9, sep-86.
- [5] Henry M. Morris " Robot Vision : Bringing eyesight to the blind ", Control Engineering, pp. 64-67. jan-85.
- [6] A. Browne and L. Norton-Wayne, " Vision and information processing for automation", Plenum Press, New York 1986.
- [7] J.A. Bosch et al., " The role of inspection in the automated factory ", The Carbide and Tool Journal, pp. 16-21, september-october, 1985.
- [8] M.P. Groover, " Automation, Production Systems and Computer Integrated Manufacturing", Prentice-Hall Inc., 1987.
- [9] R.T. Chin and C. Harlow, " Automated visual inspection: A survey ", IEEE PAMI, vol.4, no. 6, 1982.
- [10] J. Deklotz, " Machine visão can keep quality high and production lines moving ", I&CS, pp. 35-38, dec-93.
- [11] P.A. McKeon, P. Cook, W. Bailey, " The application of optics to the quality control of automotive components ", Proc. SPIE, vol.60, pp 68-76, may-75.
- [12] P.D. Poulson, L.O. Ford, " Inspection of axially symmetric parts ", Proc. SPIE, vol.60, pp. 91-98, may-75.
- [13] B.G. Batchelor, G.A. Williams, " Defect detection on the internal surface of hydraulics cylinder for motor vehicles ", Proc. SPIE, vol 182, pp. 65-78, apr.-79.
- [14] R.V. Williams, " Applied optics in the European coal and steel community ", Proc. SPIE, pp. 52-56, may-75.
- [15] D.J. Purl, " Automated surface inspection with solid-state image sensors ", Proc. SPIE, vol 130, pp. 84-89, 1977.
- [16] G.B. Porter, T.M. Cipolla, J.L. Mundy, " Automatic visual inspection of blind holes in metal surfaces ", Proc. IEEE Comput Soc. Conf. Pattern Recognition and Image Processing, pp. 83-86, aug-79.
- [17] L.Norton-Wayne, W.J. Hill, R.A. Brook, " Automatic visual inspection of moving steel surfaces ", British Journal of NDT, pp. 242-248, sep-77.

-
- [18] Manual SACMI, "Defeitos", INTRATEC. Traduções Técnicas Ltda.
- [19] Qin-Zhong Ye, Per E. Danielsson, " Inspection of Printed Circuits Boards by Connectivity Preserving Shrinking ", IEEE PAMI, vol.10, no.5, sep-88.
- [20] F.S. Cohen, Z. Fan And S. Attali, " Automated Inspection of Textile Fabrics Using Textural Methods ", IEEE PAMI, no.8, pp. 803-808, aug-91.
- [21] R. Connors, M.H. Trivedi and C. Harlow, " Segmentation of a high resolution urban scene using texture operators ", CVGIP, no.25, pp.273-310, 1984.
- [22] R.T. Chin, " Automated visual inspection: 1981 to 1987 ", CVGIP - 41, pp. 346-381, 1988.
- [23] J.W. Schoonard, J.D. Gould, " Field of view and target uncertainty in visual search and inspection ", Human Factors, feb.-73.
- [24] S.C. Wang, " Human reability in visual inspection ", Quality, set.-74.
- [25] W. Siedlecki, K. Siedlecka and J. Sklansky " Mapping techniques for exploratory pattern analysis ", Pattern Recognition and Artificial Intelligence, Elsevier Science Publishers, 1988.
- [26] B.V. Dasarathy and B.V. Sheela, " A composite classifier system design: Concepts and methodology", Proc. IEEE, vol.67, no.5, may.-79.
- [27] Yu-Chi Ho and A.K. Agrawala, " On pattern classification algorithms: Introduction and survey", Proc. IEEE, vol.56, no.12, dec.-68.
- [28] R.M. Haralick, " Statistical and Structural Approaches to Texture ", Proc. IEEE, vol.67, no.5, may-79.
- [29] F. Tomita, Y. Shirai, S. Tsuji, " Description of textures by a structural analysis ", IEEE PAMI, vol.4, pp.183-191, 1982.
- [30] F. Tomita, S. Tsuji, " A structural analyzer for a class of textures", CGIP, vol.2, pp.216-231, 1973.
- [31] S. Wang, F.R. Velasco, A. Wu, A. Rosenfeld, " Relative Effectiveness of Selected Texture Primitive Statistics for Texture Discrimination ", IEEE trans. on SMC, vol.11, no.5, pp. 360-370, may.-81.
- [32] Bela Julesz, " Experiments in the visual perception of texture ", Scientific American, 235, pp.34-43, 1975.
- [33] R.M. Haralick, K. Shanmugam, Its'Hak Dinstein. " Textural features for image classification ", IEEE trans. on SMC, vol.3, no.6, nov-73.
- [34] R. Bajcsy, " Computer Description of Textured Surfaces ", Proc. 3rd Int. Joint Conf. Om Artificial Intelligence, pp. 572-579, 1973.
- [35] J. Weszka, C. Dyer, A. Rosenfeld, " A comparative study of texture measures for terrain classification ", IEEE trans. om SMC, vol.4, no.4,pp.269-285, apr.-76.
- [36] H. Tamura, S. Mori, T. Yamawaki, " Textural Features Corresponding to Visual Perception ", IEEE trans. om SMC, vol.8, no.6, pp. 460-473, jun.-78.

- [37] F. Tomita, S. Tsuji, " Computer analysis of visual textures ", Kluwer Academic Publishers, 1990.
- [38] R. Connors, M.H. Trivedi, S. Goh and C. Haralick, " Object detection based on gray level co-occurrence ", CVGIP, no.28, pp.199-219, 1984.
- [39] R.C. Gonzalez, R.E. Woods, " Digital Image Processing ", Addison-Wesley Publishing Co.,1992.
- [40] O.R. Mitchell, C.R. Myer and W. Boyne, " A max-min measure for image texture analysis", IEEE Trans. Comput., vol.C-26, pp. 408-414, apr.-77.
- [41] A. Rosenfeld, " The fuzzy geometry of image subsets ", Pattern Recognition Letters, vol.2, pp. 311-317, sep.-84.
- [42] C. Sun and W.G. Wee, " Neighboring gray level dependence matrix for texture classification ", CVGIP, no.23, pp. 341-352, 1983.
- [43] H. Tamura, S. Mori, T. Yamawaki, " Textural Features Corresponding to Visual Perception ", IEEE trans. on SMC, vol.8, no.6, pp. 460-473, jun.-78.
- [44] A. Rosenfeld, B. Lipkin, " Texture synthesis ", Academic Press, NY, pp. 309-345, 1970.
- [45] R. Ehrlich and J.P. Foith, " A new of texture topology and texture description", CGIP, vol.8, pp.174-202, 1978.
- [46] P. De Souza, " Texture recognition via autorregression ", Pattern Recognition, no.15, pp.471-475, 1982.
- [47] L.S. Davis, S.A. Johns and J.K. Aggarwal " Texture analysis using generalized co-occurrence matrices ", IEEE Trans. PAMI, no.1, pp. 251-259, 1979.
- [48] W.D. Stromberg and T.G. Farr " A Fourier-based textural feature extraction procedure ", IEEE Trans. Geosci. Remote Sensing, no.24, pp. 722-731, 1986.
- [49] W.K. Pratt, "Digital Image Processing", Wiley, 1978.
- [50] ao.A. Ravishankar, "A Taxonomy for Texture Description and Identification", Springer, 1990.
- [51] R. Haralick, "Statistical Image Texture Analysis", em "Handbook of Pattern Recognition and Image Processing", Young-Fu Eds., Academic Press 1986.
- [52] Chung M. Wu and Yung Ch. Chen, "Statistical Feature Matrix for Texture Analysis", CGVIP:GMIP, vol.54(5), pp.407-419, set. 1992.
- [53] B. Julesz, "Visual pattern discrimination", IRE Trans. Inform. Theory, vol.8, no.2, pp.84-92, feb.-62.
- [54] C. Dyer, T.H. Hong and A. Rosenfeld, " Texture classification using gray level coocurrence based on edge maxima ", IEEE Trans. on SMC, vol. 10, no. 3, pp.158-163, 1980.
- [55] Pitas, I. , Venetsanopoulos, A.N., "Nonlinear Filters", Kluwer Academic Publishers, 1990.

- [56] R.M. Haralick, L.G. Shapiro, " Image segmentation techniques ", CVGIP, vol.29, pp.100-132, 1985.
- [57] I.E. Abdou, W.K. Pratt, " Quantitative design and evaluation of enhancement/thresholding edge detectors ", Proc. IEEE, vol.67, no.5, pp.753-763, may-79.
- [58] N. Otsu, " A Threshold Selection Method from Gray-level Histograms ", IEEE Trans. on SMC, vol.9, no.1, pp.62-66, jan-79.
- [59] T.W. Ridler, S. Calvard, " Picture thresholding using an iterative selection method ", IEEE Trans. on SMC, vol.8, pp. 630-632, aug-78.
- [60] K.V. Mardia, T.J. Hainsworth, " A Spatial Thresholding Method for Image Segmentation ", IEEE PAMI, vol.10, no.6, pp.919-927, nov-88.
- [61] R.C. Gonzalez, R.E. Woods, " Digital Image Processing", Addison-Wesley Publishing Co., 1992.
- [62] J.Weszka, A. Rosenfeld, " An Application of Texture Analysis to Materials Inspection ", Pattern Recognition, vol.8, pp. 195-199, 1976.
- [63] R.O. Duda, P.E. Hart, " Pattern Classification and Scene Analysis ", John Wiley and Sons, 1973.
- [64] J.Sklansky, K. Siedlecka, W. Siedlecki, " Mapping Techniques for Exploratory Pattern Analysis ", Proc. of Pattern Recognition and Artificial Intelligence, vol.7, 1988.
- [65] R.A. Fisher, " The use of multiple measurements in taxonomic problems ", Ann. Eugenics, vol.7, pp.178-188, 1936.
- [66] K. Fukunage, " Introduction to Statistical Pattern Recognition ", New York Academic, 1972, pp.260-267.
- [67] O.J. Tobias, R. Seara, F.A. Soares & J.C.M. Bermudez, " An automatic inspection algorithm for using in the ceramic industry", *ICSPAT'94 The Int. Conf. on Signal Processing Applications & Technology*, Dallas, USA, 1994, pp.1061-1065.
- [68] O.J. Tobias, R. Seara, F.A. Soares & J.C.M. Bermudez, " Automatic visual inspection using the co-occurrence approach," *38th Midwest Symposium on Circuits and Systems*, Rio de Janeiro, Brazil, 1995.
- [69] de MARCA, José Roberto Boisson. An LSF Quantizer for the North-American Half-Rate Speech Coder. A ser publicado no IEEE Transactions on Vehicular Technology. 1993.