

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

**ANÁLISE E EXTRAÇÃO DE CARACTERÍSTICAS
DE IMAGENS TERMOGRÁFICAS UTILIZANDO
COMPONENTES PRINCIPAIS**

Gilnete Leite dos Santos

Orientador: Prof. Dr. João Antônio Pereira

Dissertação apresentada à Faculdade de
Engenharia - UNESP – Campus de Ilha
Solteira, para obtenção do título de Mestre
em Engenharia Mecânica.
Área de Conhecimento: Mecânica dos
Sólidos.

Ilha Solteira – SP
julho/2010

FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

- S237a Santos, Gilnete Leite dos.
Análise e extração de características de imagens termográficas utilizando componentes principais / Gilnete Leite dos Santos. -- Ilha Solteira : [s.n.], 2010
112 f. : il.
- Dissertação (mestrado em Engenharia Mecânica) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de Conhecimento: Mecânica dos Sólidos, 2010
- Orientador: João Antônio Pereira
Inclui bibliografia
1. Termografia. 2. Análise de componentes principais. 3. Manutenção preditiva. 4. Análise de imagens térmicas. 5. Reconhecimento de padrões. 6. Classificação de padrões. 7. Processamento de imagens.

CERTIFICADO DE APROVAÇÃO

TÍTULO: ANÁLISE E EXTRAÇÃO DE CARACTERÍSTICAS DE IMAGENS TERMOGRÁFICAS
UTILIZANDO COMPONENTES PRINCIPAIS


AUTORA: GILNETE LEITE DOS SANTOS

ORIENTADOR: Prof. Dr. JOAO ANTONIO PEREIRA


Aprovada como parte das exigências para obtenção do Título de MESTRE em ENGENHARIA
MECÂNICA, Área: MECANICA DOS SÓLIDOS, pela Comissão Examinadora:


Prof. Dr. JOAO ANTONIO PEREIRA

Departamento de Engenharia Mecânica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. AMARILDO TABONE PASCHOALINI

Departamento de Engenharia Mecânica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. RENE PEGORARO

Departamento de Computação / Faculdade de Ciencias de Bauru

Data da realização: 15 de julho de 2010.

DEDICATÓRIA

Dedico esta dissertação à minha Família, em especial ao meu pai Miguel Leite e minha mãe Irani Salvador, por sempre estar ao meu lado me dando apoio e confiança.

AGRADECIMENTOS

Primeiramente a Deus pela vida, oportunidades, força e coragem.

À minha família pelo apoio, incentivo, confiança, paciência e carinho.

Ao professor Dr. João Antônio Pereira pela paciência na orientação, pela contribuição no meu aprendizado e, sobretudo por acreditar neste trabalho.

À banca examinadora, por dispor de seu tempo e contribuir para o enriquecimento deste trabalho.

Ao Programa de Pós-Graduação em Engenharia Mecânica, professores do departamento que direta ou indiretamente contribuíram para execução deste trabalho. Em especial, aos professores Dr. Gilberto Pechoto de Melo e Dr. Vicente Lopes Júnior que sempre me deram apoio com palavras acolhedoras e de incentivo.

Aos professores Dr. Amarildo Tabone Paschoalini e orientados Jeferson Fukushima e Edilson Guimarães de Souza que contribuíram com a realização dos experimentos dispondo tempo e atenção as minhas solicitações.

A todos os meus amigos que contribuíram de forma direta e indireta para a realização deste trabalho.

“Com apenas alguns segundos de entrada no mundo, aqueles que dentre nós foram abençoados com o presente da visão, começam a perceber imagens do que está ao seu redor. Pouco tempo depois, o processamento, a análise e o entendimento de imagens por seres humanos se tornam quase uma rotina.”

(Sergio Neves Rodrigues)

As técnicas de termografia vêm atualmente ganhando espaço como técnicas de manutenção preditiva, principalmente, por seu caráter não invasivo (ferramenta de não contato) que possibilita o monitoramento do aquecimento de máquinas e equipamentos em operação ou mesmo energizados. A utilização de câmeras termográficas hoje é uma realidade em vários setores industriais para monitoramento e detecção de falhas com base na temperatura. Entretanto, a utilização de câmaras termográficas na manutenção não deve se restringir apenas à avaliação da temperatura, uma vez que as imagens termográficas são sinais que apresentam padrões complexos que podem captar as diferentes características e condição de operação do equipamento. Outras informações além da temperatura poderiam ser observadas para uma avaliação mais consistente do estado de operação do equipamento. Este trabalho discute a utilização da técnica da estatística multivariada, Análise de Componentes Principais (ACP) para o processamento e análise de um conjunto de imagens termográficas. Essa proposta visa à identificação de padrões associados às variações térmicas das imagens, bem como, a interpretação desses dados em termos da sua variabilidade espacial/temporal para aplicação na manutenção preditiva com base na termografia. Num primeiro momento a técnica foi aplicada para a avaliação de um conjunto de dados (imagens térmicas) obtidos a partir da simulação do aquecimento de um dado componente (chave elétrica), cujo objetivo foi testar e verificar a validade da proposta e do programa desenvolvido. Posteriormente a técnica foi aplicada para o acompanhamento e avaliação do aquecimento de componentes de um modelo simplificado de um painel de telefonia, formado por blocos de alumínio fixados em uma placa de acrílico. A análise no modo espacial e no modo temporal do conjunto de termogramas obtidos para as diferentes condições de aquecimento dos blocos mostrou que é possível verificar e estabelecer correlações entre as Componentes Principais e o perfil térmico do sistema.

Palavras-chaves: *Termografia. Análise de componentes principais. Manutenção preditiva. Análise de imagens térmicas. Reconhecimento e classificação de padrões.*

ABSTRACT

Thermography techniques are currently gaining ground as predictive maintenance techniques, mainly due to its non-invasive character (non-contact tool) that allows the monitoring of heating condition of machines and equipment also in operation and even energized. The use of thermographic cameras is now a reality in many industrial and electrical sectors for monitoring and fault detection based on temperature. However, the use of thermal imagers in the maintenance should not be restricted to only the evaluation of temperature, since the thermographic images are signs that show complex patterns and they can capture the different characteristics of the actual condition of the monitored equipment. Information other than temperature could be observed for a more consistent evaluation of its state of operation. This paper discusses the propose of use of the multivariate analysis technique, Principal Component Analysis (PCA) for the processing and analysis of a series of thermographic images in order to identify patterns associated with temperature variations of the images, as well as, the interpretation of these data in terms of their spatial/temporal variability. Initially the technique was used to the analysis of data (thermal images) obtained from the simulation of heating conditions of a component (electric switch) aiming at to test and verify the validity of the proposal and program development. Later the technique was applied to the monitoring and evaluation of the heating condition of components of a simplified model of a telephone panel, formed by aluminum blocks fixed in a plate of acrylic. The analysis in the spatial and temporal mode of the set of thermograms obtained for different heating conditions of the blocks, it showed that it is possible to verify and establish correlations between the Principal Components and the thermal profile of the system.

Keywords: Thermography. Analysis of principal component. Predictive maintenance. Pattern recognition and classification.

LISTA DE FIGURAS

<i>Figura 3.1: Espectro eletromagnético e a região de medição do infravermelho (Fonte: Adaptado de Kaplan,1999).....</i>	<i>26</i>
<i>Figura 3.2: Imagem digital em 256 tons de cinza (Fonte: Adaptado de Silva, 2005).</i>	<i>35</i>
<i>Figura 3.3: Imagem infravermelha de um sistema elétrico.....</i>	<i>36</i>
<i>Figura 3.4: Imagens do satélite LANDSAT, de Washington. (a)-(c) bandas azul, verde e vermelho do espectro visível, (d) infravermelho próximo, (e) infravermelho médio e (f) infravermelho térmico (Fonte: Gonzalez e Woods, 2007).</i>	<i>37</i>
<i>Figura 4.1: Dispersão de cinco amostras em função dos escores das Componentes Principais.....</i>	<i>47</i>
<i>Figura 4.2: Seqüência de N imagens, cada imagem com $n_x.n_y$ elementos (Fonte: adaptado de Gonzalez; Woods, 2000 e Rajic, 2002)</i>	<i>51</i>
<i>Figura 4.3: Formas de Entrada e Saída de dados da ACP (Fonte: Gurgel, 2000)</i>	<i>54</i>
<i>Figura4.4: Fluxograma da metodologia proposta neste trabalho.....</i>	<i>59</i>
<i>Figura 5.1: Imagem de um sistema elétrico sobre aquecido: (a) em cores, (b) em cinza.....</i>	<i>60</i>
<i>Figura 5.2: Seqüência de termogramas utilizados na análise.....</i>	<i>61</i>
<i>Figura 5.3: Imagem média utilizada na análise.</i>	<i>63</i>
<i>Figura 5.4: Componentes Principais espaciais obtidas por subtração da imagem média. ..</i>	<i>64</i>
<i>Figura 5.5: Porcentagem da variabilidade dos dados, explicada por cada componente principal.....</i>	<i>65</i>
<i>Figura 5.6: Perfil Temporal Médio</i>	<i>66</i>
<i>Figura 5.7: Componentes Principais espaciais obtidas por subtração do perfil temporal médio.....</i>	<i>67</i>
<i>Figura 5.8: Porcentagem da variabilidade dos dados, explicada por cada componente principal.....</i>	<i>68</i>
<i>Figura 5.9: Componentes Principais Temporais obtidas por subtração da imagem média.</i>	<i>70</i>
<i>Figura 5.10: Componentes Principais Temporais obtidas por subtração do perfil temporal médio.....</i>	<i>71</i>
<i>Figura 5.11: (a) Gráfico dos escores das duas primeiras Componentes Principais. (b) Diferentes agrupamentos dos escores.</i>	<i>73</i>
<i>Figura 5.12: Regiões correspondentes aos diferentes agrupamentos dos escores na primeira CP.</i>	<i>74</i>
<i>Figura 5.13: Escores do grupo 5 na segunda CP.</i>	<i>75</i>
<i>Figura 5.14: Gráfico dos loadings para as duas primeiras CP(s) da figura 5.4.....</i>	<i>77</i>

<i>Figura 5.15: (a) Gráfico dos escores das duas primeiras Componentes Principais. (b) Diferentes agrupamentos dos escores.</i>	<i>79</i>
<i>Figura 5.16: Regiões correspondentes aos diferentes agrupamentos dos escores. (a) Primeira CP. (b) Segunda CP.....</i>	<i>80</i>
<i>Figura 5.17: Regiões correspondentes aos diferentes agrupamentos dos escores. (a) Primeira CP. (b) Segunda CP.....</i>	<i>80</i>
<i>Figura 5.18: Escores do grupo 5 nas duas primeiras CP(s). (a) Primeira CP. (b) Segunda CP.</i>	<i>81</i>
<i>Figura 5.19: Gráfico dos loadings para as duas primeiras CP(s) da figura 5.7.....</i>	<i>82</i>
<i>Figura 6.1: Modelo esquemático do sistema analisado.</i>	<i>85</i>
<i>Figura 6.2: Bancada experimental com os principais materiais utilizados no teste.....</i>	<i>85</i>
<i>Figura 6.3: Materiais utilizados na realização do teste.</i>	<i>86</i>
<i>Figura 6.4: Termogramas em cores, utilizados na análise.....</i>	<i>87</i>
<i>Figura 6.5: Vetor das temperatura para os nove termogramas.....</i>	<i>89</i>
<i>Figura 6.6: Termogramas, em tons de cinza, utilizados na análise.</i>	<i>90</i>
<i>Figura 6.7: Imagem média utilizada na análise.</i>	<i>91</i>
<i>Figura 6.8: Componentes Principais espaciais obtidas por subtração da imagem média. ..</i>	<i>92</i>
<i>Figura 6.9: Porcentagem da variabilidade dos dados, explicada por cada componente principal.....</i>	<i>93</i>
<i>Figura 6.10: Perfil Temporal Médio.</i>	<i>94</i>
<i>Figura 6.11: Componentes Principais espaciais obtidas por subtração do perfil temporal médio.....</i>	<i>95</i>
<i>Figura 6.12: Porcentagem da variabilidade dos dados, explicada por cada componente principal.....</i>	<i>96</i>
<i>Figura 6.13: Componentes Principais Temporais obtidas por subtração da imagem média.</i>	<i>97</i>
<i>Figura 6.14: Componentes Principais Temporais obtidas por subtração do perfil temporal médio.....</i>	<i>98</i>
<i>Figura 6.15: (a) Gráfico dos escores das duas primeiras Componentes Principais. (b) Diferentes agrupamentos dos escores.</i>	<i>99</i>
<i>Figura 6.16: Regiões correspondentes aos diferentes agrupamentos dos escores na primeira CP</i>	<i>100</i>
<i>Figura 6.17: Gráfico dos loadings para as duas primeiras CP(s) da figura 6.8.....</i>	<i>102</i>
<i>Figura 6.18: (a) Gráfico dos escores das duas primeiras Componentes Principais. (b) Diferentes agrupamentos dos escores.</i>	<i>103</i>
<i>Figura 6.19: Regiões correspondentes aos diferentes agrupamentos dos escores na primeira CP.</i>	<i>104</i>
<i>Figura 6.20: Gráfico dos loadings para as duas primeiras CP(s) da figura 6.11.....</i>	<i>105</i>

LISTA DE TABELAS

<i>Tabela 5.1: Relação entre as Componentes Principais e os termogramas da figura 5.4.</i>	<i>76</i>
<i>Tabela 5.2: Relação entre as Componentes Principais e os termogramas da figura 5.7.</i>	<i>82</i>
<i>Tabela 6.1: Valores das Temperaturas dos Termogramas.</i>	<i>88</i>
<i>Tabela 6.2: Relação entre as Componentes Principais e os termogramas da figura 6.8. ..</i>	<i>101</i>
<i>Tabela 6.3: Relação entre as Componentes Principais e os termogramas da figura 6.11.</i>	<i>105</i>

SUMÁRIO

CAPÍTULO 1	15
1 <i>Introdução</i>	15
1.1 <i>Justificativa e Importância do Trabalho</i>	16
1.2 <i>Objetivo</i>	18
CAPÍTULO 2	19
2 <i>Levantamento Bibliográfico</i>	19
2.1 <i>Termografia</i>	19
2.2 <i>Análise das Componentes Principais</i>	21
CAPÍTULO 3	24
3 <i>Fundamentos Teóricos</i>	24
3.1 <i>Termografia</i>	24
3.2 <i>Introdução à Teoria da Termografia</i>	25
3.3 <i>Termografia para Ensaio Não Destrutivo</i>	29
3.4 <i>Processamento e Análise de Imagens Digitais</i>	32
3.5 <i>Imagens Térmicas</i>	34
CAPÍTULO 4	39
4 <i>Análise das Componentes Principais</i>	39
4.1 <i>Conceitos Gerais</i>	39
4.2 <i>Componentes Principais</i>	40
4.3 <i>Redução da Dimensionalidade via ACP</i>	49
4.4 <i>Análise das Componentes Principais na Termografia</i>	50
4.5 <i>Aspectos Computacionais e Cálculo de Médias</i>	55
4.6 <i>Metodologia</i>	57
CAPÍTULO 5	60
5 <i>Aplicação da ACP em Termografia</i>	60
5.1 <i>Conjunto de Dados Analisado</i>	60

5.2	<i>Componentes Principais no Modo Espacial</i>	62
5.2.1	<i>Subtração da Imagem Média</i>	63
5.2.2	<i>Subtração do Perfil Temporal Médio</i>	66
5.3	<i>Componentes Principais no Modo Temporal</i>	69
5.3.1	<i>Subtração da Imagem Média</i>	69
5.3.2	<i>Subtração do Perfil Temporal Médio</i>	70
5.4	<i>Análise do Gráfico dos Escores e Loadings Utilizando a Imagem Média</i>	72
5.4.1	<i>Análise dos Escores</i>	72
5.4.2	<i>Análise dos Loadings</i>	75
5.5	<i>Análise do Gráfico dos Escores e Loadings Utilizando o Perfil Médio</i>	78
5.5.1	<i>Análise dos Escores</i>	78
5.5.2	<i>Análise dos Loadings</i>	81
CAPÍTULO 6		84
6	Testes Experimentais	84
6.1	<i>Descrição e Montagem do Set-Up Experimental</i>	84
6.2	<i>Aquisição e Análise dos Termogramas</i>	86
6.3	<i>Componentes Principais no Modo Espacial</i>	91
6.3.1	<i>Subtração da Imagem Média</i>	91
6.3.2	<i>Subtração do Perfil Temporal Médio</i>	93
6.4	<i>Componentes Principais no Modo Temporal</i>	96
6.4.1	<i>Subtração da Imagem Média</i>	97
6.4.2	<i>Subtração do Perfil Temporal Médio</i>	98
6.5	<i>Gráfico dos Escores e Loadings Utilizando a Imagem Média</i>	99
6.5.1	<i>Análise dos escores</i>	99
6.5.2	<i>Análise dos loadings</i>	101
6.6	<i>Gráfico dos Escores e Loadings Utilizando o Perfil Médio</i>	102
6.6.1	<i>Análise dos escores</i>	103
6.6.2	<i>Análise dos Loadings</i>	104
6.7	<i>Discussão</i>	106
CAPÍTULO 7		107
7	Conclusão	107
REFERÊNCIAS		109

PREÂMBULO

Este trabalho discute a proposta de utilização da técnica da estatística multivariada, Análise de Componentes Principais (ACP) para o processamento e análise de um conjunto de imagens termográficas, visando à identificação de padrões físicos associados às variáveis térmicas, bem como, a interpretação desses dados em termos da sua variabilidade espacial/temporal para aplicação na manutenção preditiva com base na termografia. A apresentação do trabalho segue a estrutura apresentada abaixo.

Capítulo 1: Introdução

Neste capítulo é feita a introdução, contextualizando o problema abordado, bem como a justificativa, importância e o objetivo do trabalho realizado.

Capítulo 2: Levantamento bibliográfico

No capítulo é feito um levantamento bibliográfico dos assuntos relacionados com a metodologia proposta (Termografia e Análise das Componentes Principais)

Capítulo 3: Fundamentos teóricos

Este capítulo apresenta uma revisão teórica dos assuntos relacionados com o desenvolvimento metodológico proposto, abordando os aspectos relacionados com as técnicas de termografia e de processamento de imagens térmicas.

Capítulo 4: Análise das Componentes Principais

Neste capítulo são apresentados os fundamentos e conceitos relacionados com a Análise das Componentes Principais: aspectos computacionais, redução de dimensionalidade e a metodologia proposta.

Capítulo 5: Aplicação da ACP em termografia

No capítulo é discutida a aplicação da técnica de Análise das Componentes Principais em imagens térmicas. A técnica é aplicada em um conjunto de imagens simuladas a partir da introdução de pequenas variações em um termograma obtido na inspeção de um componente (chave elétrica) que apresenta um sobreaquecimento.

Capítulo 6: Resultados experimentais

Este capítulo discute a aplicação da Análise das Componentes Principais Térmicas ACPT em dados obtidos a partir do acompanhamento do aquecimento de um modelo simplificado de um painel de telefonia formado por um conjunto de nove blocos de alumínio (componentes) fixados dentro de uma caixa de acrílico. O objetivo principal da aplicação é identificar variações e tendências do comportamento térmico do sistema.

Capítulo 7: Conclusões

Este capítulo apresenta a conclusão do trabalho.

Referências

Aqui é apresentada a bibliografia utilizada na elaboração desta pesquisa.

CAPÍTULO 1

1 Introdução

No campo dos ensaios não destrutivos a manutenção preditiva é aquela que pode ser utilizada para indicar o estado de funcionamento e vida útil de um equipamento. Sua aplicação em rotinas de manutenção no setor elétrico, mecânico e industrial tem ajudado a prever de maneira confiável, o desgaste e a degradação de equipamentos e máquinas. Nas técnicas preditivas, a manutenção tem sido discutida com base no estudo e avaliação das informações do estado de operação do componente que são obtidas com sistemas de monitoramento adequados. Isso possibilita uma melhor análise das necessidades e prioridades de manutenção do equipamento, quando comparado com as técnicas mais convencionais de manutenção corretiva e manutenção preventiva.

A análise do mau funcionamento e desgaste de máquinas e equipamentos por técnicas apropriadas pode trazer um bom resultado e assim prever eventos e processos físicos que possam levar a parada desses equipamentos e provocar a perda de produção ou mesmo falhas inesperadas.

Neste caso, técnicas e métodos estatísticos, inteligência artificial ou até mesmo a combinação destas são utilizadas como suporte à tomada de decisão em manutenção preditiva. Entretanto, os investimentos de empresas modernas em novos equipamentos, geralmente mais sofisticados e que demandam um maior controle e acompanhamento de sua operação têm exigido o desenvolvimento e criação de novas técnicas de manutenção preventiva.

Neste contexto, as técnicas de termografia vêm atualmente ganhando espaço como técnicas de manutenção preditiva por serem ferramentas bastante adequadas tanto, para medida de temperatura, como para monitoramento da assinatura térmica de máquinas e equipamentos. A sua utilização hoje é uma realidade em vários setores industriais (controle de qualidade e monitoramento de processos, isolamentos e refratários, instalações elétricas em geral, fornos e caldeiras, linhas de vapor, máquinas rotativas, rolamentos e motores elétricos, verificação de níveis de líquidos, perdas em válvulas e outros).

1.1 Justificativa e Importância do Trabalho

O aquecimento de equipamentos e componentes mecânicos e elétricos, principalmente em plantas industriais, de produção e distribuição de energia, causado muitas vezes por falhas em montagens ou falta de manutenção, pode ocasionar problemas como rupturas de superfícies metálicas, fadiga térmica de material e conseqüente a perda de produção da planta, implicando altos custos. A identificação destas falhas num estágio inicial pode contribuir efetivamente para o bom desempenho e uma redução de custos de manutenção.

Termografia é uma das técnicas de inspeção não destrutiva que vem ganhando espaço no monitoramento e detecção de falhas com base na temperatura. Ela tem como base a detecção da radiação infravermelha que é emitida naturalmente pelos corpos, permitindo efetuar medições de temperaturas, sem contato físico com os equipamentos, mesmo em operação. A medição de temperatura é feita a partir da radiação térmica emitida pelo objeto que é convertida em imagem térmica. A conversão é feita a partir de câmeras especiais que transforma leitura de radiação térmica em uma imagem térmica, apresentando a resposta em forma de um termograma. Possibilitando assim que se faça uma análise do comportamento térmico do equipamento inspecionado a partir de informações térmicas lidas nas imagens.

A utilização desse tipo de monitoramento tem sido aplicada com bastante sucesso, principalmente em sistemas e componentes elétricos. Associações como o IEEE, ANSI, ABNT e fabricantes têm desenvolvido padrões de variação de temperatura para os vários componentes elétricos e etc. Entretanto, a utilização de câmara termográfica na manutenção não deve se restringir apenas á avaliação da temperatura. Uma vez que imagens termográficas são sinais que apresentam padrões complexos contendo informações a respeito de diferentes aspectos e condições do equipamento monitorado, outras informações além da temperatura poderiam ser observadas na análise (local do defeito/região) e levar a uma avaliação mais consistente do estado de operação dos equipamentos.

Desta forma, as técnicas de processamento e análise de imagens, em especial, as técnicas de extração de parâmetros, surgem como ferramentas importantes no auxílio da Termografia Preditiva e podem abrir novos horizontes para a sua aplicação, incluindo inclusive, o processamento e avaliação automática do problema que é uma das metas das técnicas não destrutivas. Neste contexto, a técnica de estatística multivariada denominada Análise das Componentes Principais (ACP) apresenta-se como uma ferramenta potencial para

o processamento e extração de características de imagens térmicas, visando o desenvolvimento de uma metodologia de identificação de padrões térmicos para uso na manutenção preditiva com base na termografia.

A ACP é uma ferramenta muito útil na investigação de relações existentes entre um conjunto de variáveis correlacionadas. Ela serve também para a identificação de padrões de variabilidade e redução dimensional de um conjunto de dados (GURGEL, 2000). A utilização da ACP no processamento e análise de imagens obtidas a partir da inspeção termográfica poderia levar a identificação dos padrões e condições físicas de operação associadas às variáveis térmicas observadas, possibilitando a interpretação dos dados em termos da sua variabilidade espacial (variações em regiões da imagem) e temporal (variações na sequência das imagens).

A utilização desta técnica no campo de ensaios não destrutivo é bastante atraente, no sentido de que ela pode ser usada para detecção e localização ou mesmo a quantificação de defeitos ou sobre aquecimentos de máquinas e equipamentos em diferentes setores. Isso é possível graças à possibilidade de se estabelecer uma relação entre as Componentes Principais e o perfil térmico do equipamento a partir da análise dos dados.

Conseqüentemente o desenvolvimento e implementação de uma metodologia para o processamento e análise de imagens térmicas voltada para a área de reconhecimento e classificação de padrões térmicos poderia ampliar o alcance da termografia na inspeção e manutenção de componentes, buscando fornecer subsídio para identificar defeitos por aquecimento ou descontinuidade nos materiais e outros.

O aquecimento em sistemas elétricos e máquinas, geralmente provocado por uma carga superior àquela suportada pelo sistema, leva ao desgaste e conseqüentemente a redução da vida útil dos mesmos. O conhecimento do tempo de vida útil do sistema e também, o conhecimento do desgaste do sistema em determinado tempo permitem a predição e prevenção de parada ou degradação do sistema. Dessa forma, é possível estabelecer uma relação entre o perfil térmico e as informações extraídas do sistema, traduzidas pelas Componentes Principais e então, acompanhar o desempenho do mesmo a fim de prevenir de possíveis defeitos e parada não previstas.

1.2 *Objetivo*

O objetivo deste trabalho é o estudo e avaliação de uma proposta de utilização da técnica de estatística multivariada, Análise das Componentes Principais (ACP), para aplicação na manutenção preditiva com base na termografia, buscando fornecer subsídio para identificar o estado ou condições de falha do componente a partir do aquecimento e/ou gradientes de temperatura do mesmo.

CAPÍTULO 2

2 Levantamento Bibliográfico

Neste capítulo é feito um levantamento bibliográfico abordando os assuntos relacionados com a metodologia proposta neste trabalho. O capítulo aborda os assuntos da termografia e Análise das Componentes Principais.

2.1 *Termografia*

A técnica de termografia tem sido aplicada com bastante sucesso no monitoramento de máquinas, principalmente em sistemas e componentes elétricos. Já nos anos sessenta e setenta companhias como Suidish Power Boand e Uk Electrical Generation Boand começaram a utilizar inspeções periódicas dos componentes elétricos com base na termografia.

Hoje o uso de câmeras termográficas para o monitoramento de temperatura é uma realidade em vários setores industriais (controle de qualidade e monitoramento de processos, instalações elétricas em geral, fornos e caldeiras, instalações frigoríficas para localização de perdas de frio, máquinas rotativas, rolamentos e motores elétricos, verificação de níveis de líquidos em recipientes, automobilismo, siderurgia, usinas, etc.) e existe uma considerável literatura (ANDRADE, 2003; KAPLAN, 1999; RAJIC, 2002; TAVARES; MARINETTI et al., 2004) a respeito do assunto, incluindo normas técnicas e procedimentos de avaliação.

Trabalho como o de Tavares e Andrade (2003) aborda os problemas relacionados à análise de incerteza na aplicação da termografia apresentando uma revisão sobre a evolução da técnica, metodologias de implementação, bem como apresentação das principais tendências de aplicação presentes e perspectivas futuras. Uma vez que o processo de medição de temperatura sem contato exige o conhecimento dos fatores externos que influenciam os resultados é necessário o estabelecimento de uma metodologia para o planejamento do experimento e análise de incerteza visando identificar os limites do uso da termografia nas diversas áreas de aplicação.

Para Tavares e Andrade (2003) poucas pesquisas têm dado atenção às fontes de incertezas associadas ao processo de medição com a termografia. Entretanto, artigos recentes têm buscado uma análise integrada das diversas metodologias de medição, incorporando resultados confiáveis do ponto de vista metrológico. E apesar das técnicas de medição de temperatura sem contato ainda conterem erros sistemáticos e/ou aleatórios associados, elas tiveram evolução notória nos últimos anos.

Em Marinetti et. al. (2004), por exemplo, a termografia ativa é utilizada para extrair características térmicas relativas à caracterização de corrosão em materiais através da Análise das Componentes Principais (ACP). No experimento o teste é feito em uma chapa de aço de espessura 3 mm contendo seis furos de 10 mm de diâmetro com diferentes profundidades para simular perda de material devido à corrosão de 2% a 50% das densidades totais. No teste a chapa de aço foi aquecida a partir de um pulso de energia e então uma sequência de termogramas foi registrada por uma câmera termográfica de modelo FLIR[®] SC3000 a uma taxa de 150 imagens em 3 segundos. Para os autores os resultados obtidos foram bons em termos qualitativos, entretanto, eles os consideram não previsíveis e, portanto, inadequados para aplicações automatizadas.

Para sanar este problema e avançar em direção a aplicações quantitativas os autores sugeriram uma aprendizagem, introduzindo uma fase de treinamento para produzir as Componentes Principais usadas como sistema de referência para implementação de um algoritmo de classificação.

A termografia infravermelha mais recentemente tem sido usada largamente em testes não destrutivos em materiais e em muitos casos métodos automáticos de processamentos de sequências de imagens infravermelhas têm sido desenvolvidos com o objetivo de otimizar a análise do material ou mesmo quantificar as informações relativas aos defeitos.

A literatura é ampla nesta área (DINIS, 2009; LIENEWEG, 1976; MARINETTI et al., 2004; MALDAGUE; MARINETTI, 1996; RAJIC, 2002), entretanto, apresenta análises feitas apenas do ponto de vista qualitativo, pois quantificar informações relativas a defeitos a fim de fazer previsão é tarefa difícil de ser realizada pela presença de sinais ruidosos que podem corromper ou mesmo mascarar informações importantes do sinal capturado pela câmera entre outros problemas envolvidos na análise.

Embora, alguns trabalhos apresentem algoritmos de automatização da técnica de termografia com bons resultados a intervenção humana ainda é necessária na interpretação de sequências de imagens termográficas. A necessidade de novos métodos ou mesmo implementação de algoritmos de extração e quantificação de informações térmicas para o

auxílio da termografia é um fato. Alguns trabalhos já apresentam algoritmos de automatização da técnica.

Susa (2007) apresenta uma análise de resultados experimentais obtidos por termografia ativa. O método foi aplicado a uma amostra de estrutura complexa, uma chapa do tipo colméia, contendo defeitos de tipos e tamanhos diferentes com localização e profundidades distintas. No trabalho, o autor propõe a possibilidade de modelar amostras complexas inspecionadas por termografia infravermelha, usando o método dos elementos finitos, bem como a possibilidade de identificar características e tipos de defeitos usando os resultados obtidos. O autor usa um pulso de duração 10 ms (milissegundos) para excitar a superfície da amostra e uma câmera do tipo ThermoCAM TM Phoenix® da FLIR Systems para aquisição da seqüência de imagens. Neste caso, a evolução de temperatura na superfície das áreas defeituosas e não defeituosa da amostra foi acompanhada a partir de curvas num gráfico. Estas curvas foram então, usadas para comparar os resultados experimentais com resultados numéricos e analisar as diferenças entre esses resultados. Na análise, parâmetros como densidade da potência da fonte de calor e a emissividade da superfície da amostra, foram ajustados para obter resultado da simulação numérica tão próximo quanto possível dos dados experimentais.

2.2 Análise das Componentes Principais

As técnicas de processamento e análise de imagens, em especial, as técnicas de extração de parâmetros, têm se mostrado como potenciais ferramentas no auxílio da Termografia Preditiva. A Análise de Componentes Principais (ACP), por exemplo, emergiu como ferramenta de grande utilização nos ensaios não destrutivos pelo seu potencial na localização de defeitos em máquinas. Essa técnica também vem sendo bastante usada para análise de imagens de satélite, reconhecimento de faces e fala e na medicina.

A literatura é bastante ampla na área de processamento de imagens e com diferentes técnicas e abordagens mostrando os vários aspectos de cada uma e uma das técnicas de grande interesse e que tem potência para análise termográfica é a Análise de Componentes Principais (KRISHNAPILLAI et al., 2005; MARINETTI et al., 2006; RAJIC, 2002).

A utilização desta técnica tem ganhado importância cada vez maior, e a sua aplicação vem se expandido para diversos setores sensoriamento remoto, compressão de dados e em

aplicações biomédicas e setores de processamento de imagens e de testes de Ensaio Não-Destrutivo (ENDs), conforme será discutido na próxima seção.

Diversos estudos têm sido feitos e muitos trabalhos publicados sobre a Análise das Componentes Principais. Sua aplicação vem crescendo em áreas como processamento de imagens, testes de Ensaio Não-Destrutivo (ENDs), reconhecimento de padrões, sensoriamento remoto entre outras.

Trabalhos como o de Gurgel (2000) na área de sensoriamento remoto utiliza a Análise das Componentes Principais em imagens de satélites. Neste trabalho a autora analisa o agrupamento e o comportamento estatístico de dados de índices de vegetação (Índice de Vegetação por Diferença Normalizada) e avalia as conexões entre esses dados, a Radiação de Ondas Longas (ROL) e as variabilidades climáticas anuais e interanuais no Brasil. A análise revelou que as Componentes Principais estão relacionadas a fatores não climáticos como, por exemplo, as queimadas. Além disso, a autora conclui que as componentes principais estão associadas da atividade convectiva, às estações do ciclo anual (verão/inverno e primavera/outono) bem como o fenômeno do *El Niño*.

Já o trabalho de Figueiredo (2006) apresenta uma nova metodologia para análise de séries temporais e conjunto de dados que possuam alta dimensão. Neste trabalho o autor propôs o uso da Análise das Componentes Principais Não Lineares (NLPCA) em séries de imagens temporais produzidas sinteticamente. Para validar o método proposto, o autor aplicou NLPCA a um conjunto de imagens da superfície do mar de uma região do Atlântico Sul, junto à costa do Rio Grande do Sul e a um conjunto de imagem de faces.

Kitani e Thomaz (2006) também utilizaram a ACP para o reconhecimento de faces. Neste caso, o trabalho aborda a técnica de maneira teórica, discutindo alguns conceitos computacionais a fim de levar o leitor à compreensão de um programa desenvolvido pelos autores (FACES.EXE). Além de abordar a técnica de um ponto de vista teórico, este trabalho apresenta um resumo sobre a pesquisa na área de reconhecimento de faces, mas concentrando-se na técnica estatística mais utilizada nesta pesquisa (ACP).

Gonzalez e Woods (2000) e Gonzalez e Woods (2007) aplicam a ACP em um conjunto de dados formados por seis imagens geradas por um “scanner” aéreo multiespectral de seis bandas operando com comprimento de ondas diferentes. Nesse caso particular a ACP foi utilizada para mostrar seu potencial em compressão de dados, entretanto, os autores abordam a ACP relacionado-a aos conceitos matemáticos, bem como aos seus aspectos computacionais.

No contexto de ensaios térmicos não destrutivos destaca-se o trabalho de Marinetti *et al* (2004) que discute a aplicação da Análise das Componentes Principais para análise estatística de seqüências de imagens termográficas (Infravermelha). Os autores utilizam esta técnica na avaliação de dados experimentais, obtido em regime transiente. No trabalho, uma fase preliminar de teste e aprendizagem foi introduzida para produzir um sistema de referência utilizado na implementação de um algoritmo de classificação.

No presente trabalho, a Análise de Componentes Principais (ACP) será estudada para ser utilizada como a principal ferramenta de análise, buscando auxiliar o desenvolvimento de técnicas de manutenção preditiva e preventiva com base na termografia.

O potencial desta técnica para aplicação como em ensaios não destrutivos, análise termográfica aparece em vários artigos como Krishnapillai *et al.* (2005), Marinetti *et al.* (2006) e Rajic (2002).

CAPÍTULO 3

3 Fundamentos Teóricos

Neste capítulo são apresentados os conceitos básicos relacionados com o trabalho em que são abordados os conceitos da termografia, ensaios não destrutivos, processamento de imagem visual e imagem térmica.

3.1 *Termografia*

A avaliação das condições de funcionamento e desempenho de máquinas e equipamento a partir do monitoramento do seu comportamento térmico vem se consolidando em várias áreas da engenharia e, pode-se dizer que uma das variáveis de maior interesse nessa avaliação é a temperatura. A temperatura é um excelente indicador para a avaliação das condições de operação e, portanto, pode ser utilizada na avaliação de índices de confiabilidade de funcionamento de sistemas e equipamentos industriais.

Embora ainda muitos métodos convencionais de medida de temperatura sejam usados, com a introdução de inovadores hardwares e softwares de computadores, o controle de processos térmicos e medidas de temperatura têm sido facilitados e a manutenção preditiva com base na temperatura vem se tornando possível em várias áreas. Mais recentemente, a termografia emergiu como uma técnica de medição de temperatura sem contato que vem sendo amplamente usada em teste não destrutivos, bem como técnicas alternativas de manutenção preditiva e preventiva ou mesmo como complemento de técnicas de inspeção convencionais (KAPLAN, 1999).

A termografia tem apresentado uma gama de utilização, desde a simples operação de detecção de presença de objetos em ambientes não iluminados, passando pela medição de temperaturas superficiais e detecção de defeitos internos em estruturas metálicas e de concreto, monitoramento de máquina, entre outros. A aplicação da termografia na manutenção preditiva tem levado a uma maior atenção com relação aos conceitos metrológicos e às possíveis fontes de incerteza da medição, seja decorrente de fatores externos ou inerentes do

próprio processo, o que poderia colocar em xeque a confiabilidade metrológica da técnica (TAVARES; ANDRADE, 2003).

A busca de métodos e procedimentos que possam auxiliar a termografia preditiva na definição de procedimentos e padrões de inspeção que garantam operacionalidade da ferramenta, calibração periódica da câmera além do desenvolvimento de pesquisas e procedimentos que possam minimizar o erro no uso da técnica (ARAÚJO et al., 2008), vem consolidando a aplicação da termografia para manutenção.

Os assuntos relacionados à metrologia e fontes de incertezas não serão diretamente tratados neste trabalho e podem ser consultados em artigos como o de Tavares e Andrade (2003). Neste trabalho, a termografia será utilizada como uma ferramenta da manutenção preditiva e o objetivo maior é estudar e avaliar como a ACP pode ser aplicada para avaliar e extrair as informações relevantes do estado do componente em análise a partir da imagem térmica.

3.2 *Introdução à Teoria da Termografia*

Todo corpo com temperatura acima do zero absoluto emite energia através de radiação eletromagnética. Essa energia produzida pela agitação das partículas desse corpo é chamada de energia térmica e a medida do estado de agitação dessas partículas é chamada de temperatura. Se um corpo tem temperatura maior que outro corpo, sua energia térmica está em um nível mais elevado que a do outro. Quando dois corpos em temperaturas diferentes são postos em contato, espontaneamente há a transferência de energia térmica do corpo mais quente para o mais frio. Assim a temperatura do mais frio aumenta e do mais quente diminui até atingir o equilíbrio e neste ponto não há mais a troca de calor entre os corpos. Dessa forma, define-se calor como sendo a energia térmica em transição, motivada por uma diferença de temperatura (BÔAS, 1987).

Para que ocorra essa transição a energia térmica precisa ser transportada de um objeto para o outro de forma que as temperaturas, e conseqüentemente o fluxo de calor, permaneça constante (KAPLAN, 1999). Neste contexto, existem três formas de transferência de calor: *condução*, *convecção* e *radiação*.

A *condução* é a transmissão de calor em que a energia passa de um corpo para outro através das partículas do meio que os separa. Para esse processo ocorrer é necessário um meio material, não podendo ocorrer, portanto, no vácuo. A *convecção* é um processo de transmissão

de calor através do movimento de massas de fluido, trocando de posição entre elas. A *radiação* é o processo de transmissão de calor por meio de ondas eletromagnéticas (ondas de calor), podendo ocorrer em meios materiais ou no vácuo (BÔAS, 1987). No caso da radiação, a esse tipo de transmissão de calor são atribuídas propriedades típicas de uma onda como frequência e comprimento de onda.

O comprimento de onda dos diferentes tipos de radiação pode ser observado quando ilustrado no espectro eletromagnético. O espectro eletromagnético é composto por radiações de diversos comprimentos de onda. Por exemplo, os raios gama, raios-X e ultravioleta são radiações com pequenos comprimentos de ondas e são interessantes pela alta energia associada. Já as ondas de rádio são ondas de grandes comprimentos. A porção intermediária do espectro eletromagnético, que se estende aproximadamente de 0,1 a 100 μm , é a porção de maior interesse nesse trabalho, visto que além dos raios ultravioleta e todo espectro visível, é nesta faixa que pode ser encontrado a radiação infravermelha (IV) que é base da termografia. A figura 3.1 ilustra o espectro eletromagnético e as faixas de ondas que vão desde os raios gama até as microondas ou ondas de radio.

Conforme discutido em Kaplan (1999) o comprimento de ondas de cada tipo de radiação que ocupa o espectro eletromagnético não mostra uma medida precisa do início e do término das regiões ocupadas por cada tipo de radiação, a literatura trabalha com medidas aproximadas do comprimento de cada tipo de faixa de onda eletromagnética dependendo do interesse particular de cada aplicação.




Figura 3.1: Espectro eletromagnético e a região de medição do infravermelho (Fonte: Adaptado de Kaplan,1999).

Como discutido anteriormente, os raios gama são ondas eletromagnéticas com comprimento muito pequeno, ou seja, ondas de comprimento que vão desde $10^{-14} m$ (metros) a $10^{-12} m$. Estes raios são produzidos por átomos e elementos radioativos e são utilizados no tratamento de algumas doenças. Já os raios X, são ondas que ocupam a porção do espectro eletromagnético entre $10^{-12} m$ e $10^{-8} m$, são utilizados no diagnóstico de ossos e dentes, em tomografias e aeroportos para detecção de materiais.

A radiação ultravioleta (UV) são ondas de comprimento entre 400 a 15 nm (nanômetro).

Os raios visíveis ou luz visível são ondas eletromagnéticas que ocupam uma porção do espectro eletromagnético compreendido entre $4 \times 10^{-7} m$ a $7 \times 10^{-7} m$ aproximadamente, são ondas que podem ser vista pelo olho humano.

A radiação infravermelha (IV) é caracterizada por comprimentos de ondas que vão de $0,75 \mu m$ a $100 \mu m$, porção que se estende desde o limite visível até a banda das microondas. Em termos práticos essa medição pode ser feitas de $0,75 \mu m$ a $30 \mu m$ conforme observado em Kaplan (1999).

Já as *microondas* são radiações que possuem comprimento acima do comprimento dos raios infravermelhos.

As *ondas de rádio* são produzidas por equipamentos eletrônicos (transmissores) e ocupam uma porção do espectro eletromagnético chamado de espectro de alta frequência. Na figura 3.1 as abreviações EHF, SHF, UHF, VHF, MF, LF, VLF derivadas do inglês *extreme high frequency*, *super high frequency*, *ultra high frequency*, *very high frequency*, *médium frequency*, *low frequency*, *very low frequency*, significam ondas de rádio de frequência extremamente alta, super alta, ultra alta, muito alta, média, baixa e muito baixa, respectivamente.

A *radiação infravermelha* que é a base deste trabalho foi detectada pela primeira vez pelo astrônomo Sir William Herschel (1738–1822) em 1800. Ela é a transmissão de energia na forma de onda eletromagnética, caracterizada por um comprimento de onda compreendido na porção infravermelha do espectro eletromagnético.

A região do infravermelho é subdividida em quatro porções cujos nomes estão relacionados com sua proximidade com a região visível: infravermelho próximo, porção que vai de $0,75 \mu m$ a $3 \mu m$ (NIR – “*near infrared*”), infravermelho médio, porção que vai de $3 \mu m$ a $6 \mu m$ (MIR – “*middle infrared*”), infravermelho distante, porção que vai de $6 \mu m$ a

$15\mu m$ (FIR – “*far infrared*”) e infravermelho extremo (XIR – “*extreme infrared*”) porção que vai de $15\mu m$ a $100\mu m$. As faixas do infravermelho médio e do infravermelho distante são regiões de particular interesse para as tarefas de detecção e reconhecimento por possuírem condições de propagação mais favoráveis (NEVES, 2003).

Além das propriedades típicas (frequência e comprimento), outro aspecto importante a ser observado na radiação é a emissividade.

Como discutido anteriormente, todo corpo com temperatura acima de zero absoluto produz radiação térmica que pode ser medida e mapeada, no entanto, essa radiação varia em função da emissividade dos corpos e sofre influência do efeito de absorção da atmosfera.

De acordo com Santos (2006) a emissividade representa a capacidade de emissão de radiação dos corpos e esta propriedade depende do tipo de material, do comprimento da onda, da temperatura e do ângulo de visão. Considerar a influência desse parâmetro no processo de medição de temperatura, além de outros como as variações climáticas, a radiação solar, a atenuação atmosférica e o vento é de fundamental importância no processo de medição de temperatura. Esses condicionantes estão associados ao processo de medição de temperatura e podem mascarar defeitos e introduzir erros nos resultados da medição.

Entretanto, a introdução de sensores mais precisos no mercado, implementados a partir de novos modelos matemáticos, tem ajudado a solucionar alguns problemas associados ao processo de medição e validação de resultados a partir de análises mais completas da informação térmica obtida. Com o progresso desses detectores de radiação infravermelha a termografia evoluiu significativamente no final do último século. Hoje vários são os instrumentos de medição de temperatura utilizados, alguns já consolidados no mercado industrial. As câmeras termográficas, equipamentos mais sofisticados, que fornecem imagens térmicas a partir de sensores de infravermelho vêm sendo empregadas cada vez com maior frequência, principalmente devido à sua gama de aplicações. Embora elas tenham tornado mais acessíveis, o seu custo ainda tem sido um limitante do seu uso.

Do ponto de vista de estímulo térmico a termografia pode ser classificada em ativa e passiva. Na termografia passiva nenhum estímulo térmico é necessário, uma vez que existe uma diferença entre a temperatura do objeto em estudo e a temperatura ambiente onde ele está sendo estudado, assim a radiação emitida pelo próprio objeto é convertida em medida de temperatura pela câmera termográfica. Já na termografia ativa, as estimulações termográficas são aplicadas durante o ensaio e várias formas de estímulo térmico podem ser empregadas, cada uma com características e limitações própria (PT (*Pulse Thermography*), termografia

modulada (*Module* ou “*Lock-in*” *Thermography*), termografia pulsada por fase (*Pulse Phase Thermography*)). A escolha do tipo de estímulo térmico depende não só das características da superfície a ser testada, mas essencialmente, do tipo de informação requerida. A termografia passiva tem sido muito eficiente em aplicações como programas de manutenção preventiva, avaliação de processos e componentes industriais e aplicações médicas onde o avaliador tem condições de identificar a presença de anomalias e diferença de temperatura no ambiente que, como discutido anteriormente, podem afetar as características qualitativas do resultado (TAVARES; ANDRADE, 2003).

3.3 Termografia para Ensaio Não Destrutivo

De acordo com o exposto na seção anterior a termografia é uma técnica que atua na porção do espectro eletromagnético ocupada pela radiação infravermelha e pode ser definida como uma técnica de sensoriamento remoto que possibilita a medição da radiação infravermelha emitida pelos corpos sujeitos a variação e tensão térmica, fornecendo os valores de temperatura bem como transformando o campo de temperatura em imagem termográfica (termograma) em tempo real.

No contexto dos Ensaios Não-Destrutivos (END(s)) a termografia infravermelha é uma técnica para uso na manutenção que converte a radiação infravermelha emitida por um equipamento, em imagem termográfica de maneira rápida, precisa e sem o desligamento do mesmo. Isso é possível porque a radiação térmica emitida pelo componente é captada e convertida em uma imagem térmica por câmeras (termovisores) que transformam o sinal térmico recebido em imagens. Os níveis de temperatura capturados pelos detectores da câmera são medidos a partir de um escala de cores, em que cada temperatura corresponde a uma dada cor numa escala policromática (escala de cores) ou um tom de cinza em uma escala monocromática (escala em tons de cinza). Neste caso, a condição de manutenção pode ser acompanhada a partir da temperatura, sendo que as diferenças de energia radiante no sistema serão mostradas como variações de tons de cinza ou de cor nessas escalas e a tomada de decisão é feita com base nesses parâmetros (ROCHA, 2006).

Assim, na termografia o perfil térmico do equipamento é mostrado em um gráfico de cores, sendo que as variações térmicas do mesmo são observadas no termograma a partir das alterações na intensidade das cores. Essas alterações podem apontar problemas como mau funcionamento ou mesmo sinais de redução da vida útil do equipamento.

A utilização da termografia na manutenção preditiva vem ganhando cada vez mais espaço como ferramenta não destrutiva. Sua importância no campo dos Ensaios Não Destrutivos se deve, principalmente, ao seu caráter não intrusivo o que permite a inspeção do equipamento sem prejuízos na produção.

A termografia também apresenta outras vantagens como possibilidade de medição da temperatura em objetos em movimento, operação em ambientes de difícil acesso, alta velocidade de medição e de respostas, inspeção de grande superfície em curto espaço de tempo associado à facilidade de operação da câmera termográfica. Todos esses aspectos tornam essa técnica bastante atraente para utilização em sistemas de manutenção, visando detectar falha ou anomalias em equipamento e processos industriais.

Uma das principais características da termografia é a sua praticidade de uso e o fato da sua aplicação não exigir o desligamento dos equipamentos sob inspeção. Isso vem consagrando sua utilização nas diversas áreas de manutenção, principalmente, como ferramenta de avaliação não destrutiva. Na área da manutenção preditiva a termografia vem se consolidando com ferramenta bastante prática e seu objetivo é detectar falhas incipientes que podem evoluir para situações de total degradação ou comprometimento do equipamento, implicando em paradas não previstas e, conseqüentemente, aumento de custos.

A técnica de termografia vem atualmente ganhando espaço para análise e medidas de temperatura por ser uma ferramenta bastante adequada tanto, para medida de temperatura, como para monitoramento da assinatura térmica de máquinas e componentes e sua aplicabilidade se dá em diversas áreas do conhecimento.

Exemplos de aplicação dessa técnica são encontrados em vários setores. Na indústria automobilística a termografia tem sua utilização na análise termográfica nos motores, no desenvolvimento e estudo do comportamento de pneumáticos, sistema de refrigeração. Na siderurgia é utilizada no levantamento do perfil térmico dos fundidos e na inspeção de revestimentos refratários dos fornos entre outros.

Neste trabalho a termografia será avaliada como ferramenta para monitoramento e avaliação da condição de funcionamento utilizada em técnica de manutenção preditiva aplicada em sistemas elétrico-eletrônicos e mecânicos.

As desvantagens da técnica são representadas pela dificuldade na detecção de defeitos em regiões mais profundas em relação à superfície analisada, variações muito pequenas de temperatura podem não ser detectadas. Além desses, problemas relacionados com o processo de medição em si como a emissividade do material, efeito da temperatura ambiente, umidade relativa, ruídos, a radiação solar ou de outras fontes introduzindo falsos

pontos, a influência do vento que dissipa o calor resfriando os componentes aquecidos gerando erro na análise podem se apresentar como limitantes no uso dessa técnica (SANTOS, 2006).

Preocupados com as fontes de incertezas que influenciam no processo de medição, pesquisadores já concentram na busca constante de métodos e procedimentos que possam auxiliar a termografia preditiva. Um exemplo é a implantação de programa de treinamentos e encontros como o promovido por FURNAS em 2001. Programas como esse tem ocorrido com frequência no intuito de estudar as limitações e vantagens da técnica e promover alternativas que possam viabilizar a aplicação da técnica. Técnicos, inspetores e operadores trocam conhecimentos e compartilhavam visões distintas sobre o uso da termografia para criar assim procedimentos padrões de inspeção que garantam operacionalidade da ferramenta; calibração periódica da câmera além do desenvolvimento de pesquisas e procedimentos que possam minimizar o erro no uso da técnica (ARAUJO et al., 2008).

O erro humano que pode variar com o treinamento, motivação e capacidade visual do inspetor também pode aparecer como um limitante no processo de medição.

Assim, as vantagens da utilização da termografia em comparação aos outros ensaios não destrutivos dependem não só da experiência, por parte do usuário, na manipulação do equipamento de medição e na interpretação da imagem termográfica obtida, mas também e, sobretudo, do conhecimento das características termográficas do material sob investigação e das condições ambientais presentes durante o ensaio, fatores que influenciam preponderantemente os resultados (TAVARES; ANDRADE, 2003).

Adicionalmente, técnicas automáticas de análise de imagens térmicas podem auxiliar a termografia para uma análise mais consistente do problema. A importância da aplicação da Análise das Componentes Principais Térmicas (ACPT) em Ensaio Não-Destrutivo está no fato de que as imagens termográficas obtidas em cada inspeção térmica apresentam correlação espacial e temporal e poderá existir uma forte relação entre as Componentes Principais e o perfil térmico do sistema. Isso permite uma real avaliação do estado do componente em questão. Outro aspecto importante nesta técnica é que ela permite uma avaliação automática de uma sequência de imagens térmicas que é uma meta dos Ensaio Não-Destrutivos.

O processamento de imagens termográficas a partir de técnica apropriada pode mostrar eventuais mudanças (periódicas ou aperiódicas) do sistema. Neste caso, técnicas de processamento de imagens podem representar ferramentas de grande alcance na manutenção preditiva baseado na termografia, visto que elas permitem a extração de outros parâmetros,

além da temperatura do objeto monitorado (ensaiado). Uma dessas técnicas é a Análise das Componentes Principais Térmicas (ACPT) que será discutida em detalhe no próximo capítulo.

3.4 *Processamento e Análise de Imagens Digitais*

Nesta seção serão tratados os conceitos básicos para o processamento de imagens, bem como sua utilização na análise de imagens termográficas.

A área de processamento de imagens vem crescendo vigorosamente nas últimas décadas e tem uma vasta gama de aplicações. Sua utilização no campo científico é multidisciplinar, se destacando em áreas como astronomia, biologia, medicina, aplicações industriais, entre outras.

O processamento de imagens tem sido utilizado ainda para tarefas de compreensão de imagens, reconhecimento de padrões, análise em multiresolução e multifrequência, análise estatística, codificação e transmissão de imagens, inspeção termográfica, etc.

A aplicação do processamento de imagens em diversas áreas está associada diretamente à análise da informação, pois estamos sempre buscando informações quantitativas ou mesmo qualitativas que representem um fenômeno estudado. O termo processamento de imagens vem de processamento de sinais, e como uma imagem é um sinal bidimensional, ela é na realidade, um suporte físico que carrega no seu interior uma determinada informação que pode estar associada a uma medida (sinal associado a um fenômeno físico), ou a um nível cognitivo (sinal associado a conhecimento). Assim, conforme discutido em Albuquerque e Albuquerque (2009), processar uma imagem significa transformá-la sucessivamente com o objetivo de extrair informação nela presente.

O interesse em processamento de imagens de acordo com Gonzalez e Woods (2000) decorre de duas áreas. Uma representando as técnicas de processamento que permitem obter melhoria (*enhancement*) de informação visual para interpretação humana e outra o processamento de dados de cenas para a percepção automática por máquinas. Uma das primeiras aplicações do processamento de imagens da primeira categoria foi o melhoramento de imagens digitalizadas para jornais, enviadas por meio de cabo submarino de Londres para New York.

Já na categoria de problemas relacionados à percepção por máquinas, inclui o reconhecimento de caracteres, visão computacional industrial para montagem e inspeção de produtos, reconhecimento militar, processamento automático de impressões digitais,

processamento de imagens de satélites e de infravermelho para o monitoramento e inspeção na área industrial. Nesta categoria, o interesse se concentra em procedimentos e técnicas para extrair de uma imagem ou sequência de imagens a informação adequada para o processamento computacional. Neste trabalho, em especial, é utilizada a técnica da ACP para extrair informações térmicas de uma sequência de imagens. Neste caso, essas informações são processadas a fim de serem utilizadas posteriormente para uma possível classificação automática.

Em geral, as informações extraídas automaticamente de uma ou mais imagens apresentam pouca semelhança com as características utilizadas pelo sistema visual humano na interpretação de conteúdos. Assim, processar imagem com o uso de máquina é tarefa extremamente complexa e, sobretudo, dependente do problema envolvido. Um sistema geral de visão, que atenda a todas as solicitações, é um sistema complexo e de alto nível. Entretanto, estudos na área de reconhecimento automático concentram o interesse em entender e projetar sistemas de reconhecimento genérico com características semelhantes a do sistema visual humano. Tarefa que demanda grande esforço, longo tempo de pesquisa e altos investimentos.

Para Gonzalez e Woods (2000) o processamento de imagens é caracterizado por soluções específicas em que técnicas dedicadas a um dado problema nem sempre apresentam bons resultados quando aplicada em outros problemas. A solução de um problema específico requer pesquisas e desenvolvimento significativos.

Embora tenham ocorrido avanços na tecnologia e a criação de inovadores softwares e superprocessadores capazes de efetuar cálculos numéricos em pouquíssimo tempo, o computador está longe de executar tarefas ainda feitas apenas pelo humano. Tal como é, por exemplo, o reconhecimento de uma pessoa que parece ser tarefa simples, porém baseada em detalhes percebidos, somente pelo cérebro humano, que é capaz a partir de uma grande quantidade de informações de luminância e crominância fazer o reconhecimento em apenas poucos milissegundos. Processar imagens, portanto, exige por antecedência uma compreensão “filosófica” do mundo ou dos conhecimentos humanos. Não existe, no entanto, uma solução única e abrangente para todos os problemas nem sistemas de análise de imagens complexos e que funcionem para todos os casos (ALBUQUERQUE; ALBUQUERQUE, 2009).

3.5 *Imagens Térmicas*

Esta seção apresenta de maneira simples os conceitos básicos do processamento de imagens para um melhor entendimento do processamento de imagem térmica, porém, sem abordar os detalhes relacionados às técnicas de análise de imagens. O leitor interessado em mais detalhes pode consultar Albuquerque e Albuquerque (2009) e Gonzalez e Woods (2000).

Para uma imagem monocromática a representação da mesma pode ser feita por uma função bidimensional de intensidade da luz $f(x, y)$, onde x e y são as coordenadas espaciais e o valor de f em qualquer ponto (x, y) é proporcional à intensidade/brilho (níveis de cinza) da imagem naquele ponto.

Em termo computacional, a imagem $f(x, y)$ digitalizada é definida discretizando seu domínio espacial (amostragem) nas direções x e y , gerando uma matriz de $M \times N$ amostras, em que M e N representa a resolução espacial. Cada elemento (x, y) da matriz é chamado de *pixel* (elemento de quadro) e está associado a um número L que representa seu nível de cinza/intensidade, em escala monocromática ou a uma dada cor, em escala de cores.

O termo níveis de cinza é usado para se referir à intensidade de imagens monocromáticas. Imagens coloridas são combinações de imagens bidimensionais individuais. No sistema de exibição de imagens em cores, por exemplo, no sistema RGB (*Red, Green, Blue*), uma imagem colorida é uma imagem multiespectral obtida a partir da combinação das três componentes (bandas) individuais da imagem, componentes vermelha, verde e azul. Neste caso, cada *pixel* P_k é representado numericamente por três valores (p_1, p_2, p_3) , um para cada banda em que P_k , com $k = 1, 2, 3$, é o valor do *pixel* em cada banda numa dada posição da imagem. A figura 3.2 ilustra uma imagem em sua forma digital. Esta figura pode ser entendida como a representação numérica (discreta) de um objeto ou uma cena. Cada elemento da matriz (*pixel*) tem um valor numérico que representa o seu valor de brilho ou intensidade na imagem. Cada valor corresponde a um nível ou tom de cinza em escala monocromática (escala em níveis de cinza). O *pixel* em destaque nesta imagem tem seu valor de brilho/intensidade 126, em uma escala que varia de 0 a 255 tons ou níveis de cinza.




Figura 3.2: Imagem digital em 256 tons de cinza (Fonte: Adaptado de Silva, 2005).

O termo imagem está inicialmente associado ao domínio da luz visível, porém é muito freqüente ouvir falar de imagens quando uma grande quantidade de dados está representada sob a forma bidimensional. São as imagens multivariadas ou multidimensionais.

O caso mais simples de imagem multivariada é, geralmente, representado por uma matriz de ordem três. São exemplos, as imagens visuais coloridas tiradas de uma determinada cena, estas imagens apresentam vários canais ou respostas para o valor de intensidade do *pixel*. Os vários canais, com diferente comprimento de onda ou energia são então, empilhados formando uma imagem multivariada (ALBUQUERQUE; ALBUQUERQUE, 2009).

Na análise de imagem visual em cores, geralmente, é realizada a decomposição da mesma nas cores primárias vermelha, verde e azul. Neste caso as três imagens são processadas como uma imagem multivariada.

Imagens infravermelhas captadas durante as inspeções de um determinado componente são também tratadas como imagens multivariadas. A figura 3.3 mostra uma imagem infravermelha (termograma) de um componente elétrico (chave elétrica) em escala de cores.




Figura 3.3: Imagem infravermelha de um sistema elétrico.

Cada cor representa um valor de temperatura de acordo com a escala representada na figura. Se esse termograma for analisado como uma imagem visual em cores, a decomposição do mesmo em suas componentes RGB pode ser usada para formar uma imagem multivariada de ordem três. No caso do monitoramento do componente uma imagem multivariada seria formada pelo empilhamento das imagens tiradas a cada inspeção.

Neves (2003) define uma imagem infravermelha como sendo um mapeamento bidimensional em tons de cinza (ou em cores) representando a captação da radiação infravermelha feita por um detector específico. Este mapeamento bidimensional representa a caracterização e quantificação da energia térmica emitida por um objeto.

Um exemplo de imagem multivariada bastante comum é encontrado na área de sensoriamento remoto. Neste caso, uma imagem que inclua as várias bandas da região visível e do infravermelho do espectro eletromagnético pode ser tratada como uma imagem multivariada.

A figura 3.4 mostra uma imagem multivariada formada por seis imagens (em tons de cinza), as chamadas bandas temáticas do satélite Landsat, utilizadas pela NASA para monitoramento da Terra. As imagens mostram a cidade de Washington, destacando características como construções, estradas, vegetação, e um rio principal passando pela cidade. Cada banda é apresentada em uma escala ou janela espectral com comprimento de ondas diferentes, expressos em μm .

As três primeiras imagens possuem resposta espectral na porção visível correspondente ao azul, verde e vermelho com comprimento de ondas $0.45 - 0.52 \mu m$, $0.52 - 0.60 \mu m$ e $0.63 - 0.69 \mu m$, respectivamente. Enquanto que as três últimas possuem

comprimento de onda na porção do espectro infravermelho correspondente a $0.76 - 0.90 \mu\text{m}$, $1.55 - 1.75 \mu\text{m}$ e $10.4 - 12.5 \mu\text{m}$, respectivamente.




Figura 3.4: Imagens do satélite LANDSAT, de Washington. (a)-(c) bandas azul, verde e vermelho do espectro visível, (d) infravermelho próximo, (e) infravermelho médio e (f) infravermelho térmico (Fonte: Gonzalez e Woods, 2007).

Cada imagem apresenta características e aplicações diferentes. A banda do azul pode ser utilizada para mapeamento de águas costeiras e identificação de feições (características) culturais (plantações), a banda verde para medidas dos picos de reflectância da vegetação e estimar o vigor da vegetação. Já a banda vermelha serve para diferenciar espécies vegetais e identificar feições (características) culturais (plantações). A banda do infravermelho próximo é utilizada para identificar o tipo, vigor e biomassa da vegetação, de rios/ mares (corpos d'água) e umidade dos solos, a banda do infravermelho médio é utilizada para o mapeamento de vegetação, umidade dos solos e para diferenciação entre nuvem e neve, enquanto que a banda do infravermelho termal serve para analisar o estresse da vegetação e também para o mapeamento térmico da cidade (COUTINHO, 1997; GONZALEZ; WOODS, 2007).

Em manutenção e em testes não destrutivos por termografia, as imagens infravermelhas são utilizadas para o acompanhamento do perfil térmico do sistema. Neste

caso, o sistema é inspecionado de tempo em tempo e a seqüência de imagens registradas nas inspeções forma uma imagem multivariada que posteriormente será tratada como tal.

A análise de imagem multivariada não é uma tarefa muito simples e o problema aumenta quando se deseja fazer o processamento dessa imagem, principalmente pelo volume de informação contido nela. Neste caso, técnicas de processamento automático de imagens são ferramentas de vital importância para a análise e extração de informações da imagem.

No entanto, ao trabalhar com imagens se deve ter em mente, antes da escolha da técnica, o que estamos buscando na imagem e tentarmos responder aos seguintes questionamentos: Qual a região de interesse e que informação relevante traz o conteúdo da imagem? O que representa ruído e o que é informação? Como essa informação está relacionada ao fenômeno físico que se quer estudar? Posteriormente faz-se a extração dos parâmetros e poderá ser feito o reconhecimento e uma classificação automática das imagens, quando for o caso.

A extração das informações relevantes de uma imagem ou de uma região de interesse é um passo importante e não existe uma técnica padrão válida para qualquer situação, cada uma tem suas vantagens e desvantagens.

Este capítulo apresentou alguns conceitos relacionados ao processamento de imagens bem como uma breve discussão a cerca de imagens visual, infravermelha e multivariada. No próximo capítulo será abordada a técnica de processamentos de imagens, a Análise das Componentes Principais (ACP), que é a proposta deste trabalho.

CAPÍTULO 4

4 Análise das Componentes Principais

Este capítulo apresenta os conceitos e fundamentos da Análise das Componentes Principais, bem como uma proposta de sua utilização como ferramenta de auxílio na termografia preditiva e os aspectos computacionais envolvidos.

Vale ressaltar que o foco desse trabalho é a aplicação da ACP, portanto, a apresentação da técnica Análise das Componentes Principais é feita de maneira simples e prática não abordando de maneira rigorosa as discussões e aspectos matemáticos.

4.1 *Conceitos Gerais*

A Análise das Componentes Principais (ACP) é uma técnica de análise multivariada descrita inicialmente por Karl Pearson e desenvolvida posteriormente por Harold Hotelling. Esta técnica é também conhecida por Transformada de Hotelling e Transformada de Karhunen-Loève em homenagem a Kari Karhunen e Michael Loève. No campo da teoria da probabilidade, Análise das Componentes Principais foi primeiramente enfocada por Karhunen e posteriormente generalizada por Loève conforme discutido em Figueiredo (2006) e Marinetti et al (2004).

A ACP é uma técnica de estatística multivariada utilizada como ferramenta de análise em diversas áreas do conhecimento (engenharia, economia, biologia, química) com aplicação multidisciplinar. Podem ser citadas como algumas das aplicações típicas da ACP a detecção e reconhecimento de faces (Kitani e Thomaz, 2006), a compressão de dados, extração de características, Ensaios Não-Destrutivos (MARINETTI et al., 2004; RAJIC, 2002) e sensoriamento remoto (GURGEL, 2000) dentre outros.

A técnica da ACP é muito útil na investigação de relações existentes entre um conjunto de variáveis correlacionadas. Ela serve para identificação de padrões de variabilidade e redução dimensional de um conjunto de dados, bem como para explicar a estrutura de variância e covariância de um conjunto de dados.

Seja um vetor aleatório, composto de k variáveis aleatórias, obtido através da construção de combinações lineares das variáveis originais (Componentes Principais).

Algebricamente, a ACP transforma um conjunto de p variáveis aleatórias $X_1, X_2, \dots, X_p$ em um conjunto de k variáveis $Y_1, Y_2, \dots, Y_k$ não correlacionadas e ortogonais entre si, denominadas, Componentes Principais (CP(s)). Essas variáveis são combinações lineares das p variáveis originais, onde a primeira variável obtida com essa transformação é responsável pela maior variância no conjunto de dados original. A segunda componente é responsável pela maior variância restante e é não correlacionada com a primeira. A terceira componente é responsável pela maior variância restante, sendo não correlacionada com a primeira e a segunda componente e assim por diante. O número de Componentes Principais é no máximo igual ao número de variáveis. Em geral, a informação contida nas p variáveis originais é substituída pela informação contida nas k ($k \leq p$) Componentes Principais não correlacionadas (MINGOTI, 2005; SCREMIN, 2003).

Geometricamente, a transformação feita pela ACP estabelece um novo sistema de coordenadas obtido por rotação do sistema original tendo $X_1, X_2, \dots, X_p$ como eixos. Os novos eixos, $Y_1, Y_2, \dots, Y_k$, representam as direções com variabilidade máxima, permitindo uma interpretação mais simples da estrutura da matriz de covariância. Esses eixos têm origem no centróide do conjunto de dados e direção dos autovetores da matriz de covariância do conjunto de dados originais. A transformação feita pela ACP por rotação alinha os dados com os autovetores e esse alinhamento é o mecanismo que separa os dados não correlacionados. O conceito de alinhar um objeto com o seu autovetor principal desempenha papel muito importante no processamento e análise de imagem, uma vez que as técnicas computacionais para reconhecimento de objetos geralmente são sensíveis à rotação (GONZALEZ; WOODS, 2000; MARQUES; MARQUES, 2005).

4.2 Componentes Principais

Nesta seção serão introduzidos os conceitos sobre vetores aleatórios, média, matrizes de covariância, correlação, escores e *loadings*, bem como variáveis padronizadas. Não serão discutidas, como comentado no início do capítulo, demonstrações algébricas por não ser objetivo do texto, e sim discutir de maneira simples e prática como esses conceitos são utilizados no contexto na Análise das Componentes Principais Térmicas.

Em termos gerais, a Análise das Componentes Principais busca identificar a partir da análise de um conjunto arbitrário de dados, quais dados são correlacionados ou não. Neste caso, um conjunto de dados contendo ou não dados correlacionados, é transformado em um novo conjunto de dados não correlacionados. Por exemplo, considere uma amostra de um conjunto arbitrário de n vetores do tipo $X = [X_1, X_2, \dots, X_p]^T$, em que T indica a transposição, cada vetor X_i formado por p variáveis, sendo que os n valores das componentes de cada variável X_i com $i = 1, 2, \dots, p$ representam os indivíduos da amostra. Assim, tem-se n vetores distribuídos da forma:

$$X_1 = \begin{bmatrix} X_{11} \\ X_{21} \\ \cdot \\ \cdot \\ \cdot \\ X_{p1} \end{bmatrix} \quad X_2 = \begin{bmatrix} X_{12} \\ X_{22} \\ \cdot \\ \cdot \\ \cdot \\ X_{p2} \end{bmatrix}, \quad \cdot \quad \cdot \quad \cdot \quad \cdot \quad X_n = \begin{bmatrix} X_{1n} \\ X_{2n} \\ \cdot \\ \cdot \\ \cdot \\ X_{pn} \end{bmatrix}$$

Na Análise das Componentes Principais é comum armazenar os elementos amostrais numa matriz $[X]$ de dados, em que os vetores da amostra são armazenados nas linhas e as variáveis nas colunas,

$$[X] = \begin{bmatrix} X_{11} & X_{21} & \dots & X_{p1} \\ X_{12} & X_{22} & \dots & X_{p2} \\ \dots & \dots & \dots & \dots \\ X_{1n} & X_{2n} & \dots & X_{pn} \end{bmatrix}. \quad (4.1)$$

A estimativa das Componentes Principais é feita a partir do cálculo dos autovalores e autovetores da matriz de covariâncias $[C]$ dos dados (matriz $[X]$).

Assim, para n vetores de um conjunto arbitrário, o vetor de médias $m = (m_1, m_2, \dots, m_p)$ e a matriz de covariâncias $[C]$ podem ser aproximados a partir da amostra por

$$m = \left[\frac{1}{n} \sum_{k=1}^n X_k \right] e \quad (4.2)$$

$$C = \left[\frac{1}{(n-1)} \sum_{k=1}^n X_k X_k^T - mm^T \right] \quad (4.3)$$

Onde o símbolo $\sum$ indica o somatório, os índices n e p indicam elemento amostral e variável. Cada m_i é a média amostral da i -ésima variável, $i = 1, 2, \dots, p$. Como os vetores da amostra têm dimensão p , a matriz de covariâncias $[C]$, Eq.4.4,

$$C = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1p} \\ c_{21} & c_{22} & \dots & c_{2p} \\ . & . & . & . \\ . & . & . & . \\ c_{p1} & c_{p2} & \dots & c_{pp} \end{bmatrix} \quad (4.4)$$

tem dimensão $p \times p$, e o elemento c_{ii} da matriz $[C]$ é a variância da variável X_i (i -ésima variável do conjunto) e o elemento c_{ij} é a covariância entre a i -ésima e a j -ésima variáveis. Se a i -ésima e a j -ésima variáveis não são correlacionadas, sua variância é zero e, portanto $c_{ij} = c_{ji} = 0$.

Uma vez que a matriz de covariância $[C]$ é real e simétrica ($[C]^T = [C]$), é sempre possível encontrar um conjunto de p autovetores, ortonormais neste caso.

Sejam V_i e λ_i ($i = 1, 2, \dots, p$), os autovetores e os correspondentes autovalores de $[C]$ encontrados a partir da equação característica

$$\det(C - \lambda I) = 0 \quad (4.5)$$

e que satisfazem a relação:

$$[C]V_i = \lambda_i V_i, \text{ com } i = 1, 2, \dots, p. \quad (4.6)$$

Pelo teorema da decomposição espectral como $[C]$ é simétrica então ela pode ser escrita em termos de seus autovalores e autovetores por (GONZALEZ; WOODS, 2000; MINGOTI, 2005):

$$[C] = \lambda_1 V_1 V_1' + \dots + \lambda_i V_i V_i' . \quad (4.7)$$

No contexto da Análise das Componentes Principais os autovalores λ_i e os autovetores V_i da matriz $[C]$ são calculados e convenientemente arranjados de maneira decrescente, em que $\lambda_j \geq \lambda_{j+1}$ ($j = 1, 2, \dots, p-1$).

A Análise das Componentes Principais busca transformar um conjunto de dados arbitrário em um novo conjunto de componentes não correlacionados entre si, ou seja, um conjunto de componentes ortogonais denominadas Componentes Principais. Essa transformação é obtida através de uma combinação linear das variáveis originais, Eq. 4.8,

$$[Y] = [A]([X] - m). \quad (4.8)$$

A matriz $[A]$ de ordem $p \times p$ é montada com os autovetores de $[C]$, de tal modo que, a primeira linha de $[A]$ é o autovetor correspondente ao maior autovalor, a segunda linha o autovetor correspondente ao maior autovalor restante e assim por diante, até que a última linha seja o autovetor correspondente ao menor autovalor, já a matriz $([X] - m)$ tem ordem $n \times p$. Conseqüentemente, a matriz $[Y]$ que contém o novo conjunto de dado não-correlacionados (Componentes Principais) é uma matriz de ordem $n \times p$.

A título de exemplo, a i -ésima componente principal Y_i pode ser expressa como:

$$Y_i = a_{i1} X_{k1} + a_{i2} X_{k2} + \dots + a_{ip} X_{kp}, \quad (4.9)$$

em que $i = 1, 2, 3, \dots, p$ e $k = 1, 2, 3, \dots, n$.

Vale lembrar que, os autovalores da matriz de covariância dão as variância do conjunto de dados e que o maior autovalor corresponde à maior variância. Neste caso, a equação 4.8, também chamada de Transformada de *Hotelling*, mapeia os valores $[X]$ em $[Y]$ a partir da matriz $[A]$.

Uma análise das CP $[Y]$ mostra que a matriz de covariância do conjunto de componentes $[Y]$, pode ser dada em termos das matrizes $[A]$ e $[C]$, neste caso a média dos vetores $[Y]$ é zero, isto é, $m_y = 0$. Conseqüentemente, a covariância da matriz $[Y]$ é dada pela expressão (4.10).

$$C_y = [A][C][A]^T \quad (4.10)$$

A matriz $[C_y]$ é uma matriz diagonal, cujos elementos ao longo da diagonal principal são os próprios autovalores da matriz $[C]$, ou seja, $c_{ii} = \lambda_i$ e os elementos fora da diagonal são todos nulos $c_{ij} = c_{ji} = 0$, expressão (4.11),

$$C_y = \begin{bmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_p \end{bmatrix}, \quad (4.11)$$

Portanto os vetores Y_i são não correlacionados entre si, e λ_i é a variância da componente Y_i ao longo do autovetor V_i (GONZALEZ; WOODS, 2002).

A contribuição C_i de cada componente Y_i em relação à matriz das Componentes Principais conforme discutido em Varella (2008) e Mingoti (2005) é calculada dividindo-se a variância da componente Y_i pela variância total, essa contribuição é expressa em porcentagem e representa a proporção de variância total explicada pela componente principal Y_i e a proporção de informação retida na redução do conjunto de dados de p para k dimensões, em que $k \leq p$, é:

$$C_i = \frac{\text{var}(Y_i)}{\sum_{i=1}^n \text{var}(Y_i)} * 100 = \frac{\lambda_i}{\sum_{i=1}^n \lambda_i} 100 \quad (4.12)$$

Na equação (4.12), $\text{var}(Y_i)$ significa a variância da i -ésima componente principal.

Para verificar a influência de cada variável sobre cada componente, calcula-se a correlação entre a variável e a componente principal:

$$\text{Corr}(X_j, Y_i) = \sqrt{\lambda_i} * \frac{a_{ij}}{\sqrt{\text{var}(X_j)}} \quad (4.13)$$

em que $\text{var}(X_j) = c_{jj}$ indica a variância da j-ésima variável, onde $j = 1, 2, \dots, p$ e a_{ij} indica os coeficientes dos autovetores.

Se uma componente tem alta correlação com uma variável, então esta componente é importante para explicar parte da variância desta variável caso contrário ela tem pouca influência na variância da variável. Esta influência neste caso é analisada por meio dos pesos (*loadings*) das variáveis originais sobre cada componente principal. Os *loadings* são os coeficientes da combinação linear da qual são derivadas as CP(s). Estes pesos representam quanto cada variável original contribui para a construção das CP(s) por meio da combinação linear. Neste caso, eles podem ser usados para selecionar quais componentes são importantes para explicar uma dada variável (GURGEL, 2000; VARELLA, 2008).

Assim, a influência das variáveis $X_1, X_2, \dots, X_p$ sobre a componente principal Y_i pode ser expressa pela equação 4.14:

$$w_j = \frac{a_{ij}}{\sqrt{\text{var}(X_j)}} \quad (4.14)$$

em que $\sqrt{\text{var}(X_j)}$ indica a variância da j-ésima variável e w_j é a correlação entre a i-ésima componente principal e a j-ésima variável, com $j = 1, 2, \dots, p$, $i = 1, 2, \dots, p$.

A expressão (4.14) mostra que para calcular os pesos das variáveis sobre uma componente qualquer se divide os elementos $a_{i1}, a_{i2}, \dots, a_{ip}$ dos autovetores pela raiz quadrada da variância das variáveis $X_1, X_2, \dots, X_p$.

Por exemplo, a influência das variáveis $X_1, X_2, \dots, X_p$ sobre a componente principal

Y_1 é: $w_1 = \frac{a_{11}}{\sqrt{\text{var}(X_1)}}$, $w_2 = \frac{a_{12}}{\sqrt{\text{var}(X_2)}}$, ..., $w_p = \frac{a_{1p}}{\sqrt{\text{var}(X_p)}}$. Neste caso, w_1 é o peso da

variável X_1 sobre a componente Y_1 , w_2 o peso de X_2 sobre Y_1 e assim por diante.

Após o cálculo das Componentes Principais os seus valores numéricos, também denominados de escores podem ser calculados para cada elemento amostral e então, analisados por meio de técnicas estatísticas como análise de variância e análise de regressão entre outras (MINGOTI, 2005).

Os escores são as novas coordenadas das amostras em um novo sistema de eixos definidos pelas Componentes Principais. A redução da dimensão dos dados será importante quando o número de componentes principais Y_i que conservam muito da informação amostral, inerente as variáveis X_i , $i = 1, 2, 3, \dots, p$, for menor que p . Nesse caso, as observações originais X_i podem ser trocadas pelos primeiros k , $k < p$ elementos dos escores dos Componentes Principais correspondentes e pode-se escrever $Y_i = (Y_{i1}, Y_{i2}, \dots, Y_{ik})^T$. Assim, uma aproximação dos dados originais pode ser exibida em um gráfico dos escores, de dimensão k (GUEDES; IVANQUI, 1998).

Em termos matriciais a ACP é um método para decompor uma matriz de dados em duas matrizes menores, a matriz dos (*loadings*) e a matriz dos escores. Geometricamente a ACP é uma técnica de projeção, em que a matriz de dados é projetada num subespaço de dimensões reduzidas. Os cossenos dos ângulos entre os eixos das variáveis originais e os eixos das PC(s) são os *loadings* descritos anteriormente. Os *loadings* variam entre os valores de -1 a 1. A variável que tem a maior contribuição para uma dada componente principal é a que apresenta o maior valor de peso (em módulo). Os escores são obtidos a partir do produto da matriz de dados pela matriz dos pesos (FREITAS, 2006).

A título de exemplo, ao se tomar duas variáveis de um conjunto de cinco amostras, tem-se uma matriz de dado de ordem 5×2 . Neste caso, cada linha da matriz de dados é representada por um ponto no gráfico. Geometricamente, as CP (s) descrevem a variação ou espalhamento entre os pontos usando o menor número possível de eixos. A primeira componente principal tem direção do máximo espalhamento (maior contraste) das cinco amostras e a segunda componente descreve o menor espalhamento restante. As novas coordenadas das amostras, no novo sistema de eixos das CP(s) são os escores.

A figura 4.1 ilustra os eixos principais e a dispersão das cinco amostras em função dos escores das duas Componentes Principais.




Figura 4.1: Dispersão de cinco amostras em função dos escores das Componentes Principais.

A ACP pode também ser feita utilizando dados padronizados e neste caso, a padronização dos dados originais é feita para evitar que uma variável tenha influência indevida sobre as Componentes Principais. A padronização é feita por meio da média e o desvio padrão dos dados originais, estabelecendo que os dados tenham, média zero e variância um ou ainda, assumindo variância um e média qualquer (SEDYIAMA, 1998; VARELLA, 2008). Neste trabalho os dados utilizados não são padronizados, mas vale aqui mostrar como é feita a padronização.

Para o primeiro caso (média zero e variância um) a padronização é feita pela expressão (4.15):

$$z_{ij} = \frac{(x_{ij} - m_i)}{s(x_i)} \quad (4.15)$$

Par uma padronização com variância um e média qualquer se tem:

$$z_{ij} = \frac{x_{ij}}{s(x_i)} \quad (4.16)$$

em que m_i e $s(x_i)$ em ambos os casos, são respectivamente, a média e o desvio padrão da i -ésima variável ($i = 1, 2, 3, \dots, p$ e $j = 1, 2, 3, \dots, n$). Então, a matriz $[Z]$ das variáveis padronizadas z_{ij} é dada pela expressão (4.17):

$$[Z] = \begin{bmatrix} z_{11} & z_{21} & \dots & z_{p1} \\ z_{12} & z_{22} & \dots & z_{p2} \\ \dots & \dots & \dots & \dots \\ z_{1n} & z_{2n} & \dots & z_{pn} \end{bmatrix} \quad (4.17)$$

Para o caso em que os dados são padronizados, a matriz de variância $[C]$ se torna a própria matriz de correlação e a análise passa a ser feita sobre esta matriz, equação 4.18

$$[R] = \begin{bmatrix} 1 & c_{12} & \dots & c_{1p} \\ c_{21} & 1 & \dots & c_{2p} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ c_{p1} & c_{p2} & \dots & 1 \end{bmatrix} \quad (4.18)$$

O elemento $c_{ij} = c_{ji}$ representa a correlação entre a variável X_i e X_j . A correlação é uma medida mais adequada para julgar o relacionamento linear entre as variáveis quantitativas, pois existe um valor de referência máximo e outro mínimo, ou seja, a correlação entre duas variáveis tem valores entre -1 e 1. Assim, quanto mais próximo de 1 maior a indicação de existência de relacionamento linear positivo (crescimento), quanto mais próximo de -1 maior a indicação de existência de relacionamento linear negativo (decréscimo) e uma correlação próxima de zero é uma indicação numérica de não- relacionamento linear entre as variáveis analisadas. Uma vez que o coeficiente de correlação é adimensional seu valor não sofre influencia das diferenças de escalas de medidas entre as variáveis (MINGOTI, 2005).

As Componentes Principais, neste caso são determinadas encontrando-se as raízes características da matriz de correlação (autovalores) e os respectivos vetores característicos (autovetores). A i -ésima componente principal, para os dados padronizados é calculada pela expressão (4.19):

$$Y_i = a_{i1}Z_{k1} + a_{i2}Z_{k2} + \dots + a_{ip}Z_{kp} \quad (4.19)$$

em que os a_p correspondem aos p coeficientes dos p autovetores, ou seja, $i = 1, 2, \dots, n$

Para variáveis padronizadas, a contribuição para cada CP em relação à matriz das Componentes Principais dada pela equação 4.12 é obtida substituindo o termo $\sum_{i=1}^n \lambda_i$ por $\text{traço}(R)$ em que o traço significa a soma dos elementos da diagonal principal da matriz de correlação R .

4.3 Redução da Dimensionalidade via ACP

Em reconhecimento de padrões, é sempre desejável dispor de uma representação compacta do conjunto de dados. Para isso, é importante que não haja redundância entre as diferentes características dos padrões, ou seja, que não haja covariância entre os vetores da base do espaço de características (CAMPOS, 2001).

Uma das características da ACP é reduzir o número de variáveis correlacionadas em um determinado conjunto de dados, preservando a sua variância total. Isto permite identificar os padrões e processos físicos associados às variáveis observadas, possibilitando a interpretação dos dados num contexto que envolve a sua variabilidade espacial/temporal (GURGEL, 2000).

Notadamente, o reconhecimento de padrões em imagens, se esbarra no problema da dimensionalidade, dado que o espaço de padrões original apresenta dimensionalidade muito alta. Desta forma, a redução de dimensionalidade se torna importante e necessária no processo de reconhecimento de padrões térmicos, uma vez que o erro de classificação, o tempo e conseqüentemente o custo computacional devem ser minimizados.

O princípio básico da redução de dimensão via ACP é o mapeamento do conjunto de dados de um espaço de maior dimensão para um espaço de menor dimensão. A transformação é feita de tal forma que o conjunto original de dados venha ser representado por um número reduzido de características efetivas retendo, no entanto, a maior parte da informação intrínseca contida nos dados (FIGUEIREDO, 2006).

De acordo com a equação 4.8, essa transformação gera um conjunto de vetores Y_i correspondentes aos vetores da matriz dos dados originais, matriz $[X]$. Como as linhas da

matriz $[A]$ são formadas pelos autovetores da matriz de covariância e as primeiras Componentes Principais Y_i representam a maior variância dos dados originais, então ao invés de armazenar todas as componentes, apenas as primeiras componentes são armazenadas juntamente com o vetor médio e as primeiras linhas da matriz $[A]$, de modo que a reconstrução do conjunto de dados possa ser realizada posteriormente.

Neste caso, a recuperação de qualquer um dos p vetores do conjunto $[X]$ através do seu correspondente $[Y]$ pode ser dada pela relação:

$$[X] = [A]^T [Y] + m_x. \quad (4.20)$$

Neste caso, a redução da dimensionalidade do conjunto de dados original é feita ao se utilizar um número reduzido de Componentes Principais, (primeiras componentes), os primeiros autovetores e o vetor médio na equação 4.20.

E no caso do uso de um número k menor de autovetores para formação da matriz $[A]$, resulta num número menor de Componentes Principais e então a reconstrução é inexata. Neste caso, o erro médio quadrático é dado por:

$$EMQ = \sum_{i=1}^p \lambda_i - \sum_{i=1}^k \lambda_i = \sum_{i=k+1}^p \lambda_i \quad (4.21)$$

em que $p > k$ e p é o número total de autovetores da matriz de covariância ou correlação. No caso em que $p = k$ o erro é zero.

4.4 *Análise das Componentes Principais na Termografia*

A Análise das Componentes Principais Termográficas (ACPT) aplicada na manutenção busca, além da avaliação dos gradientes de temperatura e pontos mais críticos do termograma, uma avaliação da evolução das temperaturas e das imagens térmica ao longo do tempo. A avaliação da evolução desta série temporal (imagens térmicas colhidas a cada inspeção) pode levar ao entendimento de eventuais variações ou tendências do estado do

componente, inclusive, a definição de um modelo matemático de predição capaz de prever valores futuros da série.

Considere um típico teste em que um dado componente é inspecionado de tempos em tempos e que N imagens termográficas de alta dimensionalidade (n_x número de *pixel* na largura da imagem por n_y número de *pixel* na altura) são capturadas durante as inspeções. Neste caso, a seqüência de imagens térmicas (termogramas) forma um conjunto de dados que pode ser arranjado como mostrado na figura 4.2.




Figura 4.2: Seqüência de N imagens, cada imagem com $n_x \cdot n_y$ elementos (Fonte: adaptado de Gonzalez; Woods, 2000 e Rajic, 2002)

Neste caso, a figura mostra esquematicamente uma série de imagens termográficas (conjunto de dados) definidas como uma matriz tridimensional (i, j, k) , $i = 1, 2, \dots, n_x$, $j = 1, 2, \dots, n_y$ e $k = 1, 2, \dots, N$. Ou seja, uma imagem multivariada com N canais.

Numa primeira análise Antes de iniciar a Análise das Componentes Principais, propriamente dita, esse volume de dados precisa passar por um pré-processamento, visando re-estruturar esse conjunto tri-dimensional de informações em uma forma mais adequada tal como a observada na matriz $[X]$, equação 4.1.

Numa primeira análise, a série de dados formada a partir das imagens termográficas pode ser vista como um conjunto de vetores onde cada elemento (imagem) desta série é um vetor. Assim, cada imagem de ordem n_x *pixel* por n_y *pixel* é escrita como um vetor, aqui

chamado de vetor imagem, contendo n componentes ($n = n_x \times n_y$), onde cada *pixel* é uma coordenada do vetor. A construção dos vetores imagens é executada fazendo uma leitura coluna a coluna das imagens (Fig. 4.2) de modo que os valores dos *pixels* de mesma posição (mesma localização) em cada imagem formem vetores X_i , com $i = 1, 2, \dots, N$ e $n = n_x \cdot n_y$, de maneira que as componentes de cada vetor X_i representam as N imagens da série. Por exemplo, o primeiro *pixel* da primeira imagem formará a primeira componente do vetor X_1 , o *pixel* de mesma posição na segunda imagem formará a segunda componente, o *pixel* de mesma posição na terceira imagem formará a terceira componente e assim por diante até que o N *pixels* na mesma posição das imagens formem as N componente deste.

Essa operação é realizada até que cada imagem seja varrida totalmente, *pixel a pixel*. Então, os vetores X_i assim construídos serão arranjados como linhas da matriz $[X]$ e ao final da operação, cada coluna de $[X]$ representa uma dada imagem (vetor imagem) da série vista na figura 4.2. Neste caso, o volume (tridimensional) de dados é reduzido, através de uma operação de rastreamento dos *pixels*, para uma matriz bidimensional $[X]$ de ordem $n \times N$.

Todos os vetores X_i assim construídos definem o conjunto de dados $[X]$, chamado de espaço de imagens, de ordem $n \times N$ onde o índice n representa o número total de *pixel* de cada imagem e N o número de imagens que compõe a série temporal.

Uma vez definida a matriz $[X]$, que representa a série de imagens termográficas ($X_1, X_2, \dots, X_N$) coletadas durante o período de monitoramento do sistema, o próximo passo é o cálculo das Componentes Principais aqui denominadas Componentes Principais Térmicas CPT(s).

Entretanto, antes de proceder ao cálculo da CPT é importante discutir o significado das linhas e das colunas na montagem da matriz de dados. No contexto da ACP, alguns problemas envolvendo a dimensionalidade do conjunto de dados devem ser considerados, ou seja, o tamanho da matriz de covariância e conseqüentemente a análise dos dados em termos das Componentes Principais vai depender da forma como os dados estão organizados na matriz $[X]$.

Neste caso, a matriz $[X]$ é formada por N medições (imagens) de um conjunto de dados n -dimensional e esse conjunto é um espaço multidimensional (seqüência de imagens), contendo informações, tanto espacial (defeito geométrico), como temporal (evolução do contraste térmico). Assim, dependendo de como o volume de dados foi convertido na matriz

$[X]$, existem duas formas de interpretar a análise: *análise no modo espacial e análise no modo temporal*.

Modo Espacial

No primeiro caso, considerando que os dados são formados por uma sequência de imagens (termograma) e a matriz $[X]$ tem n linhas (número total de *pixels* de uma imagem) por N colunas (número de imagens que compõe a série obtida nas inspeções).

Cada coluna é um vetor imagem cujas componentes representam todos os *pixels* dessa imagem (dada posição na imagem). No modo espacial, a dimensão dos dados é n , o número de imagens (medições) é N e o valor médio que será subtraído de cada coluna de $[X]$ é uma imagem média.

Neste modo, cada *pixel* na imagem representa uma dada variável e para cada imagem tem-se n variáveis. Assim, o vetor médio é um vetor de ordem $n \times 1$ cujas componentes são os valores médios de cada variável para N medições (média de cada *pixel* ou posição da imagem variando ou não seus valores para as N imagens).

Os eixos principais de uma região da imagem, como discutido anteriormente, são os autovetores da matriz de covariância das variáveis que compõem essa região. Assim, sob o ponto de vista dimensional, no modo espacial, os eixos principais são imagens (autovetor de mesma dimensão das imagens) e os dados projetados sobre esses eixos são os perfis temporais.

Modo Temporal

No segundo caso, em que as imagens compõem as linhas da matriz, considerando que os dados são formados por sequência de perfis térmicos (contraste térmico entre uma imagem e outra) a matriz $[X]$ tem N linhas e n colunas, cada coluna é um perfil temporal.

Cada coluna representa um vetor de perfis temporais, cujas componentes representam cada imagem para os n valores. No modo temporal, a dimensão dos dados é N (imagens) e o número de casos é n e o valor subtraído de $[X]$ é o perfil temporal médio. Ou seja, um vetor de ordem $N \times 1$ cujas componentes são os valores médios de cada imagem. Sob o ponto de vista dimensional, agora os eixos principais são os perfis temporais, neste caso, os autovetores

têm a mesma dimensão dos perfis temporais e os dados projetados sobre esses eixos principais são imagens.

A figura 4.3 ilustra as formas de entrada e saída dos dados na ACPT, as quais podem levar a uma descrição temporal e espacial do conjunto de dados como foi discutido anteriormente.




Figura 4.3: Formas de Entrada e Saída de dados da ACP (Fonte: Gurgel, 2000)

No primeiro caso (modo espacial), os vetores de características analisados são vetores de mesma dimensão das imagens (n variáveis), então, a matriz de covariâncias (quadrada) tem mesma a dimensão (Eq. 4.3). Neste caso, os autovetores gerados a partir da matriz de covariâncias terão a mesma dimensão das imagens e conseqüentemente as Componentes Principais geradas a partir desses autovetores (combinação linear) terão a mesma dimensão dos perfis temporais. No segundo caso (modo temporal), os vetores que representam os dados são perfis temporais e acompanhando o mesmo raciocínio, os autovetores terão mesma dimensão dos perfis temporais, conseqüentemente, as componentes geradas a partir desses autovetores terão a mesma dimensão das imagens.

O modo espacial é utilizado para acompanhar variações espaciais (local) ocorridas nos termogramas a cada inspeção, enquanto que no modo temporal essas variações são acompanhadas num gráfico ($Tempo \times CP$) onde cada termograma está relacionado a um tempo de observação do sistema inspecionado.

Em sensoriamento remoto de imagens termográficas, por exemplo, o segundo caso é o mais usado enquanto que em meteorologia (estações meteorológicas), o primeiro caso é o mais empregado. Assim, o primeiro caso é usado para estudar os padrões espaciais de variabilidade com o objetivo de eliminar a correlação espacial entre as variáveis e o segundo caso é usado para estudar os padrões temporais de variabilidade, com o propósito de eliminar a correlação temporal entre os dados (GURGEL, 2000).

Em Testes Não-destrutivos e na manutenção, o estado de um dado componente é monitorado por imagens tiradas em fração de tempo (ensaios de curta duração) ou períodos longos (dias, semanas ou meses) e a análise dos dados (imagens) é feita nos dois modos por apresentar correlação tanto no espaço (defeito geométrico) como no tempo (evolução do perfil térmico).

No contexto de processamento de imagens, a ACP é uma técnica de realce que remove a redundância espectral de imagens multibanda. A ACP transforma através da matriz de covariância entre as bandas, o conjunto original em um novo conjunto de imagens (Componentes Principais). Cada valor de "pixel" das CP(s) é uma combinação linear dos valores originais. O número de Componentes Principais é igual ao número de bandas espectrais utilizadas e estas são ordenadas de acordo com o decréscimo da variância de nível de cinza. Os autovalores representam o comprimento dos eixos das Componentes Principais de uma imagem e são medidos em unidade de variância. A cada autovalor está associado um autovetor que representa as direções dos eixos das Componentes Principais. Os autovetores são fatores de ponderação que definem a contribuição de cada banda original para uma componente principal, numa combinação aditiva e linear (CAMARA et al, 1996)

4.5 Aspectos Computacionais e Cálculo de Médias

Em termos computacionais a dimensão da matriz de covariância $[C_x]$ tem uma diferença básica dependendo de como é formada a matriz de dados de entrada $[X]$. Como imagens digitais apresentam uma grande quantidade de dados, isso pode tornar o problema bastante oneroso computacionalmente. Por exemplo, considere uma seqüência de seis imagens tendo 231×309 pixels cada e o conjunto de imagens $[X]$ arranjado como no primeiro caso (modo espacial), a ordem da matriz de covariância $[C_x]$ é de 71.379×71.379 , o que torna difícil o cálculo e a manipulação desses dados em computadores comuns.

Entretanto, se a matriz $[X]$ for arranjada como no segundo caso (modo temporal) a matriz de covariância $[C_x]$ terá ordem 6x6, o que torna mais fácil o cálculo das Componentes Principais. Neste caso, os eixos principais serão os perfis temporais e os dados projetados as imagens.

Analisando o primeiro caso num contexto de dimensionalidade, o problema é bastante crítico uma vez que a ordem da matriz de covariância $[C_x]$ é muito grande. Esse cálculo conforme mostrado em Marinetti (2004) pode ser feito de forma indireta a partir dos próprios autovetores obtidos no segundo caso, através da relação dada pela expressão (4.22):

$$V_1 = ([X_1] - m_1)[V_2]D_2^{-1/2} \quad (4.22)$$

em que $([X_1] - m_1) = ([X_2] - m_2)^T$ e $[V_2]$ e $[D_2]$ são os autovetores e autovalores do modo temporal, $[X_1]$ e m_1 , $[X_2]$ e m_2 são o conjunto de imagens e o vetor médio do primeiro e segundo caso, respectivamente.

A equação 4.22 permite calcular a matriz dos autovetores do primeiro caso a partir dos autovalores, dos autovetores e da média do segundo caso e então a partir dessa matriz de autovetores calculam-se as Componentes Principais temporais.

Outro aspecto muito importante na ACPT é com relação a forma com que a média é calculada (disposição dos dados).

Do ponto de vista de dimensionalidade, o modo como a matriz de dados é disposta, ou seja, a permuta entre os vetores projeção e os dados projetados tem influência no modo como será feita a análise. Entretanto, a influência nos resultados da Análise das Componentes Principais Térmicas não é dada pela disposição do conjunto original em si, pois se a análise for feita como no modo espacial $[X]$ ou no modo temporal $[X]^T$ o que muda é a maneira como a média é calculada (MARINETTI, 2004).

No cálculo das Componentes Principais a média é subtraída do conjunto de dados. De um lado se tem a imagem média e de outro o perfil temporal médio e os resultados dependem de como é possível subtrair de cada imagem a imagem média (centrar cada imagem na média) e de como é possível subtrair de cada perfil temporal o perfil médio (centrar cada perfil temporal na média). Conseqüentemente isso tem influência no cálculo da matriz de covariância de onde são extraídos os autovalores e autovetores envolvidos na análise. Como discutido anteriormente, o mecanismo de centrar na média e alinhar os dados com os maiores

autovetores correspondentes aos maiores autovalores (maiores variâncias) é que descorrelaciona os dados.

Neste trabalho toda a análise foi feita com a matriz de dados $[X]$ disposta como nos dois casos (modos espacial e temporal), levando-se em conta a permuta entre os vetores projeção e os dados projetados uma vez que esta permuta influencia no modo como será feita a análise. Assim, quando as Componentes Principais tiverem mesma dimensão dos perfis temporais serão chamadas de componentes temporais, quando tiverem mesma dimensão das imagens serão chamadas de componentes espaciais.

Foram também utilizadas as duas médias, imagem média e perfil médio, para mostrar que os resultados são influenciados pela maneira como são calculadas a média.

4.6 Metodologia

Este trabalho discute a proposta de utilização da ACP aplicada para manutenção preditiva com base na termografia. Neste caso, o estado do componente é monitorado a partir de imagens térmicas (termogramas) obtidos ao longo das inspeções e as características marcantes e variações do estado do componente (mudanças no perfil térmico espacial/temporal) são obtidas a partir da ACPT.

A proposta da pesquisa foi inicialmente avaliada com dados simulados e posteriormente com dados experimentais.

A análise a partir de dados simulados teve o objetivo principal de estudar e avaliar a potencialidade da aplicação da técnica. O procedimento foi feito a partir da introdução artificial (simulação) do aumento de temperatura em uma região de um termograma de referência obtido na inspeção de um componente elétrico (chave elétrica) gerando assim, um conjunto de seis imagens de diferentes níveis de temperatura na região de interesse. A utilização de dados simulados visa fornecer uma base de referência para que os resultados obtidos possam ser confrontados posteriormente com os dados experimentais.

Na análise experimental, a técnica da ACP foi aplicada em um modelo simplificado de um painel de telefonia buscando identificar variações térmicas e tendências do comportamento do sistema. O sistema analisado é formado por um conjunto de nove blocos de alumínio representando componentes elétrico-eletrônicos sujeitos ao aquecimento quando em operação. Neste caso, o bloco central foi aquecido por uma resistência elétrica e a sequência de termogramas registrada para diferentes condições do sistema.

As características térmicas do conjunto de imagens foram analisadas via ACP buscando identificar variações térmicas relacionadas com eventuais avarias no sistema.

Tanto para os dados simulados quanto para os dados experimentais as componentes principais foram analisadas no modo espacial e no modo temporal utilizando as duas médias discutidas anteriormente (imagem média e perfil médio).

Outra análise foi feita a partir dos gráficos dos escores e *loadings* das componentes principais. Na análise dos escores, os valores das componentes principais foram utilizados para analisar diferentes regiões dentro dos termogramas e localizar a área afetada no sistema que, neste caso, é representada pela região de maior espalhamento das amostras no gráfico dos escores. Já os *loadings* (autovetores) foram utilizados para verificar o relacionamento entre as CP(s) e os termogramas, ou seja, para verificar os termogramas de maior importância na composição de cada CP.

A metodologia desta pesquisa segue a seguinte estrutura:

Inicialmente uma seqüência de imagens térmicas é adquirida utilizando uma câmera específica e o pré-processamento do volume de dados é então executado visando re-estruturar a seqüência de imagens em um formato mais adequado para o cálculo das CP(s). Neste caso, o conjunto tridimensional (seqüência de imagens) é arranjado em uma matriz de dados, cujas linhas dessa matriz representam as imagens da série.

Após o pré-processamento dos dados, as CP(s) são então calculadas a partir de um algoritmo desenvolvido utilizando rotinas implementadas a partir de funções pré-definidas no Matlab[®] versão 6.5 e as características térmicas do sistema são analisadas via ACP com base em parâmetros estatísticos bem como a partir dos gráficos dos escores e dos *loadings*.

A região de interesse, nas componentes principais, que representa a região de maior variabilidade, no gráfico dos escores é identificada pelo espalhamento das amostras (regiões de maior dispersão). Já as regiões de menor variação estão associadas a grupos de amostras mais concentradas neste mesmo gráfico.

Na análise, os grupos de amostras de interesse para análise dos escores foram selecionados segundo conhecimento previamente adquirido em relação à variabilidade dos dados e então identificados dentro dos termogramas com o auxílio de uma ferramenta interativa (gráfica) disponível no software Matlab (*mapcaplot*). Esta ferramenta permite a localização das amostras (índices) correspondentes a uma dada região no vetor das CP(s).

A figura 4.4 mostra esquematicamente a metodologia utilizada nesta pesquisa.




Figura4.4: Fluxograma da metodologia proposta neste trabalho.

CAPÍTULO 5

5 Aplicação da ACP em Termografia

Este capítulo discute a aplicação da Análise das Componentes Principais (ACP) em termográfica, mais especificamente, busca identificar como a ACPT pode captar as variações e tendências de um conjunto de imagens térmicas (termogramas). Numa aplicação real este conjunto de imagens térmicas viria do monitoramento periódico da condição de operação de um equipamento específico. Entretanto, dado que o objetivo principal deste capítulo é estudar e avaliar a capacidade e potencialidade da aplicação da técnica, as imagens do conjunto de dados utilizado na análise são simuladas a partir da introdução de pequenas variações em um único termograma, obtido na inspeção de um componente real (chave elétrica) que apresenta um sobreaquecimento.

5.1 Conjunto de Dados Analisado

A figura 5.1 mostra a imagem térmica do componente elétrico obtida em uma condição real de operação, em (a) é mostrada uma versão em cores onde as variações de temperatura são apresentadas em tons que variam do azul ao vermelho e em (b) em tons cinza.




Figura 5.1: Imagem de um sistema elétrico sobre aquecido: (a) em cores, (b) em cinza.

O conjunto de imagens analisado foi obtido introduzindo de forma artificial (simulação) um aumento de temperatura em uma região da imagem, denominada de região de interesse, mostrada no termograma da figura 5.1. A imagem térmica real foi tomada como base e foram simulados aquecimentos (aumento de temperatura) na região em destaque, gerando um conjunto de seis imagens apresentando diferentes níveis de temperatura na região de interesse. A utilização de dados simulados, ou seja, dados obtidos a partir da introdução de variações conhecidas nesta fase de validação e implementação da proposta visa fornecer uma base de referência para que os resultados obtidos possam ser confrontados posteriormente.

O procedimento para a simulação de aquecimento foi feito aumentando o valor de brilho da imagem térmica na região de interesse, de modo que o valor de temperatura dessa região variasse de um termograma para o outro. Neste caso, as seis imagens apresentam mesmo valor de brilho em toda a cena com exceção da região de interesse. A figura 5.2 ilustra a sequência de imagens geradas e utilizadas na análise.




Figura 5.2: Sequência de termogramas utilizados na análise.

Os termogramas apresentam valores de temperatura diferentes na região de interesse, sendo que o primeiro termograma é definido como referência (imagem original) e a

temperatura vai aumentando gradativamente, do primeiro até o terceiro termograma (maior registro de temperatura), cai no quarto e prossegue aumentando até o sexto termograma, atingindo um nível ainda menor do que o nível de temperatura do terceiro.

Esse conjunto de dados poderia ser interpretado como aos dados obtidos no monitoramento (termografia) do equipamento e cada imagem é interpretada como a condição de operação do componente para aquele dado instante (tempo) de inspeção. Para a análise dos dados cada imagem é transformada em um vetor denominado vetor imagem (item 4.4) contendo n componentes ($n = \text{num. linhas} \times \text{num. colunas}$), onde cada *pixel* é uma coordenada desse vetor.

A seqüência de armazenamento (posicionamento) de cada imagem na matriz $[X]$ é associada com o tempo, de forma que a imagem (1) está associada à inspeção no tempo t_1 , a imagem (2) no tempo t_2 e assim por diante.

5.2 Componentes Principais no Modo Espacial

A análise das CP(s) no modo espacial permite avaliar a evolução espacial do perfil térmico do componente, ou seja, ela busca detectar e localizar a região da imagem que apresenta mudanças (submetida às variações térmica).

Para isso, as imagens da seqüência analisada devem ser registradas adequadamente, apresentar a mesma cena de maneira que ao formar uma imagem multiespectral/multibanda elas fiquem alinhadas no sentido de haver uma correspondência espacial entre os *pixels* correspondentes. Esses *pixels* serão as componentes dos vetores de características dos dados. Não atentar a esse fato é o mesmo que analisar o comportamento térmico de um sistema a partir de uma seqüência de termogramas em que um desses termogramas nada tem a ver com o componente em questão.

A matriz de dados $[X]$ utilizada neste modo é arranjada de forma que as linhas da matriz representam os termogramas (Fig. 5.2.a-f), enquanto que as colunas representam o perfil térmico (evolução dos termogramas no tempo). Um aspecto importante quando se trabalhando com variância e covariância é que qualquer mudança na cena será traduzida pelas Componentes Principais que têm uma forte relação com a média da matriz de dados. Conseqüentemente, a forma em que é definida a média vai refletir nos resultados.

5.2.1 Subtração da Imagem Média

A utilização da imagem média no cálculo das CP(s) espaciais na Análise das Componentes Principais Térmicas busca a variabilidade espacial dos dados de um termograma para outro.

Uma avaliação preliminar do conjunto de imagens mostra que existem *pixels* com valores comuns e outros com valores diferentes, conseqüentemente, se for tomadas somente essas variações, cada imagem do conjunto poderia ser representada com um mínimo de informação e sem perda da qualidade. Assim, partindo da hipótese de que muitas informações são redundantes, estas podem ser representadas pela variância que ocorre em torno de uma média. Essa média busca representar o que é comum a todas as imagens da série (imagem média) (KITANI; THOMAZ, 2006).

No modo espacial o vetor médio é calculado a partir da média aritmética dos valores de cada coluna da matriz $[X]$ e é dado por um vetor de ordem 71379×1 elementos. Esse vetor pode ser reordenado na forma de uma matriz utilizando uma operação inversa (*reshape*) a utilizada na definição do vetor imagem. A figura 5.3 mostra a imagem média do conjunto de dados analisado.




Figura 5.3: Imagem média utilizada na análise.

Essa imagem média (vetor de ordem 71379×1 elementos) agora é subtraída da matriz de dados $[X]$. Essa operação é feita subtraindo o vetor médio, de cada linha da matriz de dados $[X]$, de forma que todas as imagens do conjunto variaram em torno dessa média.

Do ponto de vista algébrico, não é possível subtrair um vetor de uma matriz. Para tanto é necessário converter esse vetor em uma matriz da mesma ordem da matriz $[X]$ e, posteriormente, fazer a subtração. O procedimento computacional para essa conversão é detalhado em Kitani e Thomaz (2006).

Uma vez definida a matriz de dados e o vetor médio, as CP(s) são calculadas de acordo com os procedimentos discutidos na seção 4.2. Cada CP é dada por um vetor de mesmo tamanho do vetor imagem (71379×1). Esse vetor, como no caso do vetor médio, pode ser reordena na forma de uma matriz utilizando uma operação inversa (*reshape*) a utilizada na definição do vetor imagem e as CP(s) podem ser analisadas na forma de imagem. A figura 5.4.a-f mostra as CP(s) calculadas a partir do conjunto de dados (imagens) em análise.




Figura 5.4: Componentes Principais espaciais obtidas por subtração da imagem média.

As CP(s) evidenciam claramente o que ocorre no conjunto de dados analisados, uma vez que imagens analisadas apresentam mudanças no valor de brilho apenas em uma região da imagem, ficando o restante da cena idêntica em todas as imagens. Isso é refletido com maior evidência na primeira componente principal que mostra a variabilidade espacial dos dados

(região de mudança), isto é, detecta a ocorrência da variação de temperatura (possível defeito) e a região alterada (local), figura 5.4.a.

Neste caso, a primeira componente principal detecta a maior parcela da variabilidade dos dados e a partir dessa componente principal é possível verificar qual a região que apresenta variação de temperatura (região mais aquecida).

Tendo em vista que a ACP remove a redundância espectral dos dados (imagens), a região que não apresenta variância de um termograma para o outro (fundo da cena) é mostrada na cor preta (ausência de variância). Resumidamente, cada CP capta uma parcela da variação espacial dos termogramas (variabilidade dos dados).

Na Análise das Componentes Principais a primeira CP está associada ao maior autovalor e este é medido em unidade de variância dos dados, conseqüentemente, esta componente apresenta o maior espalhamento (contraste) na região que sofreu variação e é a componente de maior importância. Neste caso, a primeira CP é responsável por 99.4 % da variância total, enquanto que a segunda responde por apenas 0.35% e as demais pelo restante. A figura 5.5 mostra esta porcentagem de variância explicada por cada CP.




Figura 5.5: Porcentagem da variabilidade dos dados, explicada por cada componente principal.

O gráfico mostra que as duas primeiras CP(s) retêm aproximadamente 100% da variabilidade ocorrida no conjunto de termogramas. As demais detectam pouca variabilidade espacial na região de mudança, sendo estas CP(s) desprezíveis (ver também figura 5.4). Neste

caso, o conjunto de dados pode ser reconstruído fazendo-se o uso de apenas as duas primeiras componentes.

5.2.2 Subtração do Perfil Temporal Médio

O cálculo das Componentes Principais aqui é parecido com o item anterior, com a diferença que a média dos termogramas foi calculada com relação ao perfil temporal. Diferentemente da imagem média, a utilização do perfil médio no cálculo das CP(s) espaciais na Análise das Componentes Principais Térmicas busca a variabilidade espacial dos dados dentro dos próprios termogramas. Neste caso, o perfil temporal médio foi obtido a partir da média aritmética dos valores de cada linha (cada termograma) da matriz que contém os seis termogramas, ou seja, um vetor de ordem 6×1 . A figura 5.6 ilustra o perfil temporal médio calculado, esse vetor é subtraído de cada coluna da matriz de dados.




Figura 5.6: Perfil Temporal Médio

Definido o vetor médio as CP(s) são calculadas e, neste caso, elas também são vetores de ordem 71379×1 . A figura 5.7 mostra o gráfico das CP(s) na forma de imagem.




Figura 5.7: Componentes Principais espaciais obtidas por subtração do perfil temporal médio.

As três primeiras CP(s) mostram as variações espaciais. Mas neste caso, em especial as duas primeiras CP(s), mostram com maior evidência variação tanto dentro da região alterada quanto fora dela. Esse fato se deve a subtração do perfil médio. Enquanto que no caso da imagem média, era verificada a variação de um termograma para o outro, agora é verificada a variação dos dados dentro dos próprios termogramas, sendo que cada termograma representa uma variável para uma amostra de tamanho 71379 (número de *pixels* em um termograma). Devido à própria forma de construção dos vetores de características e o perfil temporal médio, as CP(s) mostram a variabilidade espacial dos dados a cada posição dentro dos termogramas.

A primeira componente principal, figura 5.7.a, como no caso anterior, é responsável por grande parte (96.5%) da variabilidade do conjunto de dados e a segunda CP por 3.5% da variação nos dados. Já a terceira CP explica apenas 0,2% desta variabilidade. O gráfico da figura 5.8 mostra a porcentagem de variabilidade explicada por cada componente principal.




Figura 5.8: Porcentagem da variabilidade dos dados, explicada por cada componente principal.

Neste caso tanto a primeira quanto a segunda componente evidenciam a região que sofreu maior aquecimento, além de mostrar a variabilidade dos dados nos termogramas. A região de interesse apresenta maiores valores (escores) relativos às amostras que compõem essa região, conforme será discutido posteriormente. Entretanto, devido à própria forma de construção das CP(s) a primeira componente é a mais significativa para representar a variabilidade espacial.

Uma análise dos dois casos discutidos mostra que de um lado é dada a variabilidade espacial do conjunto de dados com relação à imagem média e do outro a variabilidade espacial com relação ao perfil temporal médio.

No caso da imagem média, as Componentes Principais detectam a evolução da temperatura sob um ponto de vista local, ou seja, capta a variabilidade dos *pixels* que compõem uma determinada região que sofre mudanças de um termograma para outro. No caso do perfil médio, as componentes detectam mudanças espaciais dentro dos próprios termogramas, pois a variação nos valores dos *pixels* agora é observada dentro dos próprios termogramas. Em ambos os casos discutidos as CP(s) captam a variabilidade dos dados espacialmente.

5.3 Componentes Principais no Modo Temporal

A análise das CP(s) no modo temporal permite observar a evolução do perfil térmico dos dados que pode ser utilizado para estabelecer uma relação entre o fenômeno físico (aquecimento) com a evolução das CP(s).

A disposição da matriz de dados no modo temporal é diferente do caso anterior e as linhas da matriz $[X]$, neste caso, representam os perfis temporais, enquanto as colunas os termogramas.

O cálculo dos autovetores da matriz de covariância arranjada desta forma, como foi discutido no quarto capítulo, é inviável em função do tamanho da matriz de covariâncias (71379×71379). Para contornar este problema, foi utilizada a transformação discutida na seção 4.5, ou seja, foram calculados os autovetores da matriz no modo espacial e posteriormente os mesmos foram transformados (eq. (4.22)) para o modo temporal. Essa transformação foi utilizada em ambos os casos, tanto para a imagem média como para o perfil médio.

5.3.1 Subtração da Imagem Média

A imagem média utilizada nos cálculos é a mesma do item 5.2.1 (Fig.5.3). Entretanto, devido ao arranjo da matriz de dados $[X]$ o tamanho do vetor das CP(s) é diferente, cada CP é dada agora por um vetor de tamanho 6×1 . A figura 5.9 mostra a evolução das CP(s) em relação aos termogramas (tempo). Neste caso em que cada termograma está associado a um dado tempo de inspeção, o gráfico mostra a tendência das CP(s) com relação a esse tempo de inspeção. Esse tempo é dado em unidades arbitrárias (u.a).




Figura 5.9: Componentes Principais Temporais obtidas por subtração da imagem média.

O gráfico das CP(s) mostra que a primeira componente principal capta o comportamento térmico do sistema, uma vez que esta componente mostra a evolução térmica do sistema ao longo das várias inspeções. O maior valor observado ocorre exatamente no terceiro termograma que está associado ao maior registro de temperatura (ver Fig. 5.2). Assim, esta poderia representar as variações de temperatura ao longo das inspeções. A figura mostra ainda que a variação entre as outras componentes é desprezível em relação à primeira CP, que é responsável por 99,4% da variabilidade total dos dados.

5.3.2 Subtração do Perfil Temporal Médio

Neste caso, as Componentes Principais foram calculadas subtraindo o perfil temporal médio do conjunto de dados que é o mesmo do item 5.2.2 (Fig.5.6). Vale ressaltar ainda que para os cálculos destas CP(s) foi utilizada a transformação da equação 4.22. A figura 5.10 mostra o gráfico das CP(s) com relação ao tempo.




Figura 5.10: Componentes Principais Temporais obtidas por subtração do perfil temporal médio.

As duas primeiras CP(s) mostram claramente uma relação com o fenômeno físico (aquecimento) de em cada termograma. A primeira CP, dada a própria forma de construção do vetor (relativa ao maior autovalor), é a mais significativa para representar a variação de temperatura nos seis termogramas. No entanto, a segunda componente principal também capta as variações de temperatura.

Ambas as CP(s) estão fortemente relacionadas com o perfil térmico do sistema analisado. Em especial, a primeira CP está relacionada com os termogramas relativos aos tempos em que ocorreram os maiores registros de temperatura na região (t_3 , t_5 e t_6), maiores coeficientes em módulo, principalmente com t_3 . Já a segunda CP está relacionada ao termograma relativo ao maior registro de temperatura (t_3), maior coeficiente em módulo.

Em resumo, a primeira CP está fortemente associada à evolução do perfil térmico do sistema e a segunda CP está associada à inspeção de maior registro de temperatura, relativo ao terceiro termograma. Adicionalmente, a segunda CP poderia ser vista como uma forma de discriminar os termogramas com maiores temperaturas (t_3 , t_5 e t_6) em relação aos termogramas de menores temperaturas (t_1 , t_2 e t_4), coeficientes de sinais contrários

5.4 *Análise do Gráfico dos Escores e Loadings Utilizando a Imagem Média*

Uma avaliação complementar dos resultados das análises anteriores pode ser obtida a partir da análise dos escores e dos *loadings*. O gráfico dos escores e dos *loadings* mostram uma projeção dos dados nos eixos formados pelas Componentes Principais e permitem uma análise da estrutura dos dados definida pelos agrupamentos das amostras.

Os escores contêm informações das coordenadas dos dados originais em um novo sistema de coordenadas, definida pelas Componentes Principais. Os valores numéricos dos mesmos, definidos no item 4.2, fornecem a composição das CP(s) em relação às amostras. Já os *loadings* fornecem essa mesma composição em relação às variáveis. Se a matriz de dados é arranjada como discutido no modo espacial, as amostras são representadas pelas linhas da matriz de dados e as variáveis são representadas pelas colunas e vice-versa para o modo temporal.

A análise do gráfico dos escores e dos *loadings* pode ser associada tanto com a análise das CP(s) no modo espacial como no e temporal. Quando se quer observar a estrutura dos dados com relação ao espaço dos termogramas (domínio espacialmente) é feita à análise dos escores, no caso em que se quer observar a estrutura dos dados com relação ao tempo (domínio temporal) é feita a análise dos *loadings*.

5.4.1 *Análise dos Escores*

A análise dos escores busca mostra a importância das amostras na formação das CP(s). Para a matriz de dados arranjada de forma que as linhas correspondem aos termogramas e as colunas ao perfil temporal (modo temporal), cada ponto representa uma amostra de coordenadas nos eixos das CP(s). Neste caso, é possível, a partir do gráfico dos escores das CP(s), observar e analisar uma dada região dos termogramas.

Uma vez que a região que apresenta maior aquecimento é representada pelo espalhamento das amostras no gráfico dos escores, os grupos de amostras de determinadas regiões podem ser selecionados de acordo com a variabilidade dos dados.

A figura 5.11 mostra o gráfico dos escores da primeira CP (Fig.5.4.a) pela segunda CP (fig. 5.4.b) obtidas na seção 5.2.1.




Figura 5.11: (a) Gráfico dos escores das duas primeiras Componentes Principais. (b) Diferentes agrupamentos dos escores.

Os valores dos escores fornecem informação da composição das CP(s) em relação às amostras, neste caso, as colunas (perfis) da matriz de dados. O gráfico mostra a distribuição dos pontos (dados) com relação à primeira e à segunda CP. Nuvens de pontos são formadas de forma que é possível observar o relacionamento entre essas CP(s) e uma dada região nos termogramas.

Analisando os escores (pontos) percebe-se que a primeira componente principal representada no gráfico pelo eixo horizontal revela dois agrupamentos importantes de dados. Um grupo maior que apresenta valores altamente positivos, formado pela união dos grupos 3 e 4 e um outro grupo de valores próximos de zero formado pelos grupos 1 e 2 (Fig. 5.11.b).

O gráfico mostra ainda que a segunda componente principal, representada no gráfico pelo eixo vertical, revela um agrupamento maior centrados em zero (pouca variação) e um pequeno grupo de amostras negativas (grupo 5).

A identificação dos valores numéricos correspondentes às regiões de maior variabilidade no vetor das CP(s) e a associação desses valores com as regiões (posição espacial) da imagem é importante, principalmente, na questão voltada para manutenção. Essa associação pode ser utilizada no reconhecimento da região que ocorreu a mudança (defeito) no

sistema físico, ou mesmo, poderia ser usada no treinamento de redes neurais artificiais para o reconhecimento automático de padrões.

Vale lembrar que a escolha dos grupos em destaque na figura (5.11.b) não foi feita ao acaso. Os grupos foram escolhidos baseando-se em conhecimentos previamente adquiridos em relação à variabilidade dos dados (regiões de maior dispersão). Uma vez identificadas as regiões de maior variação foi utilizada uma ferramenta interativa disponível no software Matlab para verificar a correspondência dos escores com uma dada região e a partir de testes as amostras foram escolhidas e então, as regiões de interesse foram identificadas nas CP(s).

A figura 5.12 destaca as amostras situadas nas nuvens de pontos relativas aos grupos discutidos anteriormente (Fig. 5.11.b) para a primeira CP. Estes conjuntos de valores permitem a identificação da respectiva região nas CP (s) ou nos termogramas, de acordo com o discutido no parágrafo anterior.




Figura 5.12: Regiões correspondentes aos diferentes agrupamentos dos escores na primeira CP.

A figura 5.12.a destaca os escores do grupo 3. A figura 5.12.b os do grupo 4 e a figura 5.12.c destaca a união dos grupos 3 e 4 em contraste com os escores do grupo 1 centrados em zero que representa o fundo dos termogramas. A figura 5.12.d destaca os escores situados nos grupos 2 e 5.

De acordo com a figura 5.12, os escores de valores altamente positivos (grupos 3 e 4) correspondentes à região de variação nos termogramas. Os escores do grupo 1 que estão centrados em zero correspondem à região das imagens que não apresentou variação. O escores dos grupos 2 e 5 representam pequenas regiões dentro da região de interesse. Em especial, o grupo 5, representa os 0.35% da variabilidade dos dados captada pela segunda CP que é apresentado na figura 5.4.b por uma pequena mancha escura (valores negativos). Este grupo é destacado na segunda CP, figura 5.13.




Figura 5.13: Escores do grupo 5 na segunda CP.

5.4.2 Análise dos Loadings

A análise da importância de cada variável na formação das CP(s) é feita a partir do gráfico dos *loadings* que são os coeficientes dos autovetores.

Nesta análise é observada como cada variável no sistema original (termograma) está associada a cada componente principal por meio do coeficiente de ponderação (autovetor), cujo valor absoluto determina a importância da variável para aquela componente principal.

Os sinais (positivo ou negativo) dos coeficientes dos autovetores dentro de cada componente principal indicam a relação existente entre as variáveis, isto é, mesmo sinal indica correlação positiva, enquanto que sinais diferentes indicam correlação negativa. Assim,

variáveis com autovetores de mesmo sinal, dentro de uma determinada componente principal, estão diretamente correlacionadas, por sua vez, sinais diferentes indicam correlação negativa e valores próximos de zero indicam não correlação (ZANINE, 2009).

A tabela 5.1 mostra os coeficientes das Componentes Principais obtidas na seção 5.2.1 (caso espacial/imagem média) que tem uma relação direta com a importância de cada termograma para aquela CP (combinação linear). Estes coeficientes representam as contribuições ou a importância de cada termograma para o valor de variância de cada CP. Como uma medida de correlação, o sinal dos coeficientes indica correlação diretamente proporcional ou inversamente proporcional.

Variável/Componente	1 ^a	2 ^a
Termograma 1	-0.5594	0.3861
Termograma 2	-0.3452	0.2168
Termograma 3	0.7016	0.5722
Termograma 4	-0.1293	-0.2875
Termograma 5	0.1229	-0.4406
Termograma 6	0.2095	-0.4469

Tabela 5.1: Relação entre as Componentes Principais e os termogramas da figura 5.4.

A figura 5.14 mostra o gráfico dos pesos (*loadings*) em relação à primeira e à segunda CP.




Figura 5.14: Gráfico dos *loadings* para as duas primeiras CP(s) da figura 5.4.

No gráfico, os termogramas são representados no plano por vetores, cuja direção mostra a máxima variabilidade do conjunto de dados e o comprimento indica a contribuição (peso) de cada termograma na composição das Componentes Principais (eixo horizontal e eixo vertical).

De acordo com a tabela 5.1 e a figura 5.14, a primeira componente apresenta coeficientes positivos para o terceiro, quinto e sexto termograma, que correspondem aos termogramas que apresentam maior registro de temperatura na região analisada e coeficientes negativos para o primeiro, segundo e quarto termograma. Isso indica que a primeira componente principal distingue entre termogramas que apresentam maiores valores de temperatura e termogramas que apresentam menores valores de temperatura na região de interesse.

Esta componente tem como principais coeficientes aqueles correspondentes aos três primeiros termogramas. O terceiro termograma (de maior importância) que corresponde ao coeficiente de maior grandeza numérica em valor absoluto, apresenta correlação negativa com o primeiro e segundo termograma. Essa correlação é mais forte entre o primeiro e terceiro termograma (sinais contrários) que apresentam coeficientes de valores altamente positivo e negativo.

A segunda componente principal tem coeficientes positivos para o primeiro, segundo e terceiro termograma e coeficientes negativos para o quarto, quinto e sexto termograma. Seus principais coeficientes estão associados ao terceiro, quinto e sexto termograma,

principalmente com o terceiro termograma que apresenta uma correlação negativa com o quinto e sexto termograma.

Outra análise pode ser feita, para melhor entendimento, comparando-se o gráfico dos escores e as duas CP(s) espaciais. Neste caso, pode-se verificar que a primeira CP pode ser utilizada para distinguir a região que sofreu mudança nos termogramas (região de interesse) e as demais regiões, que não apresentam nenhuma variação (fundo da cena). Neste caso, a primeira CP espacial pode ser interpretada como um índice que distingue (contraste) entre a região que sofreu a mudança e a que não apresentou nenhuma variação (valores de sinais contrários).

Analogamente, analisando o gráfico dos *loadings* e as CP(s) temporais a primeira CP pode ser interpretada como um índice que distingue (coeficientes de sinais contrários) o menor e maior registro de temperatura, neste caso, representados pelo primeiro e pelo terceiro termograma, respectivamente. Já a segunda componente temporal distingue os maiores e os menores registros de temperatura e é bem representada pelo terceiro termograma (maior coeficiente).

5.5 Análise do Gráfico dos Escores e Loadings Utilizando o Perfil Médio

A análise agora é discutida com relação o perfil médio (Fig. 5.6) e, neste caso, a análise espacial, dos escores, mostra a discriminação de regiões dentro do próprio termograma, diferentemente do caso anterior, que mostrou mudança em uma dada região ao longo das várias inspeções (tempo).

5.5.1 Análise dos Escores

A análise dos escores para as duas primeiras Componentes Principais da figura 5.7, caso em que foi utilizado o perfil temporal médio, é feita de maneira análoga ao item 5.4.1. A figura 5.15 mostra o gráfico dos valores numéricos (escores) das duas primeiras CP(s) calculadas na seção 5.2.2.




Figura 5.15: (a) Gráfico dos escores das duas primeiras Componentes Principais. (b) Diferentes agrupamentos dos escores.

A figura 5.15 permite observar que tanto para a primeira quanto para a segunda componente existe uma separação de valores em dois agrupamentos de amostras. Esses agrupamentos são representados pelos grupos 1 e 2 em destaque na figura 5.15.b.

As amostras dos dois grupos se aproximam de uma reta, apresentando uma tendência linear em que os escores do grupo 1 mostram uma tendência linear positiva enquanto que os escores do grupo 2 mostra uma tendência linear negativa. Isso indica que essas duas novas variáveis (CP(s)) apresentam relação diretamente proporcional na região correspondente ao grupo 1 e relação inversamente proporcional na região correspondente ao grupo 2.

Fisicamente isso significa que existem regiões nas duas primeiras CP(s) apresentando mesmo padrão e outras apresentando padrão inverso. Essas regiões são ilustradas na figura 5.16.a-b, em branco e preto (imagem lógica).

A exibição das CP(s) neste formato teve o objetivo de destacar as diferentes regiões apresentadas por essas CP(s), bem como mostrar a inversão nos valores de brilho (branco e preto) em algumas regiões e mesmo padrão na região de interesse.




Figura 5.16: Regiões correspondentes aos diferentes agrupamentos dos escores. (a) Primeira CP. (b) Segunda CP.

No gráfico da figura 5.15.b, Os escores do grupo 1 com exceção daqueles situadas no grupo 3 apresentam valores positivos para as duas Componentes Principais (mesmo sinal). A maioria dos escores do grupo 2, apresentam valores positivos para a primeira CP e valores negativos para a segunda CP (sinais opostos). Em particular, o grupo 4 apresenta valores positivo para a primeira CP e valores negativos para a segunda CP (sinais opostos). As regiões que apresentam sinais positivos são apresentadas nas CP(s) da figura 5.16.a-b em branco enquanto que as regiões que apresentam sinal negativo são apresentadas em preto.

A figura 5.17.a-d destaca as diferentes regiões apresentadas por essas duas CP(s), em tons de cinza.




Figura 5.17: Regiões correspondentes aos diferentes agrupamentos dos escores. (a) Primeira CP. (b) Segunda CP.

De acordo com a figura 5.17.a-b e o gráfico, os escores do grupo 1 correspondem à região de interesse (maior registro de temperatura), pois esta região apresenta mesmo padrão para as duas CP(s), em branco na figura 5.16. Os escores do grupo 3 e do grupo 5 representam pequenas regiões dentro da região de interesse enquanto as demais regiões correspondem aos escores do grupo 2. Os escores do grupo 5 representam uma pequena região que dentro da região de interesse e esta é apresentada em destaque nas CP(s) da figura 5.18.




Figura 5.18: Escores do grupo 5 nas duas primeiras CP(s). (a) Primeira CP. (b) Segunda CP.

Diferentemente do caso em que foi calculada a imagem média, neste caso, as CP(s) evidenciam diferenças dentro dos próprios termogramas, entretanto, não mostram apenas a região de interesse, discriminando diferentes regiões dos termogramas. As Componentes Principais calculadas desta forma são bastante utilizadas na área de sensoriamento remoto para localização e análise de áreas de desmatamento, uma vez que as CP(s) captam variações espaciais dentro da própria cena. Para localização de defeitos por aquecimento, por exemplo, a ACP a partir da imagem média é a mais empregada.

5.5.2 Análise dos Loadings

De maneira análoga, aqui é analisado os *loadings* e, neste caso, a tabela 5.2 mostra por meio dos *loadings* a importância de cada termograma na composição de cada CP.

Variável/Componente	1 ^a	2 ^a
Termograma 1	0.3357	-0.6050
Termograma2	0.3624	-0.3931
Termograma3	0.4917	0.6464
Termograma4	0.3892	-0.1789
Termograma5	0.4205	0.0709
Termograma6	0.4313	0.1566

Tabela 5.2: Relação entre as Componentes Principais e os termogramas da figura 5.7.

A figura 5.19 mostra o gráfico para esses dados.




Figura 5.19: Gráfico dos *loadings* para as duas primeiras CP(s) da figura 5.7.

De acordo com tabela 5.2 e o gráfico (Fig. 5.19), a primeira CP apresenta todos os coeficientes positivos e está relacionada com todos os termogramas, principalmente com o terceiro e sexto, coeficientes de maior grandeza numérica. A segunda CP apresenta coeficiente negativo para o primeiro, segundo e quarto termograma e, coeficiente positivo para os demais termogramas, sendo dominada pelo terceiro termograma que apresenta uma correlação negativa com o primeiro termograma. Neste caso, os termogramas de maior importância para discriminar as diferentes regiões nas CP(s) no caso da primeira CP são o terceiro e o sexto

termograma. No caso da segunda CP, os termogramas de maior importância são o primeiro e o terceiro termograma.

No caso aqui analisado (perfil médio), as CP(s) captam diferentes regiões dentro dos termogramas, entretanto, sua utilização para localização da área afetada por aquecimento em componentes e máquinas não apresenta eficiência como o caso em que foi utilizada a imagem média³.

CAPÍTULO 6

6 Testes Experimentais

A capacidade e potencialidade de aplicação da Análise de Componentes Principais Térmicas (ACPT) para manutenção preditiva com base na termografia foi discutida no capítulo anterior utilizando dados simulados. Este capítulo discute a aplicação da ACPT com a utilização de dados experimentais. Neste caso, o aquecimento de componentes de um sistema formado por um conjunto de blocos de alumínio fixados em uma placa de acrílico e envolto por uma caixa é avaliado. O sistema é uma representação bastante simplificada de um painel de telefonia em que os blocos representam os componentes elétrico-eletrônicos montados no painel e sujeitos ao aquecimento. Na análise, um conjunto de imagens obtidas com uma câmera térmica (Termovisor) para diferentes condições de aquecimento dos blocos é estudado buscando identificar variações e tendências do comportamento do sistema.

6.1 Descrição e Montagem do Set-Up Experimental

O sistema analisado é um modelo simplificado de um painel de telefonia formado por um conjunto de nove blocos de alumínio (componentes), todos de mesmo tamanho ($25,4\text{ mm} \times 25,4\text{ mm} \times 4,9\text{ mm}$), fixados dentro de uma caixa de acrílico de dimensões $423\text{ mm} \times 193,8\text{ mm} \times 100\text{ mm}$. Estes blocos representam os componentes elétrico-eletrônicos que estão sujeitos ao aquecimento quando em operação. Neste caso, o aquecimento dos blocos é feito por uma resistência elétrica no interior do bloco controlado por uma fonte de tensão.

A figura 6.1 ilustra de forma esquemática o modelo e a disposição dos blocos, com destaque para o componente submetido à tensão elétrica para simular a fonte de aquecimento.




Figura 6.1: Modelo esquemático do sistema analisado.

A bancada experimental utilizada para o teste foi montada no Laboratório de Simulação do Departamento de Engenharia Mecânica e consiste basicamente de uma placa (1a) e uma caixa de acrílico (1b); uma fonte alimentadora (2); um termômetro (3) para a referência dos termopares fixados aos componentes; um multímetro (4) e uma câmera termográfica INFRACAM™ da FLIR SYSTEM. A figura 6.2 mostra uma vista dos principais equipamentos utilizados.




Figura 6.2: Bancada experimental com os principais materiais utilizados no teste.

A figura 6.3 mostra, em destaque, o termovisor (Fig. 6.3.a) utilizado na aquisição dos termogramas, o detalhe da placa com os blocos montados (Fig. 6.3.b) e o destaque do bloco simulando a “fonte” de aquecimento (resistência) com os termopares fixados a ele (Fig. 6.3.c).




Figura 6.3: Materiais utilizados na realização do teste.

A bancada de testes foi projetada e construída para estudar o aquecimento e a dissipação de calor pelos componentes (blocos) e é parte de outra dissertação do Programa de Pós Graduação de Engenharia Mecânica (PPGEM). Neste trabalho, a mesma foi utilizada para avaliar a capacidade e potencialidade da ACPT em identificar variações e tendências do comportamento térmico do sistema a partir de um conjunto de imagens térmicas obtidas para diferentes valores de aquecimento dos blocos.

A caixa de acrílico foi montada sobre a placa e os componentes, buscando isolar o sistema do ambiente para que o componente submetido ao aquecimento (tensão) pudesse aquecer os demais componentes vizinhos (convecção, condução e radiação) evitando uma dissipação mais acentuada para o meio externo. A caixa teve ainda, a função de fixar a câmera de modo que os termogramas fossem registrados adequadamente sem nenhum movimento. Tanto a caixa quanto a placa com os nove componentes foram pintados de preto para diminuir a refletividade e aumentar a absortividade das superfícies dos componentes de alumínio e das paredes da caixa.

A seqüência de imagens capturadas e o tempo entre a aquisição de uma imagem e outra foram registrados de modo a permitir avaliar o comportamento do aquecimento do sistema tanto no modo espacial como no modo temporal.

6.2 Aquisição e Análise dos Termogramas

O experimento consistiu no aquecimento do bloco central e registro dos diferentes estágios de aquecimento do sistema através de imagens térmicas (termogramas). Inicialmente

foi feito o registro para o sistema desligado (temperatura ambiente) e posteriormente foram feitos registros com o sistema de aquecimento acionado.

O aquecimento do bloco central foi controlado através da tensão aplicada no resistor e o valor da temperatura do bloco foi medido com um conjunto de termopares instalados no próprio bloco, próximo da resistência, Fig. 6.3.c. As imagens térmicas (termogramas) foram registradas para nove diferentes condições de aquecimento. A seqüência de imagens térmicas medidas para as diferentes condições do sistema é mostrada, em cores na figura 6.4. O tamanho original de cada imagem é de 240 por 240 *pixels*.




Figura 6.4: Termogramas em cores, utilizados na análise.

O primeiro termograma foi registrado com o sistema à temperatura ambiente de $24,5 \pm 0,5$ °C. Uma vez acionado o sistema de aquecimento (resistência) do bloco, foram registrados cinco novos termogramas obtidos com pequenos intervalos de tempo entre um registro e outro e posteriormente mais três termogramas foram obtidos com intervalos de observação bem maiores que os anteriores. Os valores, em graus, das temperaturas registradas em cada termograma, bem como o tempo de aquisição dos termogramas são apresentados na tabela 6.1.

Termogramas	Temperaturas (Graus)	Tempo (minutos)
1	24.5	0
2	25.5	7
3	25.6	7.35
4	26.1	7.7
5	26.6	8.05
6	27.2	9.05
7	36.4	11.05
8	55.9	20.05
9	67.6	35.05

Tabela 6.1: Valores das Temperaturas dos Termogramas.

A figura 6.5 mostra o gráfico do vetor das temperaturas obtido para cada termograma (tempo de registro).




Figura 6.5: Vetor das temperatura para os nove termogramas.

A figura 6.6 mostra uma versão recortada (em escala de cinzas) da seqüência de termogramas da figura 6.4. O corte foi feito para eliminar a escala que poderia interferir na análise (ruído). O tamanho de cada imagem analisada, neste caso, é de 171 por 171 *pixels*.

Vale lembrar que a seqüência da figura 6.6, bem como a seqüência da figura 6.4 são ilustradas neste texto apenas para visualização das versões, em cores e em tons de cinza.

Uma vez que os termogramas da seqüência de termogramas apresentaram ganhos diferentes, provavelmente inseridos pelo termovisor, estes foram normalizadas antes de serem utilizados na análise.




Figura 6.6: Termogramas, em tons de cinza, utilizados na análise.

Para a avaliação das CP(s) o conjunto de dados (termogramas normalizados) foi tratado de maneira análoga à do capítulo anterior, cada imagem foi convertida em um vetor denominado vetor imagem (item 4.4) contendo n componentes ($n = \text{num. linhas} \times \text{num. colunas}$) e esses vetores foram utilizado para montar a matriz de dados $[X]$.

As imagens foram dispostas na mesma seqüência de aquisição, onde cada termograma representaria a condição do equipamento para aquele dado instante. O primeiro termograma representa a condição inicial (tempo $t=t_0$) em que todos os blocos estão na mesma temperatura. Os registros do segundo até o sexto termograma mostram uma variação

(aumento) pequena de temperatura e os três últimos mostram uma variação maior, sendo que o nono termograma apresenta um aumento temperatura em relação à condição inicial bastante considerável.

6.3 Componentes Principais no Modo Espacial

A análise das CP(s) do conjunto de dados no modo espacial mostra, conforme discutido no capítulo anterior, variações espectrais dos *pixels* no domínio espacial. A matriz de dados $[X]$ é arranjada de forma que as linhas da matriz representassem os termogramas e as colunas o perfil térmico. Foram analisadas ambas as condições, CP(s) calculadas utilizando a média dos termogramas e a média dos perfis temporais.

6.3.1 Subtração da Imagem Média

A Análise das Componentes Principais a partir da subtração da imagem média envolve inicialmente a definição e o cálculo da média das imagens. O vetor de média, neste caso, é de ordem 1×29.241 e foi obtido a partir da média aritmética dos valores de cada coluna da matriz de dados. Como no capítulo anterior, o mesmo pode ser redefinido na forma de imagem. Vale lembrar que os termogramas da figura (6.6) foram normalizados para utilização na análise. A figura 6.7 mostra a imagem média obtidas a partir dos dados normalizados.




Figura 6.7: Imagem média utilizada na análise.

Os procedimentos para o cálculo e obtenção das CP(s) são os mesmo os do item 5.2.1. Cada CP é dada por um vetor de mesmo tamanho do vetor imagem (1×29.241) que pode ser reordena na forma de uma matriz. A figura 6.8.a-i mostra as Componentes Principais calculadas a partir do conjunto de dados (imagens) em análise.




Figura 6.8: Componentes Principais espaciais obtidas por subtração da imagem média.

Uma análise das CP(s) mostra que a primeira CP capta a localização exata do componente aquecido e o aquecimento em torno dessa região. Esta componente é a mais significativa em termos de variabilidade espacial conforme pode ser observado na figura 6.9

que mostra a porcentagem da variabilidade explicada por cada componente principal, bem como a porcentagem acumulada pelas CP(s). Neste caso, 97.82% da variabilidade dos dados (maior contraste) é explicada apenas pela primeira componente e as demais componentes acumulam juntas apenas 2.18% da variação dos dados.




Figura 6.9: Porcentagem da variabilidade dos dados, explicada por cada componente principal.

O gráfico mostra que a variabilidade das oito últimas CP(s) é desprezível em relação à primeira CP. Elas acumulam cada uma, menos de um décimo de toda a porcentagem da variação dos dados. As últimas CP(s) geralmente são responsáveis pelo acúmulo de ruídos podendo, portanto, ser descartadas na análise. Neste caso, para uma futura reconstrução do conjunto original de dados apenas a utilização da primeira CP é suficiente.

6.3.2 Subtração do Perfil Temporal Médio

O cálculo das CP(s), neste caso, é feito utilizando a média dos termogramas, calculada com relação ao perfil temporal. A figura 6.10 ilustra o perfil médio do conjunto de dados analisado, conforme pode ser observado, o vetor médio agora é um vetor de ordem 9×1 .




Figura 6.10: Perfil Temporal Médio.

Já as Componentes Principais são vetores de mesmo tamanho (1×29.241) que também podem ser observados na forma de imagem.

A figura 6.11.a-i mostra as Componentes Principais calculadas utilizando o perfil médio temporal do conjunto de dados.




Figura 6.11: Componentes Principais espaciais obtidas por subtração do perfil temporal médio.

A primeira CP (Fig. 6.11.a) mostra a localização do bloco aquecido, bem como a região em torno do bloco. Esta CP é a mais significativa e de maior contraste, acumulando aproximadamente 97% da variância de todos os dados, Fig. 6.12.




Figura 6.12: Porcentagem da variabilidade dos dados, explicada por cada componente principal.

Nos dois casos analisados, tanto para a imagem média quanto para o perfil médio, a primeira CP é a mais representativa em termos da variabilidade dos dados. Em ambos os casos a primeira componente mostra a localização do componente aquecido bem como o aquecimento da região em torno do componente. Essa localização é uma informação importante que, inclusive, poderia ser utilizada para o treinamento de sistemas automáticos para reconhecimentos de padrões. As demais CP(s) podem ser descartadas, pois são responsáveis por uma pequena parcela da variabilidade dos dados que provavelmente representam ruídos adicionados na aquisição dos termogramas.

No processo de reconstrução do conjunto original de dados, a utilização apenas da primeira CP é suficiente para uma boa reconstrução dos dados

6.4 Componentes Principais no Modo Temporal

No modo temporal a ACPT busca captar o comportamento térmico do sistema ao longo do tempo (termogramas) e a análise das CP(s) mostra a evolução temporal do perfil térmico do sistema. Neste caso, verificada a existência da relação das CP(s) com o perfil térmico do sistema ou mesmo com um termograma específico, então é possível estabelecer uma relação entre o fenômeno físico observado a cada intervalo de tempo (termograma) e as Componentes Principais.

A matriz de dados utilizada foi arranjada de forma que as colunas representassem os termogramas e as linhas os perfis temporais. As CP(s), devido à dimensão da matriz de covariâncias, foram calculadas tanto no caso da imagem média quanto no caso do perfil médio a partir dos autovetores obtidos pela transformação discutida no capítulo 3, equação 3.22.

6.4.1 Subtração da Imagem Média

O vetor médio utilizado para o cálculo das CP(s) é o mesmo do item 6.3.1. Entretanto, devido ao arranjo da matriz de dados $[X]$ o tamanho do vetor das CP(s) é diferente, cada CP é dada agora por um vetor de tamanho 9×1 . A figura 6.13 mostra a evolução das CP(s) em relação aos termogramas (tempo).




Figura 6.13: Componentes Principais Temporais obtidas por subtração da imagem média.

O gráfico mostra a evolução de cada CP em relação a cada imagem. Neste caso, a primeira componente está fortemente relacionada com o perfil térmico do sistema e capta essa variação ao longo dos vários termogramas. Note que, do primeiro ao sexto termograma a primeira CP tem uma evolução lenta, aumentando consideravelmente a partir do sexto termograma até o nono mostrando um padrão semelhante ao do vetor das temperaturas medidas (Fig. 6.4).

As demais CP(s), não mostram nenhuma relação consistente com o perfil térmico do sistema.

6.4.2 Subtração do Perfil Temporal Médio

Nesta análise o vetor médio utilizado no cálculo das CP(s) é o mesmo do item 6.3.2 e as CP(s) também são vetores de tamanho tamanho 9×1 . A figura 6.14 mostra a evolução das CP(s) em relação ao perfil temporal médio.




Figura 6.14: Componentes Principais Temporais obtidas por subtração do perfil temporal médio.

A primeira componente mostra claramente a evolução térmica do sistema. Já as demais CP(s) apresenta variância próxima de zero. Em particular, a segunda e a terceira CP capta uma pequena variação relativa ao sétimo e oitavo termograma que comparada com a primeira CP, é desprezível.

No caso temporal, para ambas as médias, a primeira CP está fortemente relacionada com o perfil térmico do sistema e as demais não apresentam nenhuma relação mais evidente. Ela apresenta ainda um padrão semelhante ao do vetor das máximas temperaturas, captando a tendência térmica do modelo aqui analisado.

6.5 Gráfico dos Escores e Loadings Utilizando a Imagem Média

Os gráficos dos escores e *loadings* mostram a projeção dos dados nos eixos formados pelas Componentes Principais. Neste caso, o gráfico dos escores permite uma análise da estrutura dos dados a partir do agrupamento das amostras (*pixels*) enquanto que o gráfico dos *loadings* permite uma análise dos dados a partir das variáveis (termogramas)

6.5.1 Análise dos escores

O gráfico dos escores mostra a estrutura espacial dos dados a partir das CP(s), permitindo discriminar as diferentes regiões dentro do termograma ou mesmo identificar as amostras que compõe uma determinada região. A figura 6.15 mostra o gráfico dos escores envolvendo a primeira e a segunda CP, obtidas na seção 6.3.1 (figuras 6.8.a e 6.8.b).




Figura 6.15: (a) Gráfico dos escores das duas primeiras Componentes Principais. (b) Diferentes agrupamentos dos escores.

O gráfico mostra regiões de agrupamento dos pontos e a figura 6.15.b destaca três grupos diferentes de amostras (grupos 1, 2 e 3). A analisando a primeira CP (eixo horizontal) que é mais importante (maior variância), observa-se que todos os escores apresentam valores positivos. Os do grupo 3 são mais significativos que os do grupo 2, uma vez que apresentam

valores altamente positivos e maior dispersão. Já os escores do grupo 1 não apresentam dispersão e seus valores são relativamente baixos.

Cada um dos agrupamentos de pontos em destaque na figura 6.15.b estão associados com uma dada região (disposição espacial) da imagem. O conjunto de pontos de cada um desses grupos ou combinação de grupos é destacado na figura 6.16 (em cor clara) que mostra a imagem da primeira CP.




Figura 6.16: Regiões correspondentes aos diferentes agrupamentos dos escores na primeira CP

A figura 6.16.a mostra os escores do grupo 1, como pode ser observado o *plot* dos valores desse conjunto de pontos na forma de imagem corresponde exatamente à imagem da primeira CP (Fig. 6.8.a), exceto a região escura, ou seja, esse conjunto corresponde ao fundo da cena que praticamente não é alterado (pouca dispersão) entre as imagens analisadas. A figura 6.16.b mostra o conjunto de pontos do grupo 3, os quais apresentam valores altamente positivos (valores altos de brilho). Essa região corresponde à região do bloco (componente)

aquecido. Já os escores do grupo 2, que apresentaram menor dispersão em relação ao grupo 3, correspondem à região próxima ao bloco (Fig. 6.16.c). Esta região é mostrada por um “anel” preto em torno do bloco na figura 6.16.d.

6.5.2 Análise dos loadings

O gráfico dos *loadings* mostra a estrutura dos dados com relação aos termogramas. Neste caso, os *loadings* representam quanto cada variável original contribui para a construção das CP(s) por meio da combinação linear e permitem estabelecer relação entre os termogramas e as CP(s) por meio dos coeficientes (autovetores) de ponderação.

A tabela 6.2 mostra os coeficientes das Componentes Principais obtidas na seção 6.3.1 (imagem média).

Variável	1ª Componente	2ª Componente
Termograma 1	-0.2244	-0.1932
Termograma2	-0.2114	-0.1521
Termograma3	-0.2111	-0.1555
Termograma4	-0.1990	-0.1145
Termograma5	-0.1878	-0.0778
Termograma6	-0.1719	-0.0306
Termograma7	0.0102	0.8915
Termograma8	0.4539	0.1238
Termograma9	0.7415	-0.2917

Tabela 6.2: Relação entre as Componentes Principais e os termogramas da figura 6.8.

Uma avaliação dos valores da tabela mostra que a primeira CP apresenta coeficientes positivos para os três últimos termogramas que apresentam uma correlação negativa com os seis primeiros (variáveis inversamente correlacionadas). O coeficiente de maior importância para essa CP é o relativo ao nono termograma que apresenta o maior registro de temperatura.

A segunda CP apresenta coeficientes positivos para o sétimo e o oitavo termograma que apresenta correlação negativa com os demais (coeficientes de sinais diferentes). O coeficiente mais expressivo para a segunda CP é o correspondente ao sétimo termograma.

A figura 6.17 mostra o gráfico dos *loadings* evidenciando os termogramas de maior importância na composição das CP(s).




Figura 6.17: Gráfico dos *loadings* para as duas primeiras CP(s) da figura 6.8.

O gráfico mostra que o nono termograma é o mais importante no processo de composição da primeira CP enquanto que a segunda CP está fortemente relacionada com o sétimo termograma. Assim, a primeira componente pode ser interpretada como um índice de temperatura do nono termograma enquanto que a segunda componente representa um índice de temperatura do sétimo termograma.

6.6 Gráfico dos Escores e Loadings Utilizando o Perfil Médio

A análise dos escores utilizando o perfil médio é feita de maneira análoga ao caso anterior, com diferença que neste caso foi utilizado o perfil médio para o cálculo das CP(s).

6.6.1 Análise dos escores

O gráfico dos escores, neste caso, permite identificar as amostras que compõe uma dada região nos termogramas, mais especificamente permite discriminar as diferentes regiões dentro dos próprios termogramas como foi discutido no capítulo anterior. A figura 6.18 ilustra o gráfico dos escores das duas primeiras CP(s), utilizando o perfil médio.




Figura 6.18: (a) Gráfico dos escores das duas primeiras Componentes Principais. (b) Diferentes agrupamentos dos escores.

A 5.18.b mostra que a primeira componente principal apresenta um grupo pequeno de amostras de valores altamente positivos (grupo 3) e um grupo maior de amostras representadas pelo grupo 2. O grupo 1 apresenta um grande grupo de amostras centradas em zero (pouca dispersão). Os escores relativos aos agrupamentos em destaque (Fig. 5.18.b) para a primeira CP são destacados na figura 6.19.




Figura 6.19: Regiões correspondentes aos diferentes agrupamentos dos escores na primeira CP.

Similar ao caso anterior, a figura 6.19 destaca as amostras dos grupos em destaque na figura 6.18.b na forma de imagem. A figura 6.19.a destaca o *plot* do grupo 2 que corresponde à região em torno do componente aquecido, ou seja, representa a variação gerada pela condução e radiação do calor, enquanto a figura 6.19.b mostra o grupo 3 (altamente positivos) que corresponde exatamente ao componente aquecido. Os escores do grupo 1 (pouca dispersão) correspondem ao fundo da cena e, neste caso, é representada pela região escura externa a mancha clara (grupo 2) na figura 6.19.a.

6.6.2 Análise dos Loadings

Analogamente à seção 6.5.3, neste caso, é feita a análise dos *loadings* a partir dos coeficientes de ponderação. A tabela 6.3 mostra os coeficientes das Componentes Principais obtidas na seção 6.3.2 (perfil médio).

ariável/Componente	1 ^a	2 ^a
Termograma 1	0.0006	0.0015
Termograma2	0.0053	0.0147
Termograma3	0.0065	0.0153
Termograma4	0.0101	0.0256
Termograma5	0.0149	0.0424
Termograma6	0.0196	0.0483
Termograma7	0.1410	0.7505
Termograma8	0.5839	0.4587
Termograma9	0.7990	-0.4702

Tabela 6.3: Relação entre as Componentes Principais e os termogramas da figura 6.11.

De acordo com a tabela, a primeira CP apresenta todos os coeficientes positivos. Esta CP tem como principais coeficientes aqueles correspondentes ao oitavo e ao nono termograma, sendo dominada pelo nono. A segunda componente apresenta como principais coeficientes aqueles correspondentes ao sétimo e ao nono termograma, sendo dominada pelo sétimo que apresenta correlação negativa com o nono termograma (sinais trocados). A figura 6.20 mostra os gráficos dos *loadings* para esse caso.




Figura 6.20: Gráfico dos *loadings* para as duas primeiras CP(s) da figura 6.11.

De acordo com a figura e a tabela 6.3 os termogramas mais importantes na composição da primeira CP são os três últimos termogramas. Sendo o nono termograma o mais significativo. No caso da segunda CP, os três últimos termogramas também são os de maior peso. Sendo o sétimo termograma a variável de maior importância na composição dessa componente.

6.7 Discussão

Uma análise da sequência de termogramas (Fig. 6.4.a-i) mostra que a variação nos valores dos *pixels*, de um termograma para outro, ocorreu tanto na região do bloco aquecido, quanto em regiões mais distantes do mesmo. Esta variação é captada pela primeira CP calculada a partir da imagem média. Já a primeira CP calculada a partir do perfil médio mostra variação na região do componente e em suas proximidades, em contraste com o fundo do termograma. Ou seja, a CP calculada desta maneira capta as diferenças dentro dos termogramas independentemente se houve variação ou não de um termograma para outro.

De acordo com o discutido no capítulo anterior, a ACPT utilizando o perfil temporal médio é bastante útil para aplicações em que se deseja localizar ou mesmo discriminar diferentes regiões dentro dos termogramas, entretanto, para aplicações voltadas para localização de uma área específica que apresenta variação ao longo do tempo, a ACP neste modo não apresenta vantagens. O emprego da ACPT a partir da imagem média mostrou maior potencialidade de aplicação para esse fim.

CAPÍTULO 7

7 Conclusão

O presente trabalho apresentou um estudo e avaliação da proposta de utilização da técnica da estatística multivariada, Análise de Componentes Principais (ACP), para identificação do estado ou condições de falha de componentes elétrico-eletrônicos a partir do processamento e análise de um conjunto de imagens termográficas.

A proposta foi inicialmente avaliada com dados simulados e posteriormente com dados experimentais e os resultados mostraram que as CP(s) captam a tendência térmica (evolução térmica) do sistema ao longo do tempo bem como localiza a região afetada, isso mostra a possibilidade da sua aplicação com sucesso para detecção e localização de defeitos por aquecimento. Análise das Componentes Principais Térmicas (ACPT) calculadas a partir da imagem média captaram a área afetada (aquecimento) bem como apresentaram relação com o perfil térmico do sistema. Além disso, os gráficos dos escores permitiram a localização da área sobre aquecida enquanto que os *loadings* mostraram quais os termogramas de maior importância na composição de cada CP. As CP(s) calculadas a partir do perfil médio mostram a variação na região do componente aquecido e em suas proximidades, em contraste com o fundo do termograma, ou seja, as CP(s) calculadas dessa forma captam as diferenças dentro dos termogramas independentemente se houve variação ou não de um termograma para outro.

Como discutido anteriormente, a ACPT utilizando o perfil temporal médio é útil para aplicações em que se deseja localizar ou mesmo discriminar diferentes regiões dentro dos termogramas (sensoriamento remoto), entretanto, para aplicações voltadas para localização de uma área específica que apresenta variação ao longo do tempo (manutenção preditiva), a ACPT utilizando a imagem média apresenta maior potencialidade de aplicação.

Os resultados mostram que a proposta do trabalho foi alcançada, uma vez que a região afetada no sistema foi detectada pelas CP(s) espacial e a evolução térmica (tendência) do sistema ao longo do tempo pode ser acompanhada a partir das CP(s) temporais correspondentes. Isso evidencia uma real potencialidade para sua aplicação na manutenção preditiva com base na termográfica.

Para trabalhos futuros fica a sugestão da utilização da técnica para sistemas reais, bem como, buscar estabelecer correlações entre as componentes principais e a evolução do perfil térmico das imagens que permitam uma avaliação quantitativa da variável física analisada. Isso poderia aumentar seu campo de aplicação e viabilizar a sua utilização em sistemas autônomos para localização e detecção automática de regiões afetadas por aquecimentos.

REFERÊNCIAS

ALBUQUERQUE, M. P.; ALBUQUERQUE, M. P. **Processamento de imagens: métodos e análises**. Centro Brasileiro de Pesquisas Físicas – CBPF/MCT– Rio de Janeiro, 2009. Disponível em: <http://www.cbpf.br/cat/pdsi/top_pesquisa.htm>. Acesso em: 11 mai. 2009.

ARAÚJO, R. A. et al. Os impactos da aplicação da termografia na operação do sistema elétrico de Furnas e as ações adotadas para buscar a máxima operacionalidade, produtividade e confiabilidade do sistema. In: ENCONTRO PARA DEBATES DE ASSUNTOS DE OPERAÇÃO, 11., 2008, São Paulo. **Anais...** São Paulo: Furnas Centrais Elétricas 2008. p. 1-10.

BÔAS, N. V. **Métodos de aprendizagem: terminologia**. São Paulo: [s.n.], 1987.

CAMARA, G. et al. **SPRING: integrating remote sensing and GIS by object-oriented data modelling**. São José dos Campos: INPE, 1996. Disponível em: <<http://www.dpi.inpe.br/geopro/trabalhos/spring.pdf>>. Acesso em: 08 abr. 2010.

CAMPOS, T. E. **Técnicas de seleção de características com aplicações em reconhecimento de faces**. 2001. Dissertação (Mestrado em Ciência da Computação) - Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2001.

COUTINHO, A. C. **Segmentação e classificação imagens Landsat-TM para mapeamento dos usos da terra na região de Campinas**. 1997. 159 f. Dissertação (Mestrado em Ciências) - Departamento de Ecologia Geral do Instituto de Biociências, Universidade de São Paulo, São Paulo, 1997.

DINIS, B. **Termografia aplicada à física das construções**. 2009. Trabalho de Conclusão de Curso (Graduação) - Universidade Fernando Pessoa, Porto, 2009.

FIGUEIREDO, M. B. **Utilização de componentes principais não lineares para análise de conjuntos de dados de alta dimensão**. 2006. 86 f. Dissertação (Mestrado em Ciências) - Universidade Tecnológica Federal do Paraná, Curitiba, 2006.

FREITAS, S. K. B. **Uma metodologia para screening analysis de sucos cítricos utilizando um analisador automático em fluxo-batelada, espectrometria UV-VIS e técnicas quimiométricas**. 2006. Dissertação (Mestrado em Química) - Universidade Federal da Paraíba, João Pessoa, 2006.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. 3.ed. São Paulo: Edgard Blücher, 2000. 509 p.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 3. ed. New York: Prentice Hall, 2007. 609 p.

GUEDES, T. A.; IVANQUI, I. L. **Análise procrustes aplicada à seleção de variáveis**. Disponível em: <<http://periodicos.uem.br>>. Acesso em: 23 jun. 2010.

GURGEL, H. C. **Variabilidade espacial e temporal do NDVI sobre o Brasil e suas conexões com o clima**. 2000. 114 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2000.

KAPLAN, H. **Practical applications of infrared thermal sensing and imaging equipment**. 2. ed. Washington: The International Society for Optical Engineering, 1999. 163 p.

KITANI, E. C.; THOMAZ, C. E. **Um tutorial sobre análise das componentes principais para o reconhecimento de automático de faces**. São Paulo: FEI, 2006. (Relatório técnico, Departamento de Engenharia Elétrica).

KRISHNAPILLAI, M. et al. Thermography as a tool for damage assessment. **Composite Structures**, Oxford, v. 67, p. 149-155, 2005.

LIENEWEG, F. **Handbuch der technischen temperaturmessung**. Braunschweig: Vieweg & Sohn, 1976. 482 p.

MALDAGUE, X.; MARINETTI, S. Pulse phase infrared thermography. **Journal of Applied Physics**, New York, v. 79, p. 2694-2698, 1996.

MARINETTI, S. et al. Statistical analysis of IR thermographic sequences by PCA. **Infrared Physics and Technology**, Exeter, v. 46, p. 85-91, 2004.

MARINETTI, S.; FINESSO, L.; E. MARSILIO. Matrix factorization methods: application to thermal NDT/E. **NDT & E International**, London, v. 39, p. 611-616, 2006.

MARQUES, J. M.; MARQUES, M. A. M. As componentes principais no descarte de variáveis em um modelo de regressão múltipla. **Revista FAE**, Curitiba, v.8, n.1, p.93-101, 2005.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada.** Belo Horizonte: Ed. UFMG, 2005. 300 p.

NEVES, S. R. **Algoritmos para segmentação de imagens infravermelhas.** 2003. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2003.

RAJIC, N. Principal component thermography for flaw contrast enhancement and flaw depth characterization in composite structures. **Composite Structures**, Oxford, v. 58, p. 521-528, 2002.

ROCHA, H. S. C. Metodologia de **registro de imagens termográficas para equipamentos elétricos.** 2006. Dissertação (Mestrado em Engenharia Elétrica) –Universidade Católica de Minas Gerais, Belo Horizonte, 2006.

SANTOS, L. **Termografia infravermelha em subestações de alta tensão desabrigadas.** 2006. Dissertação (Mestrado em Engenharia da Energia) – Universidade Federal de Itajubá, Itajubá, 2006.

SEDYYAMA, G. C. Métodos **quantitativos em climatologia: análise das componentes principais.** Viçosa: Universidade Federal de Viçosa, Viçosa, 1998. (Notas de aula).

SCREMIN, M. A. A. **Método para a seleção do número de componentes principais com base na lógica difusa.** 2003. Tese (Doutorado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2003.

SILVA, R. R. **Reconhecimento de imagens digitais utilizando redes neurais artificiais.** 2005. 51 f. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) - Universidade Federal de Lavras, Lavras, 2005.

SUSA, M.; CASTANEDO, C. I.; MALDAGUE, X.; BENDADA, A. Pulse thermography applied on a complex structure sample: comparison and analysis of numerical and experimental results. In: CONFERENCIA PAN-AMERICANA DE END, 4., 2007, Buenos Aires. **Anais...** Buenos Aires: [s.n.], 2007.

TAVARES, S. G.; ANDRADE, R. M. **Metodologia de ensaio e análise de incertezas na aplicação da termografia:** metrologia para a vida. Recife: Sociedade Brasileira de Metrologia, 2003.

VARELLA, C. A. A. **Análise multivariada aplicada às ciências do solo**: análise das componentes principais. Universidade Rural Federal do Rio de Janeiro, Rio de Janeiro, 2008. (Notas de aula). Disponível em: < <http://www.ufrj.br> >. Acesso em: 12 abr. 2009.

ZANINE, A. M. et al. Avaliação do capim-tanzânia (*Panicum maximum*) por meio de métodos de análise multivariada. **Revista Brasileira de Saúde Produção Animal**, Salvador, v. 9, n. 1, p. 179-189, 2008. Disponível em: < <http://www.rbspa.ufba.br> >. Acesso em: 11 abr. 2010.