

**UNIVERSIDADE FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM MÉTODOS NUMÉRICOS EM
ENGENHARIA, ÁREA DE CONCENTRAÇÃO EM MECÂNICA COMPUTACIONAL
SETORES DE TECNOLOGIA E DE CIÊNCIAS EXATAS**

ROBERTO PETTRES

**RECONHECIMENTO DE PADRÕES DE DEFEITOS EM CONCRETO A PARTIR
DE IMAGENS TÉRMICAS ESTACIONÁRIAS E REDES NEURAIS ARTIFICIAIS.**

CURITIBA – PR

2011

ROBERTO PETTRES

**RECONHECIMENTO DE PADRÕES DE DEFEITOS EM CONCRETO A PARTIR
DE IMAGENS TÉRMICAS ESTACIONÁRIAS E REDES NEURAIAS ARTIFICIAIS.**

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre em Ciências, Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Área de Concentração em Mecânica Computacional, Setores de Tecnologia e de Ciências Exatas da Universidade Federal do Paraná.

Orientador: Prof. D.Sc. Luiz Alkimin de Lacerda

CURITIBA – PR

2011

ROBERTO PETTRES

“Reconhecimento de padrões de defeitos em concreto a partir de imagens térmicas estacionárias e redes neurais artificiais”

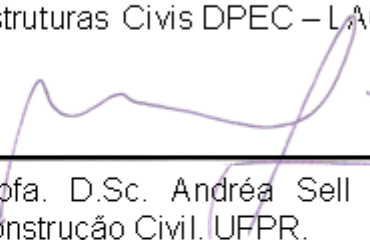
Dissertação aprovada como requisito parcial do grau de Mestre no Curso de Pós-Graduação em Métodos Numéricos em Engenharia – Área de Concentração em Mecânica Computacional, Setores de Tecnologia e de Ciências Exatas da Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientador:



Prof. D.Sc. Luiz Alkimir de Lacerda. Departamento de Estruturas Cíveis DPEC – LACTEC/UFPR.

Coorientadora:



Profa. D.Sc. Andréa Sell Dyminski. Departamento de Construção Civil. UFPR.



Prof. D.Sc. Sérgio Scheer. Departamento de Construção Civil. UFPR.



Prof. D.Eng. Rogério Carrazedo. Departamento de Estruturas. UTFPR.

Curitiba, 25 de fevereiro de 2011.

DEDICATÓRIA

Dedico este trabalho aos meus pais José e Fátima, à minha noiva Andréia e aos meus irmãos Ronaldo, Reginaldo e Jaqueline que sempre acreditaram em mim, sempre estiveram ao meu lado e sempre me apoiaram em minhas escolhas e no caminho que decidi seguir.

AGRADECIMENTOS

O autor agradece à Universidade Federal do Paraná - UFPR e ao Instituto de Tecnologia para o Desenvolvimento – LACTEC pela estrutura e apoio concedidos para a realização da pesquisa e à ELEJOR – Centrais Elétricas do Rio Jordão S.A. pelo apoio financeiro através da lei 10.973/2004 de incentivos à inovação e à pesquisa científica e tecnológica.

Agradecimento especial ao Professor Luiz Alkimin de Lacerda pela amizade e orientação, à Professora Andréa Sell Dyminski pela coorientação, aos Professores Orestes Hacke, Gerson Ulbricht, Richardson Ribeiro, Paulo Henrique Siqueira, Mara Valério, Edison Luis Groscopp, Marcos Reway, José Carlos Bus e José Alceu Valério pelo incentivo, aos meus amigos Jefferson, Amanda, Saimon, Fábio, Reginaldo, Eliel, Rafael, Sidney, Francielle, Alex, Liliane, Enéias, Teodoro, Maristela, Cassiano, Carlinhos, Moacir, Vanessa, Marlon, João e a todos que de uma forma ou outra contribuíram para realização deste trabalho.

*“O começo é a parte mais importante do trabalho.”
(Platão)*

LISTA DE FIGURAS

Figura 1 – Visão de parte da face de uma barragem do tipo CCR com percolação de água.	18
Figura 2 - Condução do calor em um sólido.....	35
Figura 3 - Fluxo de calor na direção x em um elemento infinitesimal.	36
Figura 4 - Geometria do problema e dimensões normalizadas associadas à geometria	40
Figura 5 – Condições de contorno.	41
Figura 6 - Amostra do conjunto de imagens, F= Largura; H = Altura; P = Espessura; D = Profundidade.	42
Figura 7 - Distribuição de temperatura adimensional (D=0.05, H=F=P=0.20 m).	43
Figura 8 – Perfil de temperatura na superfície em $y=0,5$ (D=0.05, H=F=P=0.20 m).....	43
Figura 9 - Imagem infravermelho da emissão de calor simulada em Ansys (ausência de anomalia).....	44
Figura 10 – Matrizes do padrão RGB.....	47
Figura 11 – Análise térmica utilizando o software SAT IR apresentando os valores de temperaturas de determinados pixels.	47
Figura 12 – Histograma caso 002.	49
Figura 13 – Histograma caso 030.	49
Figura 14 – Histograma caso 045.	49
Figura 15 – Histograma caso 200.	50
Figura 16 – Histograma caso 255.	50
Figura 17 – Histograma caso 256.	50
Figura 18 – Ilustração da inferência estatística realizada nas imagens.	51
Figura 19 – Resultado para localização do centro de gravidade das temperaturas mínimas.	52
Figura 20 - Plano cartesiano com origem no centro da anomalia térmica.	53
Figura 21 – Localização das características térmicas.	55
Figura 22 – Malha 09 para localização das características térmicas.....	55
Figura 23 – Malha 25 para localização das características térmicas.....	56

Figura 24 - Modelo de neurônio artificial.	59
Figura 25 - Modelo de redes neurais artificiais. (1) Hopfield e (2) Perceptron.	60
Figura 26 - Estrutura típica de rede neural <i>feedforward</i> que pode ser aplicada a retropropagação (<i>backpropagation</i>).	61
Figura 27 – Ilustração para otimização e definição das topologias.	63
Figura 28 – Distribuição dos erros APE, RNA 1.	68
Figura 29 – Distribuição dos erros APE, RNA 2.	68
Figura 30 – Distribuição dos erros APE, RNA 3.	68
Figura 31 – Distribuição dos erros APE, RNA 4.	68
Figura 32 – Desempenho das topologias testadas.	70
Figura 33 – Interface do aplicativo Thermography and Artificial Neural Network.	73
Figura 34 – Topologia da ANN 1.	74
Figura 35 – Topologia da ANN 2.	74
Figura 36 – Operação do aplicativo Thermography and Artificial Neural Network.	75
Figura 37 – Operação do aplicativo Thermography and Artificial Neural Network.	76
Figura 38 – Modelo de um caso irregular para os parâmetros F , H , P e D	77
Figura 39 – Caso com maior região de análise.	77
Figura 40 – Caso com a geometria irregular 1.	77
Figura 41 – Caso com a geometria irregular 2.	77
Figura 42 – Resultados das simulações para o parâmetro F	80
Figura 43 – Resultados das simulações para o parâmetro H	80
Figura 44 – Resultados das simulações para o parâmetro D	80
Figura 45 – Processamento e análise de temperaturas para localização do defeito no interior do bloco.	81
Figura 46 – Comparação do perfil térmico do modelo 50x50 cm (treinamento) e 100x100 cm (teste).	82
Figura 47 – Defeitos com geometrias irregulares utilizados no teste (1) e teste (2).	83
Figura 48 – Localização da região de menor temperatura indicando a posição do defeito para os testes 1 e 2.	83
Figura 49 – Distribuição de temperaturas em x na direção do defeito para os testes 1 e 2.	84

Figura 50 – Posicionamento do defeito no interior do bloco.....	85
Figura 51 – Concretagem do bloco com defeito para ensaios em laboratório.....	87
Figura 52 – Bloco de concreto com defeito para ensaios em laboratório.....	88
Figura 53 – Manta térmica siliconada.....	88
Figura 54 – Convecção com o ar.....	89
Figura 55 – Controle de fluxo térmico nulo. (1) Bloco de concreto, (2) Revestimento do bloco com lã de rocha e manta de alumínio, (3) Terceira camada de revestimento com isopor e (4) Quarta camada de revestimento utilizando a manta de alumínio.....	89
Figura 56 – Ensaio de termografia.....	90
Figura 57 – Equipamento de termografia InfraREM®.....	90
Figura 58 – Captação das imagens termográficas.....	91
Figura 59 – Termografia de uma face do bloco de concreto.....	91
Figura 60 – Indício da localização do defeito.....	92

LISTA DE TABELAS

Tabela 1 – Tempo de processamento para obtenção das características.....	56
Tabela 2 – Análise dos erros das simulações e números de neurônios na camada escondida	66
Tabela 3 – Definição das topologias	66
Tabela 4 – Análise dos erros dos testes para cada parâmetro e tempo médio de processamento.	69
Tabela 5 – Resultados da ANN 1 para os testes com parâmetros diferenciados.	78
Tabela 6 – Resultados da ANN 2 para os testes com parâmetros diferenciados.	79
Tabela 7 – Resultados dos testes para localização irregular.....	82
Tabela 8 – Dosagem do concreto do bloco de ensaio.....	86
Tabela 9 – Resultados dos testes experimentais.	92

RESUMO

Este trabalho apresenta um método não destrutivo para o diagnóstico da integridade subsuperficial de estruturas de concreto utilizando imagens térmicas estacionárias e redes neurais artificiais (RNA). As imagens térmicas utilizadas no estudo foram geradas pelo software Ansys 12®, onde foi simulado um bloco com as propriedades equivalentes ao concreto contendo um elemento de alta porosidade representando um defeito em seu interior. Nestas simulações, as dimensões do defeito foram parametrizadas e o modelo de transferência de calor adotado foi a Equação de Condução do calor de Fourier em regime estacionário sob condições de contorno que estabeleciam um fluxo de calor em uma única direção. A partir dos resultados obtidos nestas simulações, campos térmicos em uma das faces do bloco, e da aplicação de técnicas de processamento de imagens com o software Matlab R2010®, foi possível o desenvolvimento dos algoritmos de localização do defeito e de coleta de dados para o treinamento das topologias neurais. Um algoritmo foi elaborado para a otimização de quatro topologias do tipo feedforward para realização dos testes numéricos. Duas delas apresentaram melhor desempenho e foram selecionadas para validar o método proposto, sendo sintetizadas no aplicativo Thermography and Artificial Neural Network, desenvolvido com o intuito de realizar o diagnóstico de estruturas de concreto a partir de imagens térmicas. O aplicativo se mostrou preciso e eficiente na análise feita em imagens simuladas em modelos de maior dimensão e contendo defeitos com geometrias irregulares, indicando satisfatoriamente a localização do defeito e apresentando em média um percentual de êxito na identificação das anomalias de 81,73% nas simulações com dados sintéticos. Resultados similares também foram observados em uma análise experimental, indicando potencialidade do método de diagnóstico não destrutivo proposto.

Palavras-Chave: Redes Neurais Artificiais, Processamento de Imagens, Transferência de Calor, Análises Não-Destrutivas, Reconhecimento de Padrões.

ABSTRACT

This paper presents a non-destructive method for diagnosis of subsurface integrity of concrete structures using stationary thermal imaging and artificial neural networks (ANN). The thermal images used in this study were generated by the software ANSYS 12TM, where a block was simulated with the equivalent properties of concrete containing a porous element representing a defect in its interior. In these simulations, the dimensions of the defect were parameterized and the used mathematical model of heat transfer equation was the *Fourier Heat Conduction* under stationary boundary conditions, with a heat flow in only one direction. From the results obtained in these simulations, thermal fields in one side of the block and the application of techniques of image processing with Matlab R2010TM, it was possible the development of algorithms for fault location and data collection for training of neural topologies. An algorithm was developed for the optimization of four different *feedforward* topologies. Two of them had better performed than others and were selected to validate the proposed method, being synthesized in software *Thermography and Artificial Neural Network*, developed with the aim of making the diagnosis of concrete structures from thermal images. The software proved to be accurate and efficient analysis of simulated images in larger models and containing defects with irregular geometries, indicating the location of the defect satisfactorily and having on average a percentage of success in identifying anomalies of 81.73% in the simulations with synthetic data. Similar results were observed in an experimental analysis, indicating the potential of non-destructive diagnostic method proposed.

Keywords: Artificial Neural Networks, Image Processing, Heat Transfer, Nondestructive Testing, Pattern Recognition.

SUMÁRIO

1	INTRODUÇÃO	15
1.1	DEFINIÇÃO DO PROBLEMA	15
1.2	JUSTIFICATIVA	16
1.3	OBJETIVOS DO TRABALHO	18
1.3.1	Objetivo Geral	18
1.3.2	Objetivos Específicos.....	18
1.4	HIPÓTESES, PREMISSAS, CONDIÇÕES TÉRMICAS DE ENSAIO E LIMITAÇÕES COMPUTACIONAIS	19
1.4.1	Hipóteses	19
1.4.2	Premissas	20
1.4.3	Condições térmicas de ensaio.....	20
1.4.4	Limitações computacionais	21
1.5	DELINEAMENTO DO TRABALHO	21
2	ESTADO DA ARTE	23
2.1	ENSAIOS NÃO DESTRUTIVOS	23
2.1.1	Ensaios não destrutivos para o concreto.....	24
2.2	TERMOGRAFIA INFRAVERMELHO - HISTÓRICO	25
2.2.1	Termografia	26
2.2.2	Viabilidade do uso da Termografia	29
2.3	REDES NEURAIS ARTIFICIAIS.....	30
3	FUNDAMENTOS SOBRE TRANSFERÊNCIA DE CALOR.....	33
3.1	PROPAGAÇÃO DO CALOR	33
3.2	TRANSFERÊNCIA DE CALOR EM UM ELEMENTO INFINITESIMAL	36
3.3	TRANSFERÊNCIA DE CALOR EM UM ELEMENTO DE CONCRETO	37

3.4	MODELO DE ANÁLISE PARA GERAÇÃO DA BASE DE DADOS SINTÉTICOS PARA A RNA.....	39
3.5	RESULTADOS DA ANÁLISE DE TRANSFERÊNCIA DE CALOR.....	41
4	PROCESSAMENTO DAS IMAGENS E SELEÇÃO DOS SINAIS FUNCIONAIS	46
4.1	PROCESSAMENTO DAS IMAGENS.....	46
4.2	SELEÇÃO DOS SINAIS FUNCIONAIS.....	51
5	FUNDAMENTOS SOBRE REDES NEURAS ARTIFICIAS	57
5.1	REDES NEURAS ARTIFICIAS.....	57
5.2	DEFINIÇÃO DAS REDES NEURAS ARTIFICIAS PARA O RECONHECIMENTO DE PADRÕES.....	62
5.3	TREINAMENTO DOS MODELOS.....	65
5.4	VALIDANDO E TESTANDO OS MODELOS.....	66
5.5	RESULTADOS E DISCUSSÃO.....	70
5.6	CONCLUSÃO DO CAPITULO 5.....	72
6	APLICATIVO DE TERMOGRAFIA E REDES NEURAS ARTIFICIAS.....	73
6.1	INTERFACE GRÁFICA.....	73
6.2	FUNCIONAMENTO DO APLICATIVO	74
6.3	TESTANDO O APLICATIVO COM MODELOS IRREGULARES.....	76
6.3.1	Testes com parâmetros diferenciados para o defeito.....	77
6.3.2	Teste em área de maior dimensão contendo um defeito não centralizado.....	81
6.3.3	Teste em área de maior dimensão contendo um defeito não centralizado e disforme	83
7	ENSAIO EXPERIMENTAL.....	85
7.1	CONFECÇÃO DO MODELO EXPERIMENTAL	85
7.2	OBTENDO AS IMAGENS TÉRMICAS.....	90
7.3	PROCESSANDO E TESTANDO AS IMAGENS.....	91
8	CONCLUSÃO	93
	PRODUÇÕES.....	97
	REFERÊNCIAS	98

CAPÍTULO 1

1 INTRODUÇÃO

1.1 DEFINIÇÃO DO PROBLEMA

O concreto é um material de composição heterogênea, consistindo, basicamente, de cimento, água e agregados de diferentes tamanhos. Seu comportamento estrutural é fortemente influenciado pela presença de vazios e micro-trincas no seu interior, decorrentes do processo de fabricação ou do carregamento externo. Tais defeitos são indesejados, especialmente em estruturas em permanente contato com a água, podendo interferir na estanqueidade e durabilidade da estrutura (ANDRIOLO, 1989).

Com o intuito de detectar esses defeitos, técnicas de análise não destrutiva, como a termografia digital, têm sido empregadas em estruturas de concreto (SPICER e OSIANDER, 2002; GALIUS e ZUKAUSKAS, 2003). O primeiro experimento documentado utilizando termografia para detectar delaminações subsuperficiais no concreto foi publicado no ano de 1973 pelo Ministério dos Transportes e da Comunicação de Ontário no Canadá. Demonstrou-se que a termografia poderia ser utilizada para detectar falhas causadas pela corrosão do aço de reforço, agrupamento de agregados ou fluidos, infiltração de água e identificar a presença e localização de eventuais anomalias subsuperficiais (MALHOTRA E CARINO, 2004).

Um fator que contribui na análise termográfica em concreto é a variação da temperatura no material devido à reação de hidratação do cimento (FARIA, 2004). Durante tal reação ocorre a liberação do calor em toda a estrutura, causando fluxo de calor no material. O fluxo pode ser alterado quando descontinuidades estão presentes na estrutura, causando diferenças na temperatura superficial. Entretanto, não é trivial diagnosticar tais alterações sem ferramentas computacionais

específicas. Uma alternativa é o emprego de técnicas de inteligência artificial, como por exemplo, redes neurais artificiais e técnicas de processamento de imagens.

Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes, podendo adquirir conhecimento pela experiência (HAYKIN, 2003; BARETO, 2004; GALUSHKIN, 2007). Uma das principais vantagens das RNA é a habilidade em descobrir e reconhecer padrões que parecem despercebidos aos especialistas humanos ou para os métodos estatísticos tradicionais. O reconhecimento de padrões é um processo que atribui um rótulo a um objeto, baseado na informação fornecida pelo seu descritor (BISHOP, 1995; OSÓRIO e BITTENCOURT, 2000; NABNEY, 2004).

Sobre o processamento de imagens, ele é composto por um tratamento bidimensional, no qual ocorre o processo de descrição, também chamado seleção de características, procurando extrair informações quantitativas de interesse ou que sejam básicas para discriminação entre classes de objetos ou fenômenos.

A partir de tais considerações propõem-se neste trabalho utilizar RNA e técnicas de processamento de imagem com o objetivo de detectar anomalias subsuperficiais no interior de uma estrutura de concreto utilizando termografia. O método desenvolvido foi testado em um conjunto de imagens térmicas geradas a partir do método dos elementos finitos em um estudo estacionário de transferência de calor em um bloco de concreto com uma anomalia cujas dimensões e distância à face avaliada são parametrizadas.

1.2 JUSTIFICATIVA

O concreto é um dos materiais mais utilizados na construção civil em edifícios, estradas, pontes e barragens que permitem controlar forças da natureza para a produção de energia. Este material apresenta rigidez e versatilidade, mas tem seus limites. Grande parte das estruturas de concreto se deteriora lentamente e progressivamente devido à exposição a condições naturais como umidade, temperatura ou por irregularidade no processo de produção. Falhas na estrutura

podem representar riscos em termos de segurança, mas este cenário pode ser evitado. Técnicas de ensaios não destrutivos com estruturas de concreto podem contribuir para diagnosticar a estrutura *in loco* buscando estabelecer condições viáveis para indicação e localização de possíveis defeitos. Entre as atuais técnicas, a termografia mostra-se precisa e eficiente na localização de vazios subsuperficiais, delaminações, bem como outras anomalias em estruturas de concreto (MALHOTRA E CARINO, 2004).

Entretanto, processar e interpretar os dados provenientes da termografia podem se apresentar como problemas complexos e demorados na ausência de ferramentas computacionais adequadas. Uma alternativa é o emprego de técnicas de inteligência artificial, como por exemplo, redes neurais artificiais e técnicas de processamento de imagens, que, como outros métodos numéricos, permitem atuar sobre os dados de maneira rápida onde o processo pode ser repetido, buscando solução para o problema.

Em vista disso, a principal motivação do estudo realizado é o desenvolvimento de uma ferramenta computacional que possibilite a avaliação não destrutiva da qualidade do concreto convencional (CCV) subsuperficial da face de montante de barragens compactadas com rolo (CCR) durante sua fase construtiva.

Em estruturas como esta, foi constatado que a percolação de água ocorre em regiões de adensamento ineficiente, e não necessariamente no plano entre camadas ou subcamadas de CCR e CCV (LACTEC, 2007). Na Figura 1 é possível observar a face de montante de uma barragem recém-construída apresentando pontos com percolação de água após a realização do ensaio de perda de água. Este ensaio possibilita a identificação de locais com defeitos que afloram ou estão muito próximos da superfície, porém, descontinuidades internas à estrutura podem não ser identificadas.

Desta forma, o estudo é justificado pelo interesse em detectar descontinuidades no interior da estrutura de concreto até uma profundidade de 50 cm da superfície a partir de ensaios não-destrutivos utilizando imagens térmicas e redes neurais artificiais, com intuito preditivo, a fim de garantir a qualidade e a segurança da estrutura.




Figura 1 – Visão de parte da face de uma barragem do tipo CCR com percolação de água.

Fonte – LACTEC (2007).

1.3 OBJETIVOS DO TRABALHO

1.3.1 Objetivo Geral

Desenvolver uma ferramenta computacional para identificação de anomalias no interior de estruturas de concreto através de diagnóstico termográfico.

1.3.2 Objetivos Específicos

- (i) Estudar o fenômeno de transferência de calor e realizar modelagens computacionais com o software Ansys 12® para a geração de dados sintéticos e validação do modelo de análise implementado.

- (ii) Realizar a modelagem matemática para o método computacional de análise das imagens termográficas a partir de redes neurais artificiais.
- (iii) Simular a presença de anomalias como agrupamento de agregados no interior da estrutura de concreto convencional e determinar sua presença e localização utilizando as técnicas de termografia digital e redes neurais artificiais.

1.4 HIPÓTESES, PREMISSAS, CONDIÇÕES TÉRMICAS DE ENSAIO E LIMITAÇÕES COMPUTACIONAIS

Os ensaios de termografia foram realizados no Laboratório de Materiais e Estruturas (LAME) do LACTEC, localizado em Curitiba – PR. Nestes ensaios são consideradas hipóteses e premissas relativas às propriedades físicas e químicas do material em estudo, condições térmicas de ensaio e também as limitações computacionais citadas a seguir:

1.4.1 Hipóteses

As diferenças físicas e anomalias no interior do corpo apresentam comportamentos diferenciados na transferência de calor.

A técnica de termografia infravermelha digital é capaz de registrar os gradientes térmicos superficiais de um corpo.

Os registros dos gradientes térmicos superficiais, obtidos pela técnica de termografia infravermelha digital serão um indicativo da estrutura, da composição e da presença de alterações, ou mesmo, de anomalias presentes no corpo.

O corpo em estudo está em regime estacionário de transmissão de calor.

Não há ocorrência interna de geração de calor por consequência da reação de hidratação do cimento no corpo em estudo.

Não há variação de massa no corpo em estudo - Sistema Fechado.

O estudo realizado é teórico e a heterogeneidade do concreto pode alterar significativamente os resultados.

1.4.2 Premissas

Todo o corpo com temperatura acima do zero absoluto ($-273,15\text{ }^{\circ}\text{C}$, ou 0K) emite radiação.

Os mecanismos de transferência de calor de um corpo são funções das propriedades físicas e químicas de seus componentes, da sua estrutura constituinte (disposição e organização dos seus elementos), de suas dimensões, do meio ambiente no qual o corpo está inserido e das interações entre o corpo e o meio.

Os gradientes térmicos superficiais de um corpo retratam o estado de desequilíbrio térmico instantâneo deste corpo e, indicam as trocas térmicas no corpo e com o meio no qual esta inserido. Estas trocas térmicas são funções dos mecanismos de transferência de calor dominantes do fenômeno.

1.4.3 Condições térmicas de ensaio

A análise termográfica ativa depende de condições artificiais de temperatura, ou seja, de aquecimento ou resfriamento do material. Esse aquecimento (ou resfriamento) depende das características térmicas e geométricas do corpo de prova e da provável característica térmica do defeito bem como sua geometria, localização e orientação. Existe a possibilidade de interferência no fluxo de calor no sistema adotado devido à emissão térmica de objetos próximos ou da forma como o aquecimento (ou resfriamento) é realizado.

A condição térmica gerada por convecção ou condução torna-se um problema por não apresentar uniformidade no fluxo de calor, implicando no não atendimento total das condições de contorno definidas.

O tempo necessário para a operação também pode acarretar em variações nos termogramas obtidos (BRAY e McBRIDE, 1992).

1.4.4 Limitações computacionais

O desenvolvimento da ferramenta computacional para identificação de anomalias no interior de estruturas de concreto através de diagnóstico termográfico restringe-se à utilização dos métodos numéricos de Elementos Finitos com uso do software Ansys 12® e de Redes Neurais Artificiais, implementado no software Matlab R2010® (MATrix LABoratory – MathWorks, 2010), com os dados representados por variáveis do formato long, que segundo HANSELMAN e LITTLEFIELD (2001) são avaliados com 16 dígitos, processados em um computador com 4 GB de memória RAM, sistema operacional de 32 bits e processador Intel® Core® 2 Quad CPU 2.33 Ghz.

1.5 DELINEAMENTO DO TRABALHO

No capítulo 02 apresenta-se a revisão da literatura sobre ensaios não destrutivos, termografia infravermelho e redes neurais artificiais.

No capítulo 03 são apresentados os fundamentos sobre transferência de calor e desenvolvido um modelo simulando um bloco de concreto para análise térmica em regime estacionário de transferência de calor a partir da equação de Fourier para condução do calor.

No capítulo 04 é realizado o processamento de imagens (termogramas) e a seleção dos sinais funcionais para estruturação das topologias de redes neurais artificiais.

No capítulo 05 são definidas as topologias dos modelos neurais, bem como a metodologia de treinamento, validação e teste das redes.

No capítulo 06 apresenta-se o *aplicativo Thermography and Artificial Neural Network*, desenvolvido a partir dos resultados obtidos no presente estudo. Neste mesmo capítulo é apresentada a funcionalidade do *aplicativo* e novos testes são realizados com os modelos contendo diferentes elementos na estrutura de concreto.

No capítulo 07 é realizado um estudo experimental utilizando o equipamento de termografia InfraREM - SC80 e o *aplicativo Thermography and Artificial Neural Network*.

No capítulo 08 é apresentada a conclusão do trabalho.

CAPÍTULO 2

2 ESTADO DA ARTE

Neste capítulo é apresentada uma breve revisão sobre ensaios não destrutivos, ensaios não destrutivos para o concreto, termografia, métodos numéricos, redes neurais artificiais e aplicações.

2.1 ENSAIOS NÃO DESTRUTIVOS

Ensaio não destrutivo (END) são definidos como ensaios usados para examinar um objeto, material ou sistema sem alterar suas características físicas, químicas, mecânicas ou dimensionais (BRAY e McBRIDE, 1992). Constituem-se numa família de métodos técnicos de inspeção os quais fornecem informações sobre as condições dos materiais e componentes sem destruí-los, sendo vistos como ferramentas de controle de qualidade estando intimamente ligados aos programas de qualidade das indústrias, não interferindo em seu uso posterior.

De maneira prática, os ensaios não-destrutivos estão relacionados com a verificação do desempenho em serviço dos elementos analisados, ou seja, se esses elementos apresentam defeitos, por quanto tempo esses elementos ainda podem ser utilizados ou quando devem ser verificados novamente.

Desde 1920 os ensaios não-destrutivos têm evoluído de uma curiosidade de laboratório para uma ferramenta de produção indispensável. Há muito tempo que a inspeção visual deixou de ser o principal meio de determinação de qualidade (MALHOTRA E CARINO, 2004).

Atualmente, os ensaios não-destrutivos são usados pelos fabricantes para assegurar a integridade de seus produtos e, dessa maneira, sua confiabilidade: para evitar danos, prevenir acidentes e salvar vidas humanas; assegurar a satisfação do cliente e manter a reputação do fabricante; melhorar o projeto de seus produtos;

controlar os processos de fabricação; reduzir os custos de produção e manter um nível de qualidade uniforme.

2.1.1 Ensaios não destrutivos para o concreto

O concreto é um dos materiais mais utilizados na construção civil, aparecendo em edifícios, estradas, pontes e também utilizado para controlar forças da natureza para a produção de energia no caso de barragens de hidrelétricas. Este material apresenta rigidez e versatilidade, mas tem seus limites. Grande parte das estruturas de concreto se deteriora lentamente e progressivamente devido à exposição a condições naturais como umidade, temperatura ou por irregularidade no processo de produção. Falhas na estrutura podem representar riscos em termos de segurança, mas este cenário pode ser evitado. Ensaios com estruturas de concreto são realizados buscando estabelecer condições viáveis para indicação e localização de possíveis defeitos. Os ensaios devem ser precisos, repetitivos e não destrutivos. Devem ser capazes de inspecionar grandes áreas, assim como áreas localizadas e apresentar eficiência tanto em termos de trabalho como em equipamentos.

As tecnologias para os ensaios não-destrutivos são variadas, bem como as aplicações existentes. Entre as técnicas mais pesquisadas para uso no concreto têm-se: inspeção visual, radiografia, análise de vibrações, emissão acústica, ultrassom, potencial elétrico, termografia, entre outras. Em linhas gerais, elas podem ser utilizadas para fornecer informações como tamanho, profundidade, condições físicas, ou para fornecer parâmetros que estão associados aos processos de deterioração ou risco de danos à estrutura.

Muitas das técnicas existentes podem fornecer mais de um tipo de informação, e para a busca de uma informação ou solução específica uma única técnica pode não ser suficiente. SHAW e XU (1997) e SCHICKERT (1997) apresentam listas de tipos de dano ou interesses mais frequentes na análise do concreto e algumas das técnicas não-destrutivas existentes mais apropriadas em cada situação, bem como suas limitações.

Entre as técnicas citadas anteriormente, a termografia se apresenta como ensaio não-destrutivo com grande potencialidade para análise de estruturas de concreto. Esta técnica evoluiu consideravelmente nos últimos 30 anos e atualmente mostra-se precisa e eficiente na localização de vazios subsuperficiais, delaminações, bem como outras anomalias em estruturas de concreto em pontes, barragens, edifícios entre outras estruturas (MALHOTRA E CARINO, 2004).

2.2 TERMOGRAFIA INFRAVERMELHO - HISTÓRICO

A história da termografia infravermelho teve início há aproximadamente 200 anos. HOLST (2000) cita em seu trabalho *“Common Sense Approach to Thermal Imaging”*, que foi Willians Herschel em 1800 e depois seu filho John Herschel, em 1840, que realizaram as primeiras imagens utilizando o sistema infravermelho por meio da técnica evaporográfica, utilizando a evaporação do álcool a partir de uma superfície pintada com carbono.

De acordo com VERATTI (1992), em 1843, Henry Becquerel verificou que certas substâncias emitiam luminescência quando expostas à radiação infravermelha, além de que poderiam ser produzidas emulsões fotográficas sensíveis à radiação próxima do infravermelho. Já em 1917, Case desenvolveu o primeiro detector baseado na interação direta entre fótons da radiação infravermelha e elétrons do material (sulfeto de tálio). VERATTI (1992) em seu trabalho *“Termografia: Princípios, aplicações e qualidade”*, cita que o primeiro termograma foi desenvolvido por Czerny, no ano de 1929.

Neste mesmo trabalho, Veratti afirma que durante a década de 1940, no período da Segunda Guerra Mundial, o Sistema de Visão Noturna em tanques alemães foi empregado visando a invasão da Rússia. A resposta dos aliados foi a elaboração e o desenvolvimento da FLIR – Forward Looking Infra Red (visão dianteira por infravermelho), utilizada pelo exército americano para localização dos inimigos. O emprego do sistema não se limitou à localização de tropas, abrangendo também o desenvolvimento de armamento (mísseis) com detectores de calor. Em 1946, surgiu o scanner de infravermelho de uso militar, com a característica da

produção de termograma em horas. Seguindo os avanços, em 1954, era possível o próprio sistema gerar uma imagem em duas dimensões em 45 minutos.

As imagens somente realizavam detecção qualitativa da distribuição de temperatura (termo visores). Esses visores térmicos permitiam o monitoramento da temperatura a partir da radiação. Esta técnica possibilitou ampla utilização da medição da temperatura como técnica preditiva.

Nos anos 1960 e 1970, houve um salto significativo com o desenvolvimento de imageadores infravermelhos e o lançamento de sistemas integrados de formação de imagens térmicas instantâneas. A imagem já era gerada em 5 minutos, com a determinação de temperatura (VERATTI, 1992).

Em 1975 foi desenvolvido um sistema que permitia a visão termográfica e a visão ótica de uma pessoa simultaneamente. Este sistema foi denominado ENOX e se baseava em sistema elétrico óptico. Entre 1980 e 1990 a imagem em tempo real é consagrada. A redução no tempo de produção da imagem acompanha o avanço nos equipamentos de captura e tratamento da imagem. Associado à substituição dos sistemas de resfriamento de nitrogênio líquido pelos sistemas de resfriamento termoelétricos, somado ainda o uso da computação – programas e equipamentos – foram lançados termovisores mais compactos e versáteis. Com o aprimoramento da óptica e a utilização de circuito integrado, em meados da década de 1990, ocorre um novo salto tecnológico com o uso do CCD (charge-coupled device ou Dispositivo de Carga Acoplado; sensor para captação de imagens formando por um circuito integrado contendo uma matriz de capacitores acoplados) tornando possível a realização de centenas de imagens por segundo utilizando uma câmera de alta resolução e grande sensibilidade ao infravermelho, atendendo as propriedades físicas da termodinâmica, ou seja, a documentação da transferência de calor pelo processo ou mecanismo da radiação.

2.2.1 Termografia

A termografia se baseia na percepção da temperatura superficial de um corpo pelo mecanismo de transferência de calor por radiação, uma vez que todo corpo

com temperatura acima do zero absoluto emite radiação térmica. Neste sentido, deverá haver um diferencial de temperatura entre o alvo e o meio, pois somente neste caso será possível ocorrer uma diferenciação entre o alvo e o meio (HOLST, 2000).

Instrumentos de detecção infravermelhos são usados para gerar imagens com diferentes distribuições de temperaturas (termogramas) no domínio espacial e temporal. Os termogramas permitem a obtenção de medidas precisas de temperatura, a distinção da distribuição de calor emitido pela região focalizada e a identificação das curvas isotérmicas do corpo em análise. A identificação da quantidade de calor presente nos materiais pode indicar estados normais e anormais no elemento. Dessa forma, por meio de um sistema de aquisição e tratamento apropriado, podem-se obter informações que proporcionem o conhecimento dos parâmetros que regem estes estados.

Devido à facilidade de utilização destes instrumentos na detecção de diferenças de temperaturas, tem-se como suas principais características como um método de inspeção, a repetibilidade, precisão, economia e aplicação abrangente em grandes superfícies, com vasta aplicação nos ambientes industriais e na construção civil.

O primeiro experimento documentado utilizando termografia para detectar delaminações subsuperficiais no concreto foi publicado no ano de 1973 pelo Ministério dos Transportes e da Comunicação de Ontário no Canadá (MALHOTRA e CARINO, 2004). Ele foi baseado no uso de um simples infravermelho imageador para medir a temperatura superficial, sem o uso do computador, coletando dados de dia e a noite devido às diferenças de temperatura causadas pela radiação solar. Os experimentos provaram que o infravermelho poderia ser utilizado para detectar vazios causados por corrosão do aço de reforço, agrupamento de agregados ou fluídos, infiltração da água, entre outros defeitos.

Anomalias como as citadas anteriormente afetam o fluxo de calor através do material. Estas mudanças no fluxo de calor causam diferenças na temperatura superficial do material. Assim, medindo temperaturas superficiais nas condições de fluxo de calor para dentro ou para fora do material, pode-se determinar a presença e localização de eventuais anomalias subsuperficiais (MALHOTRA E CARINO, 2004).

Esta técnica que utiliza análise térmica a partir de gradientes de temperatura vem sendo amplamente explorada e aperfeiçoada. De acordo com MALDAGUE

(2000), AVDELIDIS e MOROPOULOU (2004), atualmente existem duas técnicas para o método não destrutivo de termografia digital, a técnica passiva e a técnica ativa.

Na técnica passiva é analisada a energia térmica já presente no material. Esta técnica é caracterizada pela falta de um estímulo de energia artificial. Condições de contorno naturais são utilizadas na análise, uma vez que nenhuma estimulação térmica é utilizada. Neste caso, deve existir uma diferença natural de temperatura entre o objeto sob estudo e o meio onde ele está inserido.

Na técnica ativa é utilizado o aquecimento ou resfriamento artificial do material ou parte deste para causar o fluxo de calor e o gradiente térmico necessário. Neste caso o fluxo de calor é variável, tendendo ao equilíbrio térmico com o meio em que o material se encontra. As imagens termográficas geradas a partir desta técnica apresentam diferentes espectros relacionados às diferentes temperaturas verificadas em função do tempo (MALDAGUE, 2000).

A análise termográfica é realizada de duas maneiras, qualitativa e quantitativa. A análise qualitativa apresenta resultados eficazes na detecção de falhas. Visa, com base em padrões térmicos, localizar eventuais anomalias. Baseia-se em padrões comparativos definindo a necessidade de uma atenção especial. Através da análise qualitativa é possível verificar se há alguma anomalia térmica e onde ela se encontra.

A análise quantitativa também apresenta resultados de qualidade, mas requer um estudo preciso e o total controle em relação às condições de vizinhança do sistema adotado. Basicamente é possível comparar os dois tipos de análise da seguinte forma:

(i) Qualitativa

Baseia-se em padrões comparativos;

Verifica a existência de uma possível anomalia térmica;

Localiza a possível anomalia térmica;

(ii) Quantitativa

Classifica a anomalia quanto à sua dimensão e gravidade;

Atualmente a termografia infravermelho têm sido utilizada com sucesso em diversos campos de atuação, tornando possível o diagnóstico de doenças como o câncer na área clínica (KOAY, 2004), permitindo a análise de estruturas metálicas

na área das ciências dos materiais (PAOLINI, 2009), entre outras aplicações. Na construção civil, esta técnica tem sido empregada para a detecção de vazamentos, inspeção térmica do entorno de novas obras, testes térmicos para detecção de anomalias em estruturas e também no monitoramento de defeitos em pontes (CLARK, McCANN e FORDE, 2003). Em síntese, as técnicas de termografia permitem a visualização da estrutura possibilitando a identificação da presença de elementos e anomalias ocultos como fissuras e vazios no interior do material.

Em relação às fissuras superficiais no concreto, estas têm sido associadas à combinação de dois mecanismos: a variação térmica das faces e a variação da temperatura interna do concreto devido à hidratação do cimento (INOUE, 1990; WU e LUNA, 2001; SILVOSO, 2002; VITHARANA e WARK, 2002; FARIA, 2004). O gradiente de temperatura entre as partes interna e superficial da estrutura causa variações volumétricas no corpo da mesma, provocando, conseqüentemente, o aparecimento de tensões de origem térmica.

De acordo com SPICER e OSIANDER (2002) muitos defeitos como vazios, fissuras e delaminações em concreto são detectados com o uso da termografia. Assim, a termografia pode ser descrita como um ensaio térmico não destrutivo, utilizado na obtenção do perfil de temperatura superficial em estruturas e, com a conseqüente correlação da informação com imperfeições internas.

2.2.2 Viabilidade do uso da Termografia

A utilização de métodos computacionais para simular as condições de operação de elementos estruturais tem permitido a identificação de irregularidades e/ou defeitos na estrutura e também como ferramenta de avaliação de determinada metodologia de análise. Nestas simulações é possível prever o comportamento da estrutura sob condições pré-definidas para os elementos que a compõem, indicando pontos suscetíveis à falha no modelo real. CHIANG *et al.* (2006) aplicou o método de diferenças finitas e elementos finitos na análise computacional de um problema térmico de uma parede de concreto e comparou com resultados experimentais de termografia infravermelho na inspeção de defeitos internos conhecidos.

ELBALLOUTI e BELATTAR (2006) verificaram a influência das dimensões de fissuras em pavimentos de concreto asfáltico sobre o campo térmico utilizando o método dos elementos finitos.

A perturbação térmica causada por um defeito interno em uma barragem de concreto é analisada por ELBALLOUTI e BELATTAR (2008), identificando a influência das condições geométricas do defeito. OBBADI e BELATTAR (2005) relacionaram as características dimensionais e térmicas de defeitos internos em materiais com a perturbação no campo de temperaturas utilizando o método dos elementos finitos.

Os trabalhos citados utilizam resultados numéricos obtidos a partir de métodos computacionais, analisando principalmente as influências dos parâmetros geométricos dos defeitos sobre o campo de temperaturas, indicando a possibilidade de registrar perturbações térmicas devido à presença de elementos irregulares internos à estrutura de concreto, demonstrando a viabilidade do uso da termografia como ensaio não-destrutivo.

2.3 REDES NEURAIIS ARTIFICIAIS

Redes Neurais Artificiais são técnicas computacionais que utilizam como modelo o funcionamento do cérebro humano, onde os neurônios artificiais são treinados de forma a responder e interpretar os diversos sinais funcionais (dados de entrada) provenientes da pesquisa ou abordagem de dado fenômeno, podendo ser utilizadas técnicas de reconhecimento de padrões e/ou modelos de aprendizagem supervisionada ou não (HAYKIN, 2003).

As Redes Neurais apresentam a capacidade de adquirir conhecimento do meio (aprendizagem) e de poder fazer generalizações (BISHOP, 1995), apresentando respostas a situações inéditas. De acordo com BARRETO (2004), as Redes Neurais Artificiais (RNA) têm sido utilizadas para solucionar diversos problemas das ciências em geral, por exemplo, na medicina, telecomunicações, climatologia entre outras.

As principais características que viabilizam o estudo e o uso das Redes Neurais Artificiais em diversos problemas incluem a capacidade de aprendizagem através da experiência, adaptabilidade, execução de tarefas específicas, robustez e tolerância a ruídos, resistindo a pequenas perturbações ou incompletude de dados, fazendo das redes neurais uma ferramenta robusta e de alto desempenho. Essas habilidades das redes têm atraído os pesquisadores em aplicações de sistemas de modelagem complexas que requerem confiabilidade e rapidez no processamento.

Um tipo de aplicação muito usado por cientistas na atualidade é o reconhecimento de padrões em conjuntos nebulosos de dados, sendo este reconhecimento, mais uma das vantagens das Redes Neurais Artificiais, pois estas têm a habilidade em descobrir padrões que parecem despercebidos aos especialistas humanos ou para os métodos estatísticos tradicionais. Dados com grau significativo de não-linearidade têm efeito negativo para grande parte das técnicas de análise matemática, sendo que em casos como estes, os fatores importantes para a tomada de decisões parecem muitas vezes imperceptíveis.

KOAY e FRIZE (2004) utilizaram redes neurais artificiais baseadas nos algoritmos *Levenberg-Marquardt* e *Resilient Backpropagation* em dois modelos neurais para diagnosticar a ocorrência de câncer em pacientes a partir de imagens termográficas. BRANCO (2008) utilizou redes neurais artificiais para desenvolver modelos de previsão de demanda para equipamentos de infraestrutura de telecomunicações. MEDEIROS (2009) realizou o monitoramento e o diagnóstico de pára-raios a ZnO (óxido de zinco) usando redes neurais artificiais a partir do reconhecimento de padrões observados em registros experimentais. CHAGAS (2008) aplicou o método de redes neurais artificiais para classificação de níveis de degradação em pastagens a partir de padrões observados durante o processamento das imagens obtidas em campo. LEE (2004; 2008) utilizou o algoritmo *Backpropagation* em seus modelos neurais para previsão de tempestades em Taichung, Taiwan.

DESHIBI (2010) desenvolveu um algoritmo baseado em redes neurais artificiais para o reconhecimento de faces a partir de um banco de imagens. LI e CHOW (2000) utilizaram redes neurais artificiais para diagnosticar elementos mecânicos. FLÓRIO FILHO (2006) desenvolveu um modelo para detecção automática do aquecimento em componentes de um sistema industrial, baseando-se em técnicas de reconhecimento de padrões, termografia e redes neurais artificiais.

A partir de tais considerações, este trabalho segue a linha teórica de determinação de defeitos em estruturas de concreto adotada pelos autores Malhotra, Carino, Maldague, Obbadi, Elballouti e Belattar e do método numérico redes neurais artificiais tipo *feedforward*, pelos autores Koay, Frize, Medeiros, Lee e Dehshibi, visando contribuir para os estudos baseados em reconhecimento de padrões em imagens a partir do algoritmo *backpropagation*.

CAPÍTULO 3

3 FUNDAMENTOS SOBRE TRANSFERÊNCIA DE CALOR

Este capítulo é iniciado com um estudo teórico sobre propagação do calor, seguido por fundamentos de transferência de calor em estruturas sólidas a partir de um elemento cúbico infinitesimal de um material com densidade de massa ρ , calor específico c e condutividade térmica k , nos casos onde existe ou não geração interna de calor. Estes fundamentos são estendidos para uma estrutura com propriedades térmicas do concreto contendo elementos com propriedades distintas em seu interior, sendo modelado computacionalmente a partir do método dos elementos finitos com condições de contorno específicas. Os resultados das simulações numéricas são apresentados ao término deste capítulo e formam a base de dados sintéticos utilizada para a validação do modelo de redes neurais desenvolvido para o reconhecimento de padrões.

3.1 PROPAGAÇÃO DO CALOR

TIPLER e MOSCA (2004) definem o calor como energia que está sendo transferida de um sistema a outro em virtude de uma diferença de temperatura. A propagação do calor ocorre fundamentalmente de três maneiras, convecção, radiação e condução. Ela pode ser considerada como uma troca de energia calorífica entre sistemas de temperaturas diferentes, dependendo das propriedades físicas e químicas dos materiais ou agentes envolvidos.

Em relação à propagação do calor por condução de um corpo sólido isolado, este está em equilíbrio térmico se a sua temperatura for a mesma em qualquer parte do corpo. Se a temperatura no sólido não for uniforme, calor será transferido por atividade molecular das regiões de temperaturas elevadas para regiões de baixas

temperaturas. O processo de condução de calor é dependente do tempo, e continuará até que um campo uniforme de temperatura exista em todo o corpo isolado.

Em grande parte das situações de engenharia, o sólido não é isolado e energia térmica flui através das superfícies do sólido que está em contato com a vizinhança (ex: sólido em meio fluido). As condições térmicas nas superfícies, que são chamadas de condições de contorno, determinam a distribuição de temperatura no sólido. Essas condições podem ser independentes do tempo resultando em condução de calor em regime permanente. Caso uma das condições de contorno seja dependente do tempo, então a distribuição de temperatura no sólido também será dependente do tempo e condução de calor transitório ocorrerá.

O processo de transferência de calor por condução, em regime permanente ou transitório, é governado pela primeira e segunda leis da termodinâmica. A primeira lei é usada em termos de fluxo, para um sistema composto de um cubo sólido infinitesimal utilizando a lei de Fourier para representar o fluxo de energia através de suas fronteiras. Fourier postulou que a taxa de transferência de calor por unidade de área da superfície é proporcional ao gradiente de temperatura normal à superfície, matematicamente expresso por:

$$\dot{q}'' = \frac{\dot{Q}'}{A} \propto \frac{\partial T}{\partial \eta} \quad (1)$$

onde \dot{Q}' é a quantidade de calor, A é a área superficial e η é a coordenada perpendicular à superfície através da qual calor é transferido. Um sinal de igualdade é obtido através da introdução de condutibilidade térmica do material k . A lei de Fourier fica:

$$\dot{q}'' = -k \frac{\partial T}{\partial \eta} \quad (2)$$

representando a taxa de transferência de calor por unidade de área sendo denominado fluxo de calor. O fluxo de calor é um vetor perpendicular à área da superfície do corpo, através da qual o calor é transferido como mostrado na Figura 2. A convenção do sinal usada é baseada na segunda lei da termodinâmica, com o

fluxo sendo positivo quando flui na direção do acréscimo da temperatura, ou seja, é positivo quando o gradiente de temperatura é negativo, razão pela qual se introduz o sinal negativo na equação.




Figura 2 - Condução do calor em um sólido.

Fonte – WROBEL (2002).

A equação diferencial de energia para a condução de calor é obtida utilizando o limite da expressão quando o volume do cubo tende a zero. Essa expressão, em conjunto com as condições de contorno no sólido, representa o modelo matemático do processo de condução no sólido.

De acordo com WROBEL (2002), a equação que descreve a equação da condução de calor em um sólido de região V pela superfície S é da forma:

$$\frac{\partial}{\partial x_1} \left(k \frac{\partial T}{\partial x_1} \right) + \frac{\partial}{\partial x_2} \left(k \frac{\partial T}{\partial x_2} \right) + \frac{\partial}{\partial x_3} \left(k \frac{\partial T}{\partial x_3} \right) + w = 0 \quad (3)$$

onde T é a temperatura, k é a condutividade térmica do meio e w é o termo não homogêneo, referente à geração de calor interno.

Assumindo que o meio é homogêneo e isotrópico e k é constante, a equação de condução do calor é simplificada para a equação de Poisson:

$$\nabla^2 T = \frac{w}{k} \quad (4)$$

$$\nabla^2 T = -\frac{w}{K} \quad (5)$$

3.2 TRANSFERÊNCIA DE CALOR EM UM ELEMENTO INFINITESIMAL

Considerando-se um sistema ortogonal de referência xyz , um elemento sólido infinitesimal homogêneo e isotrópico com coeficiente de condutividade k , densidade de massa ρ e calor específico c (Figura 3) sob geração interna de calor, em que $w dx dy dz$ é a quantidade de calor gerada no interior do elemento por unidade de tempo e a variação da energia interna do elemento é dada por:

$$\Delta U = \rho c dx dy dz \frac{\partial T}{\partial t} \quad (6)$$




Figura 3 - Fluxo de calor na direção x em um elemento infinitesimal.

Fonte – MEHTA e MONTEIRO (2008).

Então a equação (3) torna-se:

$$k \left(\frac{\partial^2 T}{\partial x^2} + \frac{\partial^2 T}{\partial y^2} + \frac{\partial^2 T}{\partial z^2} \right) + w = \rho c \frac{\partial T}{\partial t} \quad (7)$$

ou equivalente

$$k\nabla^2 T + w = \rho c \frac{\partial T}{\partial t} \quad (8)$$

No regime permanente, T é uma função independente do tempo e na ausência de geração interna de calor, $w = 0$, assim a equação anterior se torna:

$$\nabla^2 T = 0 \quad (9)$$

que é a equação de Laplace.

A solução do modelo representa a distribuição de temperaturas no sólido e a taxa de transferência de calor através das fronteiras.

3.3 TRANSFERÊNCIA DE CALOR EM UM ELEMENTO DE CONCRETO

Para determinar uma solução única para a Equação de Fourier, devem ser dadas as condições iniciais e as condições de contorno adequadas, compatíveis com as condições físicas do problema particular.

No caso da determinação da distribuição de temperatura em concreto, um dos elementos que pode ser avaliado é a taxa de geração de energia w , que está associada à elevação adiabática de temperatura. Esta elevação é consequência da reação de hidratação do cimento e consiste na hidrólise de seus compostos anidros dando origem a numerosos compostos hidratados e calor (MEHTA e MONTEIRO, 2008). Mas este aspecto não é relevante no presente estudo.

Deve-se definir a condição inicial pela prescrição da distribuição de temperatura através do corpo no tempo zero, como uma função conhecida de x , y e z .

$$T(x, y, z, t = 0) = f(x, y, z) \quad (10)$$

A temperatura existente em uma parte do contorno Γ_t do corpo é dada por:

$$T(x, y, z, t) = f(x, y, z, t) \quad x, y, z \text{ em } \Gamma_t \quad (11)$$

Essa condição também é conhecida como condição de Dirichlet ou condição essencial de contorno. No concreto, essa condição pode existir na interface entre concreto e água ou outro fluido, onde a convecção é pequena, fazendo com que a temperatura do concreto que está em contato com o fluido seja a mesma do fluido.

Pode-se expressar uma condição do fluxo de calor prescrito no contorno como:

$$-k \frac{\partial T}{\partial n}(x, y, z, t) = q_n(x, y, z, t) \quad x, y, z \text{ em } \Gamma_t \quad (12)$$

onde q_n é a quantidade de fluxo de calor dada no ponto (x, y, z) , e n é a normal externa à superfície.

A taxa de transferência de calor através de uma camada de contorno a partir da condição de convecção é dada por:

$$-k \frac{\partial T}{\partial n}(x, y, z, t) = h(T_s - T_e)^N \quad x, y, z \text{ em } \Gamma_h \quad (13)$$

onde h = coeficiente de transferência de calor

T_e = temperatura conhecida do ambiente externo

T_s = temperatura superficial do sólido

Γ_h = porção da superfície de contorno submetida à transferência de calor convectiva.

Para uma condição de contorno com convecção linear, $N = 1$, a equação (13) se torna:

$$k \frac{\partial T}{\partial n}(x, y, z, t) = h(T_s - T_e) = g(x, y, z, t) - hT_s \quad (14)$$

onde $g(x, y, z, t) = hT_e$.

A expressão de transferência de calor por radiação entre a superfície limite de contorno Γ e suas adjacências é dada por:

$$q_r(x, y, z, t) = V\sigma \left(\frac{1}{\frac{1}{\varepsilon_r} + \frac{1}{\varepsilon_s} - 1} \right) [T_r^4 - T_s^4]; \quad x, y, z \text{ em } \Gamma_r \quad (15)$$

onde V = fator de radiação

σ = constante de Stefan-Boltzmann

ε_r = emissividade da fonte de radiação externa

ε_s = emissividade da superfície

T_r e T_s = temperaturas absolutas da fonte de radiação e da superfície, respectivamente (MEHTA e MONTEIRO, 2008).

3.4 MODELO DE ANÁLISE PARA GERAÇÃO DA BASE DE DADOS SINTÉTICOS PARA A RNA

Utilizou-se o modelo de um bloco de concreto visando relacionar o campo de temperaturas resultante de um regime estacionário de transferência de calor às características dimensionais e propriedades térmicas conhecidas do defeito interno ao bloco. Este modelo foi descrito por INÁCIO *et. al* (2009) em seu trabalho intitulado “*Análise da Viabilidade do uso de Termografia como Ensaio não Destrutivo para Identificação de Falhas Internas de Concretagem*”, sendo simulado um elemento cúbico com as propriedades físicas do concreto com aresta medindo $L=0,5m$ e uma anomalia interna caracterizada por um material de maior porosidade para simular a presença de um nicho de concreto. A anomalia foi caracterizada pelas seguintes variáveis parametrizadas: D , profundidade da localização do defeito a partir da superfície de análise do bloco, F (largura), H (altura) e P (espessura) do

defeito. A geometria e as dimensões normalizadas (índice * em relação a L) do bloco e da anomalia são apresentadas na Figura 4.




Figura 4 - Geometria do problema e dimensões normalizadas associadas à geometria
Fonte – INÁCIO *et al.* (2009).

O modelo matemático adotado foi a equação de Laplace na sua formulação tridimensional, analisando-se a condução de calor no interior do bloco e do defeito através da equação da difusão de calor para meios isotrópicos, considerando o regime estacionário, onde k_s é a condutividade térmica do meio (bloco ou defeito):

$$\frac{\partial}{\partial x} \left(k_s \frac{\partial T}{\partial x} \right) + \frac{\partial}{\partial y} \left(k_s \frac{\partial T}{\partial y} \right) + \frac{\partial}{\partial z} \left(k_s \frac{\partial T}{\partial z} \right) = 0 \quad (16)$$

A simulação numérica adotada consistiu em discretizar a equação (16) através do Método dos Elementos Finitos (ODEN, 1981; BUCHANAN, 1994; KWON e BANG, 1997) com a utilização do software Ansys 12®, adotando um campo de temperatura uniforme, aplicado na superfície do bloco em $z=0$ ($T(x,y,0) = T_w$). Em $z^* = L^*$ uma condição de contorno é aplicada, descrevendo a existência na superfície de um resfriamento por convecção (ar) com coeficiente h_a a temperatura T_a . As demais superfícies externas (paralelas aos planos yz e xz) são consideradas adiabáticas, ou seja, com fluxo térmico nulo.

Nas superfícies de contato do defeito com o bloco são aplicados balanços de energia igualando os fluxos de calor entre os elementos adjacentes. A Figura 5 ilustra as condições de contorno aplicadas ao problema:




Figura 5 – Condições de contorno.

Fonte – INÁCIO *et al.* (2009).

A fim de generalizar o conjunto de soluções foram utilizadas as seguintes relações:

$$\theta = \frac{T - T_a}{T_w - T_a} \quad (17)$$

$$D^* = \frac{D}{L}, \quad F^* = \frac{F}{L}, \quad H^* = \frac{H}{L}, \quad P^* = \frac{P}{L}, \quad (18)$$

$$x^* = \frac{x}{L}, \quad y^* = \frac{y}{L}, \quad z^* = \frac{z}{L}$$

Substituindo as equações (17) e (18) na equação (16), tem-se:

$$\frac{\partial}{\partial x^*} \left(k_s \frac{\partial \theta}{\partial x^*} \right) + \frac{\partial}{\partial y^*} \left(k_s \frac{\partial \theta}{\partial y^*} \right) + \frac{\partial}{\partial z^*} \left(k_s \frac{\partial \theta}{\partial z^*} \right) = 0 \quad (19)$$

Assim, o campo térmico resultante pode ser definido para diferentes valores de temperaturas T_w e T_a , e θ assume valores entre 0 e 1.

3.5 RESULTADOS DA ANÁLISE DE TRANSFERÊNCIA DE CALOR

Com o modelo numérico utilizado e a partir das considerações descritas anteriormente, os resultados foram obtidos considerando:

- Condutividade térmica do concreto $K_B = 2,75 \text{ W/m.K}$ (MEHTA e MONTEIRO, 2008);
- Condutividade térmica do defeito $K_d = 25\%K_B, 50\%K_B$ e $75\%K_B$ – definindo $R_k=K_d/K_B$;
- Coeficiente de convecção concreto/ar: $h_a = 13,95 \text{ W/m}^2\text{K}$ (KRÜGER *et al.*, 2005);
- Valores para D^* , H^* , F^* , e P^* variando entre 0.1, 0.2, 0.3 e 0.4 (valor normalizados), correspondendo a 256 combinações possíveis;
- $\theta_{\text{máx}}$ = máxima temperatura obtida na face;
- $\theta_{\text{mín}}$ = mínima temperatura obtida na face;
- $T_a < T_w$ na interpretação do fenômeno físico (INÁCIO *et al.*, 2009)

A solução numérica para cada caso é ilustrada através de imagens térmicas (termogramas) representando a distribuição de temperaturas adimensionais na superfície de análise ($z^*=L^*$). O conjunto de imagens térmicas obtidas forma a base de dados sintéticos utilizada no estudo com redes neurais artificiais. Na Figura 6 é apresentada uma amostra do conjunto de soluções obtidas utilizando escala de 128 cores otimizada entre $\theta_{\text{mín}}$ e $\theta_{\text{máx}}$ sobre toda a superfície.

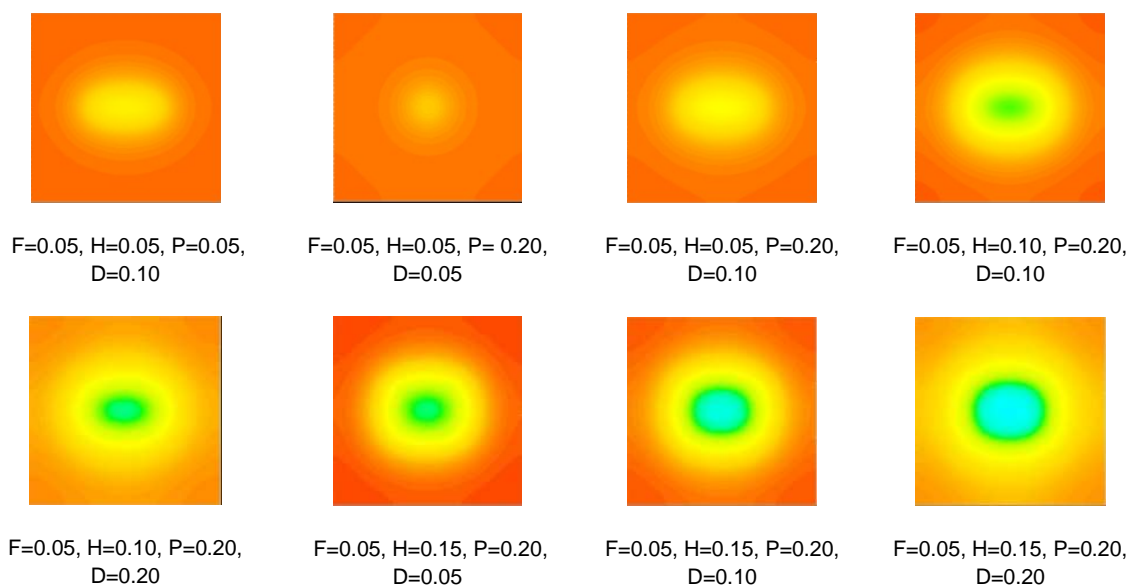


Figura 6 - Amostra do conjunto de imagens, F= Largura; H = Altura; P = Espessura; D = Profundidade.

Nos resultados numéricos foi verificado que a presença do defeito no interior do bloco, sob as condições estabelecidas, produz uma clara perturbação do campo térmico, conforme mostrado na Figura 7, coincidindo a localização da região mais fria do campo com a localização da projeção do defeito no plano xy (representado pela linha tracejada). Essa conclusão é evidente ao se analisar o perfil de temperatura adimensional para $y^*=0.5$ (Figura 8), com o ponto de menor temperatura localizado em $x^*=0.5$.




Figura 7 - Distribuição de temperatura adimensional ($D=0.05$, $H=F=P=0.20$ m).
Fonte – INÁCIO *et al.* (2009).




Figura 8 – Perfil de temperatura na superfície em $y^*=0,5$ ($D=0.05$, $H=F=P=0.20$ m).
Fonte – INÁCIO *et al.* (2009).

Diferentes faixas de temperatura causadas pela emissão de calor do material foram registradas em cada imagem e foram observadas faixas contínuas em regiões homogêneas do material indicando sua integridade. Este fato é explicado pelos casos onde não ocorre existência de anomalias, ou destas se apresentarem em

tamanho muito reduzido, fazendo com que o fluxo de calor percorra sua trajetória principal sem sofrer desvios ou reflexões consideráveis, permanecendo homogêneo em toda a superfície (Figura 9). Em contrapartida, foi verificado que as regiões da imagem onde ocorre maior variação no espectro infravermelho (gradiente de temperatura) representam indícios da presença de materiais com condutividade térmica diferente (descontinuidades), alterando o fluxo de calor no material (Figura 7).

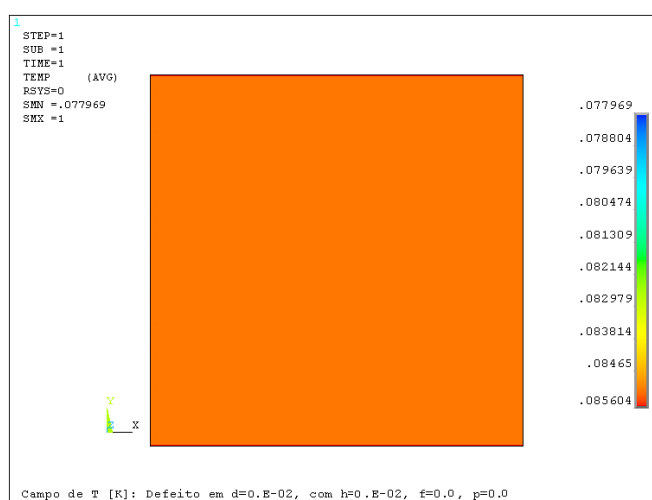


Figura 9 - Imagem infravermelho da emissão de calor simulada em Ansys (ausência de anomalia).

No estudo paramétrico realizado por INÁCIO *et al.* (2009), observou-se que os casos analisados para $R_k^1=75\%$ não apresentaram variações térmicas significativas no campo, indicando que defeitos internos com um valor de condutividade térmica próximo ao do concreto não são detectáveis através da termografia. A avaliação de valores menores de R_k é mais relevante, visto também que valores de condutividade térmica menores geralmente estão relacionados a materiais com propriedades mecânicas piores (INCROPERA e DeWITT, 1992), podendo afetar mais fortemente a estabilidade global de estruturas.

Dos resultados obtidos pode-se afirmar que quanto menor a relação R_k e quanto maior a diferença de temperatura imposta entre o meio e a face $(x,y,0)$, a presença do defeito será mais passível de identificação por conta da perturbação térmica gerada. Para cada valor de R_k foram simuladas 256 combinações com as dimensões D^* , H^* , F^* e P^* normalizadas. Para $R_k =25\%$, e com as condições

¹ O coeficiente R_k é definido como a razão entre o coeficiente de condutividade térmica do defeito (K_d) e o coeficiente de condutividade térmica do concreto (K_B).

impostas para a identificação do defeito (temperaturas de contorno), verificou-se que foram identificáveis entre 2,7% ($T_w - T_a = 25K$) e 19,5% ($T_w - T_a = 75K$) dos casos. Com $R_k = 50\%$ a quantidade de casos identificados variou entre 3,5% ($T_w - T_a = 50K$) e 10,1% ($T_w - T_a = 75K$). Em relação às características dimensionais e térmicas, percebe-se que o uso da termografia, em condições estacionárias de transferência de calor, é viável na identificação dos defeitos que se enquadrem nas seguintes condições:

- Próximos à superfície de análise: $D^* \approx 0.1$ ($D \approx 0,05m$);
- Com altura $H^* > 0.2$ ($H > 0,10m$);
- Com largura $F^* > 0.2$ ($F > 0,10m$);
- Razão de condutividade $R_k \leq 50\%$.

De acordo com INÁCIO *et. al* (2009), as alterações significativas na imagem térmica na face resultaram da variação dos parâmetros, largura, altura e profundidade do defeito.

Nas simulações realizadas, o parâmetro espessura P^* do defeito não causou influência evidente sobre os casos identificáveis. Em resumo, o emprego da termografia como ensaio não-destrutivo em concreto, sob as condições de contorno empregadas neste estudo, resulta na identificação de grandes defeitos internos, próximos à superfície, com valores de condutividade térmica de até metade do valor do concreto.

Desta forma, a base de dados sintéticos foi estabelecida com $R_k = 25\%$ e optou-se em utilizar apenas os parâmetros F , H e D , para as saídas conhecidas *a priori* pela RNA em seu processo de treinamento.

É importante salientar que o estudo realizado é teórico e a heterogeneidade do concreto pode alterar significativamente os resultados.

CAPÍTULO 4

4 PROCESSAMENTO DAS IMAGENS E SELEÇÃO DOS SINAIS FUNCIONAIS

Neste capítulo são apresentadas as etapas do processamento das imagens térmicas utilizando-se o programa computacional Matlab R2010®, compreendendo a implementação dos algoritmos de conversão RGB (do inglês *Red, Green and Blue*) (RUSS, 2007) e de mineração de dados relativos aos sinais funcionais necessários para o reconhecimento de padrões pela Rede Neural Artificial. Quatro bases de dados contendo estes sinais são apresentadas ao término do presente capítulo.

4.1 PROCESSAMENTO DAS IMAGENS

No processamento das imagens foram aplicadas as funções *colormap(128)* e *imread* ao conjunto de imagens térmicas, ambas funções computacionais do Matlab R2010®, que associadas, convertem a imagem colorida em uma matriz tridimensional, M por N por 3 (onde M=228 linhas e N=228 colunas de pixels) retornando valores do padrão RGB, associando a cada imagem um mapa de cores contendo 128 cores, alocando um valor numérico a cada componente *ijk* (onde *i* e *j* variam de 1 até o número de pixels na horizontal (linhas) e vertical (colunas), respectivamente, da imagem e *k*= 1, 2, 3) da matriz correspondente (Figura 10).

Desta forma, cada pixel da imagem térmica passa a ser representado por um vetor de três componentes.

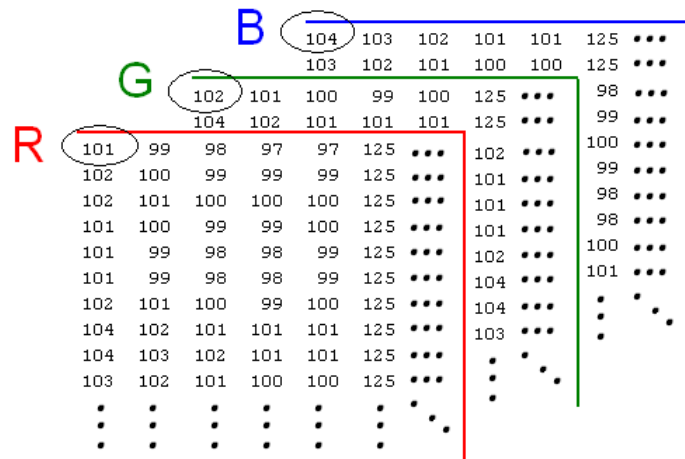


Figura 10 – Matrizes do padrão RGB.

A variação de cor entre pixels em regiões específicas da imagem revela a distribuição térmica e seus gradientes na superfície do bloco. A Figura 11 ilustra parte de uma análise térmica realizada com o software SAT IR REPORTING SYSTEM (2010), utilizado para análise termográfica, apresentando a temperatura de determinados pixels.

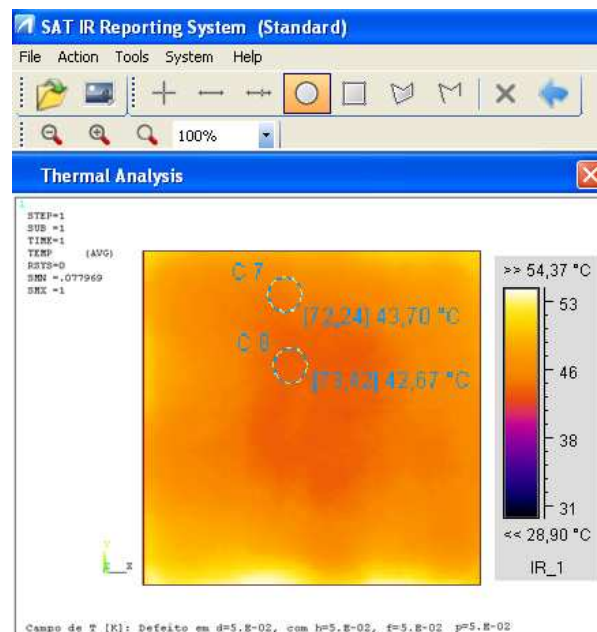


Figura 11 – Análise térmica utilizando o software SAT IR apresentando os valores de temperaturas de determinados pixels.

Com o intuito de obter as variações térmicas em cada imagem, foram associados valores de temperaturas para cada pixel a partir da matriz $M \times N \times 3$ correspondente. Neste processamento, as componentes RGB de cada vetor foram

combinadas linearmente pela função injetora (19) a partir dos coeficientes a_1 , a_2 e a_3 (constantes) retornando um valor biunívoco ao conjunto de temperaturas padronizadas (128 cores).

$$p(R, G, B) = a_1R + a_2G + a_3B \quad (20)$$

Desta forma cada vetor da matriz $M \times N \times 3$ foi substituído por um valor de temperatura de acordo com a emissão de calor registrada na simulação em Ansys 12®, compondo assim, uma matriz bidimensional.

Grande parte das técnicas de processamento de imagens associadas a técnicas de classificação e/ou reconhecimento de padrões utiliza o tratamento bidimensional das informações, realizando o processo de descrição, também chamado seleção de características ou de sinais funcionais, extraindo informações quantitativas de interesse ou que sejam básicas para discriminação entre classes de objetos ou fenômenos.

Para determinar quais características comporiam o conjunto de entradas da RNA, o processamento das imagens contou inicialmente com um estudo de inferência estatística de acordo com FLÓRIO FILHO (2006), verificando a ocorrência de pixels com seus respectivos valores de temperatura em cada imagem do conjunto. De acordo com QUEIROZ (2008), os métodos de classificação podem ser divididos em classificadores por pixel ou por regiões. A partir de tal afirmação e levando em conta os classificadores baseados em pixels, o estudo desenvolvido permitiu verificar que as variações de temperatura se apresentam em intervalos bem definidos, sendo uma forma de caracterizar cada imagem, indicando um padrão a ser detectado pela RNA no processo de classificação.

Para ilustrar o estudo realizado, nas figuras 12 a 17 é apresentada uma amostra dos histogramas de freqüências de pixels de temperaturas padronizadas para as imagens térmicas disponíveis. Constam em cada figura os valores das dimensões da anomalia presente no cubo de concreto e sua distância à face da imagem termográfica.




Figura 12 – Histograma caso 002.




Figura 13 – Histograma caso 030.

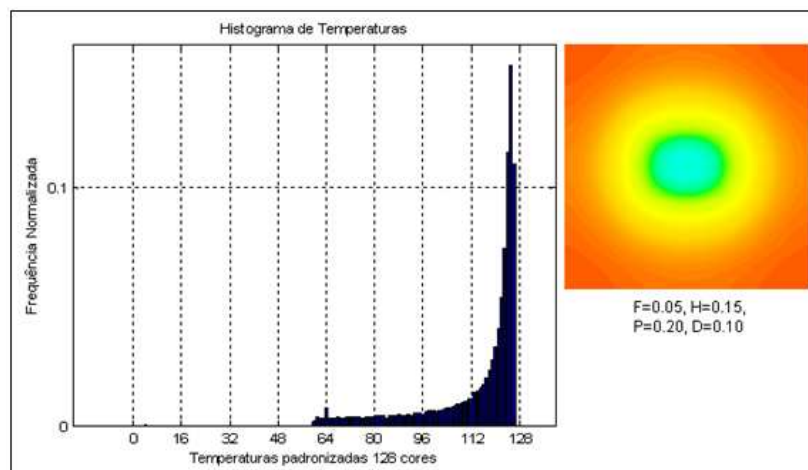


Figura 14 – Histograma caso 045.




Figura 15 – Histograma caso 200.

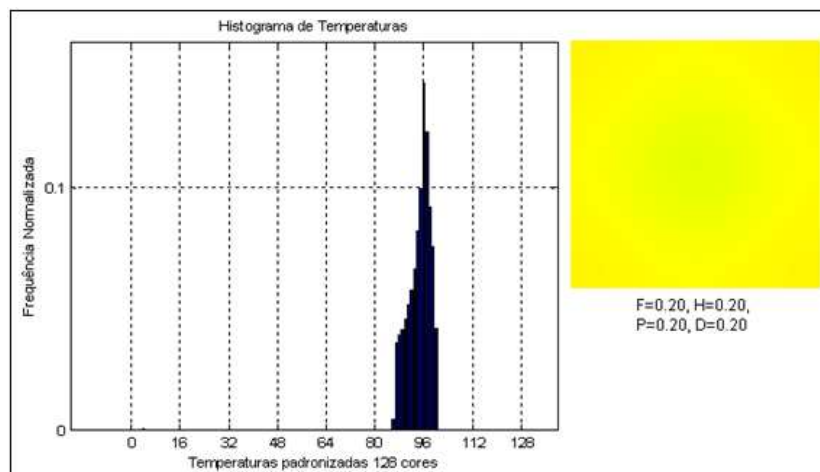


Figura 16 – Histograma caso 255.

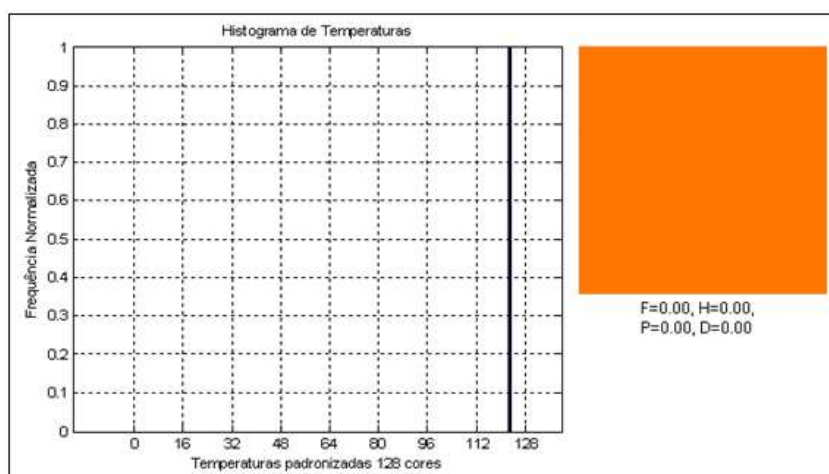


Figura 17 – Histograma caso 256.

4.2 SELEÇÃO DOS SINAIS FUNCIONAIS

Analisando os histogramas do conjunto total de imagens, foi possível perceber a concentração de temperaturas em subintervalos bem definidos, como mostrado na Figura 13. Com o intuito de obter mais informações sobre a distribuição térmica em cada imagem, o intervalo de temperaturas padronizadas foi dividido em três subintervalos de mesmo tamanho, limitados pela menor e maior temperatura registrada em todo o conjunto de imagens ilustrado pela Figura 18. Os valores obtidos no processo de inferência estatística em cada subintervalo representam parte dos padrões de entrada da RNA.

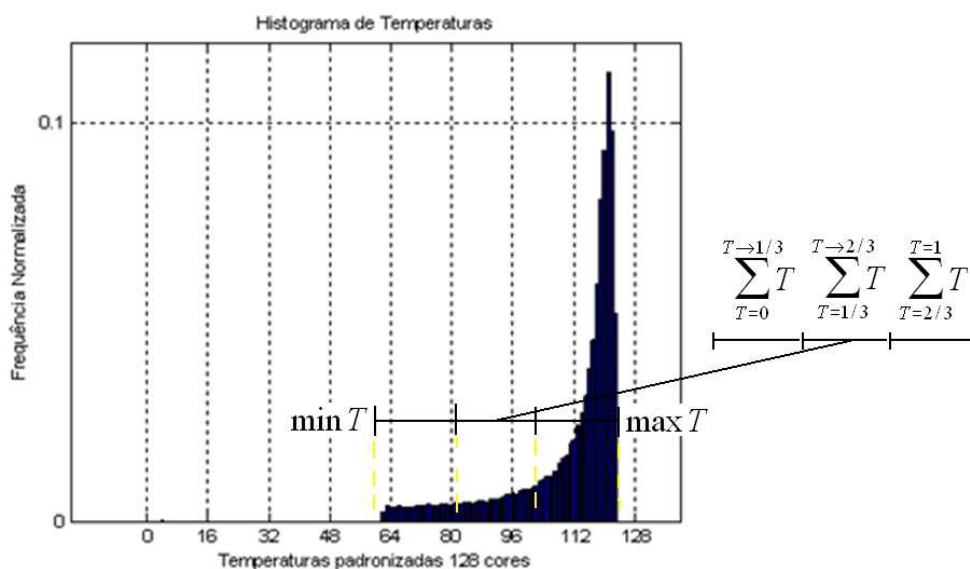


Figura 18 – Ilustração da inferência estatística realizada nas imagens.

Para se obter os três parâmetros de saídas (F =largura, H =Altura e D =distância do defeito à face), mais informações sobre cada imagem são necessárias, tornando o aprendizado da RNA mais eficiente. Para isso, durante o processamento das imagens foram analisadas outras características relacionadas à distribuição térmica e observados alguns critérios para a coleta de novos padrões. O primeiro critério diz respeito à localização do centro de gravidade da distribuição das menores temperaturas em cada imagem (Figura 19). Para isto foi implementado o seguinte algoritmo no Matlab R2010®:

1. leia o arquivo *matriz-imagem_001*
2. encontre o menor valor de temperatura
3. encontre as coordenadas i, j dos pixels de menor temperatura
4. armazene as coordenadas i, j no vetor *tempmin*
5. encontre a média do vetor *tempmin* (centro de gravidade = $G(G_x, G_y)$)
6. imprima o vetor *tempmin* em um gráfico
7. imprima a coordenada média no mesmo gráfico
8. obtenha os valores de temperatura na direção x em $y = G_y$
9. imprima estes valores em um novo gráfico
10. repita os passos de 1 a 9 para todos os arquivos *matriz-imagem*

A aplicação deste algoritmo é justificada pela localização do defeito coincidir com a região mais fria do campo térmico, como citado na parte 3.5 do capítulo 3.

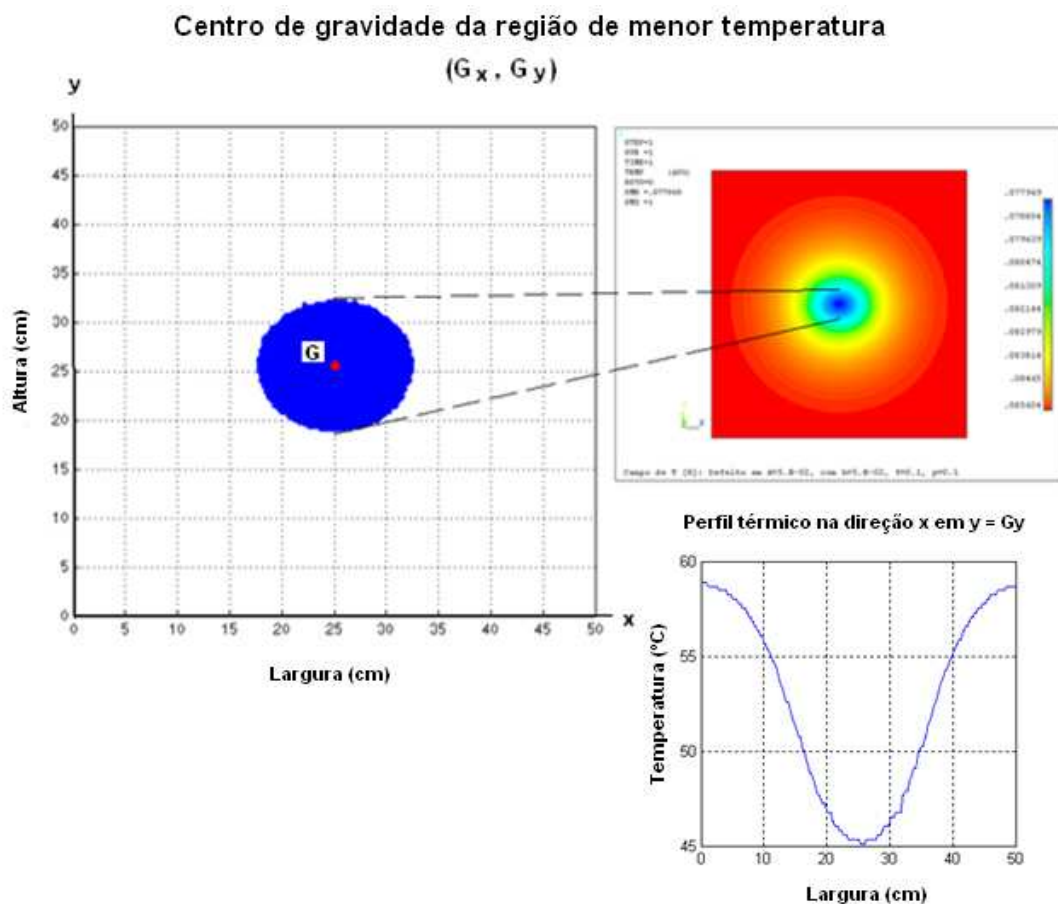


Figura 19 – Resultado para localização do centro de gravidade das temperaturas mínimas.

Uma vez determinados os centros de menor temperatura das imagens, que podem indicar a possível presença de uma anomalia, o critério seguinte é definido pela análise da variação térmica a partir deste ponto, sendo estabelecido um sistema cartesiano de coordenadas com origem no centro da anomalia térmica, como ilustra a Figura 20.

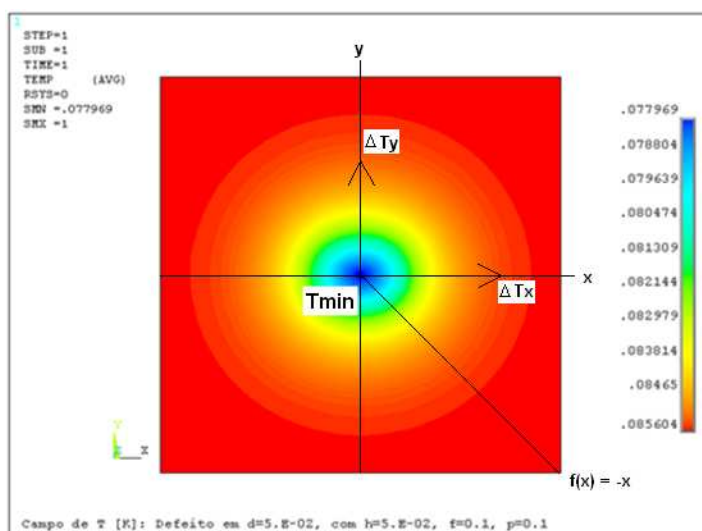


Figura 20 - Plano cartesiano com origem no centro da anomalia térmica.

Neste plano cartesiano são verificadas as variações relativas à temperatura em pontos fixos equidistantes a partir da origem (centro de gravidade das temperaturas mínimas). O primeiro ponto está localizado na origem do sistema xy , já os outros dois pontos estão sobre os eixos cartesianos em seus sentidos positivos x e y . O cálculo da variação é feito pela diferença do valor registrado sobre cada um dos eixos e a origem, traçando um perfil térmico da superfície da estrutura de concreto, verificando em qual direção o gradiente de temperatura sofre maior ou menor variação.

No mesmo plano cartesiano também são avaliados os valores de temperatura mínima e máxima para cada imagem, assim como o valor de temperatura de maior frequência em uma linha a partir do centro da anomalia térmica, de acordo com a função $f(x) = -x$, em seu domínio positivo (Figura 20). Isto é feito com o intuito de mapear cada imagem, sendo atributos característicos úteis em casos de comparação.

Estes cinco dados obtidos nesta etapa são incorporados aos dados obtidos no processo de inferência estatística, completando o conjunto de padrões de

entradas da RNA. Assim, as características extraídas em cada imagem neste processamento são:

1. *Quantidade de pixels de temperaturas no primeiro terço do intervalo de temperaturas padronizadas;*
2. *Quantidade de pixels de temperaturas no segundo terço do intervalo de temperaturas padronizadas;*
3. *Quantidade de pixels de temperaturas no terceiro terço do intervalo de temperaturas padronizadas;*
4. *Gradiente horizontal de temperatura a partir do ponto de temperatura mínima;*
5. *Gradiente vertical de temperatura a partir do ponto de temperatura mínima;*
6. *Temperatura de maior freqüência;*
7. *Temperatura mínima e*
8. *Temperatura máxima.*

Devido à variabilidade dos tipos de características observadas e a sensibilidade das redes neurais às magnitudes absolutas, as informações obtidas durante o processamento das imagens foram normalizadas entre -1 e 1 de acordo com sua ordem de grandeza e dimensionalidade, sendo armazenadas em um vetor contendo os padrões característicos de cada imagem. Assim, estes vetores representam os sinais funcionais da RNA 1.

Com o intuito de verificar alternativas para o conjunto de descritores que caracterizam cada imagem, três novas abordagens foram incorporadas ao processamento das imagens. Na primeira são extraídos os valores pontuais de temperatura em treze pontos distintos sobre cada imagem a partir do ponto de temperatura mínima de acordo com a Figura 21.

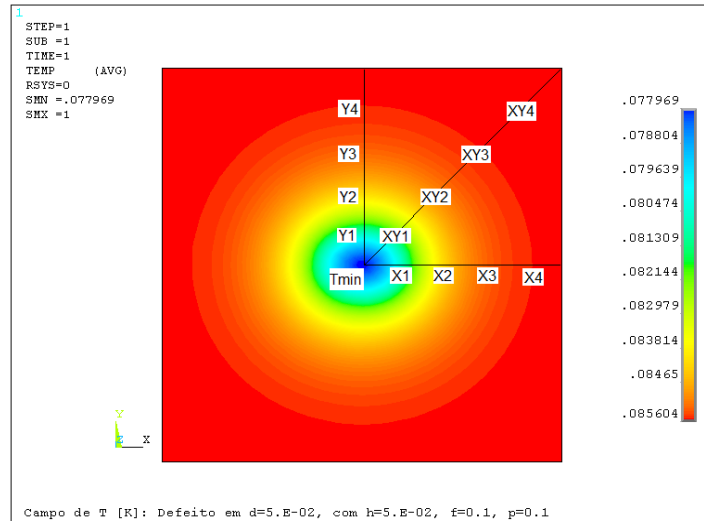


Figura 21 – Localização das características térmicas.

Esta abordagem tem como justificativa o registro das variações de temperatura em parte do entorno radial do ponto de menor temperatura em cada imagem, sendo um indicativo particular de cada caso simulado.

Com a intenção de se obter mais informações sobre o registro de temperaturas, na segunda e terceira abordagens foram definidas regiões com $0,16\text{m}^2$ a partir de malhas quadradas contendo 9 (Figura 22) e 25 (Figura 23) nós respectivamente, centradas na região de menor temperatura sendo coletados os valores de temperatura em cada um destes nós.




Figura 22 – Malha 09 para localização das características térmicas.




Figura 23 – Malha 25 para localização das características térmicas.

Procedendo-se da mesma forma que na RNA 1 (coleta, normalização e vetorização das informações), são obtidos os sinais funcionais para a RNA 2, RNA 3 e RNA 4, contendo treze, nove e vinte e cinco características respectivamente, de acordo com cada abordagem definida.

A Tabela 1 apresenta a relação entre a quantidade de características e o tempo necessário de processamento registrado para aplicação de cada uma das abordagens para o conjunto de 256 imagens.

Tabela 1 – Tempo de processamento para obtenção das características.

RNA	Quantidade de características	Tempo
1	08	1,00
2	13	1,02
3	09	1,00
4	25	1,01

Tempo normalizado em função do registro RNA 1 = 8,82 segundos.

Todas as redes neurais artificiais têm em comum a tarefa de apresentar como resposta os três parâmetros F , H e D (saídas) estabelecidos no item 3.5 do capítulo 3. A variação das bases de dados tem como objetivo obter os sinais funcionais que melhor desempenham a tarefa proposta a partir do reconhecimento de padrões.

CAPÍTULO 5

5 FUNDAMENTOS SOBRE REDES NEURAS ARTIFICIAS

Neste capítulo são apresentados fundamentos sobre redes neurais artificiais e também as etapas do desenvolvimento das topologias neurais implementadas no programa computacional Matlab R2010®, compreendendo a determinação da estrutura, quantidade de camadas e neurônios, algoritmos de aprendizagem e de análise de erros das redes. Os resultados dos treinamentos e simulações realizados com os modelos neurais são apresentados na seção 5.5 do presente capítulo e a conclusão deste desenvolvimento é apresentada na seção 5.6.

5.1 REDES NEURAS ARTIFICIAIS

Redes Neurais Artificiais são técnicas computacionais que utilizam como modelo o funcionamento do cérebro humano, onde os neurônios artificiais são treinados de forma a responder e interpretar os diversos sinais funcionais (dados de entrada) provenientes da pesquisa ou abordagem de dado fenômeno, podendo ser utilizadas técnicas de reconhecimento de padrões e/ou modelos de aprendizagem supervisionada ou não (HAYKIN, 2003).

As principais características que viabilizam o estudo e o uso das redes neurais artificiais em diversos campos das ciências são: a capacidade de aprendizado através da experiência, a adaptabilidade a situações adversas e a tolerância a ruídos. Essas habilidades das redes neurais artificiais as têm tornado úteis para modelar sistemas complexos e que requerem alto grau de confiabilidade e velocidade de processamento.

Uma das principais vantagens das redes neurais artificiais são as habilidades em descobrir padrões que parecem despercebidos aos especialistas humanos ou

para os métodos estatísticos tradicionais. Dados com grau significativo de não-linearidade têm efeito negativo para grande parte das técnicas de análise matemática, pois os fatores importantes para a tomada de decisões parecem muitas vezes imperceptíveis.

A descoberta ou reconhecimento de padrões usando redes neurais artificiais pode ser considerado um processo de busca de informações ou de aprendizado pela rede, determinando características pontuais e padrões no fenômeno em estudo.

A partir das informações obtidas a rede pode ser treinada e pode aprender a classificar determinados padrões ou conjuntos de informações. Tais informações podem ser posicionadas, classificadas ou previstas de acordo com o seu padrão ou problema que se deseja resolver.

Este reconhecimento de padrões é definido como um processo que atribui um rótulo a um objeto, baseado na informação fornecida pelo seu descritor. Para o caso em que a informação é oriunda do processamento de imagens, a maioria das técnicas de reconhecimento de padrões envolve o tratamento bidimensional destas, ocorrendo o processo de descrição, também chamado seleção de características ou de sinais funcionais, procurando extrair informações quantitativas de interesse ou que sejam básicas para discriminação entre classes de objetos ou fenômenos.

A estrutura de uma rede neural artificial é formada por várias unidades de processamento, que podem ser resumidas no modelo matemático de McCulloch e Pitts (1943) ilustrado na Figura 24 (McCULLOCH e PITTS, 1943; BARRETO, 2004), onde:

- x_1, \dots, x_n : vetor de valores de entrada;

- w_{ij} : matriz de pesos das entradas;

- $I_j = \sum_{i=1}^n w_{ij} x_i$: função de entrada, multiplicando o valor dos pesos pelas respectivas entradas;

- $\Phi(I_j)$: função de ativação, que dirá se o valor de entrada foi suficiente ou não para gerar algum dado na saída;

- y_j : função de saída, que irá conter o resultado das operações efetuadas no neurônio artificial.




Figura 24 - Modelo de neurônio artificial.

De forma geral, a operação de uma unidade da rede se resume em:

- Sinais são inseridos na entrada da rede. Estes sinais representam as informações sobre o comportamento a ser mapeado pelo modelo neural;
- Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade. Esta quantificação é feita em função dos objetivos funcionais da rede, cujo propósito será então mapear o comportamento entrada/saída do referido processo;
- Em seguida, o valor da composição de todas as entradas já devidamente ponderadas pelos seus respectivos pesos, adicionado ainda do limiar de ativação, é repassado como argumento da função de ativação, produzindo um nível de atividade;
- Se este nível excede um limiar de ativação (threshold) a unidade produz uma saída.

Existem modelos de redes neurais como o Perceptron (ANDRADE, 2004) e a rede de Kohonen (BISHOP, 1995), que apresentam neurônios como a definida acima.

Quanto à disposição dos neurônios, a rede neural deve ter ao menos duas camadas para apresentar um resultado significativo no desempenho de suas funções: entrada e saída de dados (HAYKIN, 2003).

Como uma rede deste tipo possui o processamento muito limitado é necessária que seja inserida uma camada intermediária, fazendo com que a rede neural artificial tenha pelo menos três camadas.

A rede neural artificial de Hopfield (Figura 25 -1) apresenta fluxo de dados multidirecional e comportamento dinâmico, devido ao fato de que todos os neurônios são interconectados, desconsiderando a ideia de camadas (HAYKIN, 2003). Neste caso, por ter um funcionamento complexo, são encontrados maiores problemas tanto na fase de aprendizado quanto na fase de testes. A utilização deste modelo é maior na área de problemas de otimização e desempenho.




Figura 25 - Modelo de redes neurais artificiais. (1) Hopfield e (2) Perceptron.

Modelos de redes neurais artificiais como o Perceptron (Figura 25 -2), são capazes de tratar problemas linearmente independentes ou separáveis. Para problemas não lineares, como computar a porta XOR (ou exclusivo) ou a operação lógica de implicação, é necessário que a rede tenha uma representação intermediária apropriada para padrões de entrada (DESCHAMPS, 2008). Isto é feito através da inserção de camadas de neurônios intermediários não-lineares.

Para o processo de aprendizado da rede neural, alguns autores como LEE (2008; 2004), FARIA (2004), VARELLA (2002), FLÓRIO FILHO (2006) e ANDRADE (2004) utilizam o algoritmo *Backpropagation*. O termo *Backpropagation* é uma abreviação para *propagação do erro para trás*, ou seja, é um método de aprendizado supervisionado onde a cada ciclo são ajustados os valores dos pesos em função do fluxo de ativação da rede e dos erros resultantes da fase de treinamento (KROSE e SMAGT, 1996). Assim, verifica-se a diferença entre a resposta desejada e a encontrada e a partir desta diferença é feito o ajuste nos pesos das conexões.

A rede é inicializada aleatoriamente para que julgamentos acerca da aplicação não sejam feitos antes desta ser apresentada ao algoritmo *Backpropagation*.

Os padrões de treinamento apresentados à rede podem ser vistos como um conjunto de pares ordenados $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, onde x_i representa um padrão de entrada, y_i representa um vetor de padrão de saída associado ao vetor de entrada x_i e o i representa a saída real obtida na rede.

O processo de treinamento da rede é então feito de acordo com o seguinte algoritmo, o qual é derivado de um resultado natural da busca pelo gradiente da superfície de erro (no espaço de pesos) da saída atual produzida pela rede em relação a um resultado desejado:

1. *Selecione o primeiro par de vetor de treinamento dos pares de vetores de treinamento. Chame este vetor de par (x, y) .*
2. *Use o vetor de entrada x como a saída da camada de entrada dos elementos de processamento.*
3. *Calcule a ativação para cada unidade na camada subsequente.*
4. *Aplique as funções de ativação apropriadas, as quais serão denotadas como $f(\text{net})$ para as camadas intermediárias e como $f(\text{net}_0)$ para a camada de saída, para cada unidade na camada subsequente.*
5. *Repita os passos 3 e 4 para cada camada da rede.*
6. *Calcule o erro para este padrão p em toda a camada de saída.*
7. *Calcule o erro para todas as camadas intermediárias j recursivamente.*
8. *Atualize os valores dos pesos das conexões das camadas.*
9. *Atualize os valores dos pesos das conexões da camada de saída.*
10. *Repita os passos de 2 a 9 para todos os vetores no conjunto de treinamento. Chame esta de época de treinamento.*

Os passos 1 a 10 devem ser repetidos quantas vezes forem necessárias até que se atinja um nível de erro determinado.

A Figura 26 mostra uma rede típica na qual pode ser utilizado o algoritmo *Backpropagation*. Tal rede é constituída de 3 camadas *feedforward* (HAGAN e DEMUTH, 2001) consistindo de uma de entrada, uma intermediária e uma de saída, com nós conectados sucessivamente, para frente, sem conexão entre os neurônios que estão na mesma camada.

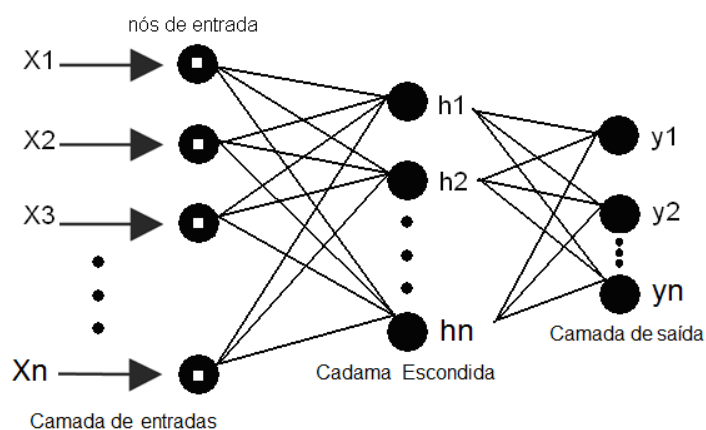


Figura 26 - Estrutura típica de rede neural *feedforward* que pode ser aplicada a retropropagação (*backpropagation*).

5.2 DEFINIÇÃO DAS REDES NEURAIS ARTIFICIAIS PARA O RECONHECIMENTO DE PADRÕES

No planejamento da RNA, buscou-se uma topologia com número de camadas e número de neurônios em cada camada que fornecesse maior qualidade de resposta.

TSOUKALAS e UHRIG (1997) citam que uma rede de três camadas (entrada, escondida e saída), com um número suficiente de neurônios é adequada para representar qualquer mapeamento, e que novas camadas só devem ser acrescentadas se a arquitetura em mãos não for adequada. SILVA, SPATTI e FLAUZINO (2010) citam que em topologias com apenas uma camada escondida, o número de neurônios nesta camada pode ser obtido a partir dos métodos de Kolmogorov (Eq.(21)), Fletcher-Gloss (Eq.(22)), Weka (*Waikato environment for knowledge analysis*) (Eq.(23)) e o método de validação cruzada com amostragem aleatória (*random subsampling cross-validation*).

$$n_1 = 2.n + 1 \quad (21)$$

$$2.\sqrt{n} + n_2 \leq n_1 \leq 2.n + 1 \quad (22)$$

$$n_1 = \frac{n + n_c}{2} \quad (23)$$

onde n = número de entradas, n_1 = número de neurônios na camada escondida e $n_2 = n_c$ = número de saídas ou padrões classificados.

É importante ressaltar que o aumento indiscriminado de neurônios na camada escondida não assegura a generalização apropriada da rede de múltiplas camadas em relação às amostras pertencentes aos subconjuntos de testes (SILVA, SPATTI e FLAUZINO, 2010).

Dada a complexidade do tipo de mapeamento realizado, a estrutura da rede foi definida por duas camadas escondidas. A primeira camada foi composta por um número de neurônios igual à quantidade de sinais funcionais de cada conjunto. Para

definir a quantidade de neurônios na segunda camada, utilizou-se o método de validação cruzada com amostragem aleatória do conjunto de imagens. Para isto, foi desenvolvido um algoritmo que simulava iterativamente as topologias variando a quantidade de neurônios na segunda camada escondida da unidade até um número igual à quantidade de sinais funcionais do conjunto (Figura 27), visando relacionar a quantidade que apresenta o menor somatório de erro quadrático médio nos testes. A aplicação deste algoritmo teve como objetivo otimizar e determinar as topologias que melhor desempenham a tarefa de reconhecimento de padrões de defeitos.




Figura 27 – Ilustração para otimização e definição das topologias.

Este processo é justificado pela importância que as camadas escondidas representam para o aprendizado da rede, pois segundo HAYKIN (2003), “os neurônios da camada escondida desempenham um papel crucial na operação de uma rede de múltiplas camadas com aprendizagem por retropropagação porque agem como detectores de características”.

Desta forma, conforme o processo de aprendizagem avança, os neurônios da camada escondida começam gradualmente a descobrir as características salientes que caracterizam os dados de treinamento. Isto é feito a partir de uma transformação não linear dos dados de entrada para um espaço de características (HAYKIN, 2003).

Baseado em tal afirmação, foram aplicadas transformações (funções de ativação ou também chamadas de funções de transferência) não lineares sobre as duas camadas escondidas, utilizando a função tangente hiperbólica (Eq.(24)) e adotando uma função linear (Eq.(25)) para a camada de saída. A escolha de neurônios lineares na camada de saída é motivada pelo desejo de concentrar a atenção sobre o papel dos neurônios da camada escondida (HAYKIN, 2003).

$$y_k = \tanh(X_k) = \frac{e^{X_k} - e^{-X_k}}{e^{X_k} + e^{-X_k}} \quad (24)$$

onde $X_k = w_{kj} \cdot x_j + bias$

$$y_k = f\left(\sum_{j=1}^m w_{kj} \cdot x_j\right) \quad (25)$$

Para arquitetura, foram definidas redes *feedforward* de camadas múltiplas. Redes *feedforward* são organizadas em camadas com conexões unidirecionais entre uma camada e outra, processando os dados paralelamente distribuídos.

Considerando que a informação de uma RNA é armazenada nos valores dos pesos e estes são iniciados randomicamente, é fundamental a aplicação de um algoritmo para o controle e correção destes valores. Existem alguns métodos para se fazer a correção dos pesos, entre os quais se encontra o algoritmo de Regularização Bayesiana (MACKAY, 1991; 1992). Este algoritmo foi desenvolvido por MACKAY (1992) e consiste em adicionar um termo de penalização (regularização) à função objetivo, de forma que o algoritmo de estimação faça com que os parâmetros irrelevantes convirjam para zero, reduzindo assim o número de parâmetros efetivos utilizados no processo. De acordo com FORESEE (1998), a aplicação deste algoritmo é feita para prevenir o *overfitting* (sobre-treinamento) na fase de treinamento da rede.

A rede neural artificial para o reconhecimento de padrões desenvolvida neste trabalho emprega a função de treinamento *trainbr* do Matlab R2010® que utiliza o algoritmo de Regularização Bayesiana com retropropagação e termo de *momentum*. (algoritmo *backpropagation*). A retropropagação significa que o processo de correção dos pesos das conexões é iniciado na última camada e prossegue em direção à primeira, gradualmente até que o desempenho desejado seja atingido. O ajuste dos pesos das conexões é chamado de aprendizagem da rede. É importante ressaltar que os ajustes dos pesos são realizados somente na fase de treinamento da rede, onde se aplicam os passos *forward* e *backward* a fim de proceder eventuais correções sinápticas necessárias. A aplicação do termo de *momentum* tem como objetivo ponderar os ajustes nas matrizes sinápticas entre duas iterações anteriores

e sucessivas acelerando o processo convergência quando a solução atual estiver longe da solução final (SILVA, SPATTI e FLAUZINO, 2010).

O modelo de treinamento da rede foi definido com aprendizado supervisionado, ou seja, quando a saída correta do conjunto de treinamento é conhecida e o objetivo do treinamento é adaptar a saída da rede à saída conhecida (BARRETO, 2004). Os testes para avaliação da RNA foram definidos usando validação cruzada com amostragem aleatória do conjunto de imagens, compondo os grupos de treinamento (80%), validação (10%) e teste (10%, dados inéditos), com o intuito de verificar a capacidade de generalização da rede. Na fase de teste da rede, nenhum tipo de ajuste é efetuado em seus parâmetros internos, sendo que, para este processo, somente a fase *forward* é processada com o objetivo de gerar as saídas da rede (SILVA, SPATTI e FLAUZINO, 2010).

Após a definição das topologias das redes, os passos seguintes se referem aos treinamentos e às simulações das RNA1, 2, 3 e 4.

5.3 TREINAMENTO DOS MODELOS

As RNAs foram inicializadas de acordo com item 5.2. Dez treinamentos foram realizados para cada topologia, permitindo encontrar a topologia que representasse o menor nível de erro.

O nível de erro foi avaliado pela média dos erros quadráticos médios (MMSE) (Eq.(26)) das respostas fornecidas por cada estrutura de RNA.

$$\frac{\sum_{n=F,H,D} (vr_n - vs_n)^2}{3} \quad (26)$$

onde vr é valor real parametrizado e vs é o valor simulado pela RNA.

O valor obtido para o MMSE mínimo é relacionado à quantidade de neurônios da camada escondida, visando à definição da topologia que obteve o melhor

desempenho. Os resultados referentes à topologia desejada para cada modelo de RNA são apresentados na Tabela 2.

Tabela 2 – Análise dos erros das simulações e números de neurônios na segunda camada escondida

RNA	MMSE mínimo	MMSE médio	MMSE máximo	NNH2	NTE	NTI	Tempo
1	6,2286	13,5797	27,8052	03	10	80	1,00
2	2,4485	18,9439	33,8238	08	10	130	8,63
3	9,7069	20,0054	35,0977	09	10	90	1,55
4	2,3646	9,1050	30,4355	15	10	250	277,57

NNH2 = número de neurônios na segunda camada escondida com mínimo MMSE, NTE = número de treinamentos e NTT = número total de iterações.

Tempo normalizado em função do registro RNA 1 = 135,47 segundos.

Na Tabela 2, os valores pertencentes ao intervalo MMSE mínimo e máximo, indicam a flutuação dos erros da topologia encontrada para cada modelo, revelando o seu comportamento durante a fase de treinamento. O tempo necessário para definição da topologia se refere ao total de treinamentos realizados para cada modelo. A partir destes resultados foi possível definir as topologias para teste. Na Tabela 3 é apresentada a quantidade de neurônios em cada camada para cada uma das topologias.

Tabela 3 – Definição das topologias

RNA	NI	NNH1	NNH2	NNO
1	08	08	03	03
2	13	13	08	03
3	09	09	09	03
4	25	25	25	03

NI = número de entrada (nós), NNH1 = número de neurônios na primeira camada escondida, NNH2 = número de neurônios na segunda camada escondida, NNO = número de saídas da rede.

5.4 VALIDANDO E TESTANDO OS MODELOS

Após a definição de cada topologia, foram introduzidos os estimadores de erro quadrático médio (MSE) (Eq.(27)), incerteza padrão média (ASU) (Eq.(28)), desvio médio absoluto (MAD) (Eq.(29)), erro percentual médio absoluto (MAPE)

(Eq.(30)) e erro percentual absoluto (APE) (Eq.(31)). Os quatro primeiros estimadores foram aplicados a cada parâmetro, e o último a cada teste realizado, procurando validar e testar a potencialidade de cada modelo. Para isto, com modelos neurais foram simulados para cada topologia e com conjuntos de testes foram aleatoriamente selecionados com o intuito de obter a distribuição de erros e o desempenho de cada topologia a partir de seus estimadores. As Figuras 31, 32, 33 e 34 representam a distribuição dos erros percentuais absolutos de cada topologia.

$$\frac{\sum_1^n (vr_n - vs_n)^2}{n} \quad (27)$$

$$\sqrt{\frac{\sum_1^n (vr_n - vs_n)^2}{n}} \quad (28)$$

$$\frac{\sum_1^n |vr_m - vs_m|}{n} \Bigg|_{m=F.H.D} \quad (29)$$

$$\frac{\sum_1^n \frac{|vr_m - vs_m|}{vr_m}}{n} \Bigg|_{m=F.H.D} \quad (\textit{percent}) \quad (30)$$

$$\sum_{n=F.H.D} \frac{|vr_n - vs_n|}{3vr_n} \quad (\textit{percent}) \quad (31)$$

onde vr é valor real parametrizado e vs é o valor simulado pela RNA.

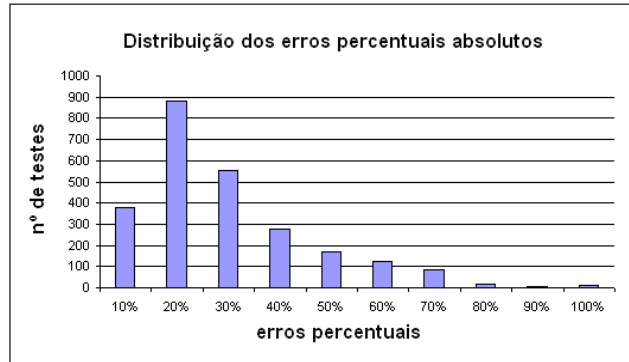


Figura 28 – Distribuição dos erros APE, RNA 1.

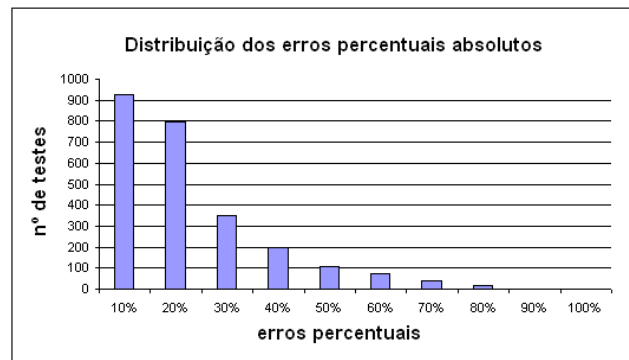


Figura 29 – Distribuição dos erros APE, RNA 2.




Figura 30 – Distribuição dos erros APE, RNA 3.




Figura 31 – Distribuição dos erros APE, RNA 4.

Para verificar a significância dos valores simulados (VS) obtidos com a RNA, foi aplicado o método estatístico de regressão linear sobre os resultados e os

valores reais (VS) parametrizados e calculado o coeficiente de determinação R^2 (quadrado do coeficiente de Pearson) medindo a proporção da variabilidade de VS que é explicada por VR. O valor de R^2 muito próximo da unidade indica uma forte relação entre as duas variáveis (MONTGOMERY e RUNGER, 2003). Estes resultados e os resultados obtidos para os estimadores MAD, MAPE, MSE e ASU são apresentados na Tabela 4.

Tabela 4 – Análise dos erros dos testes para cada parâmetro e tempo médio de processamento.

MAD(cm)				
RNA	F	H	D	
1	1,65	2,90	3,56	
2	1,01	2,49	2,51	
3	1,73	3,42	3,77	
4	1,71	1,98	2,18	
MAPE				
RNA	F	H	D	
1	18,20%	27,56%	28,73%	
2	9,69%	24,11%	21,76%	
3	16,75%	31,48%	44,92%	
4	15,05%	23,84%	23,23%	
MSE(cm²)				
RNA	F	H	D	
1	5,13	12,63	20,64	
2	3,41	10,90	12,92	
3	5,72	17,94	20,07	
4	5,32	7,73	10,78	
ASU(cm)				
RNA	F	H	D	
1	2,26	3,55	4,54	
2	1,85	3,30	3,59	
3	2,39	4,24	4,48	
4	2,31	2,78	3,28	
R²				
RNA	F	H	D	
1	0,85	0,52	0,19	
2	0,89	0,61	0,56	
3	0,80	0,45	0,24	
4	0,83	0,72	0,70	
Tempo médio de processamento para cada conjunto testado				
RNA 1	RNA 2	RNA 3	RNA 4	
1,00	7,54	2,89	81,95	

Tempo normalizado em função do registro RNA 1 = 1,18 segundos.

5.5 RESULTADOS E DISCUSSÃO

A partir dos gráficos de distribuição de erros dos testes realizados, é possível verificar que as RNA 1, 2, 3 e 4 apresentaram uma grande concentração dos erros percentuais absolutos (APE) nos intervalos de 10, 20 e 30%, indicando erros de baixa significância. Utilizando como critério o percentual de erros inferiores a 30% para avaliar as quatro topologias, observa-se (Figura 32) que a RNA 2 apresentou o melhor desempenho, com 82,56% das estimativas neste intervalo, seguida pela RNA 4, 77,12%, RNA 1, 72,68%, e por fim a RNA 3 com 61,64%.




Figura 32 – Desempenho das topologias testadas.

Analisando individualmente cada parâmetro na Tabela 4 e verificando os erros dos testes cometidos pelas topologias de RNA, é possível verificar que em média os menores erros foram obtidos pela RNA 2 e RNA 4. A RNA 2 apresentou resultados positivos para identificação do parâmetro F , sendo observado para este parâmetro um MAD de 1,01 cm. Os parâmetros H e D foram melhores avaliados pela RNA 4, com MAD de 1,98 e 2,18 cm respectivamente. O estimador MAD utilizado indica o desvio médio absoluto para cada parâmetro, indicando a flutuação média dos erros nos cem conjuntos de testes.

O erro quadrático médio (MSE) obtido pela RNA 2 foi igual $3,41 \text{ cm}^2$ para o parâmetro F , seguido pelos parâmetros H , $7,73 \text{ cm}^2$ e D , $10,78 \text{ cm}^2$ obtidos pela

RNA 4. Em termos matemáticos, a raiz quadrada do MSE indica a incerteza padrão média (ASU) dos resultados, ou seja, o valor de erro de cada parâmetro, assim, a incerteza de cada um destes parâmetros citados é de 1,85, 2,78 e 3,28 cm.

Na análise dos erros percentuais médios absolutos (MAPE), o menor valor foi observado para o parâmetro F , 9,69%, nos testes realizados pela RNA 2. Para este mesmo estimador a RNA 4 apresentou o percentual de 23,84 para o parâmetro H e a RNA 2 obteve 21,76 para parâmetro D .

Os resultados verificados anteriormente aliados aos valores obtidos para o coeficiente de determinação R^2 indicam maior eficiência para determinação do parâmetro F , 0,89, pela RNA 2, seguido pelos parâmetros H e D , com R^2 iguais a 0,72 e 0,70 obtidos pela RNA 4.

Em relação ao intervalo de operação de cada uma das RNA, o menor valor obtido para o limite inferior do intervalo foi conseguido pela RNA 4 (Tabela 2), apresentando também a melhor média de MMSE (menor média dos erros quadráticos médios). O menor valor obtido para o limite superior foi conseguido pela RNA 1, que também apresentou menor tempo médio de treinamento.

O fator tempo foi considerado nesta aplicação, com o intuito de verificar a aplicabilidade ou não de determinada topologia, pois, para topologias contendo um número elevado de neurônios, a fase de treinamento pode se tornar dispendiosa ou até mesmo impraticável, exigindo hardware de alta capacidade de processamento e grande quantidade de tempo. Desta forma, o tempo de treinamento acaba sendo um fator importante na escolha da abordagem dada ao reconhecimento de padrões de defeitos, sendo mais um atributo relevante de acordo com o nível de precisão desejado.

Outras funções de ativação (*Sigmóide e Linear com saturação*) bem como algoritmos de treinamento (*Gradient descent backpropagation, Gradient descent backpropagation com taxa adaptativa, Gradient descent backpropagation com momentum e taxa adaptativa e Levenberg-Marquardt backpropagation*) foram utilizados em testes comparativos, mas apresentaram resultados inferiores aos obtidos a partir da aplicação das funções de ativação e algoritmos de aprendizado definidos em 5.2.

5.6 CONCLUSÃO DO CAPITULO 5

De acordo com os resultados apresentados na Tabela 4, verifica-se que a RNA 2 e a RNA 4 foram as topologias que apresentaram os melhores resultados globais (R^2 , MAPE, APE, MSE, incerteza padrão média), seguida pela RNA 1 e 3.

Analisando as redes neurais de maior eficiência, foi verificado a partir dos testes realizados, que a RNA 2 obteve êxito em 82,56% das estimativas, com erros relativos médios inferiores a 30% para os parâmetros característicos dos defeitos e a RNA 4, 77,12%, tornando possível a identificações de padrões defeituosos nas estruturas de concreto. Apesar da RNA 1 ter apresentado para esta análise um valor de 72,68%, seus estimadores individuais (Tabela 4) não são bons, quando comparados aos conseguidos com as RNA 2 e 4.

Desta forma, os resultados obtidos a partir dos inúmeros treinamentos, validações e testes indicam que a RNA 2 e a RNA 4 são as topologias que melhor desempenham a tarefa de reconhecimento de padrões de defeitos a partir das imagens térmicas e a escolha de uma das topologias está relacionada ao nível de precisão desejado e ao tempo disponível para operação da rede.

A partir destes resultados e conclusões, foi desenvolvido o aplicativo “*Thermography and Artificial Neural Network*” em ambiente Matlab R2010® para o processamento e análise de imagens termográficas de estruturas de concreto. Detalhes sobre o aplicativo são apresentados no capítulo 6.

CAPÍTULO 6

6 APLICATIVO DE TERMOGRAFIA E REDES NEURAIS ARTIFICIAIS

Este capítulo apresenta o aplicativo desenvolvido com base no estudo realizado sobre reconhecimento de padrões de defeitos em estruturas de concreto a partir de imagens térmicas estacionárias e redes neurais artificiais. No item 6.1 é apresentada a interface gráfica do aplicativo e as informações sobre o seu funcionamento estão presentes em 6.2. No item 6.3 o aplicativo é testado com modelos irregulares simulados computacionalmente para verificar o seu desempenho.

6.1 INTERFACE GRÁFICA

A partir dos resultados obtidos neste trabalho foi desenvolvido o aplicativo *Thermography and Artificial Neural Network* (Figura 33), utilizando linguagem de programação e recursos gráficos pertencentes ao software comercial Matlab R2010®.

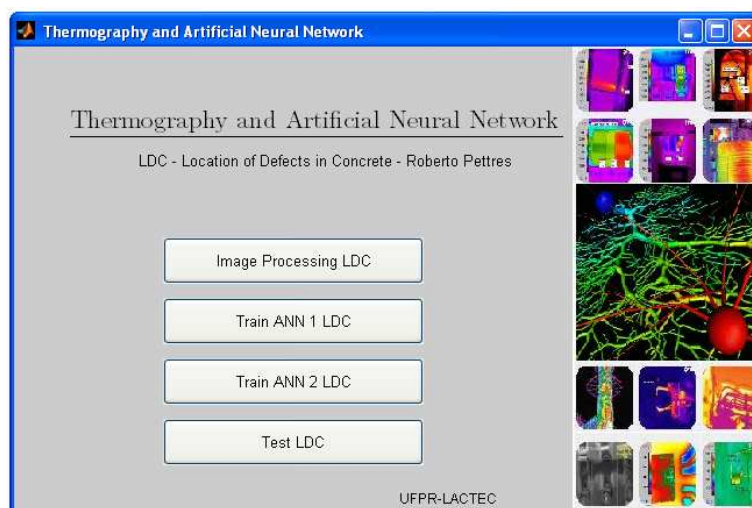
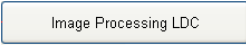




Figura 33 – Interface do aplicativo Thermography and Artificial Neural Network.

6.2 FUNCIONAMENTO DO APLICATIVO

A funcionalidade do aplicativo é apresentada em ambiente Matlab R2010®, selecionando-se o diretório contendo os arquivos para teste e digitando a palavra *start* no espaço de trabalho (Figura 36). Este comando carrega a interface gráfica do aplicativo contendo os botões de operação. O botão  realiza o processamento das imagens convertendo-as para o padrão RGB e posteriormente, para o padrão térmico bidimensional permitindo a seleção dos sinais funcionais utilizados no treinamento das redes neurais artificiais. Neste processamento também é identificado o centro de gravidade da região de menor temperatura do campo térmico de cada imagem de teste. Sendo realizado o processamento, um clique sobre os botões  e  inicializam duas redes neurais artificiais que diferem por suas topologias. A Figura 34 e a Figura 35 ilustram cada uma das topologias.




Figura 34 – Topologia da ANN 1.





Figura 35 – Topologia da ANN 2.

As duas arquiteturas são do tipo *feedforward* e suas topologias utilizam aprendizado supervisionado, função tangente hiperbólica (Eq.(24)) na primeira e segunda camada escondida, função linear (Eq.(25)) para a camada de saída e função de treinamento *trainbr* do Matlab R2010® que emprega o algoritmo de Regularização Bayesiana com retropropagação (algoritmo *backpropagation*).

Sendo realizado o treinamento de uma das topologias, a ferramenta computacional está pronta para realizar os testes. Para isto, um clique sobre o botão  seleciona os sinais funcionais do conjunto de testes obtidos no processamento das imagens e aplica-os à rede neural artificial definida (ANN 1 ou ANN 2). O resultado do conjunto de testes é apresentado na tabela indexada do Matlab R2010®, trazendo os valores para os parâmetros F , H e D desejados, com o nível de precisão definido para cada modelo (ASU). Nesta mesma tabela também são apresentadas as coordenadas do centro de gravidade das menores temperaturas observadas em cada imagem, sendo um indicativo da localização da anomalia térmica de acordo com os resultados obtidos no presente trabalho (Figura 37).

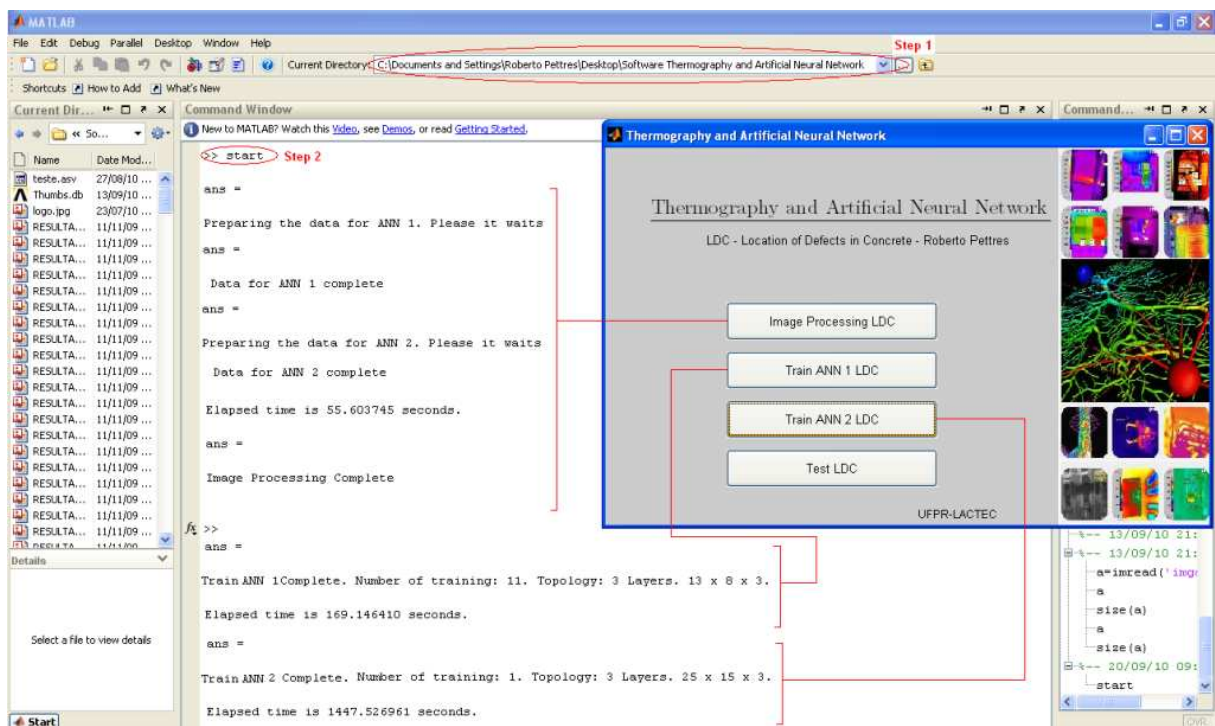


Figura 36 – Operação do aplicativo Thermography and Artificial Neural Network.

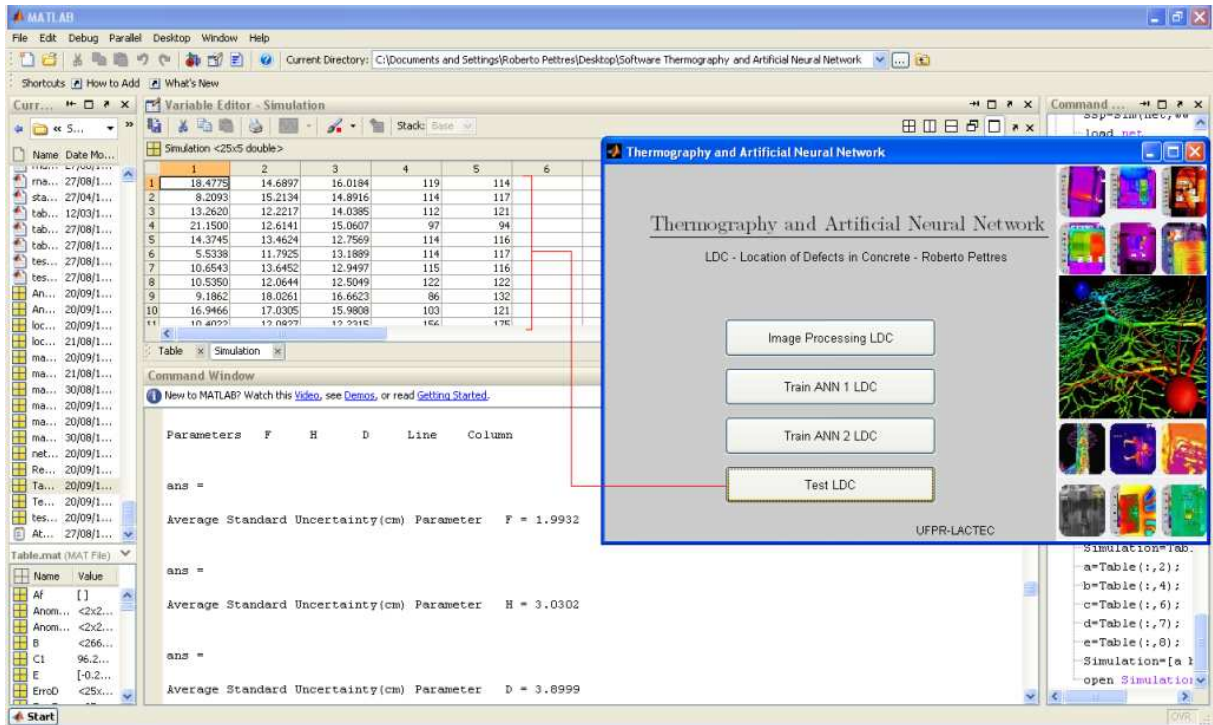


Figura 37 – Operação do aplicativo Thermography and Artificial Neural Network.

6.3 TESTANDO O APLICATIVO COM MODELOS IRREGULARES

Com o intuito de verificar a potencialidade do aplicativo, novos valores para os parâmetros F , H , P e D da anomalia foram estabelecidos bem como sua localização e geometria. Estas alterações representam ruídos no conjunto de sinais funcionais das redes neurais artificiais e são úteis para testar a capacidade de generalização do modelo matemático. A Figura 38 ilustra um dos 25 casos em que os parâmetros da anomalia são diferentes dos utilizados na fase de treinamento das RNA. A Figura 39 ilustra o caso em que o defeito contendo as mesmas dimensões dos modelos de treinamento foi deslocado do centro da imagem em uma área de análise de 1 m^2 . A Figura 40 e a Figura 41 ilustram dois casos contendo cada um, uma anomalia com geometria irregular, diferente do modelo prismático regular utilizado na fase de treino.




Figura 38 – Modelo de um caso irregular para os parâmetros F , H , P e D .




Figura 39 – Caso com maior região de análise.




Figura 40 – Caso com a geometria irregular 1.

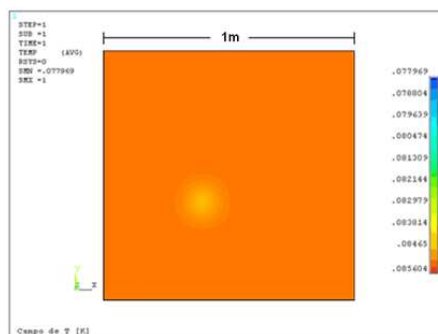


Figura 41 – Caso com a geometria irregular 2.

6.3.1 Testes com parâmetros diferenciados para o defeito

Após o processamento das imagens pelo aplicativo *Thermography and Artificial Neural Network*, a amostra contendo 25 imagens foi testada pelo mesmo e os resultados comparados entre as duas topologias.

A Tabela 5 e a Tabela 6 apresentam o resultado do conjunto testado. Com o intuito de verificar o desempenho individual de cada topologia, forma comparados os valores reais (VR) dos parâmetros utilizados na modelagem térmica do problema e os valores simulados (VS) fornecidos pelos modelos neurais e aplicados os estimadores de erro MAD, APE, MSE, ASU e R^2 .

Tabela 5 – Resultados da ANN 1 para os testes com parâmetros diferenciados.

Teste	<i>F</i>		<i>H</i>		<i>D</i>		MAD	APE
	VR	VS	VR	VS	VR	VS		
1	19,00	18,72	7,00	7,40	14,00	13,25	0,48	4,20%
2	9,00	15,18	17,00	17,07	16,00	15,82	2,14	23,39%
3	5,00	6,42	7,00	7,40	6,00	6,46	0,76	13,99%
4	11,00	13,16	15,00	15,85	6,00	6,42	1,14	10,78%
5	13,00	12,97	13,00	16,07	8,00	12,48	2,52	26,59%
6	9,00	10,62	5,00	6,42	16,00	14,69	1,45	18,23%
7	7,00	7,40	19,00	16,85	14,00	14,14	0,90	6,01%
8	11,00	8,95	19,00	18,72	6,00	7,61	1,31	15,63%
9	9,00	11,74	13,00	15,91	12,00	14,33	2,66	24,05%
10	15,00	15,85	19,00	18,72	10,00	16,14	2,42	22,84%
11	15,00	16,09	5,00	10,30	8,00	8,61	2,33	40,29%
12	17,00	17,68	13,00	12,81	10,00	13,61	1,49	13,87%
13	13,00	12,70	15,00	11,24	8,00	8,61	1,56	11,65%
14	19,00	18,72	11,00	11,07	8,00	11,23	1,19	14,15%
15	19,00	17,37	9,00	9,80	8,00	8,61	1,01	8,36%
16	11,00	9,43	19,00	18,72	8,00	8,51	0,79	7,36%
17	7,00	7,45	19,00	18,82	10,00	13,96	1,53	15,69%
18	19,00	19,00	9,00	14,34	20,00	14,91	3,48	28,28%
19	19,00	18,72	13,00	10,18	8,00	8,61	1,24	10,27%
20	13,00	16,57	11,00	11,45	20,00	12,47	3,85	23,07%
21	17,00	16,63	15,00	15,85	10,00	12,55	1,25	11,09%
22	7,00	10,29	17,00	17,77	18,00	15,20	2,29	22,37%
23	19,00	18,72	19,00	16,84	12,00	16,27	2,24	16,15%
24	17,00	17,29	17,00	16,91	18,00	16,16	0,74	4,16%
25	11,00	10,55	17,00	18,59	20,00	15,71	2,11	11,63%
	MSE	3,66	MSE	4,56	MSE	9,85		
	ASU	1,91	ASU	2,13	ASU	3,14		
	R²	0,8434	R²	0,7924	R²	0,5561		

VR=valor real, VS=valor simulado.

Tabela 6 – Resultados da ANN 2 para os testes com parâmetros diferenciados.

Teste	<i>F</i>		<i>H</i>		<i>D</i>		MAD	APE
	VR	VS	VR	VS	VR	VS		
1	19,00	18,65	7,00	10,38	14,00	12,13	1,86	21,14%
2	9,00	8,83	17,00	17,03	16,00	18,29	0,83	5,47%
3	5,00	4,91	7,00	7,32	6,00	5,92	0,16	2,56%
4	11,00	15,44	15,00	12,78	6,00	5,90	2,25	18,96%
5	13,00	13,10	13,00	14,60	8,00	8,68	0,79	7,17%
6	9,00	12,40	5,00	6,87	16,00	16,77	2,01	26,65%
7	7,00	6,36	19,00	18,73	14,00	14,66	0,52	5,07%
8	11,00	12,28	19,00	17,78	6,00	7,13	1,21	12,33%
9	9,00	11,02	13,00	14,71	12,00	16,82	2,85	25,24%
10	15,00	15,12	19,00	17,99	10,00	18,50	3,21	30,37%
11	15,00	18,13	5,00	6,13	8,00	7,77	1,50	15,45%
12	17,00	18,74	13,00	12,91	10,00	13,33	1,72	14,75%
13	13,00	16,14	15,00	14,75	8,00	7,88	1,17	9,12%
14	19,00	20,16	11,00	12,43	8,00	7,62	0,99	7,97%
15	19,00	20,12	9,00	11,21	8,00	7,03	1,43	14,21%
16	11,00	11,38	19,00	18,48	8,00	8,45	0,45	3,94%
17	7,00	7,22	19,00	18,83	10,00	15,97	2,12	21,27%
18	19,00	19,03	9,00	11,24	20,00	17,82	1,48	11,96%
19	19,00	17,33	13,00	12,26	8,00	9,81	1,40	12,35%
20	13,00	16,38	11,00	12,82	20,00	17,88	2,44	17,74%
21	17,00	18,78	15,00	16,78	10,00	13,52	2,36	19,19%
22	7,00	6,71	17,00	18,78	18,00	15,27	1,60	9,90%
23	19,00	17,46	19,00	14,68	12,00	12,23	2,03	10,92%
24	17,00	19,85	17,00	18,69	18,00	16,45	2,03	11,77%
25	11,00	13,03	17,00	17,82	20,00	18,82	1,34	9,72%
	MSE	3,81	MSE	2,96	MSE	7,65		
	ASU	1,95	ASU	1,72	ASU	2,77		
	R²	0,8814	R²	0,8796	R²	0,6927		

VR=valor real, VS=valor simulado.

As Figuras 42, 43 e 44 trazem os resultados das simulações contidas na Tabela 5 e Tabela 6 para os parâmetros *F*, *H* e *D*. As linhas representam as respostas de cada uma das estruturas neurais e os pontos representam os valores reais padronizados e conhecidos.




Figura 42 – Resultados das simulações para o parâmetro F.




Figura 43 – Resultados das simulações para o parâmetro H.

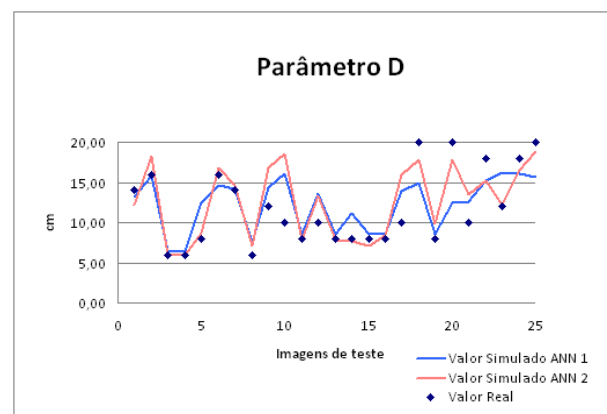


Figura 44 – Resultados das simulações para o parâmetro D.

Neste conjunto de testes a ANN 1 obteve êxito em 96% das estimativas, com erros percentuais absolutos inferiores a 30% para os parâmetros característicos dos defeitos e média de 1,72 cm para o desvio médio absoluto. Foi verificado um nível satisfatório de correlação entre as variáveis VR e VS, dos parâmetros H e D tomando como referência os valores obtidos para o coeficiente de correlação R^2 com esta topologia, iguais a 0,7924 e 0,5561 respectivamente. Para este coeficiente o parâmetro F apresentou melhor resultado, 0,8434.

A ANN 2 apresentou resultados superiores para o coeficiente de correlação R^2 dos parâmetros F , H e D (0,8814, 0,8796 e 0,6927 respectivamente) em comparação com os valores obtidos com a ANN 1. A ANN 2 apresentou 100% das estimativas com erros percentuais absolutos inferiores a 30% e 1,59 cm em média para o estimador MAD. Estes resultados são superiores aos obtidos pela ANN 1 e são ilustrados pelos gráficos anteriores onde é possível verificar uma melhor aproximação por parte da linha em vermelho (ANN 2) aos valores reais do que pela linha em azul (ANN 1).

6.3.2 Teste em área de maior dimensão contendo um defeito não centralizado

No teste para o caso em que o defeito foi deslocado do centro da imagem, o processamento realizado pelo aplicativo se mostrou eficiente para indicar a possível localização do defeito a partir da região de menor temperatura. A Figura 45 ilustra o local indicado pelo aplicativo estando em comum acordo com a análise térmica representada pelo gráfico de temperaturas.




Figura 45 – Processamento e análise de temperaturas para localização do defeito no interior do bloco.

Este teste também teve como objetivo avaliar a capacidade do aplicativo em intervenções práticas em que a área em análise apresenta maior dimensão, pois a

técnica foi desenvolvida para analisar áreas quadradas de 0,16 m² (modelos de treinamento) a partir da região de menor temperatura. Os parâmetros médios obtidos com as topologias ANN 1 e ANN 2 são apresentados na Tabela 7.

Tabela 7 – Resultados dos testes para localização irregular.

Topologia	<i>F</i>		<i>H</i>		<i>D</i>		MAD	APE
	VR	VS	VR	VS	VR	VS		
ANN 1	5,00	5,03	5,00	5,41	5,00	6,50	0,65	13,00%
ANN 2	5,00	6,13	5,00	4,81	5,00	2,79	1,18	23,53%

VR=valor real, VS=valor simulado.

Neste teste a ANN 1 apresentou um desvio médio absoluto (MAD) de 0,65 cm para os parâmetros *F*, *H* e *D* enquanto a ANN 2 apresentou 1,18 cm. Comparando o erro percentual absoluto (APE) das duas topologias, pode-se afirmar que a ANN 1 obteve melhores resultados para os parâmetros desejados, atingindo um nível de precisão de 87% enquanto a ANN 2 obteve 76,57%. Analisando cada parâmetro individualmente, verifica-se que o parâmetro *H* foi avaliado em média com maior precisão pelas duas topologias atingindo em média um erro percentual absoluto de 6,06%, seguido pelo parâmetro *F*, 11,68% e *D*, com um nível médio de erro igual a 37,20%.

Como neste teste os parâmetros do defeito são os mesmos utilizados no modelo de treinamento, foi realizada uma análise sobre a distribuição de temperaturas nos dois casos (50x50cm – treinamento, 100x100cm – teste) para identificar o erro cometido pelas topologias. Nesta análise foi constatada divergência entre as distribuições de temperatura dos dois casos (Figura 46), proveniente da não equivalência entre as condições de contorno impostas aos modelos de 50x50cm e 100x100cm, influenciando de maneira negativa nas respostas dos modelos neurais.




Figura 46 – Comparação do perfil térmico do modelo 50x50 cm (treinamento) e 100x100 cm (teste).

6.3.3 Teste em área de maior dimensão contendo um defeito não centralizado e disforme

Na terceira etapa de testes, as imagens dos dois casos contendo anomalias com geometria irregular (Figura 47) foram processadas e testadas pelo aplicativo. As duas anomalias apresentam dimensões próximas às de um cubo de 125 cm^3 e foram posicionadas a 5 cm da face analisada termograficamente.




Figura 47 – Defeitos com geometrias irregulares utilizados no teste (1) e teste (2).

O processamento das imagens identificou a localização do defeito com precisão nos dois testes (Figura 48).




Figura 48 – Localização da região de menor temperatura indicando a posição do defeito para os testes 1 e 2.

Os resultados obtidos com as topologias para os dois testes diferiram a partir da oitava casa decimal, classificando os parâmetros F , H e D de cada teste em uma classe quando consideradas apenas duas casas decimais. Esta aproximação entre

os resultados é devida à semelhança na distribuição de temperatura na direção do defeito nos dois casos ilustrada pela Figura 49.




Figura 49 – Distribuição de temperaturas em x na direção do defeito para os testes 1 e 2.

Nestes testes a ANN 1 apresentou os valores 7,18, 5,35 e 5,74 centímetros para os parâmetros F , H e D respectivamente enquanto a ANN 2 obteve 8,84, 5,28 e 5,47 centímetros na mesma ordem.

Como nestes casos os defeitos apresentam geometrias irregulares, o único parâmetro que pode ser avaliado com os estimadores utilizados neste trabalho é o parâmetro D , apresentando um desvio médio absoluto (MAD) de 0,74 cm e um erro percentual absoluto (APE) de 14,8% com a aplicação da topologia ANN 1. Para estes estimadores a ANN 2 obteve 0,47 cm (MAD) e 9,4% (APE).

Para avaliar os parâmetros F e H foram calculadas as diagonais da face dos retângulos formados pelos lados F e H (largura e altura) fornecidos pelas duas topologias e estes valores, comparados ao valor aproximado da diagonal da face frontal do defeito (7,0711 cm), obtendo uma aproximação do erro percentual em relação ao valor real.

A diagonal do retângulo calculada a partir dos parâmetros F e H obtidos pela topologia ANN 1 mede 8,9540 cm, indicando um erro aproximado de 26,63% em relação a diagonal do defeito real. Para esta mesma análise a ANN 2 apresentou o valor 10,2968 cm, com erro de 45,62%.

CAPÍTULO 7

7 ENSAIO EXPERIMENTAL

Este capítulo apresenta as etapas do ensaio termográfico realizado no Laboratório de Materiais e Estruturas do LACTEC utilizando o equipamento InfraREM – SC80 e o aplicativo *Thermography and Artificial Neural Network*.

7.1 CONFECÇÃO DO MODELO EXPERIMENTAL

Um bloco cúbico de concreto convencional com aresta de 0,50 m foi preparado para os testes experimentais no Laboratório de Materiais e Estruturas (LAME). Este modelo foi executado de acordo com as condições e dimensões estabelecidas na modelagem computacional no Ansys 12®. Para simular o defeito no interior da estrutura, utilizou-se um tijolo com dimensões 9 cm x 14 cm x 19 cm, cujas arestas maior e menor foram posicionadas em paralelo à face do bloco, sendo seu espaço substituído por brita durante a concretagem simulando uma região de elevada porosidade (Figura 50).




Figura 50 – Posicionamento do defeito no interior do bloco.

A dosagem do concreto utilizado se assemelha a mesma empregada na face montante da UHE Fundão de propriedade da ELEJOR. A Tabela 8 apresenta as características da dosagem empregada nesse teste experimental.

Tabela 8 – Dosagem do concreto do bloco de ensaio.

Materiais	Registro LAME	Massa S.S.S.	Umidade (%)	Absorção (%)	Massa a corrigir	Massa corrigida
Brita 38 mm (kg)						
Brita 25 mm (kg)						
Brita 19 mm (kg)	1.0591.07	99,97	2,1%	1,7%	0,39	100,36
Areia artificial (kg)	1.0590.07	57,47	5,4%	2,0%	1,92	59,39
Areia natural (kg)						
Cimento (kg)	1.0169.09	35,42	-	-	-	35,42
Água (kg)		18,83	-	-	-2,31	16,52
Pozolana (kg)	1.0076.09	3,94	-	-	-	3,94
Supplast (g)			-	-	-	
Plastif 0,40% (g)	1.0982.08	141,68	-	-	-	141,68
Incorp (g)			-	-	-	

A seqüência de fotos abaixo (Figura 51) ilustra a concretagem do bloco:

1. *forma montada para o bloco cúbico;*
2. *concretagem da camada inicial;*
3. *posicionamento de um tijolo para definir o espaço ocupado pelo defeito;*
4. *substituição do tijolo por brita simulando uma região de elevada porosidade;*
5. *deposição da segunda camada de concreto.*



Figura 51 – Concretagem do bloco com defeito para ensaios em laboratório.

O modelo final executado é ilustrado pela Figura 52.



Figura 52 – Bloco de concreto com defeito para ensaios em laboratório.

Para simular as condições de contorno estabelecidas no modelo computacional, um campo de temperatura uniforme foi aplicado a partir de uma manta térmica siliconada (Figura 53) na superfície do bloco em uma das faces. Na face oposta, o resfriamento por convecção (ar) foi naturalmente conseguido no ambiente de ensaio, estando de acordo com a condição de contorno proposta (Figura 54). As demais superfícies externas foram envolvidas por material isolante (lã de rocha 50 mm e densidade 32, isopor 50 mm e manta térmica em alumínio 2 mm) por serem consideradas adiabáticas, ou seja, com fluxo térmico nulo (Figura 55).

Nas superfícies de contato do defeito com o bloco, os balanços de energia são conseguidos por condução do calor, igualando os fluxos de calor entre os elementos adjacentes interiores ao bloco.



Figura 53 – Manta térmica siliconada.



Figura 54 – Convecção com o ar.




Figura 55 – Controle de fluxo térmico nulo. (1) Bloco de concreto, (2) Revestimento do bloco com lã de rocha e manta de alumínio, (3) Terceira camada de revestimento com isopor e (4) Quarta camada de revestimento utilizando a manta de alumínio.

A metodologia adotada para este ensaio é descrita no trabalho de Gerald C. Holst, intitulado “*Common Sense Approach to Thermal Imaging*” (2000), simulando a excitação de calor em parte da estrutura de concreto que contém uma anomalia em seu interior. A Figura 56 ilustra a montagem final dos equipamentos.




Figura 56 – Ensaio de termografia.

7.2 OBTENDO AS IMAGENS TÉRMICAS

Para captar a alteração do fluxo de calor na superfície oposta à fonte de calor foi utilizado o aparelho InfraREM–SC80 de termografia (Figura 57). Este equipamento lê as temperaturas superficiais de estruturas a partir da radiação infravermelha emitida pelo corpo em estudo e as registra em imagens coloridas (termogramas). De acordo com o fabricante InfraREM®, o equipamento apresenta campo de visão (*FOV – Field Of View*) de $20^{\circ} \times 15^{\circ}$ com distância mínima do foco de 0,1 m, sensibilidade térmica de $0,1^{\circ}\text{C}$, faixa de medição de -20°C a 250°C com precisão de $\pm 2\%$ da leitura e atualização automática de temperatura ambiente. Os arquivos de saída são do formato SAT e JPEG, resolução de 14 bits (160 x 120 pixels) com dados de medição inclusos.



Figura 57 – Equipamento de termografia InfraREM®.

Após o posicionamento dos equipamentos para o ensaio, foi acionada a manta térmica durante 24 horas a uma temperatura constante de 100 °C ($T_w - T_a \approx 75K$) para simular a condição estacionária de fluxo de calor no material. Os termogramas foram obtidos a uma distância de 1,80 metros da superfície do bloco em intervalos de dois segundos como ilustra a Figura 58. A Figura 59 representa um destes termogramas.




Figura 58 – Captação das imagens termográficas.




Figura 59 – Termografia de uma face do bloco de concreto.

7.3 PROCESSANDO E TESTANDO AS IMAGENS

As imagens termográficas obtidas neste ensaio foram processadas e testadas pelo aplicativo *Thermography and Artificial Neural Network*. A Figura 60 ilustra parte deste processamento e indica satisfatoriamente a localização do defeito no interior do bloco de concreto de acordo com o modelo executado.

Centro de gravidade da região de menor temperatura




Figura 60 – Indício da localização do defeito.

A média dos testes realizados pelas topologias ANN 1 e ANN 2 são apresentados na Tabela 9:

Tabela 9 – Resultados dos testes experimentais.

Teste	<i>F</i>		<i>H</i>		<i>D</i>		MAD	APE
	VR	VS	VR	VS	VR	VS		
ANN 1	19,00	15,54	9,00	17,24	10,00	8,04	4,55	43,13%
ANN 2	19,00	22,47	9,00	12,46	10,00	12,05	3,00	25,78%

VR=valor real, VS=valor simulado pela RNA.

As aproximações obtidas com os modelos neurais apresentaram um APE de 43,13% pela ANN 1 e 25,78% pela ANN 2. Os resultados da análise experimental obtidos com a ANN 2 se assemelham aos conseguidos com os modelos simulados computacionalmente, apresentando um desvio médio absoluto de 3 cm, indicando potencialidade à ferramenta computacional desenvolvida e viabilidade para a metodologia de ensaio não destrutivo utilizada.

O percentual de erro observado neste teste pode ter sido causado pelo não atendimento total das condições de contorno estabelecidas na fase de treinamento das topologias, podendo causar perturbações térmicas nas imagens. Outro fator que também pode contribuir de maneira negativa nos resultados é a possível divergência entre o valor de R_k^2 definido na análise térmica e o R_k do elemento de concreto contendo o defeito, dada a impossibilidade de se obtê-lo com precisão.

² O coeficiente R_k é definido como a razão entre o coeficiente de condutividade térmica do defeito (K_d) e o coeficiente de condutividade térmica do concreto (K_B).

CAPÍTULO 8

8 CONCLUSÃO

A partir dos resultados obtidos com o software Ansys 12® foi constatado que a presença de um defeito no interior de um bloco maciço com propriedades equivalentes ao concreto, sob as condições térmicas (estacionárias) estabelecidas, produzia uma clara perturbação no campo térmico em uma face do bloco, sendo um indício de sua localização. Essa observação se tornou evidente ao se analisar o perfil térmico de cada caso simulado, apresentando como região de menor temperatura a projeção do defeito à superfície em análise. Este fato motivou o estudo de inteligência computacional através de redes neurais artificiais com o intuito de se identificar o tamanho e posição do defeito no interior do bloco. Um resultado deste estudo foi o desenvolvimento do algoritmo de identificação e localização do defeito, presente no aplicativo *Thermography and Artificial Neural Network*.

A primeira etapa deste estudo consistiu da leitura dos termogramas ou imagens térmicas e mineração de características relevantes para a formação de um banco de dados representativo para a modelagem com redes neurais artificiais. Esta leitura foi realizada com o software Matlab R2010® convertendo as imagens para o padrão RGB em uma matriz de ordem $M \times N \times 3$ e posteriormente processadas para o padrão térmico bidimensional utilizando o algoritmo desenvolvido para substituição descrito no item 4.1.

Para formar os conjuntos de características foram obtidas informações estatísticas sobre a distribuição térmica de cada imagem e foi desenvolvido o algoritmo para localização do defeito, registrando as variações térmicas a partir desta região bem como os valores máximo e mínimo de temperatura de cada caso simulado. Estas informações formaram a base do banco de dados para o desenvolvimento da topologia RNA 1.

O segundo conjunto de características foi composto pelos valores de temperatura em treze pontos distintos na imagem a partir da região que indicava a

localização da anomalia térmica. Estes dados foram utilizados para o desenvolvimento da topologia RNA 2.

O terceiro e quarto conjunto de características foram obtidos a partir de duas malhas quadradas de $0,16 \text{ m}^2$ contendo nove e vinte e cinco nós respectivamente, centradas sobre a região de menor temperatura de acordo com o algoritmo de localização do defeito. Na primeira malha nove valores de temperatura foram coletados e formaram o banco de dados da topologia RNA 3. Na malha seguinte, vinte e cinco valores foram obtidos, compondo assim, o conjunto de características da topologia RNA 4.

Os algoritmos para o processamento das imagens utilizados nesta etapa se mostraram ágeis e eficientes, demandando em média 0,03 segundos para processar cada arquivo e coletar as informações necessárias para a modelagem matemática das topologias neurais.

Em seguida, realizou-se um estudo que permitiu identificar o número de neurônios na segunda camada escondida das redes neurais artificiais que representasse o menor nível de erro de cada modelo neural. Este estudo definiu as topologias que foram testadas neste trabalho.

Entre as topologias testadas, foi verificado que a RNA 2 obteve êxito em 82,56% das estimativas, com erros relativos médios inferiores a 30% para os parâmetros característicos dos defeitos e a RNA 4, 77,12%, permitindo a correlação entre as características do conjunto de termogramas à existência de defeitos na estrutura de concreto. Apesar da RNA 1 ter apresentado para esta análise um valor de 72,68%, seus estimadores individuais são inferiores aos obtidos com as RNA 2 e 4. Para esta mesma análise, a RNA 3 obteve êxito em 61,64% de suas estimativas, resultado inferior em relação às outras topologias testadas.

A partir destes resultados e dos valores obtidos para o coeficiente de determinação R^2 de cada parâmetro, é possível afirmar que a RNA 2 apresenta maior precisão para determinação do parâmetro F , 0,89, em um tempo médio de 8,90 segundos para treinamento e teste, sendo os parâmetros H e D , determinados com maior eficiência pela RNA 4 com R^2 iguais a 0,72 e 0,70, respectivamente, em um intervalo de 96,71 segundos. Desta forma, os resultados obtidos a partir destes testes indicam que a RNA 2 e a RNA 4 são as topologias que melhor desempenharam a tarefa de reconhecimento de padrões de defeitos a partir das

imagens térmicas e a escolha de uma das topologias está relacionada ao nível de precisão desejado e ao tempo disponível para operação da rede.

Estes resultados foram sintetizados no aplicativo acadêmico *Thermography and Artificial Neural Network* em duas topologias, ANN 1 (RNA 2) e ANN 2 (RNA 4), atingindo um percentual de êxito igual a 92% para as estimativas dos parâmetros do defeito com erros relativos médios inferiores a 30% com o uso da topologia ANN 1 e igual a 100% com a topologia ANN 2 na análise de modelos simulados contendo irregularidades.

Na análise de imagens maiores e com defeitos com geometrias irregulares o aplicativo identificou com precisão a localização do defeito e apresentou resultados aproximados para os parâmetros monitorados, com um nível de erro de 13,00% com a topologia ANN 1 e 23,53% com a ANN 2.

Na análise experimental, as aproximações obtidas com o aplicativo apresentaram um erro médio percentual de 43,13% pela ANN 1 e 25,78% pela ANN 2. Os resultados fornecidos pela ANN 2 se assemelham aos conseguidos com os modelos simulados computacionalmente, indicando potencialidade para a ferramenta computacional desenvolvida e viabilidade para a metodologia de ensaio não destrutivo utilizada.

Nas simulações realizadas não foi possível detalhar ou classificar o tipo de defeito, pois diferentes imagens com defeitos semelhantes são reconhecidas e classificadas em uma mesma classe. No entanto, em determinadas imagens, as simulações indicaram a existência de problemas no interior da estrutura, sua localização e suas dimensões aproximadas.

Finalizando, ressalta-se que todos os objetivos traçados nesse trabalho foram atingidos, mas apesar dos resultados obtidos terem sido satisfatórios, segue algumas sugestões para continuidade dessa pesquisa:

- (i) a aplicação de algoritmos de processamento de imagens em outros níveis de cores;
- (ii) investigação de técnicas alternativas para aprendizado das redes e uso de outras funções de ativação, bem como a quantidade de sinais funcionais e de camadas escondidas;
- (iii) avaliação da influência da heterogeneidade do concreto nas simulações térmicas e o impacto sobre as respostas das redes neurais artificiais;

- (iv) geração de modelos sintéticos em áreas de maior dimensão;
- (v) utilização de outras linguagens computacionais para implementação dos modelos neurais;
- (vi) comparação dos resultados com outros métodos numéricos de inteligência computacional.

Ainda, a pesquisa pode ser direcionada para análise de imagens térmicas provenientes de regimes transientes de transferência de calor, que supostamente seriam mais facilmente encontrados ou aplicados na prática.

PRODUÇÕES

- PETTRES, R.; LACERDA, L. A. Análise de imagens termográficas de estruturas de concreto a partir de redes neurais artificiais. In: **CILAMCE - Congresso Ibero Latino Americano de Métodos Computacionais em Engenharia**, Buenos Aires, 2010.
- PETTRES, R.; LACERDA, L. A. Reconhecimento de padrões de defeitos em concreto a partir de imagens térmicas estacionárias e redes neurais artificiais. **Revista Ágora**, 2010. Submetido para publicação.
- PETTRES, R.; FIGUEIRA, I. F. R.; LACERDA, L. A. Seleção de método não destrutivo para detecção da integridade estrutural da face montante de barragens em CCR. In: **CITENEL - Congresso de Inovação Tecnológica em Energia Elétrica**, 2011. Submetido para publicação.
- PETTRES, R.; JAREK, A.; LACERDA, L. A. Thermography and Artificial Neural Network. **Learning and Nonlinear Models. Revista da Sociedade Brasileira de Redes Neurais Artificiais (SBRN)**, 2011. Submetido para publicação.
- PETTRES, R.; LACERDA, L. A. Non-Destructive Technique for Diagnosis of Concrete CCV from Infrared and Neural Network. **NDT and E International**, 2011. Submitted for publication.

REFERÊNCIAS

- ANDRADE, M. C. Spatiotemporal Patterns Estimation Using a Multilayer Perceptron Neural Network in a Solar Physics Application, Learning and Nonlinear Models – **Revista da Sociedade Brasileira de Redes Neurais**. V. 2, N. 1, pp. 14-21, 2004.
- ANDRIOLO, F. R. **Contribuições para o conhecimento e desenvolvimento do concreto rolado**. Rio de Janeiro: Graphos, 1989.
- AVDELIDIS N.P., MOROPOULOU A. Application of infrared thermography for the investigation of historic structures. **Journal of Cultural Heritage**. V.5, N. 3, pp. 119-127, 2004.
- BARRETO, J. M. **Introdução às Redes Neurais Artificiais**. Santa Catarina: UFSC, 2004.
- BISHOP, C. M. **Neural Networks for Pattern Recognition**. Oxford: Clarendon Press, 1995.
- BRANCO, S. T. Aplicação de Redes Neurais Artificiais em modelos de previsão de demanda para equipamentos de infraestrutura de telecomunicações. In: **XXVIII Encontro Nacional de Energia de Produção - ENEGEP**. Rio de Janeiro, Brasil: 2008.
- BRAY, D. E., McBRIDE, D. **Nondestructive testing techniques**, Nova York: John Wiley and Sons, 1992.
- BUCHANAN, G. R. **Schaum's outline of theory and problems of element analysis**. USA: McGraw-Hill Companies, 1994.
- CHAGAS, C. S. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. **Revista Brasileira de Engenharia Agrícola e Ambiental**. V.13, n.3, pp.319–327, 2008.
- CHIANG, C.H., et al., 2006. Modeling of Heat Transfer in a Multi-layered System for Infrared Inspection of a Building Wall. In: **12th Asia-Pacific Conference on NDT - 12th A-PCNDT**. Auckland, Nova Zelândia: 2006.

- CLARK, M.R., McCANN, D.M., FORDE, M.C. Application of infrared thermography to the non-destructive testing of concrete and masonry bridges. **NDT&E International**. V. 36, N.1, pp. 265-275, 2003.
- DEHSHIBI, M. M. A new algorithm for age recognition from facial images. **Signal Processing**. V. 90, N.1, pp. 2431-2444, 2010.
- DESCHAMPS, F. **Redes Neurais Artificiais – Fundamentos das Redes Neurais**. (Apostila do curso de Ciência da Computação) Santa Catarina, UFSC: 2008.
- ELBALLOUTI, A., BELATTAR, S. Numerical method applied to the non-destructive characterization of the cracks in the roadways. **Physical & Chemical News**. V. 35, pp. 43-47, 2006.
- ELBALLOUTI, A., BELATTAR, S. Finite Element Method Applied to Thermal Nondestructive Characterization of Delamination in the Dam Structure. In: **16th World Conference on Nondestructive Testing**. Shanghai, China: 2008.
- FARIA, É. F. Modelo de Previsão da Elevação Adiabática de Temperatura do Concreto através de Redes Neurais artificiais. In: **Congresso Ibero Latino Americano de Métodos Computacionais em Engenharia - CILAMCE**. Recife, Brasil: 2004.
- FLÓRIO FILHO, O., Detecção automática do aquecimento em componentes de um sistema industrial, baseada no reconhecimento de imagens térmicas, In: **XXVI Encontro Nacional de Engenharia da Produção - ENEGEP**. Ceará, Brasil: 2006.
- FORESSE, F. D., HAGAN, M. T. **Gauss-Newton Approximation to Bayesian Learning**. Disponível em: < <http://hagan.okstate.edu/icnn97a.pdf> >. Acesso em 06 Ago 2010.
- GAILIUS, A., ŽUKAUSKAS, D. Determination of Concrete Structural Defects by Infrared Spectrum Analysis. **Material Science**. V. 9, N. 1, pp. 106-110, 2003.
- GALUSHKIN, A. I. **Neural networks theory**. New York: Springer, 2007.
- HAGAN, M. T., DEMUTH, H. B. **Neural Network Design**. China: China Machine Press, 2001.

- HANSELMAN, D., LITTLEFIELD, B. **Mastering Matlab – A Comprehensive Tutorial and Reference**. USA: Prentice Hall, 2001
- HAYKIN, S. **Neural Networks – A Comprehensive Foundation**. Ontário: Pearson Prentice Hall, 2003.
- HOLST, G. C. **Common Sense approach to thermal imaging**. Connecticut: Spie Press, 2000.
- INÁCIO, G. R., ZDANSKI, P. S. B., CARRAZEDO, R., LACERDA, L. A. Análise da Viabilidade do uso de Termografia como Ensaio não Destrutivo para Identificação de Falhas Internas de Concretagem. In: **Congresso Ibero Latino Americano de Métodos Computacionais em Engenharia - CILAMCE**. Armação de Búzios, Brasil: 2009.
- INCROPERA, F. P., DeWITT, D. P. **Fundamentos de Transferência de Calor e Massa**. Rio de Janeiro: LTC, 1992.
- INOUE, G. **Determinação das tensões de origem térmica para indução de juntas de contração em barragens de concreto compactado a rolo**. (Tese de doutorado em Engenharia Civil – Escola Politécnica). Universidade de São Paulo, São Paulo, 1990.
- KOAY, C. J. H., FRIZE, M. Analysis of Breast Thermography with an Artificial Neural Network. In: **26th Annual International Conference of the IEEE EMBS**, San Francisco, USA: 2004.
- KROSE, B., SMAGT, P. **An Introduction to Neural Networks**. Amsterdam: University of Amsterdam, 1996.
- KRUGER, D., *et al.* Efeito das tensões de origem térmica no comportamento tridimensional de barragens executadas em camadas. In: **Seminário Nacional de Produção e Transmissão de Energia Elétrica - SNPTEE**. Curitiba, Brasil: 2005.
- KWON, Y. W., BANG, H. **The finite element method using MATLAB/ by Young W Kwon and Hyochoong Bang**. Florida: CRC Press, 1997.
- LACTEC. **Complexo Santa Clara – Fundão**. (Relatório de monitoramento. RT LAME. 012.2007-R1), 2007.

- LEE, T. L. Back-propagation neural network for long-term tidal predictions. **Ocean Engineering**. V.31, N. 4, pp. 225-238, 2004.
- LEE, T. L. Back-propagation neural network for the prediction of the short-term storm surge in Taichung harbor, Taiwan. **Artificial Intelligence**. V. 21, N.2, pp. 63-72, 2008.
- LI, B., CHOW, M. Y., TIPSUWAN, Y., HUNG, J. C. Neural-Network-Based Motor Rolling Bearing Fault Diagnosis. **IEEE Transactions on industrial electronics**, V. 47, N. 5, pp. 1060-1069, 2000.
- MACKAY, D. J. C. A practical Bayesian Framework for Backprop Networks. **Neural Computation**. V.3, N.4, pp. 448-472, 1991.
- MACKAY, D. J. C. Bayesian Interpolation. **Neural Computation**. V.4, N.5, pp.720-736, 1992.
- MALDAGUE, X. Applications of infrared thermography in non destructive evaluation. In: **Trends in optical nondestructive testing**. [S.l.]: Pramod Rastogi,. pp. 591-609, 2000.
- MALHOTRA, V. M., CARINO, N. J. **Handbook on Nondestructive testing of concrete**. New York: CRC Press, 2004.
- McCULLOCH, W. S., PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**. V.5, pp. 115–133, 1943.
- MEDEIROS, R. A. C. Monitoramento e diagnóstico de pára-raios a ZnO usando redes neurais artificiais. In: **VIII Seminário Internacional de Metrologia Elétrica - Semetro**. João Pessoa, Brasil: 2009.
- MEHTA, K., MONTEIRO, J. M. **Concreto: estrutura, propriedades e materiais**. São Paulo: IBRACON, 2008.
- MONTGOMERY, D. C., RUNGER, G. C. **Applied Statistics and Probability for Engineers**. Student Workbook with Solutions, 3rd Edition. USA: WILEY, 2003.
- NABNEY, I. T. **Netlab Algorithms for Pattern Recognition**. Great Britain: Springer, 2004.

- OBBADI, A., BELATTAR, S. Characterization of delamination by a thermal method of non destructive testing. In: **5th International Workshop, Advances in Signal Processing for Non Destructive Evaluation of Materials**. Québec, Canadá: 2005.
- ODEN, J. T. **Finite Elements an Introduction**. Vol 1. Englewood Cliffs, USA: Prentice Hall, 1981.
- OSÓRIO, F., BITTENCOURT, J. R. Sistemas Inteligentes baseados em RNAs aplicados ao Processamento de Imagens. In: **I Workshop de Inteligência Artificial UNISC**. Santa Cruz do Sul, Brasil: 2000.
- PAOLINI, S. IR thermography characterization of residual stress in plastically deformed metallic components. **Applied Physycs A: Material Science & Processing**, 2009.
- QUEIROZ, R. B. Estudo Comparativo entre as Técnicas Máxima Verossimilhança Gaussiana e Redes Neurais na Classificação de Imagens IR-MSS CBERS 1. In: **I Workcomp Sul**. Rio Grande do Sul, Brasil: 2008.
- RUSS, J. C. **The image processing handbook**. Canadá: CCR Press, 2007.
- SCHICKERT, G. NDT-CE Symposium Berlin 1995: A Concluding Review. **The e-Journal of Nondestructive testing**. V.2, N.4, pp. 159-166, 1997.
- SHAW, P., XU, A. High Energy Radiography and Radar Applications to Concrete Inspection. In: **Proceedings of Non Destructive Testing in Civil Engineering Conference**. Liverpool, England:1997.
- SILVA, I. N. SPATTI, D. H., FLAUZINO, R. A. **Redes Neurais Artificiais para a engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.
- SILVOSO, M. M. **Modelagem Numérica do Concreto a Poucas Idades**. (Dissertação de mestrado em Engenharia Civil – Universidade Federal do Rio de Janeiro) Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2002.
- SPICER, J. M., OSIANDER, R. **Active Thermography, Nondestructive Evaluation – Theory, Techniques and Applications**. Edited by Petter J. Shull, New York: CRC Press, 2002.

- TIPLER, P. A., MOSCA, G. **Física para Cientistas e Engenheiros**. Vol 1. São Paulo: LTC, 2004.
- TSOUKALAS, L. H., UHRIG, R. E. **Fuzzy and neural approaches in engineering**. New York: John Wiley & Sons, 1997.
- VARELLA, C. A. A. Determinação da cobertura do solo por análise de imagens e redes neurais. **Revista Brasileira de Engenharia Agrícola e Ambiental**. V.6, N.2, pp.225-229, 2002.
- VERATTI, A. B. **Termografia: princípios, aplicações e qualidade**. São Paulo: ICON Tecnologia, 1992.
- VITHARANA, N., WARK, R. Thermal Cracking in Large Concrete Placements Theory and Applications. In: **Australian National Committee on Large Dams – ANCOLD, Conference on Dams**. Sydney, Australian: 2002.
- WROBEL, L.C. **The Boudary Element Method Volume 1 Applications in Thermo-Fluids and Acoustic**, England: John Wiley and Sons LTD, 2002.
- WU, Y., LUNA, R. Numerical implementation of temperature and creep in mass concrete. **Finite Elements in Analysis and Design**. V. 37, N. 2, pp. 97-106, 2001.