

APLICATIVO PARA O DIAGNÓSTICO SUBSUPERFICIAL DE ESTRUTURAS BASEADO EM IMAGENS TÉRMICAS E REDES NEURAIS ARTIFICIAIS

Roberto Pettres^{a,b}
Amanda Jarek^b
Luiz Alkimin de Lacerda^b

^{a,b} *Doutorando do Programa de Pós-graduação em Métodos Numéricos em Engenharia pela Universidade Federal do Paraná - Curitiba, Paraná, Brasil, robertopettres@yahoo.com.br*

^b *Instituto de Tecnologia para o Desenvolvimento LACTEC, Departamento de Estruturas Cíveis DPEC - Curitiba, Paraná, Brasil. CEP: 81531-090. Caixa Postal: 19067. Tel.: +55 41 3361 6002. Fax: +55 41 3361 6141. E-mail: roberto.pettres@lactec.org.br, amanda.jarek@lactec.org.br, alkimin@lactec.org.br.*

Resumo - Este trabalho apresenta um aplicativo baseado em redes neurais artificiais desenvolvido para detectar e diagnosticar anomalias subsuperficiais no interior de estruturas de concreto a partir de imagens térmicas resultantes de um processo estacionário de transferência de calor. As imagens utilizadas para o desenvolvimento e validação do aplicativo foram geradas numericamente com o auxílio do software Ansys® com a simulação de transferência de calor em um bloco cúbico contendo um elemento de alta porosidade representando um defeito em seu interior. Nas simulações, as dimensões do defeito foram parametrizadas e as condições de contorno foram definidas para garantir um fluxo de calor unidirecional. Com o campo térmico em uma das faces do bloco e o uso de técnicas de processamento de imagens com o software Matlab®, algoritmos de coleta de dados foram desenvolvidos para o treinamento das topologias neurais. As redes neurais testadas foram definidas com a otimização de quatro topologias do tipo *feedforward*. As topologias que apresentaram melhor desempenho foram selecionadas para compor o aplicativo *Thermography and Artificial Neural Network*, desenvolvido com o intuito de avaliar imagens térmicas resultantes de ensaios não-destrutivos. A funcionalidade do aplicativo é apresentada através de análises em um conjunto de imagens sintéticas com diferentes áreas, resultantes de simulações com anomalias regulares e irregulares. O desempenho do aplicativo foi satisfatório, apresentando êxito na identificação dos parâmetros dimensionais dos defeitos.

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

Abstract - This paper presents a software based on artificial neural networks for detecting subsurface anomalies in concrete structures by analyzing thermal images resulting from a steady state heat transfer condition. All images used in the software development and validation were generated numerically with Ansys™ heat transfer simulations of a cubic solid block containing an element of high porosity in its interior representing the anomaly. In the simulations, the dimensions of the anomaly were parameterized and the boundary conditions were established to guarantee heat flow in a single direction. With the thermal field on one side of the block and the application of image processing techniques with Matlab™, data collecting algorithms were developed for the training stage of the neural topologies. The tested neural networks were defined through optimization of four feedforward topologies. The topologies with better performance were selected and introduced in the software *Thermography and Artificial Neural Network*, developed with the aim of evaluating thermal images resulting from nondestructive tests. The software functionality is shown through analyses of several synthetic images with different sizes, resulted from numerical simulations with regular and irregular anomalies. Software performance was satisfactory in detecting the anomaly dimensional parameters.

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

1 Introdução

O concreto é um dos materiais mais utilizados na construção de edifícios, estradas, pontes e barragens. Este material apresenta rigidez e versatilidade, mas se deteriora progressivamente com a exposição ao meio na qual está inserido. Esta

deterioração é potencializada pela presença de irregularidades no seu interior resultantes do processo construtivo da estrutura, podendo inclusive representar riscos em termos de segurança.

Com o intuito de detectar e mitigar tais defeitos, o uso de técnicas de ensaios não destrutivos tem sido estudado para diagnosticar a estrutura *in loco* buscando, assim, 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).

O processamento e a interpretação de dados provenientes da termografia podem se apresentar como problemas complexos e demorados na ausência de ferramentas computacionais adequadas. Uma alternativa interessante para essas tarefas é o emprego de técnicas de Processamento de Imagens e de Inteligência Artificial, como por exemplo, Redes Neurais Artificiais (RNAs), que, como outros métodos computacionais permitem processar os dados de maneira rápida e eficiente buscando solução para o problema.

Desta forma, este trabalho apresenta um aplicativo baseado em RNAs desenvolvido para detectar e diagnosticar anomalias subsuperficiais no interior de estruturas de concreto a partir de imagens térmicas resultantes de um processo estacionário de transferência de calor. O programa desenvolvido é validado com o uso de uma base dados sintéticos, gerada com o software Ansys®, no estudo numérico de um bloco de concreto com uma anomalia subsuperficial cujas dimensões e distância à face avaliada foram parametrizadas.

2 Termografia e Métodos Computacionais

Atualmente, a termografia por infravermelho tem sido utilizada com sucesso em diversas áreas do conhecimento, tornando possível o diagnóstico de doenças como o câncer na área médica (Koay e Frize, 2004), permitindo a análise de componentes e ligas metálicas na área das ciências dos materiais (Paolini, 2009), dentre outras aplicações. Na construção civil, esta técnica tem sido utilizada para a detecção de vazamentos e para detecção de anomalias e monitoramento de defeitos em estruturas de concreto (Clack, McCann e Forde, 2003).

As imagens obtidas com a aplicação da termografia podem ser comparadas a resultados de simulações efetuadas com métodos numéricos sob condições pré-definidas. Desta forma, é possível avaliar se o comportamento da estrutura é compatível com o desempenho esperado e, eventualmente, indicar de regiões ou anomalias de interesse específico. Com esse intuito Chiang *et al.* (2006) aplicaram o método das diferenças finitas e o método dos elementos finitos na análise computacional de um problema térmico em uma parede de concreto e comparou com resultados experimentais de termografia por infravermelho para a inspeção de defeitos internos conhecidos. Elballouti e Belattar (2008) simularam a perturbação térmica causada por um defeito interno numa barragem de concreto com o objetivo de identificar a influência das condições geométricas do defeito. Seguindo a mesma linha de investigação, os mesmos autores relacionaram as características dimensionais e térmicas de defeitos internos em materiais com a perturbação no campo de temperaturas utilizando o método dos elementos finitos (Obbadi e Belattar, 2005). Este trabalho de pesquisa segue a mesma linha dos trabalhos citados, buscando a identificação de elementos irregulares internos à estrutura através da análise das perturbações no campo térmico em superfície.

2.1 Modelo de análise para geração dos dados sintéticos para o desenvolvimento do aplicativo

Para gerar os dados sintéticos (imagens térmicas) 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), que descreve a simulação de um elemento cúbico com as propriedades físicas do concreto, com aresta $L = 0,5$ m e uma anomalia interna caracterizada por um material de maior porosidade para simular a presença de um nicho de concreto mal vibrado. 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 do problema contendo a anomalia é apresentada na Figura 1.

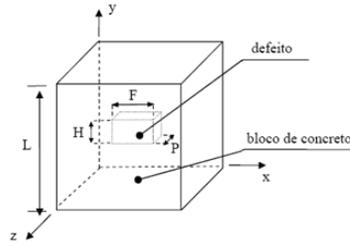


Figura 1 - Geometria do problema.

Fonte – Inácio *et al.*(2009).

O modelo matemático adotado baseia-se na equação de Laplace em um domínio tridimensional isotrópico, onde se analisa a condução de calor no interior do bloco e do defeito sob regime estacionário, onde k_s é a condutividade térmica do meio (bloco ou defeito):

$$\frac{\partial}{\partial x} \left(k_s \frac{\partial T}{\partial x} \right) + \frac{\partial}{\partial y} \left(k_s \frac{\partial T}{\partial y} \right) + \frac{\partial}{\partial z} \left(k_s \frac{\partial T}{\partial z} \right) = 0 \quad (1)$$

A formulação numérica adotada consistiu em discretizar a equação (1) através do Método dos Elementos Finitos (Buchanan, 1994) com a utilização do software Ansys®, adotando-se um campo uniforme de temperaturas na superfície do bloco em $z = 0$ ($T(x, y, 0) = T_w$). Em $z^* = L^*$, a condição de contorno aplicada descreve a existência de um resfriamento por convecção (ar) com coeficiente h_a e 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 2 ilustra as condições de contorno aplicadas ao problema:

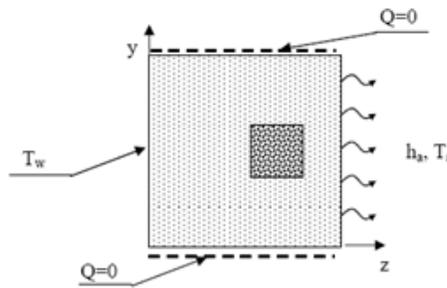


Figura 2 – Condições de contorno.

Fonte – Inácio *et al.*(2009).

De acordo com Inácio *et al.* (2009), as simulações foram realizadas com os seguintes dados:

- (I) Condutividade térmica do concreto $K_B = 2,75 \text{ W/m.K}$ (Mehta e Monteiro, 2008);
- (II) Condutividade térmica do defeito $K_d = 25\%K_B$, definindo $R_k = K_d/K_B$;
- (III) Coeficiente de convecção concreto/ar: $h_a = 13.95 \text{ W/m}^2\text{K}$;
- (IV) Valores para D , H , F , e P variando entre 0,05, 0,10, 0,15 e 0,20 m, correspondendo a 256 combinações possíveis;
- (V) $T_a < T_w$ na interpretação do fenômeno físico.

A solução numérica para cada caso é ilustrada por meio de imagens térmicas (equivalentes a termogramas) representando a distribuição de temperaturas na superfície de análise ($z = L$). O conjunto de 256 imagens térmicas obtidas forma a base de dados sintéticos utilizada no estudo com RNAs. Na Figura 3 é apresentada uma amostra do conjunto de soluções obtidas utilizando escala de 128 cores.

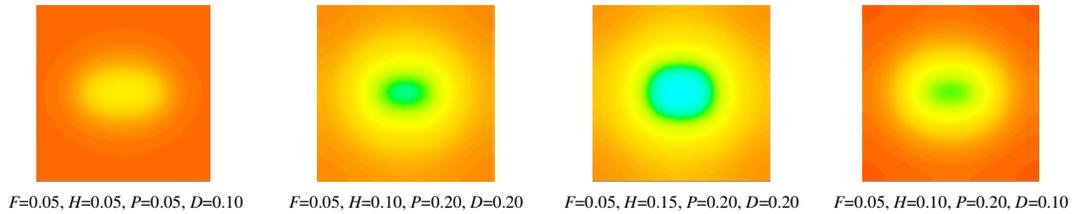


Figura 3 - Amostra do conjunto de imagens, F = Largura; H = Altura; P = Espessura; D = Profundidade.

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. Já o parâmetro espessura (P) do defeito, não causou influência significativa sobre os casos simulados. Além disso, foi constatado que a região mais fria do campo térmico coincide com a projeção do defeito à superfície em análise. Desta forma, optou-se em utilizar apenas os parâmetros F , H e D , para as saídas conhecidas *a priori* pelas RNAs em seu processo de treinamento.

3 Processamento de Imagens e Redes Neurais Artificiais

O processamento de imagens inclui uma série de técnicas de conversão e padronização. Entre as quais está o padrão RGB (Red, Green ad Blue) (Russ, 2007) que converte a imagem em uma matriz de ordem $M \times N \times 3$, o padrão binário que utiliza dois níveis de cores, preto e branco e também padrões baseados em tratamento bidimensional. Para a maioria das técnicas de processamento, o objetivo principal é caracterizar cada imagem, procurando extrair informações quantitativas de interesse ou que sejam básicas para discriminação entre classes de eventos e/ou fenômenos buscando um padrão a ser determinado.

Entre as ferramentas matemáticas utilizadas para trabalhar com determinação de padrões, existem técnicas baseadas na aplicação de RNAs. RNAs são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes, podendo adquirir conhecimento pela experiência (Haykin, 2003; Galushkin, 2007). Uma das principais vantagens das RNAs é a habilidade em descobrir e reconhecer padrões que parecem despercebidos aos especialistas humanos ou para uma série de 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.

Atualmente, aplicações baseadas em RNAs são cada vez mais frequentes. Este fato é justificado pela sua habilidade em fazer generalizações, executar tarefas específicas e por apresentar uma estrutura tolerante a falhas resistindo a pequenas perturbações ou incompletude nos dados, fazendo das RNAs uma ferramenta robusta e de alto desempenho.

3.1 Processando as imagens térmicas

No processamento das imagens foram aplicadas as funções *colormap(128)* e *imread* ao conjunto de imagens térmicas, ambas funções computacionais do Matlab R2010®. A combinação destas funções permite converter a imagem colorida em uma matriz tridimensional, $M \times N \times 3$ (onde $M = 228$ linhas e $N = 228$ colunas de pixels), que retorna valores do padrão RGB, associando a cada imagem um mapa contendo 128 cores e 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.

Para trabalhar com as imagens de forma bidimensional foi utilizada uma função injetora para substituição dos vetores de três componentes por um valor único de temperatura (Petres e Lacerda, 2010):

$$p(R, G, B) = a_1R + a_2G + a_3B \quad (2)$$

Neste processamento, as componentes RGB de cada vetor foram combinadas linearmente através dos coeficientes a_1 , a_2 e a_3 (constantes) retornando um valor biunívoco ao conjunto de temperaturas padronizadas (128 cores) pelo Ansys (Figura 4).

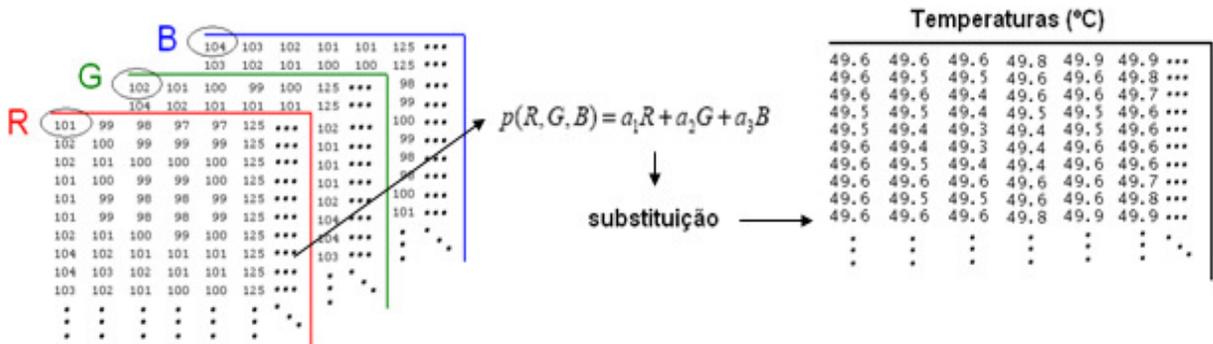


Figura 4 – Matrizes do padrão RGB sendo processada para o padrão térmico bidimensional.

Para determinar quais características comporiam o conjunto de entradas da RNAs, o processamento das imagens contou inicialmente com um estudo de inferência estatística onde foi verificada a ocorrência de pixels com seus respectivos valores de temperatura em cada imagem do conjunto (Flório Filho, 2006). 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 e a quantidade de calor em cada subintervalo poderia ser uma forma de caracterizar cada imagem, indicando um padrão a ser detectado pelas RNAs no processo de classificação.

Levando em consideração os métodos de classificação por regiões, foi utilizado um algoritmo para localização da anomalia térmica (Pettres e Lacerda, 2010), fundamentado nos resultados obtidos por Inácio *et al.* (2009). O algoritmo consistiu em encontrar os elementos (i, j) com menor temperatura da matriz de temperaturas e calcular o centróide desta distribuição. A Figura 5 ilustra uma análise feita pelo algoritmo, estando a localização do defeito em acordo com o perfil de temperaturas do termograma.

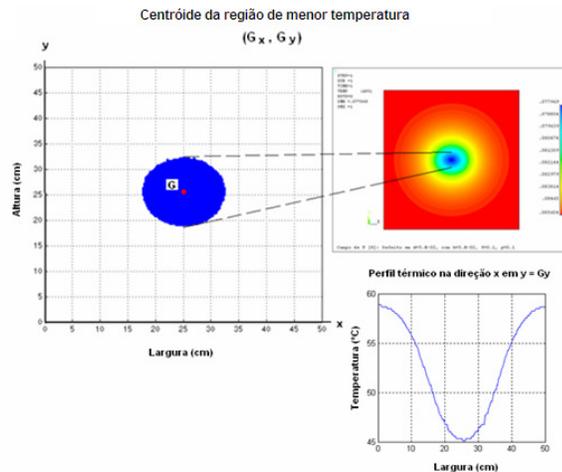


Figura 5 – Resultado para localização do centróide das temperaturas mínimas.

Com a aplicação deste algoritmo foram obtidos quatro conjuntos de informações sobre as imagens com intuito de caracterizá-las. O primeiro conjunto chamado de RNA 1 foi formado por três valores referentes à quantidade de calor em três subintervalos limitados pela temperatura máxima e mínima das imagens térmicas e por cinco valores de temperatura coletados a partir de um sistema cartesiano com origem no centro da anomalia térmica, totalizando oito características (Figura 6 - a). O segundo conjunto de informações, RNA 2, foi formado por treze valores de temperatura obtidos em parte do entorno radial da

anomalia como ilustra a Figura 6 - b. O terceiro e quarto conjuntos, RNA 3 e RNA 4, foram obtidos com a aplicação de uma malha quadrada de $0,16 \text{ m}^2$ contendo nove (Figura 6 - c) e vinte e cinco nós (Figura 6 - d), respectivamente, centradas sobre o centróide de temperaturas mínimas, sendo coletados os valores sob cada nó (Pettres, 2011). O tempo médio de processamento de cada abordagem foi de 0,03 segundos por imagem.

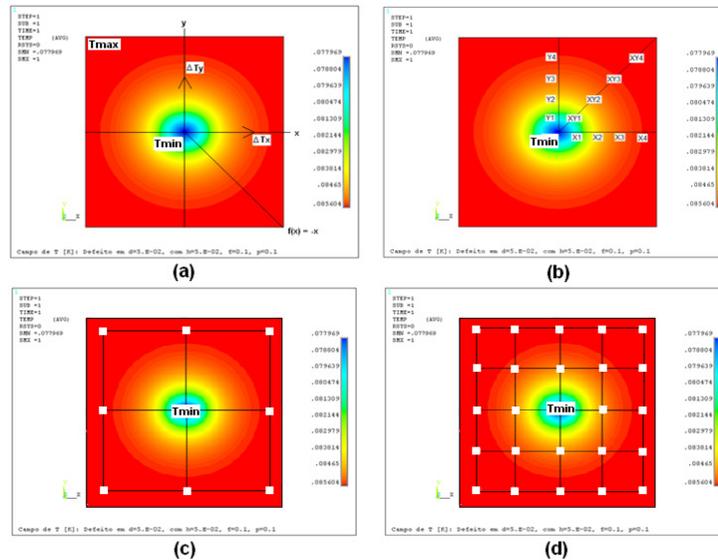


Figura 6 – Coleta de dados para o treinamento das RNAs.

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 (Haykin, 2003), sendo armazenadas em um vetor contendo os padrões característicos de cada imagem. Assim, os quatro conjuntos de dados obtidos nesta etapa representam os sinais funcionais de cada uma das RNAs 1, 2, 3 e 4.

4 Definição das topologias neurais para o reconhecimento de padrões

Para arquitetura, foram definidas redes *feedforward* de camadas múltiplas com o algoritmo de Regularização Bayesiana que utiliza o algoritmo *backpropagation* (retropropagação). Pettres e Lacerda (2010) utilizaram uma arquitetura contendo uma camada oculta de neurônios para analisar imagens termográficas, porém, dada a complexidade do tipo de mapeamento realizado, nesta pesquisa as topologias das redes foram definidas contendo duas camadas ocultas. A primeira camada oculta 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 oculta, utilizou-se o método de validação cruzada com amostragem aleatória do conjunto de imagens (*random subsampling cross-validation*). Para isto, foi desenvolvido um algoritmo que simulou iterativamente as topologias variando a quantidade de neurônios na segunda camada oculta, desde uma unidade até um número igual à quantidade de sinais funcionais do conjunto (Figura 7), visando selecionar a quantidade que apresentasse o menor somatório de erro quadrático médio nos testes (Pettres, 2011). A aplicação deste algoritmo teve como objetivo otimizar e determinar as topologias que melhor desempenhassem a tarefa de reconhecimento de padrões de defeitos. Neste processo, o conjunto de informações foi dividido em treinamento (80%), validação (10%) e teste (10%, dados inéditos), com o intuito de verificar a capacidade de generalização da rede. Este processo é justificado pela importância que as camadas ocultas representam para o aprendizado da rede, pois segundo Haykin (2003), “os neurônios das camadas ocultas desempenham um papel crucial na operação de uma rede de múltiplas camadas com aprendizagem por retropropagação porque agem como detectores de características”.

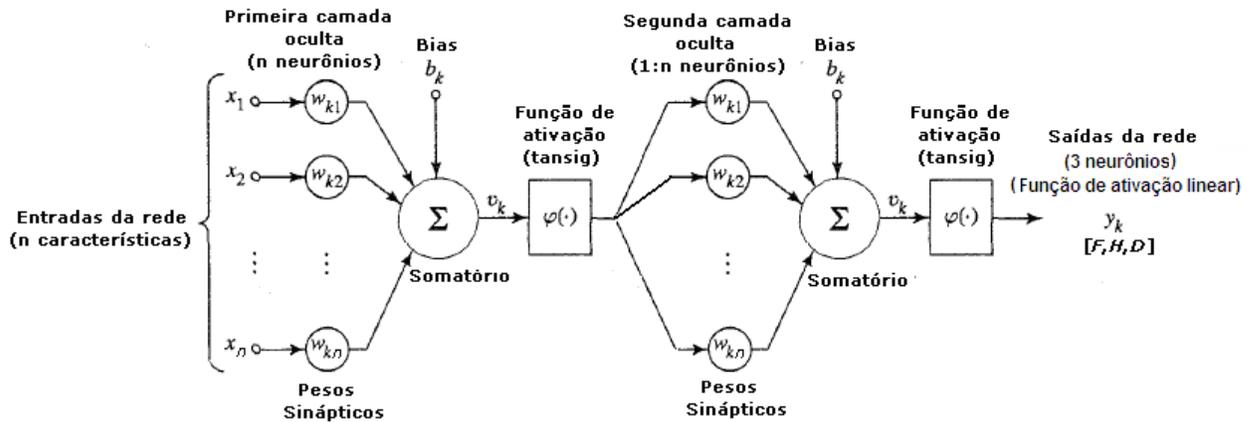


Figura 7 – Ilustração para otimização e definição das topologias.

É importante ressaltar que o aumento indiscriminado de neurônios na camada oculta não assegura a generalização apropriada da rede de múltiplas camadas em relação às amostras pertencentes aos subconjuntos de testes (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).

Após uma série de treinamentos e validações foram obtidos os valores correspondentes a quantidade de neurônios da segunda camada oculta (*NNH2*) de cada modelo. Estes resultados são apresentados na Tabela 1.

Tabela 1 – Análise dos erros das simulações e definição do número de neurônios na segunda camada oculta

RNA	<i>MMSE</i> mínimo	<i>MMSE</i> médio	<i>MMSE</i> máximo	<i>NNH2</i>	<i>NTE</i>	<i>NTT</i>	Tempo (segundos)
1	6,22	13,57	27,80	03	10	80	1,00
2	2,44	18,94	33,82	08	10	130	8,63
3	9,70	20,00	35,09	09	10	90	1,55
4	2,36	9,10	30,43	15	10	250	277,57

NNH2 = número de neurônios na segunda camada oculta com mínimo *MMSE*, *NTE* = número de treinamentos por topologia e *NTT* = número total de treinamentos. Tempo normalizado em função do registro RNA 1 = 135,47 segundos.

O nível de erro foi avaliado pela média dos erros quadráticos médios (*MMSE*) (Eq.(3)) das respostas fornecidas por cada estrutura de RNA.

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

(*vr* = valor real parametrizado e *vs* = valor simulado pela topologia)

Na Tabela 1, 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 valor obtido para o *MMSE* mínimo é relacionado à quantidade de neurônios da segunda camada oculta, visando à definição da topologia que obteve o melhor desempenho. 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 testes. Na Tabela 2 é apresentada a quantidade de neurônios em cada camada para cada uma das topologias.

Tabela 2 – 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 oculta, NNH2 = número de neurônios na segunda camada oculta, NNO = número de saídas da rede.

4.1 Treinamento e testes das topologias

Após a definição de cada topologia, foi introduzido o estimador de erro percentual absoluto (APE) (Eq.(4)), aplicado a cada teste realizado, procurando validar e testar a potencialidade de cada modelo. Para isto, cem modelos neurais foram simulados para cada topologia e cem conjuntos de testes foram aleatoriamente selecionados com o intuito de obter a distribuição de erros e identificar o desempenho de cada topologia.

$$APE = \sum_{n=F.H.D} \frac{|vr_n - vs_n|}{3vr_n} \quad (4)$$

(vr = valor real parametrizado e vs = valor simulado pela topologia)

Nos testes realizados foi verificada uma grande concentração dos erros percentuais absolutos nos intervalos de 10, 20 e 30%, que podem ser considerados pequenos para o propósito do diagnóstico. Utilizando como critério o percentual de erros inferiores a 30% para avaliar as quatro topologias, a figura a seguir ilustra o desempenho de cada topologia.

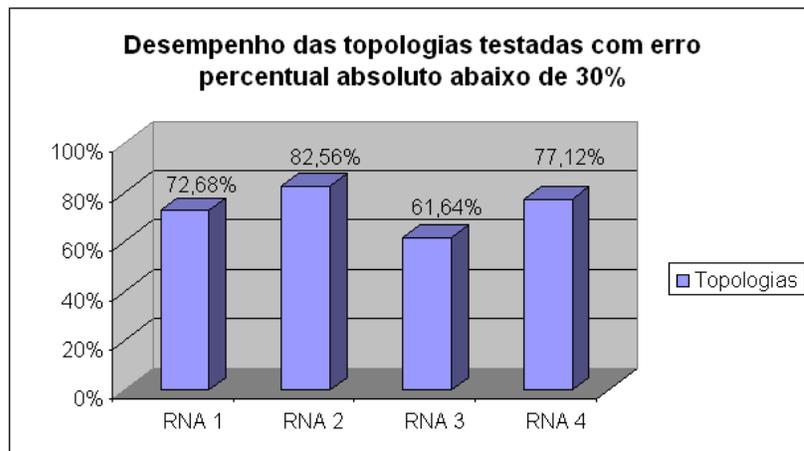


Figura 8 – Desempenho das topologias testadas.

Observa-se que a RNA 2 apresentou o melhor desempenho, com 82,56% das estimativas no intervalo definido, seguida pela RNA 4, 77,12%, RNA 1, 72,68%, e por fim a RNA 3 com 61,64%. Desta forma, os resultados obtidos a partir do grande número de 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.

5 Aplicativo de processamento de imagens térmicas e análise por redes neurais artificiais

A partir dos resultados obtidos neste trabalho foi desenvolvido o aplicativo *Thermography and Artificial Neural Network* (Figura 9) para o processamento e análise de imagens termográficas de estruturas de concreto, utilizando linguagem de programação e recursos gráficos pertencentes ao software Matlab R2010®.

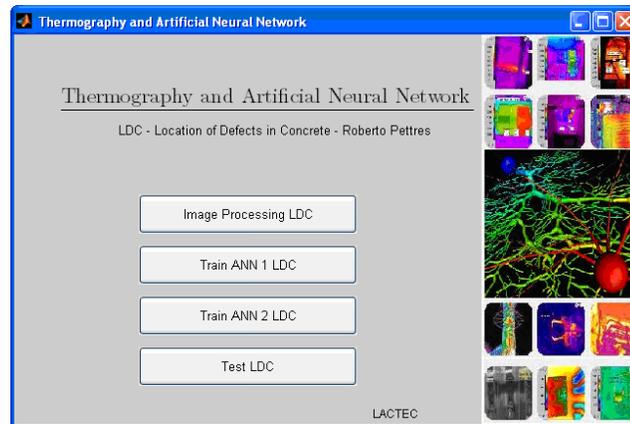


Figura 9 – Interface do Aplicativo *Thermography and Artificial Neural Network*.

5.1 Funcionamento do aplicativo

Ao executar o aplicativo é carregada a interface gráfica contendo os botões de operação em ambiente Matlab R2010® (Figura 12). 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 RNAs. Neste processamento é identificado, também, o centróide 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 RNAs que diferem por suas topologias (ANN 1 = RNA 2 e ANN 2 = RNA 4). A Figura 10 e a Figura 11 ilustram cada uma das topologias.

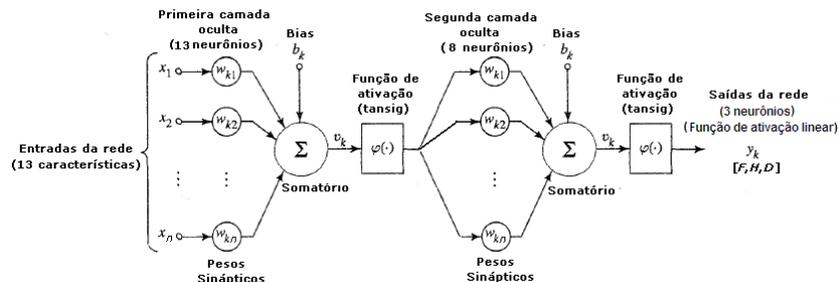


Figura 10 – Topologia da ANN 1.

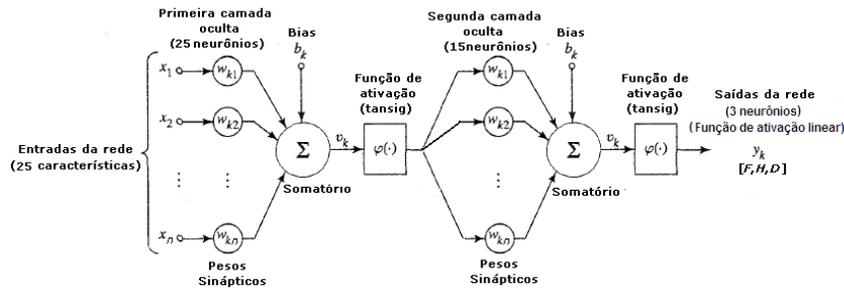


Figura 11 – Topologia da ANN 2.

Com a realização do treinamento de uma das topologias, a ferramenta computacional está pronta para realizar os testes. Para isto, basta um clique sobre o botão que seleciona os sinais funcionais do conjunto de testes obtidos no processamento das imagens e aplica-os à RNA definida (ANN 1 ou ANN 2). O resultado do conjunto de testes é apresentado na tabela indexada do Matlab R2010®, trazendo estimativas para os parâmetros F , H e D desejados, com o nível de precisão definido para cada modelo (*Average Standard Uncertainty*). Nesta mesma tabela também são apresentadas as coordenadas do centróide da região com as menores temperaturas observadas em cada imagem sendo, assim, um indicativo da localização da anomalia térmica de acordo com os resultados obtidos no presente trabalho (Figura 13).

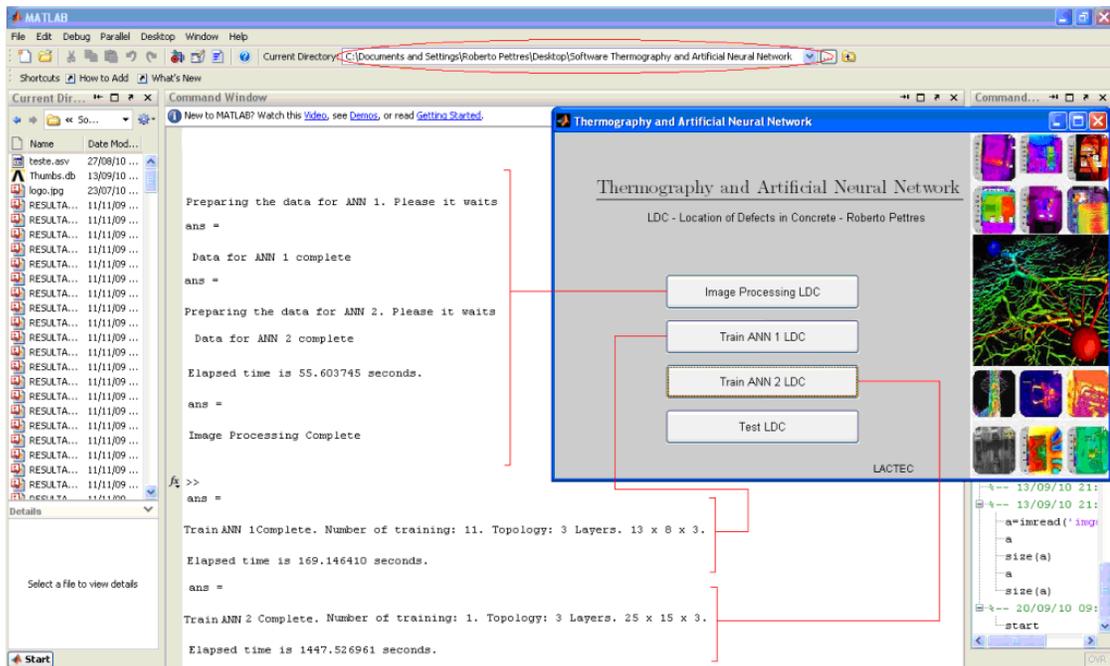


Figura 12 – Operação do Aplicativo *Thermography and Artificial Neural Network*.

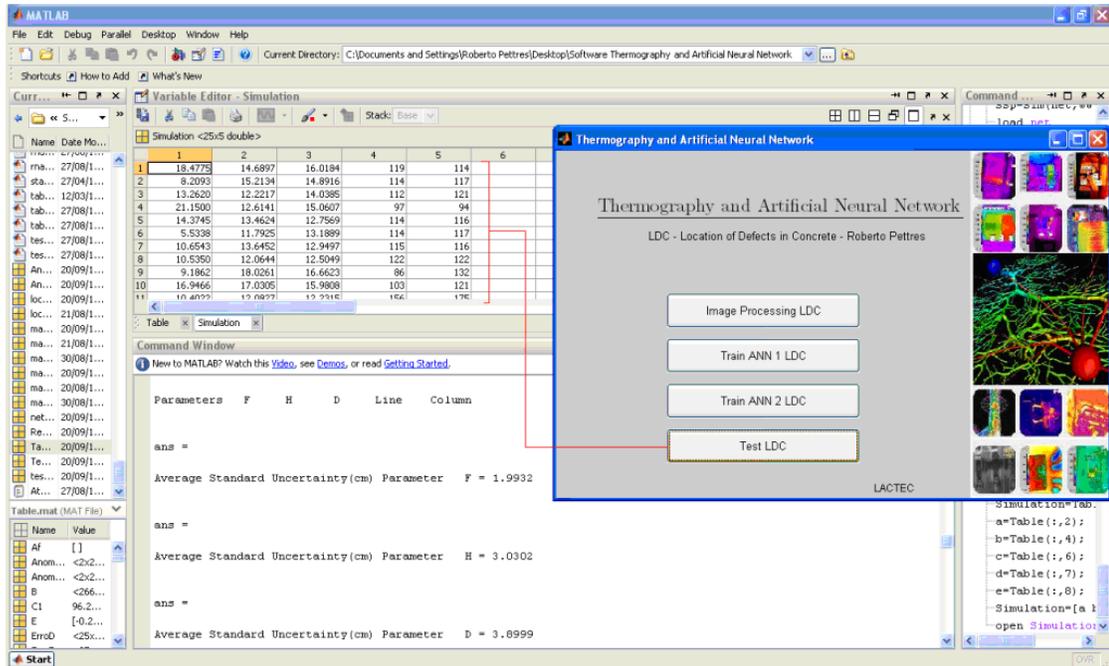


Figura 13 – Operação do Aplicativo *Thermography and Artificial Neural Network*.

5.2 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 para a geração de novas imagens térmicas através de análises com o método dos elementos finitos. Além disso, geometrias irregulares, descentralizadas em áreas de análise maiores que as utilizadas para treinamento foram testadas. Estas alterações representam ruídos no conjunto de sinais funcionais das RNAs e são úteis para testar a capacidade de generalização do modelo matemático. A Figura 14 (a) ilustra um dos 25 casos testados em que os parâmetros da anomalia são diferentes dos utilizados na fase de treinamento das topologias. A Figura 14 (b) ilustra o caso em que o defeito contendo as mesmas dimensões de um dos modelos de treinamento foi deslocado do centro da imagem em uma área de análise de 1 m^2 . A Figura 14 (c) ilustra o caso que contém uma anomalia com geometria irregular diferente do modelo prismático regular utilizado na fase de treinamento.

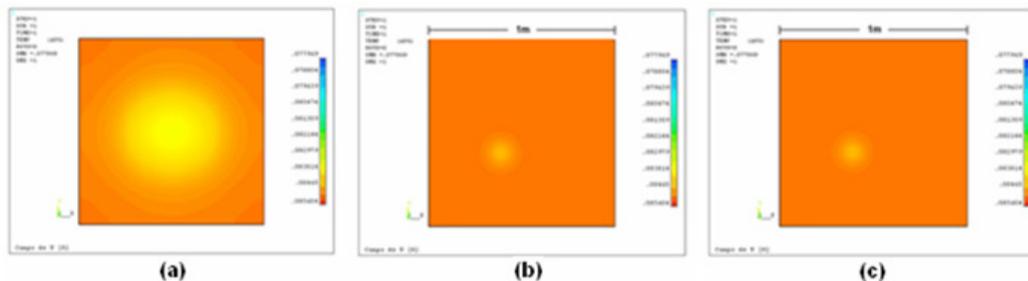


Figura 14 – Exemplos de anomalias utilizadas para validação do aplicativo: (a) geometria regular com parâmetros diferenciados, (b) geometria regular descentralizada em uma área de 1 m^2 , (c) geometria irregular.

Anomalias regulares com novos parâmetros F , H e D

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

As Figuras 15, 16 e 17 trazem os resultados das simulações 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.

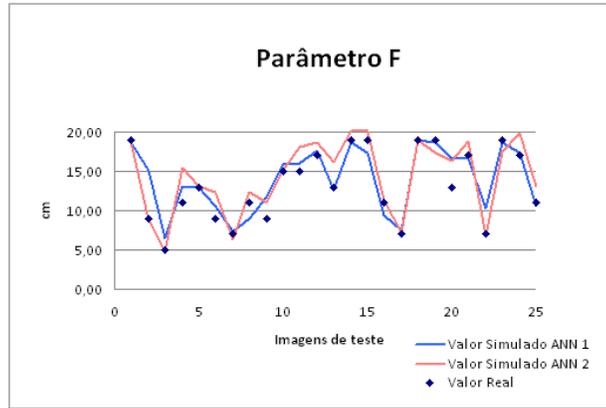


Figura 15 – Resultados das simulações para o parâmetro F .

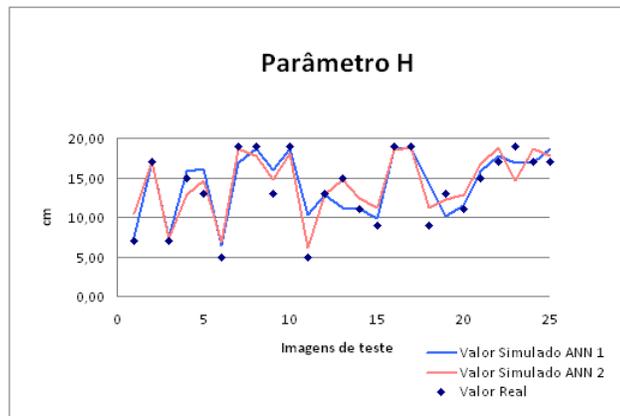


Figura 16 – Resultados das simulações para o parâmetro H .

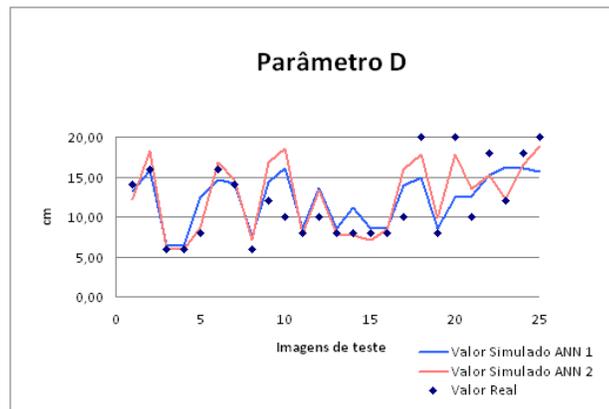


Figura 17 – Resultados das simulações para o parâmetro D .

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 (MAD) (Eq.(5)). O

estimador MAD indica o desvio dos valores obtidos com os modelos neurais para as dimensões do defeito em relação aos valores conhecidos.

$$MAD = \frac{\sum_{m=1}^n |vr_m - vs_m|}{n} \quad (5)$$

$m=F, H, D$

(vr = valor real parametrizado e vs = valor simulado pela topologia)

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. Estes resultados são considerados satisfatórios, pois de acordo com Inácio *et al.* (2009), seriam detectáveis termograficamente apenas os casos em que a anomalia está próxima à superfície (D menor ou igual a 5 cm) e com as dimensões largura (F) e altura (H) superiores a 10 cm, dado que no conjunto testado foram utilizados valores superiores a 5 cm para o parâmetro D e inferiores a 10 cm para os dois parâmetros restantes.

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 como ilustram as Figuras 15, 16 e 17.

Anomalia regular descentralizada

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 18 ilustra o local indicado pelo aplicativo de acordo com a análise térmica representada pelo gráfico de temperaturas.

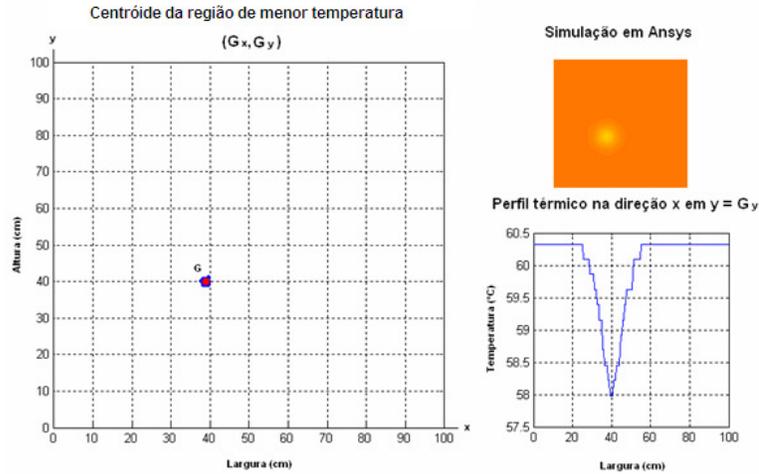


Figura 18 – Processamento e análise de temperaturas para localização do defeito no interior do bloco.

Este teste também teve como objetivo avaliar a capacidade do aplicativo em análises de imagens de intervenções práticas em que a área registrada apresenta uma dimensão mais ampla, dado que o treinamento foi realizado com um conjunto de imagens de áreas quadradas com 0,16 m² centralizadas na região de menor temperatura. Os parâmetros médios obtidos com as topologias ANN 1 e ANN 2 são apresentados na Tabela 3.

Tabela 3 – Resultados dos testes para a anomalia descentralizada - ANN 1 e ANN 2.

Topologia	<i>F</i>		<i>H</i>		<i>D</i>		<i>MAD</i>	<i>APE</i>
	<i>vr</i>	<i>vs</i>	<i>Vr</i>	<i>vs</i>	<i>vr</i>	<i>vs</i>		
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*) (Eq.(4)) 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 37,10%.

Como neste teste os parâmetros do defeito são iguais ao de um modelo utilizado no treinamento, foi realizada uma análise sobre a distribuição de temperaturas nos dois casos (50x50 cm – treinamento, 100x100 cm – teste) para identificar o motivo do erro cometido pelas topologias. Nesta análise foi constatada que a divergência entre as distribuições de temperatura dos dois casos (Figura 19) é proveniente da diferença entre as distâncias da anomalia às condições de contorno.

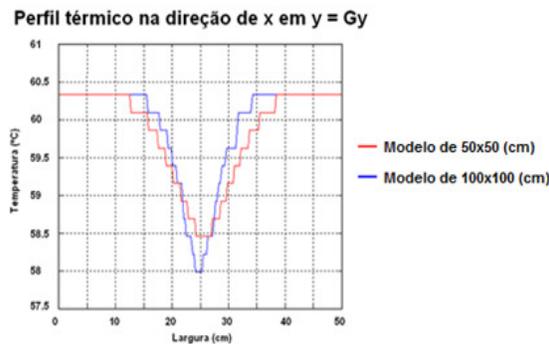


Figura 19 – Comparação do perfil térmico do modelo 50x50 cm (treinamento) e 100x100 cm (teste).

Anomalia irregular

Na terceira etapa de testes, a imagem térmica resultante da análise numérica do caso contendo anomalia com geometria irregular (Figura 20) foi processada e testada pelo aplicativo. A anomalia apresenta dimensões próximas às de cubo de 125 cm³ e foi posicionada a 5 cm da face 100x100 cm do bloco e descentralizada.

Geometria Irregular

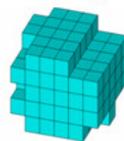


Figura 20 – Defeito com geometria irregular utilizados no teste.

O processamento da imagem identificou a localização do defeito com precisão (Figura 21).

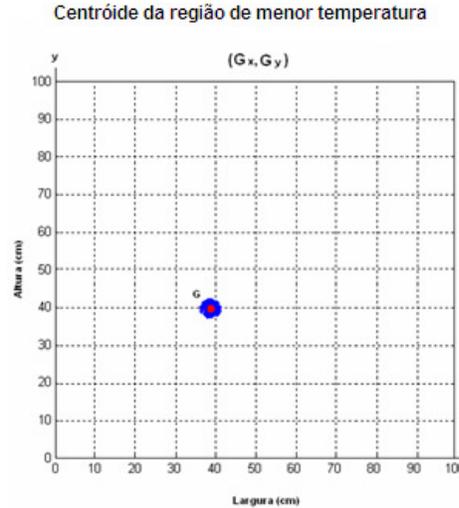


Figura 21 – Localização da região de menor temperatura indicando a posição do defeito.

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 neste caso o defeito apresenta geometria irregular, 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 para obter uma aproximação do erro percentual em relação ao valor real da diagonal da face frontal do defeito (7,0711 cm).

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%.

6 Conclusões

A partir dos resultados numéricos obtidos com o software Ansys® 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 com inteligência computacional através de RNAs 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*.

Entre as topologias testadas nesta pesquisa, foi verificado que a RNA 2 obteve êxito em 82,56% das estimativas, apresentando erros relativos médios inferiores a 30% para os parâmetros característicos dos defeitos. Similarmente, a RNA 4 teve êxito em 77,12% das estimativas seguindo o mesmo critério, 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 êxito em 72,68% dos casos, 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 *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 em áreas maiores com defeito com geometria regular 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 da imagem resultante de defeito com geometria irregular o aplicativo se mostrou preciso na localização do defeito e apresentou um erro percentual absoluto (APE) de 14,8% para determinação do parâmetro D com a aplicação da topologia ANN 1. Para estes estimadores, a ANN 2 apresentou resultado superior, 9,4%. Para os parâmetros F e H foram verificados erros 26,63% pela ANN 1 e 45,62% pela ANN 2 tomando como referência a medida da diagonal do retângulo formado pelo lados F e H .

Os resultados obtidos nestas simulações indicam a potencialidade do aplicativo *Thermography and Artificial Neural Network* para o diagnóstico de estruturas de concreto a partir de imagens térmicas, permitindo assim, a verificação da ocorrência de problemas no interior da estrutura, sua localização e dimensões aproximadas.

Agradecimentos

Os autores agradecem 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.

7 Referências Bibliográficas

- Barreto, J. M. **Introdução às Redes Neurais Artificiais**. Santa Catarina: UFSC, 2004.
- Buchanan, G. R. **Schaum's outline of theory and problems of element analysis**. USA: McGraw-Hill Companies, 1994.
- 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.
- 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.
- 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 de Produção - ENEGEP**. Ceará, Brasil: 2006.
- Galushkin, A. I. **Neural networks theory**. New York: Springer, 2007.
- Haykin, S. **Neural Networks – A Comprehensive Foundation**. Ontário: Pearson Prentice Hall, 2003.
- 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.
- 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.

Malhotra, V. M., Carino, N. J. **Handbook on Nondestructive testing of concrete**. New York: CRC Press, 2004.

Mehta, K., Monteiro, J. M. **Concreto: estrutura, propriedades e materiais**. São Paulo: IBRACON, 2008.

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.

Paolini, S. IR thermography characterization of residual stress in plastically deformed metallic components. Applied Physycs A: **Material Science & Processing**, 2009.

Pettes, R.; Lacerda, L. A. Análise de imagens termográficas de estruturas de concreto a partir de redes neurais artificiais. In: **Congresso Ibero Latino Americano de Métodos Computacionais em Engenharia - CILAMCE**, Buenos Aires, 2010.

Pettes, R. **Reconhecimento de padrões de defeitos em concreto a partir de imagens térmicas estacionárias e redes neurais artificiais**. Dissertação de Mestrado em Métodos Numéricos em Engenharia – Universidade Federal do Paraná. Paraná, 2011.

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.

Silva, I. N. Spatti, D. H., Flauzino, R. A. **Redes Neurais Artificiais para a engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.