

TÉCNICA NÃO DESTRUTIVA PARA DIAGNÓSTICO DE CONCRETO A PARTIR DE TERMOGRAFIA E REDES NEURAS ARTIFICIAIS

Roberto Pettres ^a
Luiz Alkimin de Lacerda ^b

^a *Doutorando do Programa de Pós-graduação em Métodos Numéricos em Engenharia pela Universidade Federal do Paraná – Curitiba-PR, Brasil, e-mail: roberto.pettres@lactec.org.br*

^b *Doutor em Engenharia Civil, LACTEC – Instituto de Tecnologia para o Desenvolvimento, Departamento de Estruturas Civis, Curitiba-PR, Brasil, e-mail: alkimin@lactec.org.br*

Resumo - Este trabalho apresenta a aplicação experimental de uma metodologia não destrutiva para diagnóstico subsuperficial de estruturas de concreto baseada em termografia e um aplicativo computacional para processamento e análise de imagens por redes neurais artificiais. Para esse propósito elaborou-se um bloco de concreto contendo um elemento de alta porosidade representando um defeito conhecido em seu interior. Sobre este bloco foram aplicadas condições de contorno que estabeleciam um fluxo de calor em uma única direção. As imagens termográficas foram obtidas da face oposta à aplicação do aquecimento, após o estabelecimento de um regime estacionário de transferência de calor. A aplicação da técnica se mostrou eficiente e indicou satisfatoriamente a localização do defeito, apresentando em média um percentual de êxito de 74,22% na identificação dos parâmetros dimensionais do defeito, com desvio médio absoluto de 3 cm em relação às dimensões reais.

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

Abstract - This paper presents the experimental application of a nondestructive methodology for subsurface diagnosis of concrete structures based on thermography and a computational applicative for image processing and analysis by artificial neural networks. For this purpose a concrete block was prepared containing a highly porous element representing a known defect in its interior. Boundary conditions were applied on the block surfaces establishing a heat flow in a single direction. The thermographic images were obtained from the opposite face to the applied thermal load side, once a steady-state heat transfer regime was established. The application of the technique indicated with reasonable efficiency the location of the defect with an average rate of success of 74.22% in the identification its dimensional parameters with a mean absolute deviation of 3 cm with respect to the real dimensions.

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

1 Introdução

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 microfissuras em 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 das mesmas (Andriolo, 1989). Com o intuito de detectar estes defeitos, técnicas de análise e ensaios não destrutivos têm sido empregadas. Ensaios não destrutivos 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), fornecendo informações sobre as condições dos materiais e componentes sem destruí-los. As tecnologias empregadas em 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 identificar dimensões, características físicas dos materiais ou parâmetros associados à integridade estrutural.

Entre as técnicas citadas anteriormente, a termografia se apresenta como ensaio não destrutivo com grande potencial para análise de estruturas de concreto. 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. Desde então, esta técnica evoluiu consideravelmente e tem sido utilizada com sucesso na construção civil. Demonstrou-se que a termografia pode ser utilizada para detectar falhas causadas pela corrosão do aço, agrupamento de agregados ou fluidos, infiltração de água e identificar a presença e localização de anomalias subsuperficiais, entre outros (Spicer e Osiander, 2002; Gailius e Zukauskas, 2003; Clark, McCann e Forde, 2003; Malhotra e Carino, 2004; Avdelidis e Moropoulou, 2004).

Para avaliar imagens térmicas, Maldague (2000) cita dois tipos de análise: qualitativa e quantitativa. Na análise qualitativa é possível localizar anomalias de maneira comparativa, baseando-se em padrões térmicos, definindo a necessidade de uma atenção especial para determinadas regiões que apresentam algum tipo de anomalia térmica. Na análise quantitativa os resultados podem apresentar precisão e permitir a classificação da gravidade da anomalia, mas requer um estudo preciso e o total controle das condições de contorno do modelo avaliado.

Trabalhos envolvendo estudos comparativos entre resultados termográficos e resultados simulados computacionalmente são discutidos por Obbadi e Belattar (2005) e Chiang *et al.* (2006), os quais relacionaram características dimensionais de defeitos conhecidos, vazios e fissuras, às perturbações térmicas causadas pelos mesmos em estruturas de concreto a partir de métodos computacionais baseados em diferenças finitas e elementos finitos. Resultado semelhante foi obtido por Elballouti e Belattar (2008) ao simular a perturbação térmica causada por um defeito interno em uma barragem de concreto, identificando a influência das condições geométricas do defeito.

Entretanto, não é trivial processar imagens termográficas reais e realizar um diagnóstico eficiente sem ferramentas computacionais específicas. Uma alternativa é o emprego de técnicas de processamento de imagens e técnicas de inteligência artificial, como Redes Neurais Artificiais (Haykin, 2003; Galushkin, 2007). Redes Neurais Artificiais (RNAs) têm sido empregadas com sucesso para solucionar diversos problemas de reconhecimento de padrões. Por exemplo: diagnóstico de para-raios a óxido de zinco a partir de registros de monitoramento (Medeiros, 2009); a classificação de níveis de degradação em pastagens a partir de imagens aéreas (Chagas, 2008); estimativa de idade a partir de imagens faciais (Dehshibi, 2010), detecção de aquecimento em componentes de um sistema industrial a partir de imagens termográficas (Flório Filho, 2006).

Reconhecendo a versatilidade das RNAs, Pettres *et al.* (2011) desenvolveram o aplicativo *Thermography and Artificial Neural Network* para diagnosticar imagens térmicas de blocos de concreto, tendo por base um banco de imagens obtidas através de simulações computacionais com o *software* Ansys. O aplicativo foi validado com o uso de um banco de imagens obtido por Inácio *et al.* (2009), que estudaram a viabilidade de uso da termografia para identificação de anomalias em blocos de concreto através de um estudo paramétrico de transferência de calor com o método dos elementos finitos.

A motivação deste trabalho está em avaliar o desempenho da aplicação da termografia como técnica não destrutiva, em conjunto com aplicativo *Thermography and Artificial Neural Network*, na avaliação experimental de um bloco de concreto com um defeito subsuperficial conhecido. Neste processo, busca-se a identificação das dimensões da anomalia, conforme descrito a seguir na metodologia empregada na investigação.

2 Materiais e métodos empregados no estudo experimental

A seguir são descritos os procedimentos adotados para realização de um estudo experimental em um bloco de concreto. Em síntese, buscou-se a aplicação de um fluxo estacionário de calor através de um cubo de concreto com uma anomalia conhecida em seu interior, e o registro de imagens termográficas para posterior análise. Detalhes sobre a confecção da estrutura de concreto, artifícios para imposição das condições de contorno e equipamento utilizado para obtenção das imagens termográficas são apresentados abaixo. Também são parcialmente reapresentados os conceitos utilizados no aplicativo de diagnóstico de imagens termográficas descrito por Pettres *et al.* (2011).

2.1 Confecção do bloco de concreto com anomalia

Um bloco cúbico de concreto convencional com aresta de 0,50 m foi preparado para o experimento. Este modelo foi executado de acordo com as condições e dimensões estabelecidas na modelagem computacional proposta por Inácio *et al.* (2009). 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. A Figura 1 mostra desenhos esquemáticos do bloco confeccionado.




Figura 1 – Desenho esquemático do bloco com posicionamento do defeito em seu interior.

O aplicativo *Thermography and Artificial Neural Network*, que será brevemente descrito a seguir, tem por objetivo identificar anomalias no interior de blocos de concreto através da definição de três parâmetros representativos: F (largura), H (altura) e D (profundidade). No bloco apresentado acima estas variáveis têm os seguintes valores fixos:

$$F = 19 \text{ cm};$$

$$H = 9 \text{ cm};$$

$$D = 10 \text{ cm}.$$

Tendo em vista o interesse em estender esse estudo ao diagnóstico de face montante de barragens de concreto tipo gravidade, optou-se por confeccionar o bloco de concreto com um traço característico do concreto empregado na face montante da UHE Fundão – ELEJOR. A Tabela 1 apresenta as características da dosagem empregada nesse teste experimental e na Tabela 2 o traço de concreto (Lactec, 2007).

Tabela 1 – Dosagem do concreto do bloco de ensaio.

Materiais	Registro	Absorção	Massa específica (g/cm ³)	Módulo de finura	DMC
Brita 9,5/25,0 mm	1.0591.07	1,70%	2,6	5,89	19,0 mm
Areia artificial	1.0590.07	2,00%	2,74	2,54	4,8 mm
Cimento CP IV 32	1.0169.09	-	3,08	-	-
Pozolana	1.0076.09	-	2,83	-	-
Aditivo Plastificante 0,4%	1.0982.08	-	1,2	-	-

Fonte – Lactec, 2007.

Tabela 2 – Traço do concreto.

Traço de concreto para 1 m ³	kg
Brita 9,5/25,0 mm	1143
Areia artificial	657
Cimento CP IV 32	405
Pozolana	45
Aditivo Plastificante 0,4%	1,62
Resistência à compressão média aos 28 dias de idade: 28 MPa	

Fonte – Lactec, 2007.

A seqüência de fotos a seguir ilustra as etapas de concretagem do bloco.




Figura 2 – (a) Vista lateral e (b) Vista superior da forma montada para o bloco cúbico de concreto.




Figura 3 – (a) Concretagem da camada inferior e (b) Posicionamento do tijolo para definir o espaço ocupado pelo defeito no bloco de concreto.




Figura 4 – (a) Posicionamento final do tijolo para definir o espaço ocupado pelo defeito e (b) Concretagem efetuada até o topo do tijolo.




Figura 5 – Substituição do tijolo por brita simulando uma região de elevada porosidade: (a) Fase inicial da deposição de brita e (b) Fase final.




Figura 6 – (a) Término da concretagem e (b) Vista superior da forma com o bloco de concreto e defeito em seu interior.

O bloco de concreto foi desformado após cura de 28 dias. O mesmo é apresentado na Figura 7. Não foram separadas amostras para obtenção da resistência característica f_{ck} , uma vez que parâmetros de resistência não teriam influência sobre o objetivo do ensaio térmico. Não foram realizados ensaios para caracterização de parâmetros térmicos, mas com base em informações bibliográficas, estima-se a condutividade térmica entre 1,8 e 2,0 W/m°C para o concreto e brita (basalto) e 0,025 W/m°C para o ar. Portanto, a razão entre as condutividades térmicas da anomalia (brita e ar) e do concreto pode ser considerada como pertencente ao intervalo $0,25 < R_k < 0,75$, considerado nas análises em regime permanente (Inácio *et al.*, 2009) que formam a base do banco de imagens do aplicativo computacional a ser empregado.



Figura 7 – Bloco de concreto com defeito para ensaios em laboratório.

2.2 Imposição das condições de contorno

Para estabelecer a condição de contorno de aquecimento em uma das faces do bloco conforme o modelo computacional de Inácio *et al.* (2009), utilizou-se uma manta térmica siliconada (ver Figura 8) com dimensões 80x80 cm, potência de 0,5 W/cm² (modelo Higherflex da empresa Higher, São José dos Campos – São Paulo) e campo de temperatura uniformemente regulado por termostato com precisão de $\pm 0,5$ °C.

Na face oposta ou frontal, o resfriamento por convecção (ar) foi naturalmente conseguido no ambiente de ensaio sob condições controladas de temperatura e umidade (ambiente fechado). As demais superfícies externas foram envolvidas por material isolante (lã de rocha 50 mm de densidade 32, isopor 50 mm e manta isolante em alumínio com 2 mm de espessura) para simular fluxo térmico nulo. A Figura 9 mostra a preparação do bloco para ensaio.



Figura 8 – Manta térmica siliconada.

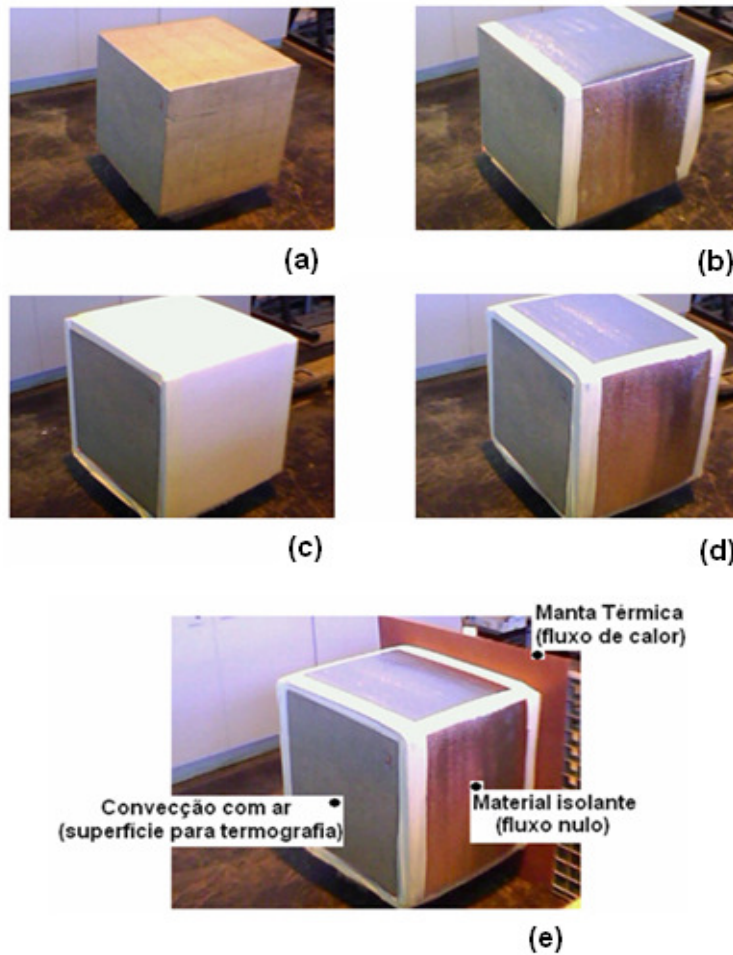


Figura 9 – Preparação do bloco: (a) Bloco de concreto, (b) Primeira e segunda camada de revestimento do bloco com lã de rocha e manta de alumínio, (c) Terceira camada de revestimento com isopor, (d) Quarta camada de revestimento utilizando novamente a manta de alumínio e (e) Configuração final do bloco para ensaio de termografia.

2.3 Obtenção das imagens termográficas

Para captar a alteração do fluxo de calor na superfície oposta à fonte de calor foi utilizado o aparelho de termografia InfraREM®-SC80 (REM Industria e Comércio Ltda – São Paulo – SP). Este equipamento lê as temperaturas superficiais de estruturas a partir da radiação infravermelha emitida pelo corpo e as registra em termogramas. Segundo o fabricante, 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.

Após o posicionamento do equipamento para o ensaio, foi acionado o sistema de aquecimento da manta térmica durante 24 horas a uma temperatura constante de 100°C ($T_w - T_a \approx 75\text{K}$, sendo a diferença de temperatura entre a fonte T_w e o ambiente T_a) para simular uma condição próxima do fluxo estacionário de calor através do bloco. Os termogramas foram obtidos a uma distância de 1,80 m do centro da superfície do bloco, como ilustra a Figura 10. As imagens foram gravadas em intervalos de dois segundos durante um minuto.

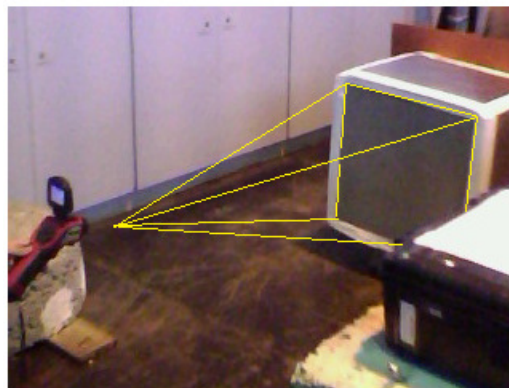


Figura 10 – Captação das imagens termográficas.

2.4 O aplicativo *Thermography and Artificial Neural Network*

O aplicativo *Thermography and Artificial Neural Network* foi desenvolvido por Pettres, Jarek e Lacerda (2011) a partir de um conjunto de 256 imagens térmicas (equivalentes a termogramas) de um bloco de concreto contendo uma anomalia em seu interior, simuladas pelo software Ansys em um estudo de transferência de calor em regime estacionário (Inácio *et. al.*, 2009). Esse conjunto de imagens forma a base de dados sintéticos utilizados no processo de treinamento das RNAs. Na Figura 11 é apresentada uma amostra do conjunto de dados sintéticos em escala de 128 cores.




Figura 11 - Amostra do conjunto de imagens. Características geométricas da anomalia: F = Largura; H = Altura; P = Espessura; D = Profundidade.

Fonte – Pettres, Jarek e Lacerda, 2011.

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, o modelo neural desenvolvido utiliza apenas os parâmetros F , H e D , para as saídas conhecidas *a priori* pelas RNAs em seu processo de treinamento.

2.4.1 Processamento das imagens

Para realizar o processamento das imagens térmicas, Pettres (2011) desenvolveu algoritmos baseados em técnicas de conversão e padronização a partir do padrão RGB (Russ, 2007), que converte a imagem inicial dada por uma matriz dimensão $M \times N \times 3$ (M = linhas, N = colunas de pixels e 3 se refere a cada uma das camadas R , G e B) em uma matriz de dimensão ($M \times N$). Neste processo os valores atribuídos a cada pixel (vetor de três componentes, R , G e B) são combinados linearmente através de coeficientes a_1 , a_2 e a_3 pré-selecionados e substituídos por um valor único de temperatura, como ilustra a

Figura 12.




Figura 12 – Matrizes do padrão RGB sendo processada para o padrão térmico bidimensional. Fonte – Pettres, Jarek e Lacerda, 2011.

Em seguida, são aplicados três algoritmos que têm por objetivo coletar informações sobre cada imagem. O primeiro algoritmo identifica o centróide da região de menor temperatura do campo térmico selecionado em imagem, que está associada a um índice de ocorrência de uma anomalia térmica. Este centróide é calculado após a identificação da região com temperaturas até 10% superiores à menor temperatura registrada, compondo assim, um subconjunto de elementos (i, j) com as menores temperaturas. A Figura 13 ilustra esta análise, com a localização do subconjunto (pontos em azul) e centróide em acordo com o perfil de temperaturas do termograma.

Os dois algoritmos seguintes coletam valores de temperatura que são utilizados para o treinamento, validação e teste de duas RNAs. A primeira RNA utiliza 13 valores de temperatura, coletados radialmente em um quadrante do entorno do centróide, como ilustra a Figura 14a. Para a segunda RNA, 25 valores são coletados a partir dos nós de uma malha quadrada de $0,16 \text{ m}^2$ (Figura 14b) com o centróide das temperaturas mínimas ao centro.

De acordo com Pettres (2011), 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, sendo armazenadas em um vetor contendo os padrões característicos de cada imagem. Dessa forma, os dois conjuntos de dados obtidos nesta etapa representam os sinais funcionais de cada uma das RNAs.

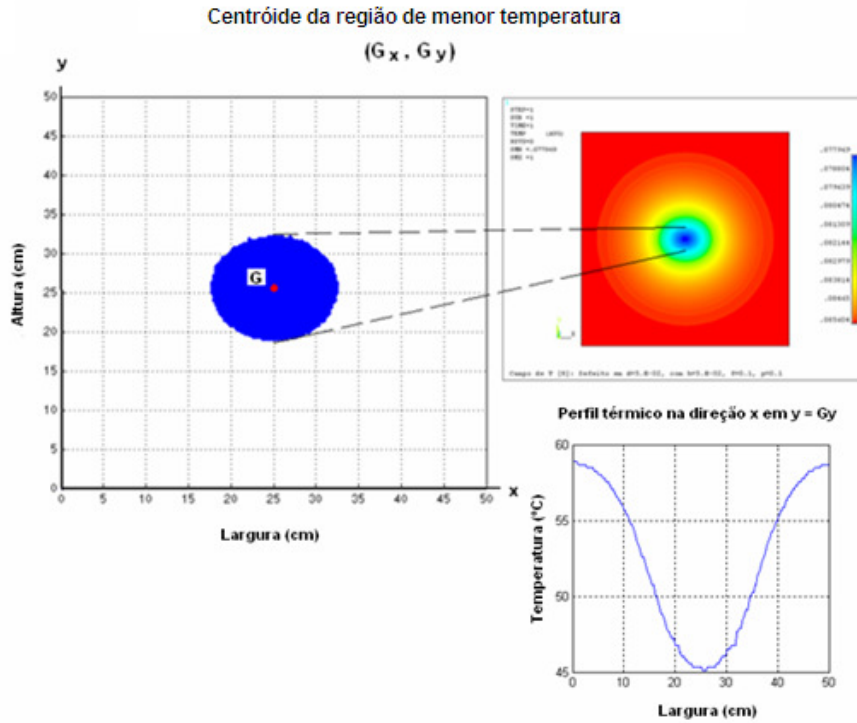


Figura 13 – Resultado para localização do centróide das temperaturas mínimas. Fonte – Pettres, Jarek e Lacerda, 2011.

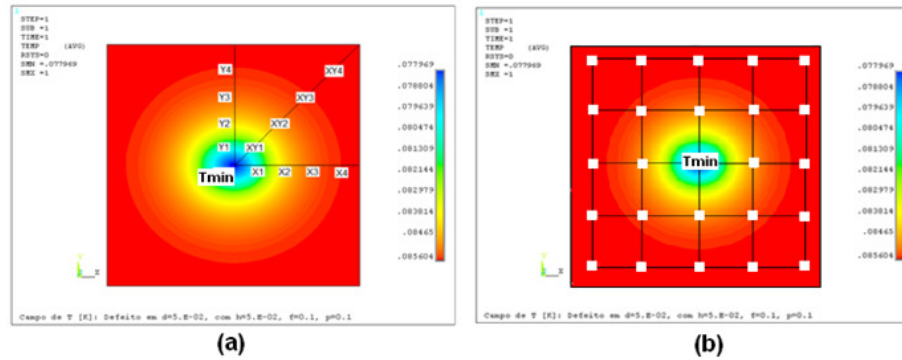


Figura 14 – Coleta de dados para o treinamento das RNAs (Modificado de Pettres, Jarek e Lacerda, 2011).

2.4.2 Descrição das RNAs

As redes neurais artificiais foram definidas com três camadas (entrada, escondida e saída) com funções de ativação tangente hiperbólica nas duas primeiras e linear na última. A função tangente hiperbólica é descrita pela equação abaixo:

$$y_k = \tanh(X_k) = \frac{e^{X_k} - e^{-X_k}}{e^{X_k} + e^{-X_k}} \quad (1)$$

onde $X_k = \sum_{vj} w_{kj} \cdot x_j + bias_k$, com w_{kj} sendo o peso utilizado para ponderar a entrada x_j da rede neural artificial e $bias_k$ é um valor usado para aumentar os graus de liberdade, permitindo uma melhor adaptação ao conhecimento fornecido à rede neural. As topologias das duas RNAs (ANN 1 - Artificial Neural Network 1 e ANN 2 - Artificial Neural Network 2) são apresentadas nas Figuras 15 e 16.




Figura 15 – Topologia da ANN 1. Fonte – Pettres, Jarek e Lacerda, 2011.




Figura 16 – Topologia da ANN 2. Fonte – Pettres, Jarek e Lacerda, 2011.

Pettes, Jarek e Lacerda (2011) citam que a escolha de neurônios lineares na camada de saída foi motivada pelo desejo de concentrar a atenção sobre o papel dos neurônios da camada escondida, 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. A inicialização das RNAs conta com o uso de pesos e valores de *bias* randômicos e também com a aplicação do algoritmo de Regularização Bayesiana que utiliza o algoritmo *backpropagation* (retropropagação) com termo de *momentum* em uma estrutura do tipo *feedforward* (Pettes, 2011). Redes *feedforward* são redes organizadas em camadas com conexões unidirecionais entre uma camada e outra, processando os dados paralelamente distribuídos.

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. Esses ajustes são feitos pelo algoritmo de Regularização Bayesiana, consistindo em adicionar um termo de penalização (regularização) à função objetivo, de forma que o algoritmo de estimação faça com que os parâmetros irrelevantes converjam para zero, reduzindo assim o número de parâmetros efetivos utilizados no processo (Mackay, 1991; 1992). A aplicação do termo de *momentum* tem como objetivo ponderar os ajustes nas matrizes sinápticas entre duas iterações anteriores e sucessivas acelerando o processo de 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). Nessa etapa, 80% das imagens térmicas geradas pelo Ansys são utilizadas pelo modelo neural para treinamento, 10% para validação e 10% para teste. Esse passo é realizado com o intuito de verificar a capacidade de generalização da rede e identificar o nível de erro da mesma.

2.4.3 Funcionamento do aplicativo

Ao executar o aplicativo é carregada a interface gráfica contendo os botões de operação em ambiente Matlab R2010® (Figura 17). O botão “Image Processing LDC” 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 (ANN 1 e ANN 2).

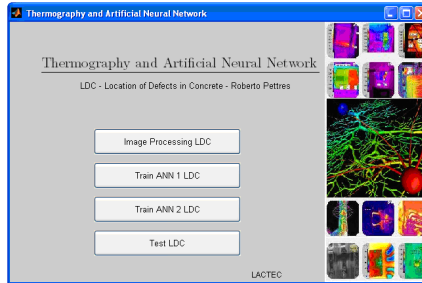


Figura 17 – Interface do aplicativo *Thermography and Artificial Neural Network*. Fonte – Pettres, Jarek e Lacerda, 2011.

Um clique sobre os botões “Train ANN 1 LDC” e “Train ANN 2 LDC” possibilita a inclusão de novas informações e novo treinamento das duas RNAs apresentadas. Como mencionado, as redes em questão foram treinadas com dados sintéticos obtidos através de uma modelagem com o software Ansys e a ferramenta computacional está pronta para realização de testes. Para isto, basta um clique sobre o botão “Test LDC” que seleciona os sinais funcionais resultantes do processamento da imagem em análise e os aplica à RNA selecionada. O resultado do conjunto de testes é apresentado na tabela indexada do Matlab R2010®, trazendo estimativas e erros para os parâmetros F , H e D desejados. 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 (Figura 18).

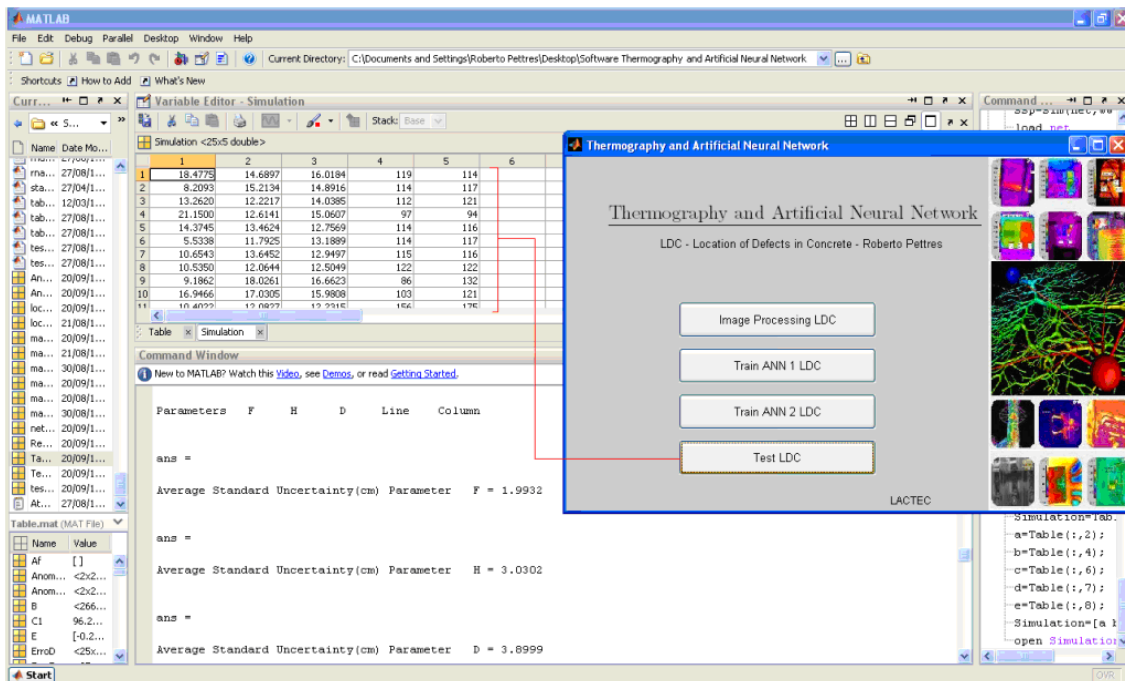


Figura 18 – Operação do aplicativo *Thermography and Artificial Neural Network*. Fonte – (Pettres, 2011).

3 Resultados e Discussões

A Figura 19 ilustra o processamento de uma imagem termográfica obtida no ensaio experimental realizado, onde se observa a localização da região de menor temperatura (região com temperaturas até 10% superiores à menor temperatura registrada; pontos em azul) e respectivo centróide (ponto G).

Centróide da região de menor temperatura
 $G(G_x, G_y)$

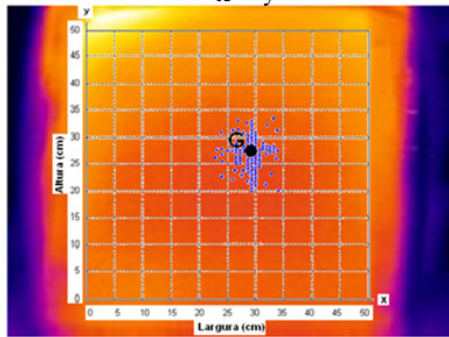


Figura 19 – Localização do centroide da região de menor temperatura.

Após identificar o centroide resultante de uma possível anomalia, o aplicativo inicia o processo de coleta dos sinais funcionais, ilustrado na Figura 20, para cada uma das duas redes neurais. Como resultado final tem-se estimativas dos parâmetros F , H e D para cada topologia neural.

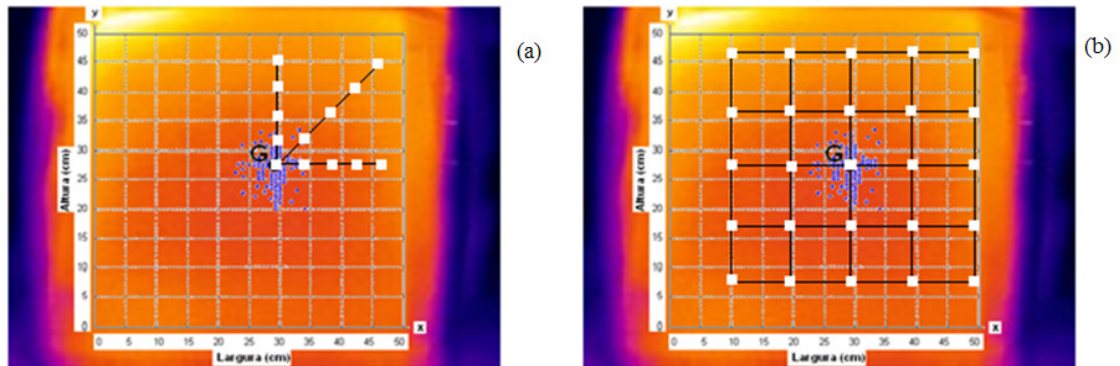


Figura 20 – Localização dos pontos de coleta de dados de entrada para as redes neurais.

Para verificar o desempenho de cada topologia, foram introduzidos os estimadores de erro relativo (ER) e desvio médio absoluto (DMA):

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

($ER=$ Erro Relativo, vr = valor real e vs = valor simulado pela topologia neural)

$$DMA = \frac{\sum_{m=F,H,D} |vr_m - vs_m|}{n} \quad (3)$$

($DMA=$ Desvio Médio Absoluto, vr = valor real e vs = valor simulado pela topologia neural)

Os resultados finais da imagem avaliada são apresentados na Tabela 3 onde se observa que a segunda topologia apresentou desempenho geral superior à primeira.

Tabela 3 – Resultados dos testes experimentais.

Topologia	F		H		D		Êxito		
	<i>VR</i>	<i>VS</i>	<i>VR</i>	<i>VS</i>	<i>VR</i>	<i>VS</i>	<i>DMA</i>	<i>ER</i>	100% – <i>ER</i>
RNA 1	19,00	15,54	9,00	17,24	10,00	8,04	4,55	43,13%	56,87%
RNA 2	19,00	22,47	9,00	12,46	10,00	12,05	3,00	25,78%	74,22%

(*DMA*=Desvio Médio Absoluto, *ER*=Erro Relativo, *VR* = valor real e *VS* = valor simulado pela topologia neural)

Uma análise individual de cada um dos parâmetros *F*, *H* e *D* é efetuada com um estimador de erro relativo individual (*ERI*), cujos resultados são apresentados na Tabela 4.

$$ERI = \frac{\sum_{n=1}^n |vr_n - vs_n|}{vr_n} \quad \Bigg|_{n=F, H, D} \quad (4)$$

(*ERI*=Erro Relativo Individual, *vr* = valor real e *vs* = valor simulado pela topologia neural)

Tabela 4 – Análise individual dos parâmetros *F*, *H* e *D*.

	F		H		D	
	<u><i>VR</i></u>	<i>ERI</i>	<u><i>VR</i></u>	<i>ERI</i>	<u><i>VR</i></u>	<i>ERI</i>
RNA 1 (<i>VS</i>)	19,00	18,21%	9,00	91,56%	10,00	19,60%
RNA 2 (<i>VS</i>)	22,47	18,26%	12,46	38,44%	12,05	20,50%

(*ERI*=Erro Relativo Individual, *VR* = valor real e *VS* = valor simulado pela topologia neural)

Observa-se que para os parâmetros *F* e *D*, o erro relativo individual (*ERI*) obtido com as duas topologias são relativamente próximos, variando entre 18,21% e 20,50%. No entanto, na determinação do parâmetro *H*, os resultados foram piores e com diferenças significativas entre as duas topologias. Destaca-se o resultado da segunda topologia que apresentou *ERI* de 38,44% contra 91,56% obtido com a primeira rede neural. Apesar das grandezas *H* e *F* representarem os comprimentos das arestas frontais do defeito, possivelmente, a menor magnitude de *H* contribuiu para um maior erro percentual.

4 Conclusão

A realização deste trabalho experimental envolveu a confecção de um bloco de concreto com uma anomalia conhecida, a utilização de equipamento termográfico específico e a aplicação de um aplicativo computacional baseado em redes neurais artificiais.

A análise de imagens termográficas obtidas no ensaio experimental do bloco permitiu a obtenção de parâmetros para o diagnóstico das condições subsuperficiais da face do bloco através de redes neurais artificiais. Constatou-se através dos resultados que foi possível identificar a presença da anomalia e, satisfatoriamente, sua localização e dimensões com a definição dos parâmetros *F* (largura), *H* (altura) e *D* (profundidade) referentes ao defeito interno.

O melhor resultado de aproximação foi obtido com a segunda rede neural artificial, que utiliza 25 dados de entrada distribuídos em uma malha quadrada centrada no ponto de menor temperatura da face. Com esta topologia o erro relativo obtido foi de 25,78% e desvio médio absoluto de 3 cm em relação às dimensões reais do defeito.

Os erros observados podem ser atribuídos às diferenças entre o protótipo ensaiado e o modelo computacional utilizado para a geração de dados sintéticos que formam a base de dados de treinamento das redes neurais artificiais. Entre essas diferenças cabe destacar a heterogeneidade do concreto, idealizado como material homogêneo nas análises numéricas, e o não atendimento das condições de contorno idealizadas no modelo computacional. Outro fator que dificulta a obtenção de melhores resultados é a possível proximidade entre os valores efetivos de condutividade térmica do concreto e do defeito imposto, ou seja, R_k mais próximo de 0,75 do que de 0,25.

Os resultados obtidos neste trabalho estão de acordo com os resultados obtidos numericamente por Obbadi e Belattar (2005), Elballouti e Belattar (2008) e por Pettres, Jarek e Lacerda (2011), comprovando o potencial do uso da termografia como ensaio não destrutivo para a identificação de anomalias subsuperficiais em concreto. Contudo, a metodologia apresentada deve ser estendida para uma situação de análise em regime transiente de transferência de calor para que a mesma possa ser utilizada na prática. Esta abordagem será considerada em um trabalho futuro.

Agradecimentos

Ao CNPq, pelos subsídios para a importação, constantes da Lei 8010/90, L.I 10/1725522-3, à ELEJOR, ao LACTEC e à ANEEL, pelo financiamento e infraestrutura para a condução deste projeto de pesquisa.

5 Referências Bibliográficas

- 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.
- Bray, D. E.; McBride, D. **Nondestructive testing techniques**, Nova York: John Wiley and Sons, 1992.
- 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.
- 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 da Produção - ENEGEP**. Ceará, Brasil : 2006.
- 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.
- 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.
- Lactec. Monitoramento do Complexo Santa Clara – Fundão. Relatório Técnico. RT LAME. 012.2011-R1, 2007.

- 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.
- 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.
- 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.
- 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.
- Pettes, R.; Jarek, A.; Lacerda, L. A. Aplicativo para o diagnóstico subsuperficial de estruturas baseado em imagens térmicas e redes neurais artificiais. **Learning & Nonlinear Models, SBRN-03/2011**, 2011.
- 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.
- Spicer, J. M.; Osiander, R. **Active Thermography, Nondestructive Evaluation – Theory, Techniques and Applications**. Edited by Petter J. Shull, New York: CRC Press, 2002.