

ANÁLISE DE IMAGENS TERMOGRAFICAS DE ESTRUTURAS DE CONCRETO A PARTIR DE REDES NEURAIIS ARTIFICIAIS

Roberto Pettres^{a, b}, Luiz A. de Lacerda^b

^{a, b} *Mestrando 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 Civis 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, alkimin@lactec.org.br.*

Palavras-chave: Testes não Destrutivos, Termografia, Processamento de Imagens, Redes Neurais Artificiais, Reconhecimento de Padrões.

Resumo. Este trabalho apresenta uma ferramenta de análise computacional baseada em termografia, processamento de imagens e redes neurais artificiais (RNA). A análise tem como objetivo obter um diagnóstico da integridade das estruturas de concreto através de teste não destrutivo, buscando a identificação de irregularidades no interior da estrutura. O desempenho da ferramenta é avaliado com o uso de imagens térmicas geradas numericamente com o software Ansys® em análises estacionárias de transferência de calor em blocos de concreto com anomalias conhecidas. As anomalias são parametrizadas por suas dimensões, posições em relação à superfície e propriedades térmicas. A ferramenta de análise foi implementada no software Matlab 6® e aplicada sobre um conjunto de 256 imagens resultantes de condições conhecidas. Os resultados foram avaliados com estimadores de erro para cada imagem, parâmetro e conjunto testado. A RNA desenvolvida apresentou testes com média de 72,88% das estimativas para os parâmetros característicos dos defeitos com erros relativos médios inferiores a 30%, permitindo a identificação de padrões defeituosos na estrutura de concreto.

Abstract. This paper presents a computational analysis tool based on thermal imaging, image processing and artificial neural networks (ANN). The analysis aims a diagnosis of the integrity of concrete structures through nondestructive testing, searching for irregularities within the structure. The tool performance is evaluated using numerically generated thermal images with the software Ansys® in steady-state heat transfer analyses in concrete blocks with known anomalies. The anomalies are parameterized by their size, position with respect to the surface and thermal properties. The analysis tool was implemented in Matlab ® 6 and applied to a set of 256 images resulting from known conditions. The results were evaluated with error estimators for each tested image, parameter and global set of parameters. The developed ANN presented an average of 72,88% of results for the characteristic parameters of the defects with mean relative errors below 30%, allowing the identification of damage patterns in the concrete structures.

Keywords: Non-Destructive Testing, Thermography, Image Processing, Artificial Neural Networks, Pattern Recognition.

INTRODUÇÃO

Estruturas de concreto podem apresentar imperfeições subsuperficiais como descontinuidades, microfissuras e espaços vazios, resultantes do processo construtivo. Tais defeitos são indesejados, especialmente em estruturas em permanente contato com a água, podendo interferir na estanqueidade e/ou durabilidade da estrutura (Metha & Monteiro, 2008).

Com o intuito de detectar esses defeitos, técnicas de análise não destrutiva, como a termografia digital, têm sido empregadas em estruturas de concreto (Spicer & Osinander, 2002). 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 & Carino, 2004).

Entretanto, não é trivial analisar os dados provenientes da termografia e obter um parecer sobre a estrutura de concreto sem técnicas e ferramentas computacionais específicas. Uma alternativa é o emprego de técnicas de Processamento de Imagem e técnicas de Inteligência Artificial, como por exemplo, Redes Neurais Artificiais (RNA).

O Processamento de imagem é uma forma de processamento de sinais, onde os dados são obtidos a partir do arquivo de imagem. Algumas técnicas de processamento utilizam um tratamento bidimensional, procurando extrair informações quantitativas de interesse ou que sejam básicas para o processo de análise, tornando possível a caracterização do fenômeno registrado no arquivo.

Sobre as Redes Neurais Artificiais, Haykin as define como técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes, podendo adquirir conhecimento pela experiência (Haykin, 2003). 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 feito pela RNA tem como objetivo classificar informações baseando-se em conhecimento *a priori* ou em informações estatísticas extraídas dos exemplos disponíveis para treinamento, atribuindo um rótulo a um objeto, de acordo com a informação fornecida pelo seu descritor (Nabney, 2004).

A partir de tais considerações, o presente trabalho tem como objetivo desenvolver uma ferramenta computacional baseada em Termografia, Processamento de Imagens e RNA, capaz de detectar anomalias subsuperficiais no interior de estruturas de concreto. A ferramenta foi desenvolvida e testada utilizando um conjunto de 256 imagens geradas numericamente no software Ansys® em regime estacionário de transferência de calor, em um bloco de concreto com uma anomalia cujas dimensões e distância à face avaliada são parametrizadas.

1 DESCRIÇÃO DO PROBLEMA TÉRMICO

O problema é descrito por Inácio *et al.* (2009), onde foi modelado um bloco com as propriedades físicas do concreto, com uma anomalia interna caracterizada por um material de maior porosidade, simulando a presença de um nicho de concreto mal vibrado, utilizando o software Ansys®. O bloco de concreto é de forma cúbica de lado $L=0.5\text{m}$, ilustrado pela Figura 1 e as variáveis parametrizadas são: a profundidade D do defeito em relação à

superfície de análise do bloco, as dimensões H (altura), F (largura) e P (espessura) do defeito.

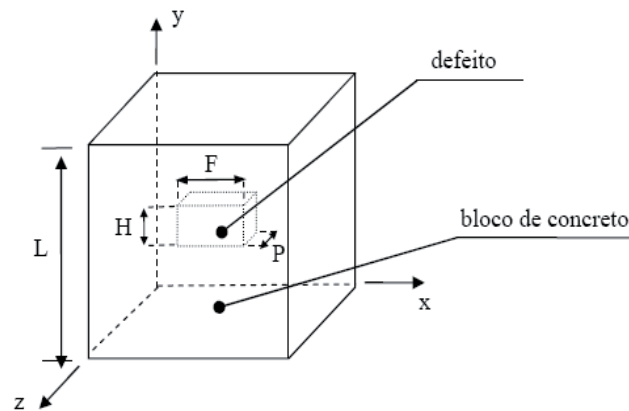


Figura 1 - Geometria do problema.

O modelo matemático adotado é 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):

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

A simulação numérica adotada consiste em discretizar a Eq. (1) através do Método dos Elementos Finitos com a utilização do software Ansys®, 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 3ª espécie é aplicada, descrevendo a existência na superfície 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.

A modelagem computacional foi realizada considerando-se: condutividade térmica do concreto $K_b = 2.75 \text{ W/m. K}$; condutividade térmica do defeito $K_d = 25\% \text{ KB}$ e coeficiente de convecção concreto/ar: $h_a = 13.95 \text{ W/m}^2 \text{ K}$.

Os valores atribuídos aos parâmetros D, H, F e P variaram entre 0.05, 0.10, 0.15 e 0.20 m, totalizando 256 combinações possíveis e, conseqüentemente, a geração de 256 imagens térmicas superficiais. Na Figura 3 é apresentada uma amostra do conjunto de imagens.




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

2 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 6, que associadas, convertem a imagem colorida em uma matriz tridimensional (M por N por 3), retornando valores do padrão RGB (do inglês *Red, Green and Blue*), associando a cada imagem um mapa de cores contendo 128 cores, e alocando um valor numérico para cada componente ijk (onde $k= 1, 2, 3$) da matriz correspondente (Figura 4).

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

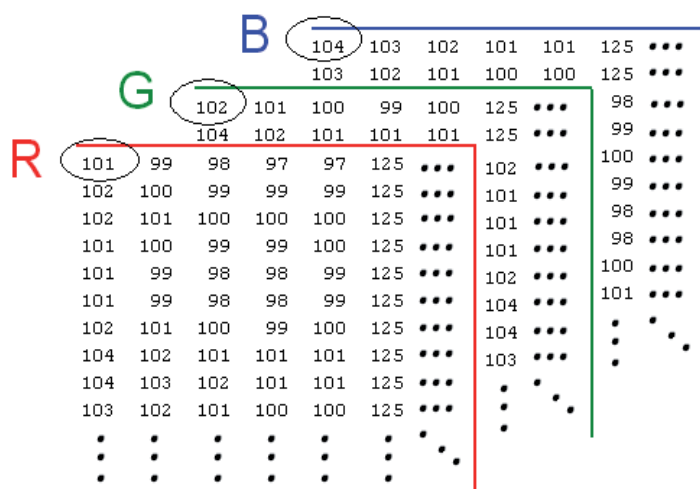


Figura 4 – Matrizes do padrão RGB.

A variação de cor entre pixels em regiões específicas da imagem revela a distribuição

térmica e seus gradientes na superfície do bloco. Com o intuito de obter estas variações, foram associados valores de temperaturas a cada pixel na imagem (Figura 5), substituindo os vetores de três componentes por valores de temperatura padronizados pelas 128 cores de acordo com a emissão de calor registrada na simulação em Ansys®, fazendo com que cada imagem seja representada por uma matriz M por N , representando um campo térmico bidimensional.




Figura 5 – Região selecionada da imagem gerada em Ansys® (esquerda); imagem ilustrativa da ampliação da região selecionada utilizando o software MikroView®2.9 (direita).

A Figura 5 é uma imagem ilustrativa representando a ampliação de uma região sobre a imagem gerada pelo Ansys® com o auxílio do software MikroView® 2.9, utilizado para análise termográfica, apresentando a temperatura de determinados pixels.

Na análise feita no campo térmico das imagens foi verificado que a presença do defeito no interior do bloco, sob as condições estabelecidas, produzia uma clara perturbação do campo térmico, coincidindo a localização da região mais fria do campo com a localização da projeção do defeito no plano frontal. Nesta mesma análise foi verificado que o parâmetro P , espessura do defeito, não apresentava alterações significativas no campo térmico registrado na superfície do bloco de concreto (Inácio *et al.*, 2009). As alterações significativas na imagem térmica na face resultaram da variação dos parâmetros, largura, altura e profundidade do defeito. Desta forma, optou-se em utilizar apenas estes três parâmetros, para as saídas conhecidas *a priori* pela RNA.

Para determinar as características para compor o conjunto de entradas da RNA, foi necessária a obtenção de informações que indicassem um padrão a ser detectado pela RNA, desta a forma, foram obtidas informações sobre o registro de temperaturas de cada modelo a partir de uma malha quadrada contendo 25 (Figura 6) nós, sendo coletados os valores de temperatura em cada nó.




Figura 6 – Malha 25 para localização das características térmicas.

Devido à sensibilidade das redes neurais às magnitudes absolutas, as informações obtidas durante o processamento das imagens foram normalizadas 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 as entradas ou também chamados sinais funcionais da RNA.

O tempo necessário de processamento para esta abordagem foi de 8,9 segundos para o conjunto de 256 imagens, utilizando um computador com 4 GB de memória RAM, sistema operacional de 32 bits e processador Intel® 2 Quad Core® CPU 2.33 Ghz.

3 PLANEJAMENTO DA REDE NEURAL ARTIFICIAL

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. Desta forma, a estrutura da rede é definida por três camadas, com vinte e cinco neurônios na camada de entrada e três neurônios na camada de saída referentes aos parâmetros desejados.

Para obter o número de neurônios na camada escondida, foram construídas vinte e cinco redes neurais, simuladas iterativamente variando a quantidade de neurônios nesta camada até um número igual à quantidade de sinais funcionais, buscando a quantidade que apresentasse o menor somatório de erro quadrático médio. Este processo é justificado pela importância que esta camada representa 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 camadas de entrada e escondida, utilizando a função tangente hiperbólica (Eq. 2) e adotando uma função linear (Eq.

3) 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).

$$y_k = \tanh(X_k) = \frac{e^{X_k} - e^{-X_k}}{e^{X_k} + e^{-X_k}} \quad (2)$$

onde

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

$$y_k = f \left(\sum_{j=1}^m w_{kj} \cdot x_j \right) \quad (3)$$

Para a arquitetura, foi definida uma rede feedforward. 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, 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 6 que utiliza o algoritmo de Regularização Bayesiana com retropropagação (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.

A fase de treinamento da rede foi definida 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 sub-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.

Sendo definida a estrutura das redes, os passos seguintes se referem ao treinamento, validação, teste dos modelos e a definição da topologia para determinar os três parâmetros de saída da RNA.

3.1 Treinando e Validando o modelo

A RNA foi inicializada de acordo com item 3. Dez treinamentos foram realizados para

cada estrutura utilizando validação cruzada, permitindo encontrar a topologia que representasse o menor nível de erro.

O nível de erro foi avaliado pela média dos erros quadráticos médios (MMSE) das respostas fornecidas por cada estrutura de 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 são apresentados na Tabela 1.

Análise dos erros e n° de neurônios na camada escondida

RNA	MMSE mínimo	MMSE médio	MMSE máximo	NNH	NTE	NTT	Tempo Total (segundos)
	2,3646	9,1050	30,4355	15	10	250	37602,4

Tabela 1 – Análise dos erros das simulações (NNH = número de neurônios na camada escondida com mínimo MMSE, NTE = número de treinamentos e NTT = número total de treinamentos).

Na Tabela 1, os valores pertencentes ao intervalo MMSE mínimo e máximo, indicam a flutuação dos erros da topologia encontrada, contendo 25 neurônios na camada de entrada, 15 na escondida e 3 na de saída, revelando o seu comportamento durante a fase de treinamento. O tempo necessário para definição desta topologia foi de 37602,4 segundos, referente ao total de 250 treinamentos. A Figura 7 ilustra a topologia encontrada e utilizada para o modelo de testes.

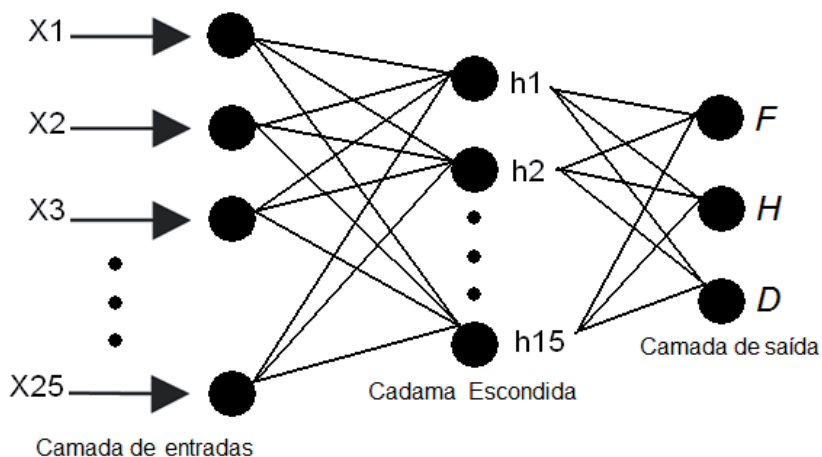


Figura 7 – Topologia da RNA.

4 RESULTADOS E DISCUSSÃO

Com o intuito de avaliar o desempenho da topologia da RNA definida, foram introduzidos os estimadores de erro quadrático médio (MSE) para cada parâmetro, incerteza padrão média (ASU), erro médio absoluto (MAE) e erro percentual médio absoluto (MAPE).

A Tabela 2 demonstra um dos conjuntos de testes realizados pela RNA. Nesta tabela são comparados os valores reais (VR) dos parâmetros utilizados na modelagem térmica do problema e os valores simulados (VS) fornecidos pela RNA. Os valores obtidos para os

estimadores de erro se referem à simulação do conjunto de teste (10%, dados inéditos).

Resultado de um conjunto de Testes (cm)

Teste	<i>F</i>		<i>H</i>		<i>D</i>		MAE	MAPE
	VR	VS	VR	VS	VR	VS		
1	10,00	10,03	10,00	9,07	15,00	15,52	0,49	4,4%
2	5,00	5,16	20,00	19,64	10,00	9,51	0,34	3,3%
3	5,00	4,91	15,00	15,18	20,00	19,84	0,14	1,3%
4	5,00	4,94	15,00	15,13	10,00	10,33	0,17	1,8%
5	5,00	5,10	10,00	10,37	10,00	10,26	0,24	2,8%
6	5,00	5,05	20,00	20,09	15,00	15,24	0,13	1,0%
7	20,00	19,80	20,00	19,67	20,00	19,96	0,19	0,9%
8	20,00	19,67	20,00	19,84	20,00	19,68	0,27	1,4%
9	20,00	19,63	15,00	12,77	5,00	5,91	1,17	11,6%
10	10,00	9,87	20,00	20,00	15,00	14,95	0,06	0,5%
11	10,00	10,08	5,00	3,87	5,00	5,08	0,43	8,3%
12	15,00	15,99	5,00	4,81	10,00	9,84	0,45	4,0%
13	20,00	19,42	20,00	11,90	20,00	20,28	2,99	14,9%
14	10,00	9,80	15,00	16,91	10,00	10,00	0,70	4,9%
15	5,00	4,98	20,00	19,31	15,00	15,14	0,28	1,6%
16	15,00	14,38	5,00	6,12	10,00	11,82	1,19	14,9%
17	20,00	19,16	10,00	7,32	15,00	14,91	1,20	10,5%
18	5,00	7,12	5,00	5,40	20,00	12,75	3,26	28,9%
19	20,00	19,14	15,00	17,35	10,00	10,92	1,38	9,7%
20	15,00	15,05	15,00	15,42	15,00	15,62	0,36	2,4%
21	20,00	19,23	10,00	7,44	10,00	11,43	1,59	14,6%
22	20,00	19,83	15,00	16,11	20,00	18,98	0,77	4,5%
23	10,00	10,42	5,00	4,15	15,00	13,54	0,91	10,3%
24	20,00	19,48	10,00	8,26	20,00	20,15	0,80	6,9%
25	20,00	20,29	20,00	19,82	10,00	9,13	0,45	3,7%
	MSE	0,37	MSE	4,13	MSE	2,60		

Tabela 2 – Resultados da RNA (VR=valor real, VS=valor simulado pela RNA).

As Figuras 8, 9 e 10 trazem os resultados da simulação contida na Tabela 2 para os parâmetros F, H e D. A linha em vermelho representa a resposta da RNA e a linha em azul representa o valor real padronizado e conhecido.

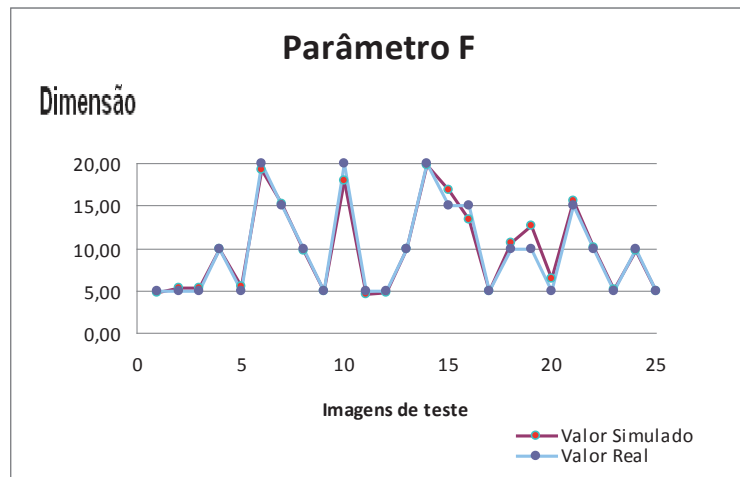


Figura 8 – Resultados da RNA, parâmetro F.

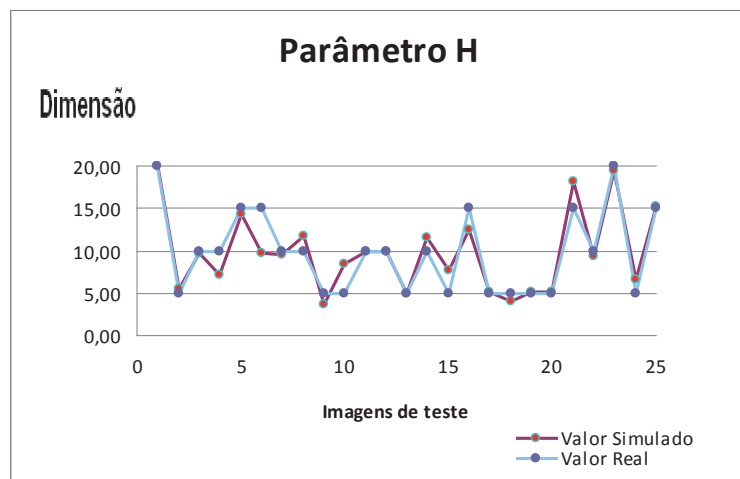


Figura 9 – Resultados da RNA, parâmetro H.




Figura 10 – Resultados da RNA, parâmetro D.

Neste conjunto de testes a RNA obteve êxito em 72% das estimativas, com erros relativos médios inferiores a 10% para os parâmetros característicos dos defeitos, tornando possível a identificações de padrões defeituosos nas estruturas de concreto.

Para testar a potencialidade da RNA, cem conjuntos de testes foram aleatoriamente selecionados com o intuito de obter a distribuição dos erros percentuais médios absolutos e o restante dos estimadores. A Figura 11 representa a distribuição dos erros.




Figura 11 – Distribuição dos erros.

É possível verificar na distribuição acima uma grande concentração dos erros médios (MAPE) nos intervalos de 10, 20 e 30%, indicando erros de baixa significância. A média dos erros cometidos pela RNA nestes testes foi de 23%, com erros médios de 12%, 23% e 33% para os parâmetros F, H e D, respectivamente. Cada conjunto de testes demandou 90,7 segundos de processamento.

Na análise de erros dos testes da RNA, foram obtidos erros quadráticos médios (MSE) de 3,24, 9,26 e 15,67 cm² para os parâmetros F, H e D. 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 1,80, 3,04 e 3,96 cm.

O estimador MAE utilizado indica o erro médio absoluto para o conjunto de parâmetros de cada imagem (teste), tornando possível a avaliação individual de cada teste. Para este estimador foram obtidos os valores 1,25, 2,33 e 3,05 cm. Estes valores indicam a flutuação média dos erros para cada um dos parâmetros F, H e D nos cem conjuntos de testes.

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 (VR) parametrizados, ajustando uma linha reta através dos pontos de modo a observar o espalhamento destes resultados (VR x VS) no entorno de $y(x)$. Para medir a proporção da variabilidade de VS que é explicada por VR, foi calculado o coeficiente de determinação R^2 (quadrado do coeficiente de Pearson). O valor de R^2 muito próximo da unidade indica uma forte relação entre as duas variáveis (Montgomery, 2003). Estes resultados são apresentados nos gráficos de dispersão a seguir:

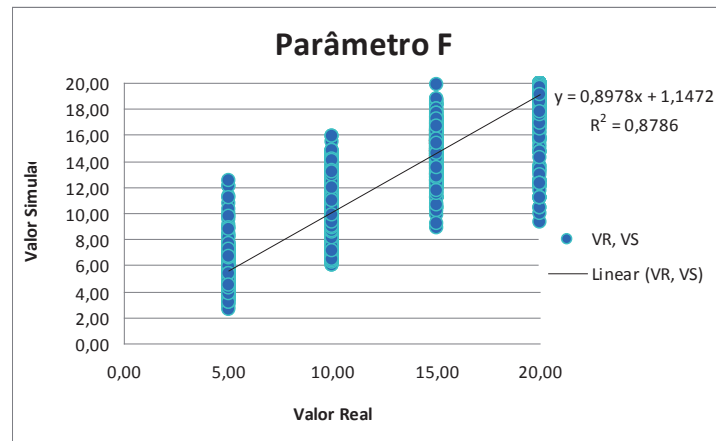


Figura 12 – Dispersão dos resultados da RNA, parâmetro F.




Figura 13 – Dispersão dos resultados da RNA, parâmetro H.




Figura 14 – Dispersão dos resultados da RNA, parâmetro D.

5 CONCLUSÃO

A partir dos estimadores de erro utilizados para a avaliação do desempenho da ferramenta computacional, foi verificado que o parâmetro F foi o que apresentou melhores resultados, sendo observado neste parâmetro uma incerteza padrão média (ASU) de 1,80 cm e R^2 de

0,8787, seguido pelo parâmetro H, ASU de 3,04 cm e R^2 de 0,7118 e D, ASU 3,96 cm com R^2 igual a 0.6004.

Os modelos matemáticos e os algoritmos utilizados na fase de processamento das imagens térmicas se mostraram precisos e eficientes, exigindo em média 0,034 segundos para efetuar cada processo. Os resultados das simulações computacionais indicaram que a rede neural artificial desenvolvida apresenta desempenho satisfatório, obtendo êxito em 72,88% das estimativas com erros relativos médios inferiores a 30%, permitindo a correlação entre as características do conjunto de imagens de superfícies térmicas à existência de defeitos na estrutura de concreto.

Nestas simulações 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, e os parâmetros obtidos para estas simulações se aproximaram dos valores reais.

Apesar dos resultados obtidos serem satisfatórios, para trabalhos posteriores fica como sugestão a aplicação de algoritmos de processamento de imagens em outros níveis de cores, outras técnicas de aprendizado das redes, outras funções de ativação bem como a quantidade de sinais funcionais e de camadas escondidas. Essas e outras hipóteses são objetos de estudos complementares e futuros.

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.

REFERÊNCIAS

- Barreto, J M. *Introdução às Redes Neurais Artificiais*, UFSC, Santa Catarina, 2004.
- Foressé, F. D & Hagan, M T. *Gauss-Newton Approximation to Bayesian Learning*, California Institute of Technology, Neural Computation, Pasadena, 1998.
- Haykin, S. *Redes Neurais Princípios e Práticas*. Bookman, 2003.
- Inácio, G R; Carrazedo, R; Lacerda, L A; Zdanski, P S B. *Análise da Viabilidade do uso de Termografia como Ensaio não Destrutivo para Identificação de Falhas Internas de Concretagem*. CILAMCE 2009.
- MacKay, D J. C. *Bayesian Interpolation*, California Institute of Technology, Neural Computation, Pasadena, 1992.
- Malhotra, V.M; Carino, N. J. *Handbook on Nondestructive testing of concrete*. Boca Raton London New York: CRC Press, 2004.
- Metha, K; Monteiro, J. M. *Concreto: estrutura, propriedades e materiais*. São Paulo: Editora IBRACON, 2008.
- Montgomery, D C. and 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*. Springer. Great Britain, 2004.
- Spicer, J M and Osiander, R. *Active Thermography, Nondestructive Evaluation – Theory, Techniques and Applications*, edited by Petter J. Shull, USA, 2002.
- Tsoukalas, L H. and Uhrig, R E. *Fuzzy and neural approaches in engineering*. John Wiley & Sons, New York, 1997.