

RECONHECIMENTO DE PADRÕES DE DEFEITOS EM CONCRETO A PARTIR DE IMAGENS TÉRMICAS ESTACIONÁRIAS E REDES NEURAIIS ARTIFICIAIS

*Roberto Pettres¹
Luiz Alkimin Lacerda²*

RESUMO: Este trabalho apresenta um método não destrutivo para o diagnóstico da integridade subsuperficial de estruturas de concreto utilizando imagens térmicas estacionárias e redes neurais artificiais (RNA). O desempenho do método 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, definidas por suas dimensões, posição em relação à superfície e propriedades térmica. O método de análise foi implementado no software Matlab 6® e aplicado sobre um conjunto de 256 imagens resultantes de condições conhecidas. Os resultados foram avaliados com estimadores de erro para cada imagem, parâmetro e conjunto global testado. A RNA desenvolvida apresentou um teste com 80% das estimativas para os parâmetros característicos dos defeitos com erros relativos médios inferiores a 20%, permitindo a identificação de padrões defeituosos na estrutura de concreto.

Palavras-Chave: Análise Não Destrutiva. Processamento de imagens. Reconhecimento de Padrões.

ABSTRACT: This paper presents a non-destructive method for diagnosis of subsurface integrity of concrete structures using stationary thermal imaging and artificial neural networks (ANN). The method performance is evaluated using numerically generated thermal images with the software Ansys® analyzes stationary heat transfer in concrete with known anomalies, defined by their size, position relative to the surface and thermal properties. The analysis method was implemented in Matlab 6® and applied on a set of 256 images resulting from known conditions. The results were compared with estimates of error for each image, and set global parameter tested. The ANN had developed a test with 80% of the estimates for the characteristic parameters of the defects with the mean relative errors less than 20%, allowing the identification of patterns in the defective concrete structure.

Keywords: Nondestructive Testing. Image Processing. 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 durabilidade da estrutura (METHA & MONTEIRO, 1994).

Com o intuito de detectar esses defeitos, técnicas de análise não destrutiva, como a termografia digital, têm sido empregadas em estruturas de concreto (SPICER & OSINDER, 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 (MALHORA & CARINO, 2004).

Um fator que contribui na análise termográfica em concreto é a variação da temperatura no material devido à reação de hidratação do cimento (FARIA, 2004). Durante tal reação ocorre a liberação do calor em toda a estrutura, causando fluxo de calor no material. O fluxo pode ser alterado quando descontinuidades estão presentes na estrutura, causando diferenças na temperatura superficial. Entretanto, não é trivial diagnosticar tais alterações sem ferramentas computacionais específicas. Uma alternativa é o emprego de técnicas de Inteligência Artificial, como por exemplo, Redes Neurais Artificiais e técnicas de Processamento de Imagens.

Redes Neurais Artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes, podendo adquirir conhecimento pela experiência (HAIKIN, 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 é um processo que atribui um rótulo a um objeto, baseado na informação fornecida pelo seu descritor (NABNEY, 2004).

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

Propõem-se neste trabalho utilizar RNA e técnicas de processamento de imagem com o objetivo de detectar anomalias subsuperficiais no interior de uma estrutura de concreto. O método desenvolvido é testado através de um conjunto de imagens térmicas geradas a partir de um estudo estacionário de transferência de calor em um bloco de concreto com uma anomalia cujas dimensões e distância à face avaliada são parametrizadas.

MATERIAIS E MÉTODOS

Modelo analisado

O conjunto de imagens térmicas utilizado no processamento com RNA foi gerado em análises numéricas de transferência de calor em regime estacionário. Para tanto, foi utilizado o software Ansys®, através do qual foi modelado um bloco com as propriedades físicas do concreto, com uma anomalia interna caracterizada por um material de maior porosidade para simular a presença de um nicho de concreto mal vibrado. As dimensões do bloco e da anomalia são apresentadas na Figura 1.

O bloco de concreto é de forma cúbica de lado $L=0.5\text{m}$. As variáveis parametrizadas são: a profundidade D da localização do defeito a partir da superfície de análise do bloco, as dimensões H (altura), F (largura) e P (espessura) do defeito.

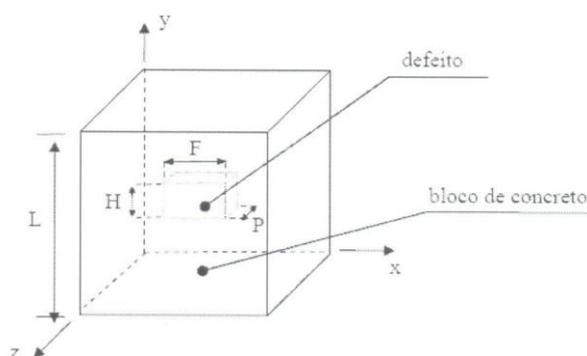


Figura 1 - Geometria do problema.
Fonte – (INÁCIO, 2009).

Modelo matemático

Para a solução do problema térmico foi analisado 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 de concreto K_B ou defeito K_d):

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

Um campo de temperatura uniforme foi aplicado na superfície do bloco em $z=0$ ($T(x,y,0)=T_w$). Em $z=L$ uma condição de 3ª espécie foi aplicada, descrevendo a existência na superfície de um resfriamento por convecção (ar) com coeficiente h_a a temperatura T_a . As demais superfícies externas (paralelas aos planos yz e xz) foram consideradas adiabáticas, ou seja, com fluxo térmico nulo.

Nas superfícies de contato do defeito com o bloco foram aplicados balanços de energia igualando os fluxos de calor entre os elementos adjacentes. A Figura 2 ilustra as condições de contorno aplicadas ao problema:

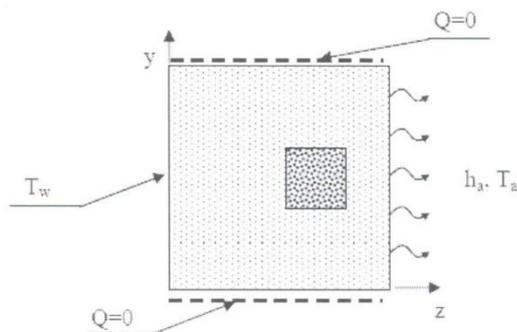


Figura 2 - Condições de contorno.
Fonte – (INÁCIO, 2009).

A modelagem computacional foi realizada considerando-se: condutividade térmica do concreto $K_B = 2.75 \text{ W/m. K}$; condutividade térmica do defeito $K_d = 25\% K_B$; 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 metros, totalizando 256 combinações possíveis e, conseqüentemente, a geração de 256 imagens. Na Figura 3 é apresentada uma amostra do conjunto de imagens.

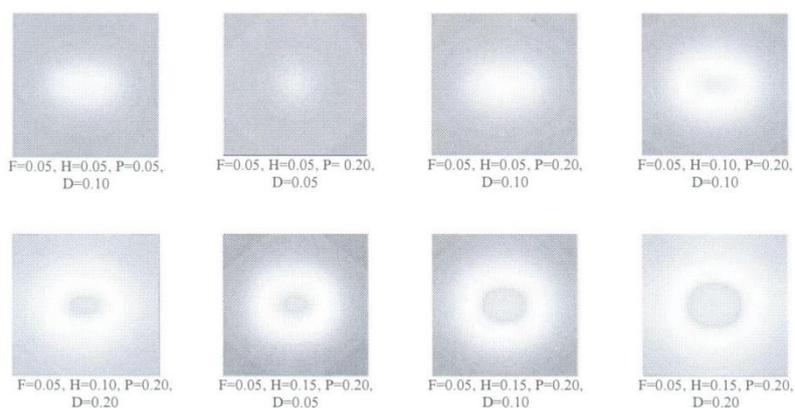


Figura 3 - Amostra do conjunto de imagens, F = Largura; H = Altura; P = Espessura; D = Profundidade.
Fonte – O Autor.

Processamento das imagens e a Rede Neural Artificial

O processamento das imagens e a técnica de reconhecimento de padrões foram desenvolvidos utilizando-se o programa computacional Matlab 6®, e compreenderam a implementação dos algoritmos de mineração de dados e da estrutura da RNA.

No processamento das imagens foram aplicadas as funções `colormap(128)` e `imread` ao conjunto de imagens térmicas. A associação destas funções computacionais do Matlab 6®, permitem a conversão da imagem colorida em uma matriz tridimensional (M por N por 3), retomado valores do padrão RGB (do inglês Red, Green and Blue) (RUSS, 2007), associando a cada imagem um mapa de cores contendo 128 cores, alocando um valor numérico a cada componente ijk (onde $k = R, G, B$) da matriz correspondente (Figura 4). Desta forma, cada pixel da imagem térmica passa a ser representado por um vetor de três componentes.

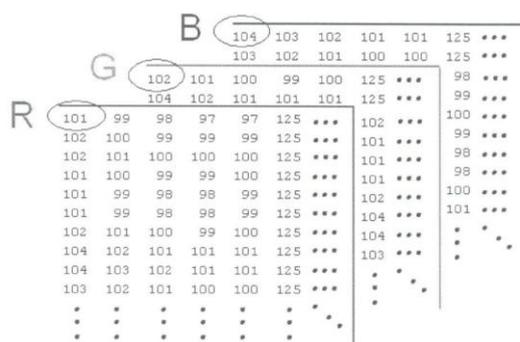


Figura 4 – Matrizes do padrão RGB.
Fonte: - O Autor.

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, 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.

A Figura 5 ilustra uma imagem térmica resultante de uma simulação numérica, para o caso $D=0.05$, $H=0.20$, $F=0.20$, $P=0.20$ m, com uma escala de cores representando a variação de temperatura na face.

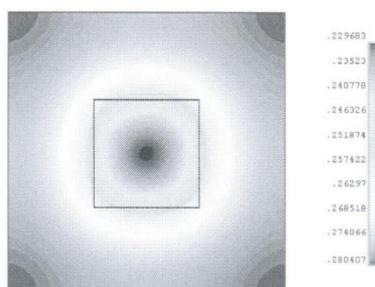


Figura 5 – Distribuição de temperatura ($D=0.05$, $H=F=P=0.20$ m).
Fonte: - O Autor.

A presença do defeito no interior do bloco, sob as condições estabelecidas, produziu 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.

Através da análise dos resultados térmicos, verificou-se que o parâmetro P, espessura do defeito, não apresentava alterações significativas no campo térmico registrado na superfície do bloco de concreto (INACIO, 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 a representação dos dados de entrada à RNA, foram analisadas características relacionadas à temperatura e observados alguns critérios para o desenvolvimento do reconhecimento de padrões. O primeiro critério diz respeito à localização do defeito, sendo encontrado inicialmente o centro de gravidade da distribuição de temperaturas mínimas em cada imagem (Figura 6), por coincidir com a região mais fria do campo térmico.

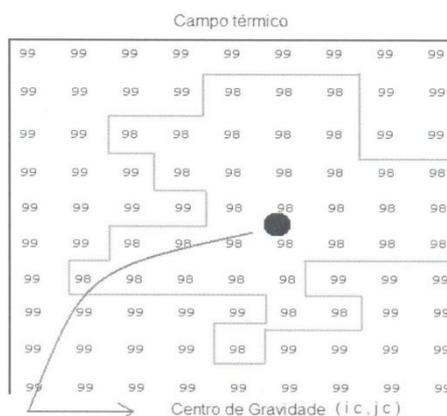


Figura 6 – Localização do centro de gravidade do defeito.
Fonte: - O Autor.

Sendo determinados estes centros, o critério seguinte é definido pela variação térmica a partir deste ponto, e a mineração destes dados permite a obtenção dos padrões característicos para gerar

descritores que caracterizam cada imagem, sendo assim, extraídos os valores pontuais de temperatura em treze pontos distintos sobre cada imagem de acordo com a Figura 7. Ao término deste processamento, são gerados vetores contendo os padrões térmicos monitorados em cada imagem, formando uma matriz de características observadas no conjunto de 256 imagens. As componentes desta matriz são normalizadas pelo valor máximo de temperatura de ensaio, devido à variabilidade dos valores observados, representando assim, os dados de entrada da RNA.

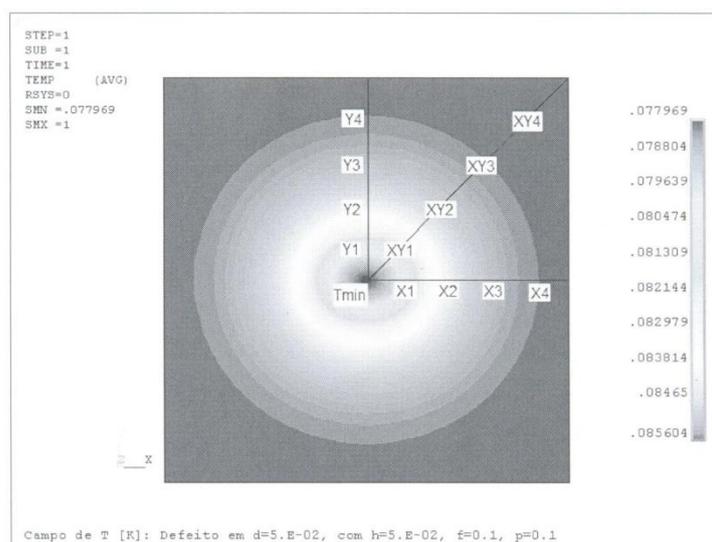


Figura 7 – Localização das características térmicas.
Fonte: - O Autor.

Para verificar o grau de correlação entre os padrões monitorados, foi aplicado um tratamento estatístico de análise de componentes principais (PCA) à matriz de características, tomando possível a análise da representatividade de cada variável no conjunto obtido. Este resultado é apresentado na Tabela 1.

Análise de Componentes Principais			
Variável	Autovalor	Var. Expl. (%)	Var. Expl. Acum(%)
1	9,2083	70,8329	70,83
2	3,2435	24,9502	95,78
3	0,3917	3,0132	98,80
4	0,0776	0,5970	99,39
5	0,0528	0,4059	99,80
6	0,0085	0,0655	99,86
7	0,0063	0,0485	99,91
8	0,0038	0,0295	99,94
9	0,0027	0,0209	99,96
10	0,0025	0,0194	99,98
11	0,0011	0,0083	99,99
12	0,0008	0,0062	100,00
13	0,0003	0,0026	100,00

Tabela 1 – Resultados da PCA.
Fonte: - O Autor.

Na tabela anterior, Var. Expl. indica o percentual de representatividade de cada variável, obtido a partir da proporção de variância explicada pelos autovalores da matriz de correlação. Desta forma, a PCA demonstrou que todas as componentes apresentam um nível significativo de relevância e a sua totalidade permite representar com qualidade cada imagem do conjunto total.

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. Uma rede de três camadas (entrada, escondida e saída), com um número suficiente de neurônios é adequada para representar qualquer mapeamento, e novas camadas só devem ser acrescentadas se a arquitetura em mãos não for adequada (TSOUKALAS & UHRIG, 1997).

Foram testadas inúmeras estruturas como o intuito de obter a rede que apresentasse melhor desempenho. Nas diferentes redes foram testados: a) o algoritmo backpropagation (BARRETO, 2004), utilizando as funções de transferência hiperbólica e linear e treinamento de regularização bayesiana (HAYKIN, 2003), b) funções de transferência gaussiana com a função de aprendizado de Bases Radiais (HAYKIN, 2003). Assim, a estrutura da rede foi definida com três camadas de neurônios, sendo treze neurônios de entrada (input i = características monitoradas, $i = 1, 2, \dots, 13$), oito na camada escondida (Hidden) e três na saída (output j = largura, altura e profundidade do defeito, $j = 1, 2$ e 3), conforme ilustra a Figura 8.

Os testes para avaliação da RNA foram definidos usando validação cruzada com subamostragem aleatória do conjunto de imagens, compondo os grupos de treinamento (80%), validação (10%) e teste (10%). O desempenho da RNA neste procedimento é apresentado no quadro 1 e se refere à simulação de uma rede neural do tipo feedforward (alimentada à frente) (BARRETO, 2004) com o algoritmo backpropagation, utilizando as funções de transferência hiperbólica nas duas primeiras camadas e linear na camada de saída. Os valores das conexões sinápticas foram inicializados aleatoriamente, modificando-se a cada ciclo no sentido de fazer a saída aproximar-se da desejada. Para o treinamento da rede foi utilizado o algoritmo de regularização bayesiana (HAYKIN, 2003) e aprendizado supervisionado (BARRETO, 2004).

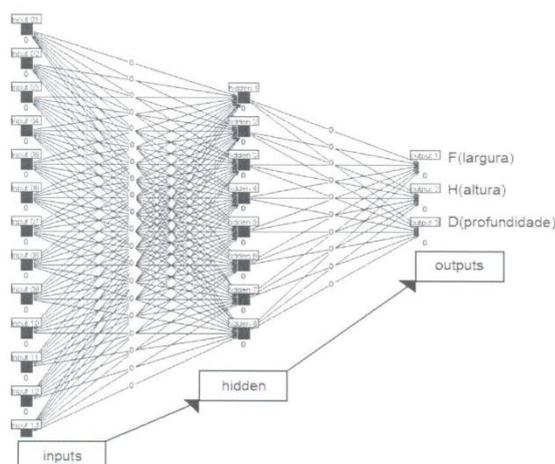


Figura 8 – Rede Neural Artificial definida para o diagnóstico das imagens.
Fonte: - O Autor.

RESULTADOS E DISCUSSÃO

Após uma série de treinamentos e validações a RNA foi selecionada para execução do conjunto de testes. Para realizar essa seleção, foi introduzido o estimador de erro quadrático médio (MSE) para cada parâmetro em uma sub-rotina iterativa visando valores mínimos de erro. Após a obtenção destes resultados também foi avaliado o erro médio absoluto (MAE), erro percentual médio absoluto (MAPE) e desvio padrão (SD) para cada imagem e o estimador de erro médio absoluto (MES) para o conjunto analisado.

O resultado do conjunto de teste é apresentado na Tabela 2, onde são comparados os valores reais (VR) dos parâmetros, utilizados nas modelagens térmicas, e os valores simulados (VS) obtidos com a RNA.

Resultados do conjunto de Teste (cm)								
Teste	<i>F</i>		<i>H</i>		<i>D</i>		MEI	MAPE
	VR	VS	VR	VS	VR	VS		
1	15.00	15.05	20.00	21.00	15.00	15.49	0.51	2.9%
2	20.00	21.20	20.00	20.90	10.00	8.26	1.28	9.3%
3	5.00	5.11	20.00	19.80	15.00	14.65	0.22	1.8%
4	20.00	19.38	10.00	10.77	20.00	18.50	0.96	6.1%
5	5.00	5.02	15.00	15.59	15.00	14.99	0.21	1.5%
6	10.00	10.51	10.00	9.47	20.00	16.30	1.58	9.6%
7	5.00	5.10	15.00	14.68	15.00	14.96	0.16	1.5%
8	15.00	16.33	5.00	6.69	20.00	15.22	2.60	22.2%
9	15.00	14.70	5.00	4.99	5.00	5.22	0.18	2.2%
10	5.00	4.97	20.00	19.39	15.00	15.18	0.28	1.7%
11	15.00	15.57	5.00	8.77	10.00	8.36	1.99	31.8%
12	10.00	9.56	5.00	6.12	10.00	11.03	0.86	12.3%
13	15.00	14.47	10.00	12.12	20.00	18.79	1.29	10.3%
14	5.00	4.62	5.00	5.97	5.00	5.30	0.55	11.0%
15	5.00	4.91	10.00	9.57	10.00	9.34	0.39	4.2%
16	15.00	16.99	5.00	5.99	20.00	16.64	2.11	16.6%
17	10.00	10.46	20.00	20.42	10.00	8.77	0.70	6.3%
18	15.00	17.26	5.00	7.15	15.00	9.91	3.17	30.7%
19	5.00	5.01	5.00	6.86	10.00	6.91	1.65	22.8%
20	20.00	18.07	5.00	6.32	15.00	10.73	2.51	21.5%
21	5.00	5.20	5.00	6.54	15.00	12.98	1.25	16.1%
22	15.00	15.45	20.00	18.92	10.00	9.84	0.56	3.3%
23	5.00	5.63	20.00	19.76	20.00	19.22	0.55	5.9%
24	15.00	14.69	20.00	21.04	15.00	16.49	0.94	5.7%
25	15.00	14.97	15.00	15.63	15.00	15.07	0.24	1.6%
	MSE	0.75	MSE	1.74	MSE	4.86	MES=1.07	

Tabela 2 – Resultados da RNA (VR=valor real, VS=valor simulado pela RNA).
Fonte: - O Autor.

Observa-se que o estimador MSE revela um erro quadrático médio de 0.75, 1.74 e 4.86 cm² para os parâmetros *F*, *H* e *D* respectivamente.

O estimador MAE indica o erro médio absoluto para o conjunto de parâmetros de cada imagem, tornando possível a avaliação individual de cada teste. O estimador MES indica o erro quadrático absoluto médio do conjunto total de testes, que em associação ao MAE e ao SD, permite a construção da zona de normalidade dos resultados da rede após a verificação de normalidade neste conjunto, sendo esta zona definida pelo intervalo [0.21, 1.93] com média (MES) igual a 1.07 cm, desvio padrão de 0.86 cm e índice de tolerância de 1.93 cm (um desvio padrão acima da média).

Na análise de erros dos testes, 8% estão sob a zona de normalidade, indicando erros com baixo grau de significância, 72% dentro desta região e apenas 20% acima. Estes resultados, aliados aos valores encontrados para o estimador MPE indicam que a RNA obteve êxito em 80% das estimativas, com erros relativos médios inferiores a 20% para os parâmetros característicos dos defeitos, tornando possível a identificações de padrões defeituosos nas estruturas de concreto.

A Figura 9 a seguir traz os resultados da simulação contida na Tabela 2 para o parâmetro *D*, onde a linha em vermelho representa a resposta da RNA e a linha em azul representa o valor real padronizado e conhecido.

Para verificar a significância desse resultado foi aplicado o método estatístico de regressão linear sobre os dados, ajustando uma linha reta através dos pontos de modo a observar a dispersão dos dados no entorno de $y(x)$. Para medir a proporção da variabilidade de VS que é explicada por VR, foi calculado o coeficiente de determinação R². A Figura 10 mostra esse resultado.

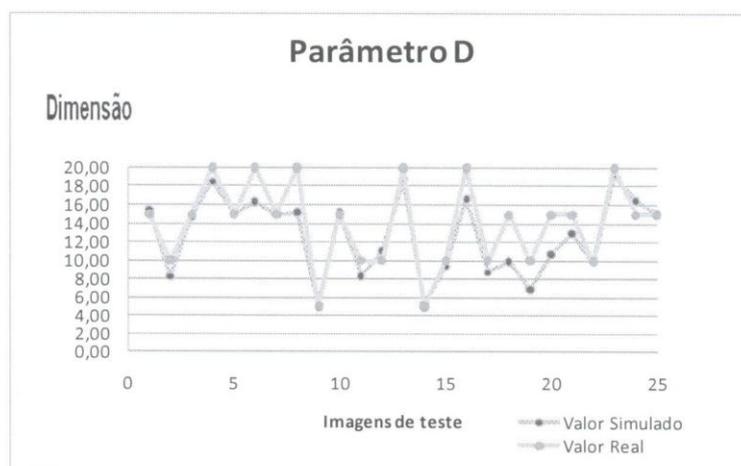


Figura 9 - Resultados da RNA, parâmetro *D*.
Fonte: - O Autor.

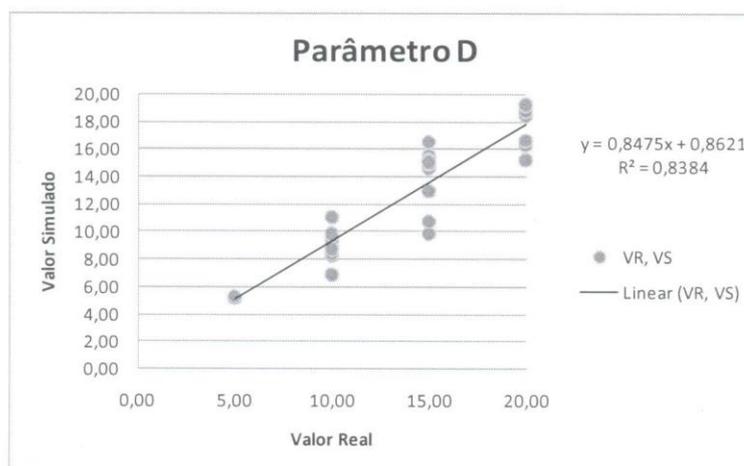


Figura 10 - Dispersão dos resultados da RNA, parâmetro *D*.
Fonte: - O Autor.

CONCLUSÃO

Os resultados das simulações com redes neurais artificiais permitiram a correlação entre características selecionadas do conjunto de imagens térmicas à existência de defeitos na estrutura de concreto.

O parâmetro *F* foi o parâmetro que apresentou melhores resultados, sendo observados neste parâmetro um MSE de 0.75 e R^2 de 0.9777, seguido pelo parâmetro *H*, MSE de 1.74 e R^2 de 0.9766 e *D*, MSE 4.86 com R^2 igual a 0.8384.

A modelagem matemática e computacional desenvolvida permitiu que o método de reconhecimento de padrões baseado em Análise Termográfica e Redes Neurais Artificiais apresentasse

os resultados esperados. Esses resultados indicam grande potencialidade da técnica aplicada para a detecção de defeitos em estruturas de concreto.

REFERÊNCIAS

BARRETO, Jorge M. **Introdução às Redes Neurais Artificiais**, UFSC, Santa Catarina, 2004.

FARIA, Étore Funchal de. **Modelo de previsão da elevação adiabática de temperatura do concreto através de redes neurais artificiais. Furnas centrais elétricas s.a.**. Departamento de Engenharia Civil. Programa de Engenharia Civil / COPPE - Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil, 2004.

HAYKIN, Simon. **Redes Neurais Princípios e Práticas**. Bookman, 2003.

INÁCIO, G. R., CARRAZEDO, R., LACERDA, L. A. **Análise da Viabilidade do uso de Termografia como Ensaio não Destrutivo para Identificação de Falhas Internas de Concretagem**. CILAMCE 2009.

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 Pini, 1994.

NABNEY, Ian T. **Netlab Algorithms for Pattern Recognition**. Springer. Great Britain, 2004.

RUSS, Jonh C. **The image processing handbook** / by Jonh C. Russ, 5th ed. CRC Press. Canadá, 2007.

SPICER, Jane Maclachlan and OSIANDER, Robert. **Active Thermography, Nondestructive Evaluation: Theory, Techniques and Applications**, edited by Petter J. Shull, USA, 2002.

TSOUKALAS, Lefteri H. and UHRIG, Robert E. **Fuzzy and neural approaches in engineering**. John Wiley & Sons, New York, 1997.

¹ Roberto Pettres é professor de Matemática e atualmente é mestrando do Programa de Pós-graduação em Métodos Numéricos em Engenharia pela Universidade Federal do Paraná - Curitiba, Paraná, Brasil, desenvolvendo pesquisas sobre Inteligência Artificial no Instituto de Tecnologia para o Desenvolvimento LACTEC no 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@dlactec.org.br, robertopettres@yahoo.com.br.

² Luiz Alkimin de Lacerda é pesquisador no Instituto de Tecnologia para o Desenvolvimento LACTEC e gerente do Departamento de Estruturas Cíveis DPEC - Curitiba, Paraná, Brasil. CEP: 81531-090. Caixa Postal: 19067. Tel.: +55 41 3361 6111. Fax: +55 41 3361 6141. E-mail: alkimin@lactec.org.br.