EMPREGO DE RNAs PARA ESTIMATIVA DA PROFUNDIDADE DE CARBONATAÇÃO DO CONCRETO: ESTUDO PRELIMINAR

SUCAPUCA, L. A. A.[1], POSSAN, E.[2], KONZEN, P.[3]

Universidade Federal de Integração Latino Americana, Estudante, e-mail: kasu.suca@gmail.com
Universidade Federal de Integração Latino Americana, Professor, e-mail: epossan@gmail.com
Universidade Federal de Integração Latino Americana, Professor, e-mail: phkonzen@gmail.com

RESUMO

Este trabalho avalia a profundidade de carbonatação de diferentes concretos, empregando Redes Neurais Artificiais (RNAs). Para formar o banco de dados, foram utilizados resultados de profundidade de carbonatação natural oriundos de estudos de diversos pesquisadores e informações advindas de conhecimento de *experts*, agrupados em nove casos distintos. Aproximadamente, 67% destes dados foram empregados no treinamento e 33% na validação da rede. O tipo de cimento, o teor de adição, a resistência à compressão axial do concreto, o tempo ou idade, o teor de CO_2 do ambiente, a umidade relativa e as condições de exposição foram empregadas como variáveis de entrada da rede, tendo como variável de saída a profundidade de carbonatação do concreto. Os cálculos foram conduzidos no pacote computacional *Yapy*, utilizando-se o algoritmo de treinamento *Levenberg-Marquardt* (LM). O erro máximo relativo obtido com o emprego do modelo gerado foi de 11%, indicando que a utilização de redes neurais artificiais é viável para o estudo comparativo da carbonatação do concreto.

Palavras chave: Simulação; Modelagem; Concreto; Estimativa; Patologia.

ABSTRACT

This paper assesses the depth of carbonation of different concrete using Artificial Neural Networks (ANN). To build the database, used results from natural carbonation depth studies originating from many researchers and information derived from the knowledge of experts, grouped into nine distinct cases. Approximately 67% of these data were used in training and 33% in the validation set. The type of cement, the addition content, the compressive strength of the concrete, time or age, the CO2 content of the environment, humidity and exposure conditions were used as input variables of the network, with the variable output depth of carbonation of the concrete. The calculations were conducted in the computational package *Yapy*, using the training algorithm *Levenberg-Marquardt* (LM). The maximum relative error obtained with the use of the generated model was 11%, indicating that the use of artificial neural networks is feasible for the comparative study of concrete carbonation.

Keywords: Simulation, Modeling, Concrete; estimate; Pathology.

1. INTRODUÇÃO

1.1. Carbonatação

A profundidade de carbonatação tem grande influência na vida útil das estruturas de concreto, pois sua ocorrência gera condições favoráveis para o início do processo corrosivo do aço, o que não é desejável.

A carbonatação é um fenômeno físico-químico de neutralização, que resulta das reações de gases ácidos do ambiente, sobretudo o dióxido de carbono (CO_2), com os componentes alcalinos do concreto (hidróxido de cálcio - $Ca(OH)_2$), que precipitam como carbonato de cálcio ($CaCO_3$) à presença de água, conforme equação simplificada abaixo (equação 1).

$$(Ca(OH)_2 + CO_2 \longrightarrow CaCO_3 + H_2O) \qquad \text{Equação 1}$$

Essa reação ocorre da superfície para o interior do concreto e, como consequência, tem-se a redução do pH do concreto, originalmente maior que 12,5, para valores em torno de 8,5 (BAKKER, 1988, MEHTA e MONTEIRO, 2008). Se a profundidade carbonatada for igual ou superior à espessura do cobrimento da armadura, diz-se que a mesma sofreu despassivação, estando suscetível à corrosão, caso haja condições favoráveis para sua ocorrência (umidade e temperatura elevadas).

Em geral, as reações de carbonatação são bastante lentas, sendo influenciadas por fatores como características do concreto e condições de exposição, que podem limitar ou intensificar o transporte dos agentes agressivos para o interior do concreto (ver figura 1). No caso da carbonatação, o mecanismo de transporte do CO_2 para o interior do concreto é a difusão.

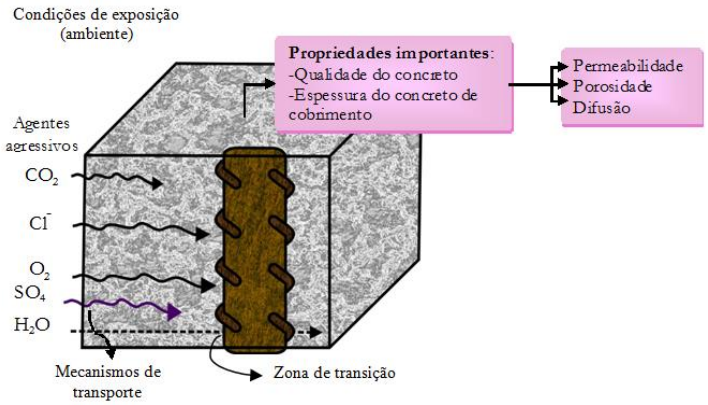

Figura 1: ingresso de agentes agressivos no concreto e fatores de influência. Fonte: (Adaptado de Rostam, 2003)

Face às inúmeras variáveis que influenciam a carbonatação e a consequente degradação do concreto, os estudos a partir de uma base probabilística, tentando simular as situações possíveis de ocorrer na natureza, têm ganhado crescente destaque. A teoria de confiabilidade destaca-se como um dos primeiros métodos estocásticos a ser utilizado para esse fim (ANG e TANG, 1984); não obstante, outras abordagens probabilísticas são empregadas atualmente para estudos de sistemas de engenharia, destacando-se a Lógica Fuzzy, as Cadeias de Markov (VESIKARI, 1992; LIFECON, 2003; MORCOUS e LOUNIS, 2005; POSSAN, ANDRADE e DAL MOLIN, 2008) e as Redes Neurais Artificiais, que são objeto deste estudo.

1.2. Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são ferramentas computacionais para o processamento de informação inspiradas por estudos de redes neurais biológicas. Tais ferramentas são obtidas de modelos matemáticos da cognição animal baseada nas hipóteses gerais de que: (1) o processamento da informação se dá paralelamente por vários elementos simples (neurônios); (2) porções da informação (sinal) são transferidas para vários neurônios através de múltiplos enlaces; (3) cada neurônio transforma o sinal recebido através de uma função de ativação, produzindo um novo sinal de saída (FAUSETT, 1993). A representação de um neurônio biológico e um neurônio artificial é mostrada nas figuras 2 e 3, respectivamente.

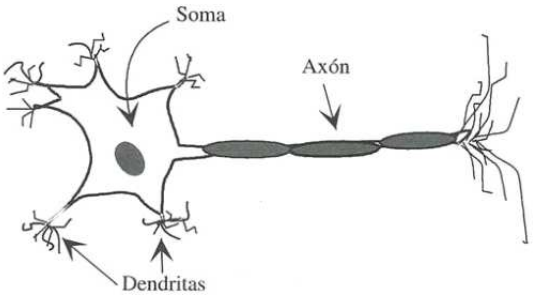

Figura 2: Neurônio Biológico

Fonte:(Grupo CAT-AM)

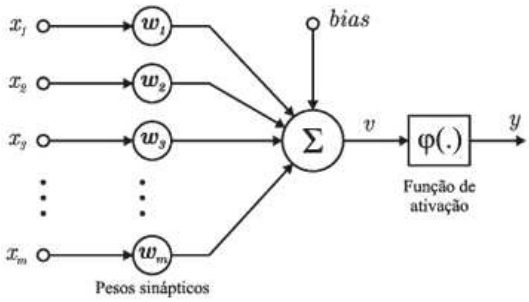

Figura 3: Neurônio Artificial Perceptron

Fonte: (Revista Cérebro & Mente)

Uma RNA é caracterizada pelo padrão das conexões entre os neurônios (arquitetura da rede), pelo algoritmo utilizado para a calibração do modelo matemático que descreve a rede (algoritmo de treinamento) e a escolha das funções de ativação de cada neurônio. Neste estudo, utilizou-se uma rede *Perceptron Multicamada* (MLP, *multilayer perceptron*), com função de ativação sigmoidal, empregando o algoritmo de treinamento *Levemberg-Marquadt backpropagation* (HAGAN, 2002).

RNAs do tipo MLP são conhecidas por terem a capacidade de modelar tanto problemas lineares como não lineares. A existência de algoritmos de treinamento eficientes para rede MLP e sua característica de ser uma mapeadora universal (HORNIK, 1989), faz dela uma ferramenta poderosa para a construção de um modelo para estimar a profundidade de carbonatação de concreto. O funcionamento da MLP aplicada neste trabalho pode ser esquematizado conforme representação da Figura 4.

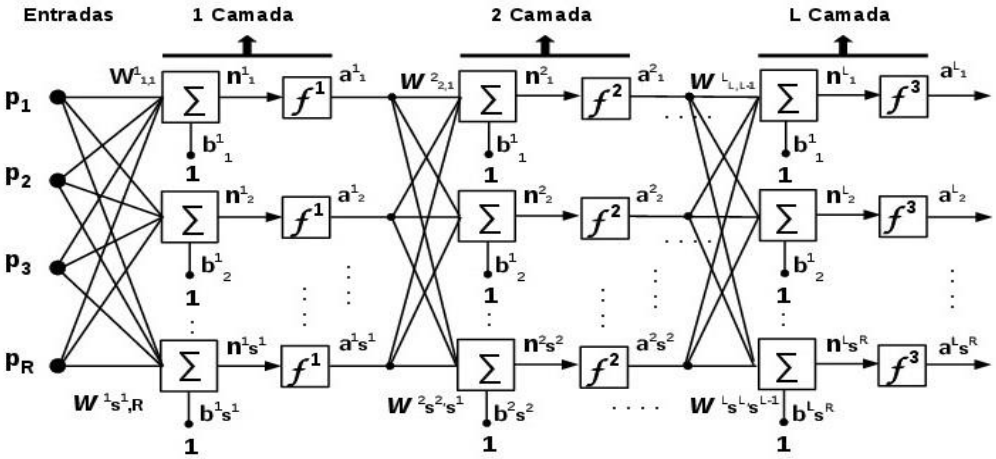

Figura 4: Esquema de uma MLP Fonte: (Adaptado da revista SciELO)

O conjunto de dados de entrada X_i, com $i = 1,2,\dots,n_{in}$, onde n_{in} é número de variáveis de entrada, é propagado através das $n_h + 1$ camadas de neurônios (n_h camadas escondidas e uma camada de saída). A camada de saída contém o mesmo número de neurônios n_{out} que o número de variáveis de saída $Y_j^{\{n_h+1\}}$, com $j = 1,2,\dots,n_{out}$. O j-ésimo neurônio da camada k, com $k = 1,2,\dots,n_h + 1$, recebe uma média ponderada dos sinais provenientes da camada anterior $k-1$, onde $k = 0$ indica a camada de entrada da rede. Esta média é, então, transformada através da função de ativação no sinal de saída do neurônio Y_j^k, i.e.:

$$Y_j^k = f\left[\sum_{i=1}^{k-1} W_{ij}\, Y_i^{k-1} + b_j^k\right]. \qquad \text{(Equação 2)}$$

Onde W_{ij} é o peso do enlace do neurônio i da camada $k-1$ com o neurônio j da camada k e b_j^k é chamado *bias* do neurônio j da camada k. A função de ativação empregada em cada neurônio foi a função sigmoidal dada por:

$$f(x) = \frac{2}{1+e^{-\theta x}} - 1 \qquad \text{(Equação 3)}$$

Onde $\theta > 0$ é um parâmetro fixo.

Desta forma, a obtenção de um modelo para a profundidade de carbonatação de concreto é, aqui, reduzido a um problema de mapeamento de um conjunto de dados X (por exemplo, tipo e idade do cimento, umidade relativa, etc.) em outro conjunto Y (profundidade de carbonatação do concreto). Resolver este problema utilizando a MLP descrita significa: 1) determinar o conjunto X; 2) determinar o número de camadas e o número de neurônios em cada camada da MLP; 3) determinar o parâmetro θ da função de ativação.

Compostas por várias unidades de processamento (neurônios) as RNA são interligadas por conexões (sinapses), sendo que cada conexão possui um peso associado (peso sináptico). A arquitetura das RNAs é formada por várias camadas, sendo uma de entrada e uma camada de saída, entre as quais se encontram camadas intermediárias. Essas camadas podem possuir vários neurônios ou podem adotar apenas um. A dependência da quantidade de neurônios leva em consideração o tipo de problema e os estudos conduzidos (FAUSETT, 1993).

Essas redes são ferramentas com capacidade de resolver problemas não lineares, cuja aplicabilidade crescente em várias áreas do conhecimento deve-se à sua capacidade de generalização. A generalização está associada à capacidade da rede aprender por meio de um conjunto reduzido de exemplos significativos e posteriormente dar respostas coerentes para dados desconhecidos. A capacidade destas redes vai muito além do que simplesmente mapear relações de entrada e saída. As RNAs são capazes de extrair informações não apresentadas de forma explícita, por meio de exemplos (BOCANEGRA, 2002).

As RNAs constituem-se uma ferramenta computacional bastante atrativa para a solução de problemas complexos de engenharia, sendo empregada neste trabalho para o estudo da profundidade de carbonatação do concreto (e_c). Para tal, fez-se uso de um pacote computacional denominado "*Yapy*", em desenvolvimento na Universidade Federal da Integração Latino Americana (UNILA), o qual permite a criação de modelos via RNAs.

1.3. Pacote computacional

1.3.1. Yapy

O pacote computacional "*Yapy*" em desenvolvimento na Unila é baseado na linguagem C++ e está fundamentado segundo a teoria das Redes Neurais Artificiais, com as redes do tipo *Hebb*, *Perceptron* e *Perceptron* Multicamadas (MLP), Função Base Radial (RBF) implementada até o momento.

A diferença entre a rede Perceptron e a MLP é o tipo de problemas que conseguem modelar. A MLP consegue resolver problemas não lineares e com várias camadas escondidas na

arquitetura da rede, enquanto a Perceptron unicamente se foca em resolver problemas linearmente separáveis. A RBF resolve os mesmos problemas das redes tipo MLP, sendo menos complexas e com maior velocidade de simulação.

As redes *Perceptron* e a MLP possuem implementados os algoritmos de treinamento *Backpropagation* (as variações classic, momentum e delta-bar-delta) e o *Levenberg-Marquardt*, sendo descrito na sequência apenas o último algoritmo, devido seu emprego neste estudo.

Devendo aclarar que o pacote computacional project-yapy é livre e pode ser obtido em https://code.google.com/p/project-yapy/.

1.3.2. Algoritmo de treinamento *Levenberg-Marquardt* (LM)

No pacote computacional *Yapy,* está implementado o algoritmo *Levenberg-Marquardt* na rede *perceptron* multicamadas. O algoritmo emprega iterações do tipo Newton para ajustar os pesos da rede de forma que minimiza o erro (ver equação 4), isto é, encontra o mínimo da função erro, onde representa os pesos da rede, é o enésimo valor esperado e o *i-ésimo* valor estimado [11].

$$F(\boldsymbol{w})=\Sigma[\ yi\ (\boldsymbol{w})-xi\ (\boldsymbol{w})]2 \qquad \text{(Equação 4)}$$

Onde; F (w) é yi , xi

A partir de uma modificação no método de Newton, a correção dos pesos na RNA é dada pela equação 5.

$$\Delta w=-[J\ T\ (w)J\ (w)+\mu\ I\ ]-1\ J\ T\ (w)v(w) \qquad \text{(Equação 5)}$$

onde, Δ_W é a variação nos pesos, J é a matriz Jacobiana dos erros em relação aos pesos e bias, I é um parâmetro para garantir a inversa indicada, v(w)=y(w)-x(w) é μ a matriz identidade. Observa-se que conforme o valor de μ aumenta, este método se aproxima ao Método de Newton e diminui (tende a zero) se aproxima ao Método de Gauss-Newton.

2. Descrição metodológica

Para conseguir desenvolver um modelo que represente o processo de carbonatação do concreto mediante o uso de Redes Neurais Artificiais, usou-se a metodologia apresentada na Figura 5.

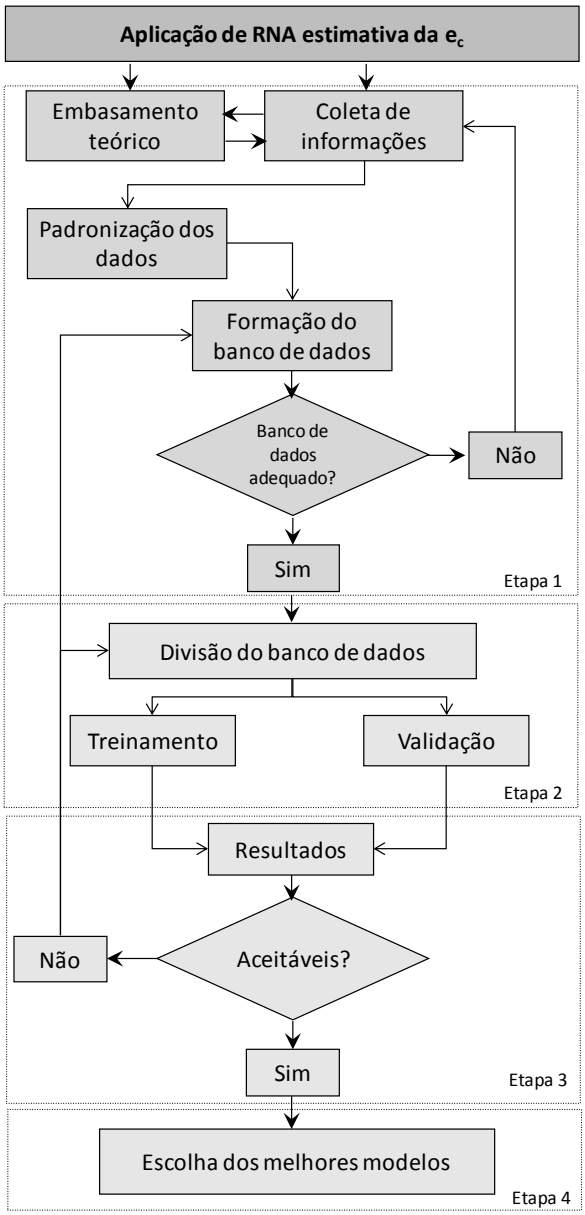

Figura 5: fluxograma do emprego de RNAs para o estudo da carbonatação do concreto

A primeira etapa compreendeu a montagem do banco de dados (padronização, seleção) e a separação nos distintos casos a examinar. Na segunda etapa, escolheram-se os dados para o treinamento e para validação. Na terceira etapa foram gerados os resultados e na quarta etapa

fez-se a seleção dos modelos mais representativos da degradação do concreto por carbonatação.

2.1 Montagem do Banco de dados

O banco de dados foi formado com dados de profundidade de carbonatação natural e informações compiladas por Possan (2010) dos trabalhos de Isaias (2001), Vieira (2009) e Meira (2006), além de informações de *experts* obtidas por Possan (2010), resultando em 252 exemplos (dados).

Os fatores de maior influência na carbonatação do concreto citados por Pauletti et al. (2007) foram considerados como entradas na rede neural (tipo de cimento, teor de adição (%), resistência à compressão do concreto (MPa), tempo (anos), teor de CO_2 do ambiente (%), umidade relativa (%), condições de exposição), tendo como saída da rede a profundidade de carbonatação do concreto, em mm. Na tabela 1, apresentam-se as características das entradas e da saída para a rede.

Tabela 1: Fatores considerados na modelagem

Variáveis		**Características dos dados - intervalos**
Número	**Descrição**	
Entrada 1	Tipo de Cimento	CP II-E*
		CP II-Z*
		CP II-F*
		CP III*
		CP IV*
		CP V ARI*
Entrada 2	Teor de adição (%)	0.0≤ teor de adição ≥ 50.0
Entrada 3	Resistência à compressão do concreto (MPa)	20.0 ≤ resistência ≥ 84.60
Entrada 4	Tempo (anos)	0.0 ≤ tempo ≥ 60.0
Entrada 5	Teor de CO_2 do ambiente (%)	0.01, 0.035, 1.0, 3.0
Entrada 6	Umidade relativa (%)	50.0, 70.0, 68.0, 90.0
Entrada 7	Condições de exposição	Ambiente interno, protegido da chuva (IP)** Ambiente externo, protegido da chuva(EP)** Ambiente externo, desprotegido da chuva(ED)**
Saída 1	Profundidade carbonatação (mm)	0.0≤ profundidade ≥ 54.64

* Para cada tipo de cimento empregou-se um algarismo para condução da modelagem.
** Empregaram-se os Coeficientes do modelo de predição de Possan (2010), onde: IP= 1.3, EP=1.0 e ED=0.65.

Os dados de profundidade de carbonatação (e_c) foram organizados de forma crescente, para a argumentação e um melhor entendimento da viabilidade do uso de RNAs na e_c os quais foram distribuídos em 9 casos. Cada caso corresponde a uma rede que é gerada após várias interações (treinamento e/ou aprendizagem).

2.2 Treinamento e Validação

O treinamento ocorre em paralelo com a validação, sendo que a cada interação (treinamento e validação) a(s) camada(s) intermediária(s) da rede sofrem opcionalmente o acrescimento de um neurônio. Para os nove casos apresentados na tabela 2, o treinamento e a validação iniciaram com uma camada intermediária, desta forma, é possível comparar resultados que se encontram nos mesmos parâmetros, para isso foi adotado: 100 treinamentos para cada caso com 100 a 1000 épocas (entende-se época como uma iteração do algoritmo de treinamento).

Tabela 2: dados empregados para o treinamento e validação da rede para cada caso estudado

Casos	Treinamento	No de dados de entrada	Validação	No de dados de entrada
Caso 1:	(POSSAN, 2010)*	77	Isaia (2001)	108
Caso 2:	(POSSAN, 2010)	77	Isaia **	48
Caso 3:	(POSSAN, 2010)	77	Vieira (2009)	40
Caso 4:	(POSSAN, 2010)	77	Vieira **	20
Caso 5:	(POSSAN, 2010)	77	Meira (2004)	27
Caso 6:	(POSSAN, 2010)	77	Meira **	24
Caso 7:	(POSSAN, 2010)	77	Isaia + Vieira + Meira	175
Caso 8:	(POSSAN, 2010)	77	Isaia + Vieira + Meira **	92
Caso 9:	~67 % do total dos dados	170	~33 % do total dos dados	82

* Dados oriundos do conhecimento de experts.
** Dados fora do intervalo do treinamento foram eliminados.

O número de épocas foi definido em função do problema estudado, em busca de resultados aceitáveis em comparação à literatura. A arquitetura inicial das redes do pacote "*Yapi*" foi alterada para uma mais adaptável ao fenômeno da carbonatação do concreto, sendo empregada a rede *Perceptron* multicamadas e o algoritmo *Levenberg – Marquardt* para o aprendizado do problema não linear da carbonatação.

3. Resultados

Para a análise e escolha dos melhores resultados usaram-se os seguintes tipos de erros de medida: a correlação, norma do máximo relativo e o Erro em volume. Na tabela 3, mostram-

se os melhores resultados obtidos nos treinamentos. Nas figuras 5 e 6 são apresentados os casos 1 e 2, cuja validação foi conduzida com os dados de Isaia (2001).

Com base na análise dos casos de 1 a 8, verifica-se que a rede teve uma boa aprendizagem (os oito casos tiveram um treinamento bem distribuído na reta y=mx). Entretanto, quando se observa a validação, verifica-se que os coeficientes de correlação são bastante reduzidos, indicando a pouca representatividade do modelo.

Tabela 3: Melhores resultados de cada caso

Casos	Treinamento			Validação		
	Correlação	Erro*	Erro em volume	Correlação	Erro*	Erro em volume
Caso 1	0.993	0.148	0.147	0.886	0.279	-81.592
Caso 2	0.980	0.177	0.310	0.748	0.322	-2.708
Caso 3	0.986	0.149	0.153	0.464	0.465	26.862
Caso 4	0.992	0.142	0.763	0.710	0.157	1.753
Caso 5	0.986	0.130	-0.091	0.251	0.435	-28.345
Caso 6	0.986	0.148	-0.038	0.480	0.353	-11.913
Caso 7	0.993	0.149	0.004	0.565	0.612	31.067
Caso 8	0.983	0.140	6.587	0.282	0.513	-3.440
Caso 9	0.996	0.065	2.619	0.988	0.111	-0.030

* Erro estimado com base no parâmetro da norma do máximo relativo

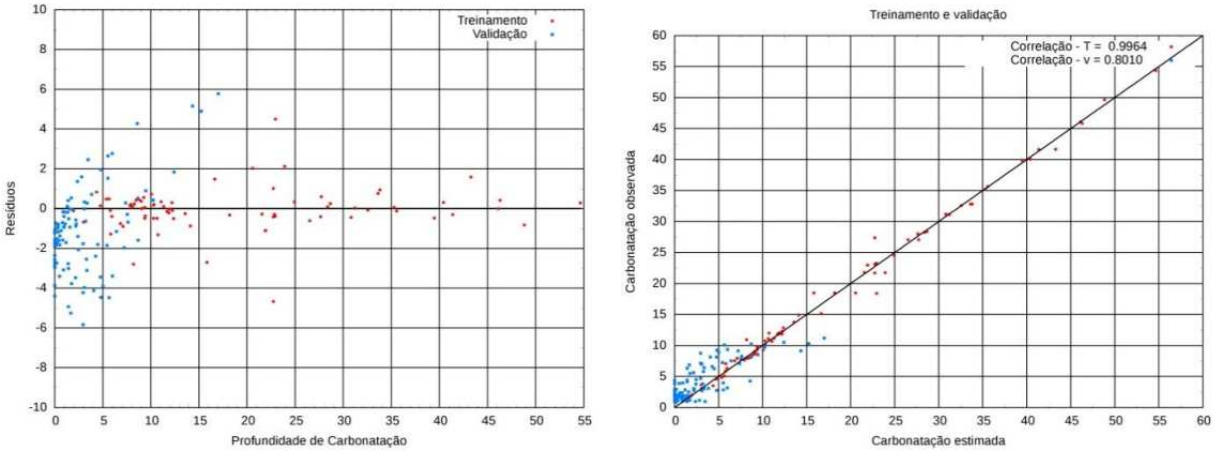

a) b)

Figura 6: CASO 1 a) resíduos b) Previsto Vs Estimado

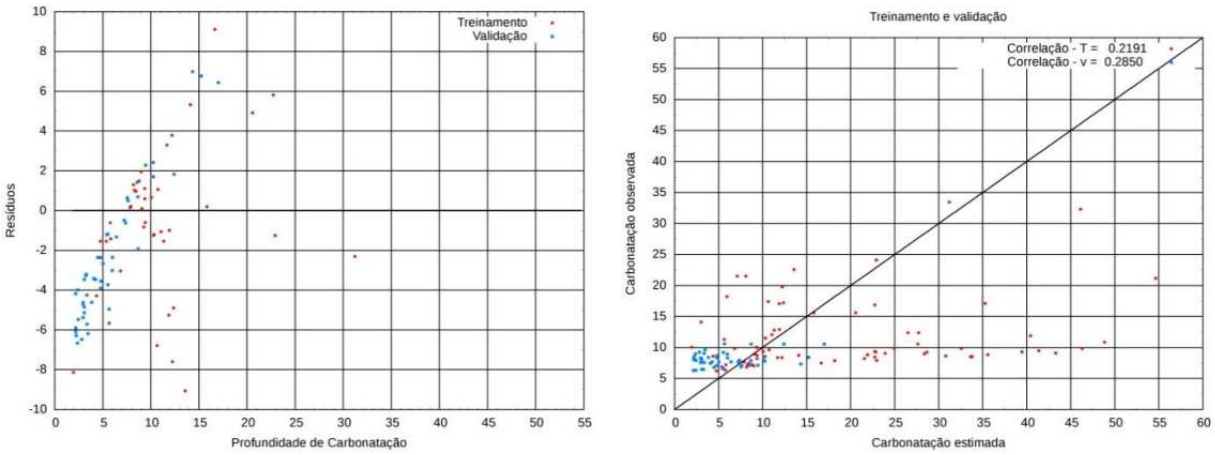

a) b)

Figura 7: CASO 2 a) resíduos b) Previsto Vs Estimado

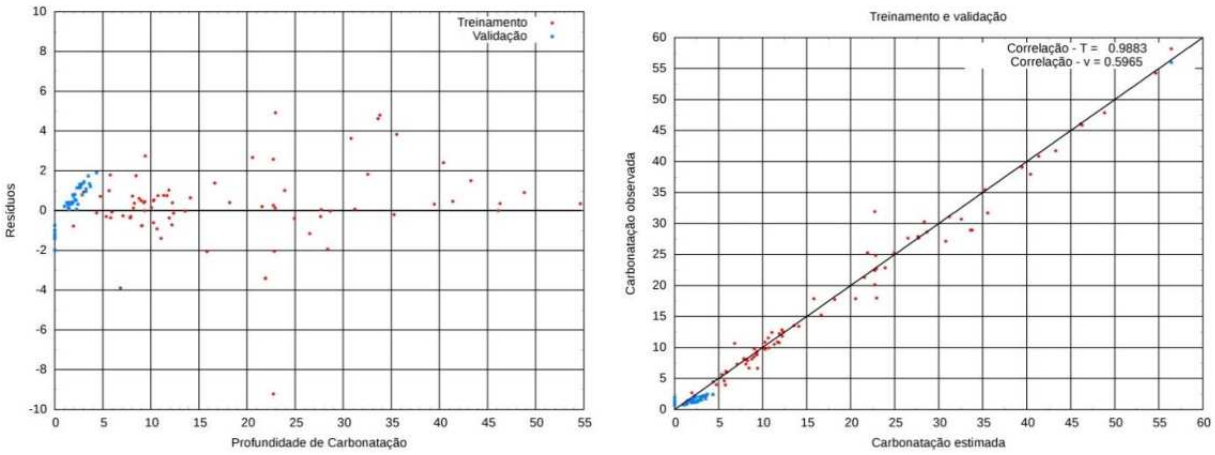

a) b)

Figura 8: CASO 3 a) resíduos b) Previsto Vs Estimado

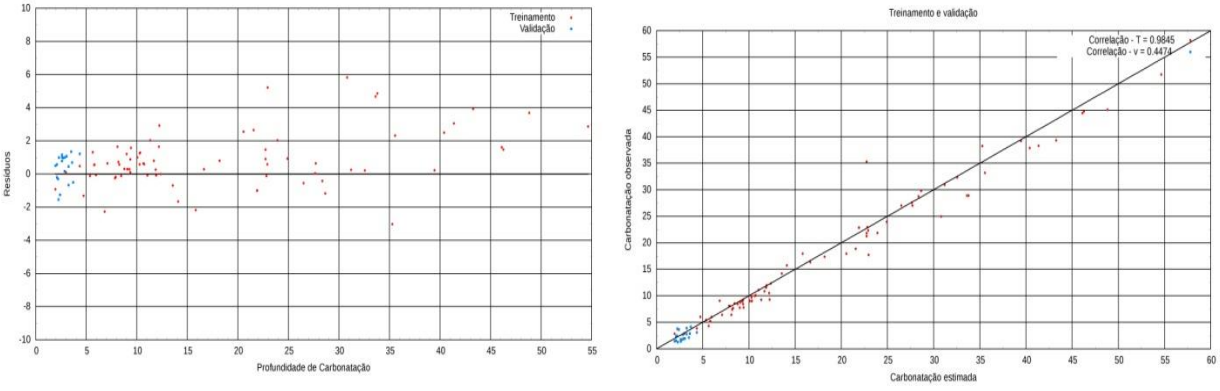

a) b)

Figura 9: CASO 4 a) resíduos b) Previsto Vs Estimado

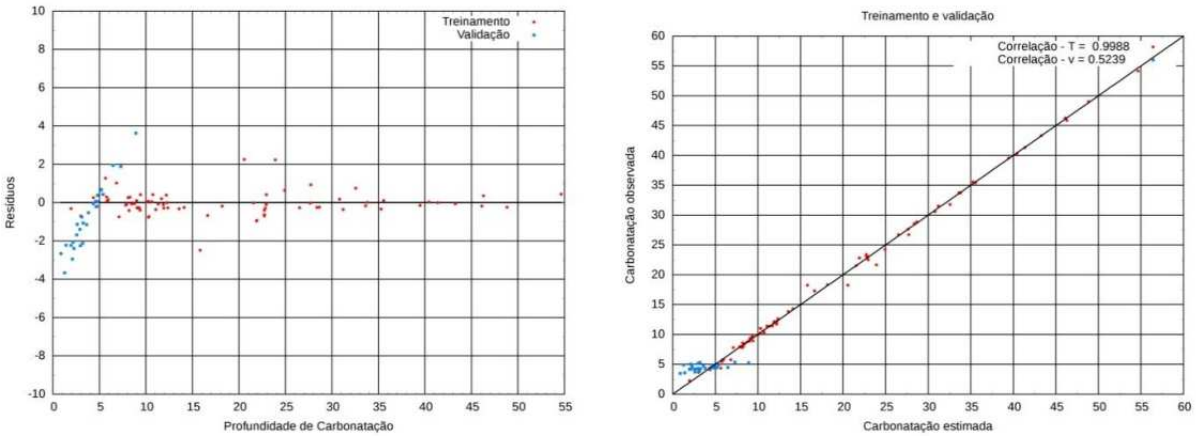

a) b)

Figura 10: CASO 5 a) resíduos b) Previsto Vs Estimado

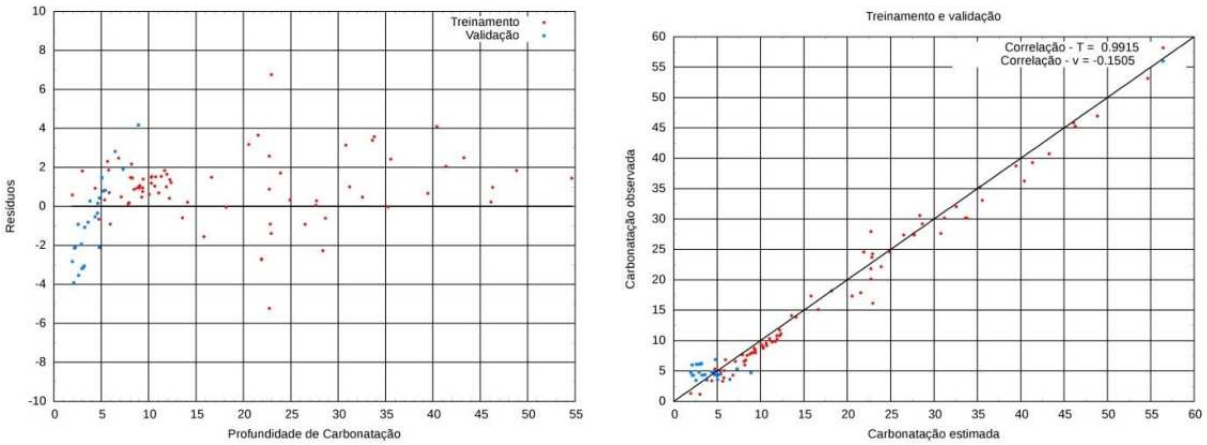

a) b)

Figura 11: CASO 6 a) resíduos b) Previsto Vs Estimado

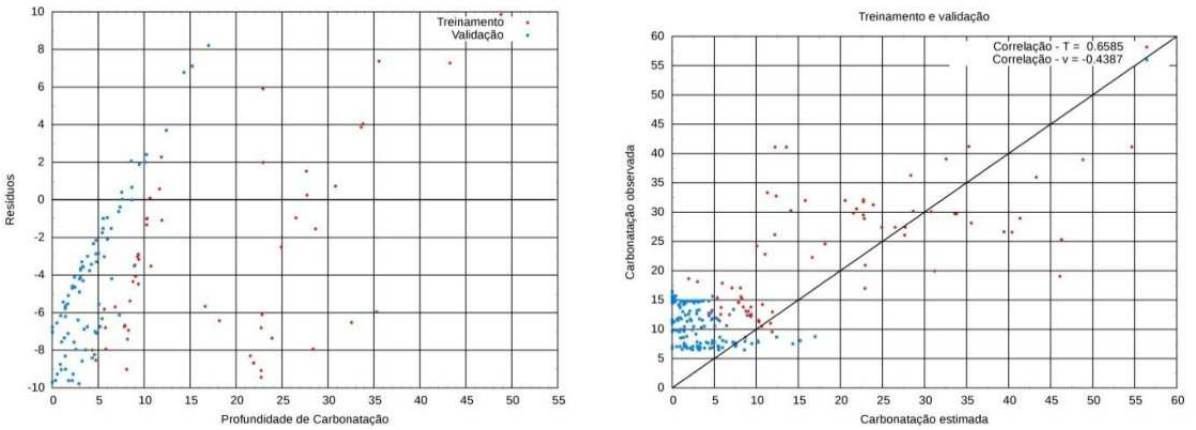

a) b)

Figura 12: CASO 7 a) resíduos b) Previsto Vs Estimado

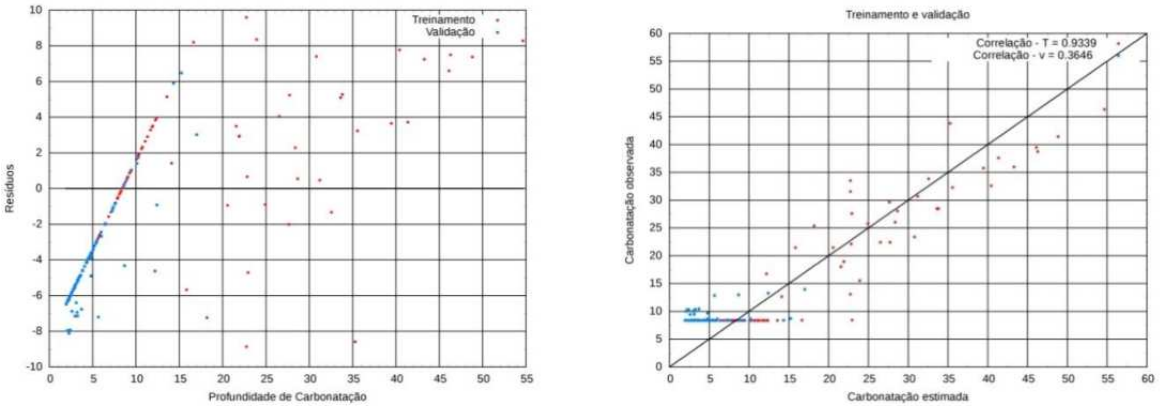

a) b)

Figura 13: CASO 7 a) resíduos b) Previsto Vs Estimado

Já no nono caso, obteve-se uma correlação na validação de 0.968 do previsto e o estimado, e 13.5% da norma do máximo relativo, que significa o maior valor dos pontos mais perto (máximo local) à curva. Na figura 4, mostra-se o gráfico de dispersão e na figura 5 mostra-se o gráfico de resíduos.

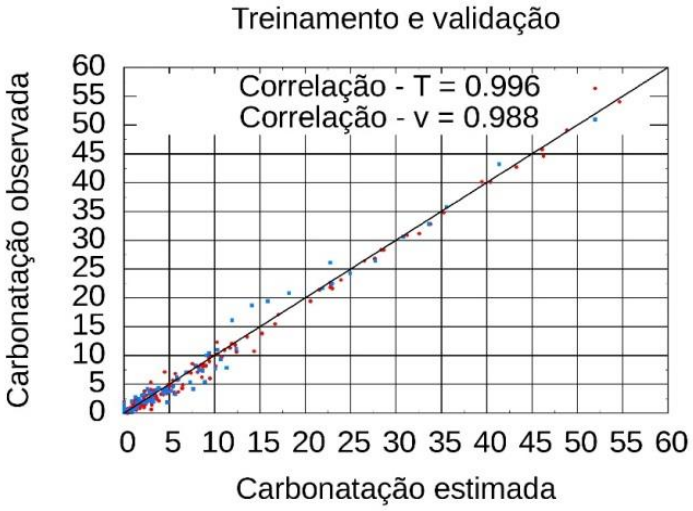

Figura 14: Previsto Vs Estimado (caso 9)

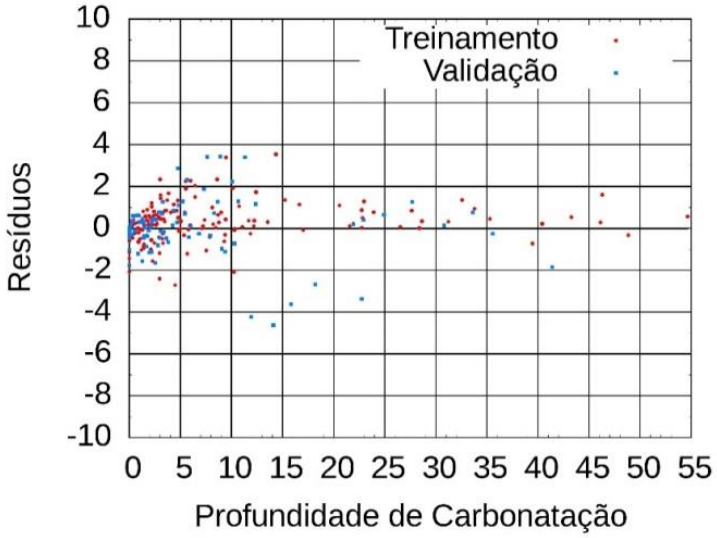

Figura 15: Carbonatação Vs Resíduos (caso 9)

O modelo de RNA definido neste artigo é somente sucedido para amostras de carbonatação reais, assim também os intervalos, segundo a Tabela 1, são consideradas como o domínio da rede, a realização do teste do modelo requer a inserção das 7 entradas nas unidades respectivas.

4. Conclusões

Os resultados obtidos após a simulação da rede e utilização do algoritmo na fase de treinamento e validação mostrou que o algoritmo tem uma boa adaptabilidade aos dados reais e uma alta eficiência junto à rede, com correlação na validação de 0.968 entre o previsto e o estimado.

Ao encontro do relatado na literatura (algoritmo *Levenberg-Marquardt* é de rápida convergência), verificou-se que média de épocas necessárias para a modelagem da carbonatação do concreto, empregando MLP e utilizando o algoritmo de treinamento *Levenberg-Marquardt*, é entre 100 a 200 épocas.

Segundo resultados de cada caso, determinou-se que dados de validação não contidos no intervalo dos dados de treinamento causam desníveis na correlação e outros tipos de erros. Com isso, confirma-se que a rede *Perceptron* Multicamada não é uma extrapoladora de dados. Logo, o banco de dados que dá origem às redes deve ser bastante representativo da carbonatação do concreto, incluindo as variáveis de influência.

Conclui-se que o emprego das RNAs é uma boa ferramenta para o estudo e Estimativa da Profundidade de Carbonatação dos diferentes tipos de concreto, sendo que as variáveis de

entrada empregadas neste trabalho influenciam fortemente no processo da carbonatação do concreto, devendo ser consideradas na modelagem para maior aproximação dos resultados.

5. Referências

CARMONA T.G. Mo**delos de previsão da despassivação das armaduras em estruturas de concreto sujeitas à carbonatação**. Dissertação (Para obtenção do título de Mestre em Engenharia) - Universidade de São Paulo - Escola Politécnica, São Paulo, 2005.

MÉNDEZ, L.R.P. **Vida útil residual de estrutura de hormigón armado afectadas por corrosión**. Trabalho final para o titulo de Mestre – Universidad Politécnica de madrid, Espanha. 2010.

POSSAN, E; ANDRADE, J. J. de O.; DAL MOLIN, D. C. C. Proposição de um modelo para a estimativa da profundidade de carbonatação do concreto. **Anais...** 52º congresso Brasileiro do Concreto, IBRACON, outubro 2010.

POSSAN, E. **Modelagem da carbonatação e previsão de vida útil de estruturas de concreto em ambiente urbano**. Tese (Obtenção de Doutorado em Engenharia) – Universidade Federal do Rio Grande do Sul. Escola de Engenharia, Porto Alegre, 2010.

HYVERT, N. **Application de l'approche probabiliste à la durabilité des produits préfabriqués en béton**. Tese (Obtenção de Doutorado em Mecânica, energética, Engenheiro civil e processos) - Université de Toulouse, França, 2009.

CERQUEIRA, E. O.; ANDRADE, J. A.; POPPI, R.J. ; MELLO C.. Redes Neurais e suas Aplicações em Calibração Multivariada . **Quim. Nova**, Vol. 24, No. 6, 864-873, 2001.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M.H. **Neural Network Desing**. Estados Unidos da América: Pws Pub,1996. 736 p.

FAUSETT, L. **Fundamentals of Neural Networks:** Architetures, Algorithms, and Applications. Prentice Hall, 1993. 461 p.

MARTINS, C. A.C. **Estimativa da profundidade de carbonatação do concreto com o uso de redes neurais**. Dissertação (Para obtenção do título de Mestre em Engenharia Civil, na área de concentração em Engenharia das Construções), Universidade Católica de Pernambuco, Recife, 2011.

PAULETTI C. **Estimativa da carbonatação natural de materiais cimentícios a partir de ensaios acelerados e de modelos de predição**. Teses(Obtenção de Doutorado em Engenharia) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

LU, C.; LIU, R. **Predicting Carbonation Depth of Prestressed Concrete under Different Stress States Using Artificial Neural Network**. Publishing Corporation Advances in Artificial Neural Systems Volume 2009, Article ID 193139, 8 pages - Department of Civil Engineering, Jiangsu University, Zhenjiang, 2009.

HORNIK, K.; STINCHCOMBE; M.; WHITE, H.. Multilayer Feedfoward Networks are Universal Approximators. **Neural Networks**, 2(5), 359-366, 1989.