MODELAGEM DA FRENTE DE CARBONATAÇÃO DO CONCRETO EM AMBIENTES MARÍTIMOS EMPREGANDO RNA'S

Felix, E.F.[1], Possan, E.[2], Konzen, P.H.A.[3]

[1] UNILA, Bolsista, Graduando em Engenharia Civil de Infraestrutura, e-mail: emerson.felix@unila.edu.br
[2] UNILA, Professora, Dra. em Engenharia Civil, e-mail: edna.possan@unila.edu.br
[3] UNILA, Professor, Dr. em Matemática, e-mail:pedro.konzen@unila.edu.br

RESUMO

A modelagem da profundidade de carbonatação do concreto exige o uso de modelos que representem este processo de degradação, no sentido de auxiliar sua compreensão. Nesta perspectiva, modelou-se a carbonatação do concreto como um problema de mapeamento dos agentes causadores da carbonatação em ambientes marítimos, considerando a distância da estrutura ao mar. O modelo desenvolvido utiliza como ferramenta as Redes Neurais Artificiais (RNA's). Para tal, foram construídas 35 redes do tipo *perceptron* multicamadas com base no algoritmo de treinamento *backpropagation*. Os dados utilizados nesta pesquisa são referentes à profundidade de carbonatação de diferentes concretos expostos a degradação por um período de quatro anos na cidade de João Pessoa na Paraíba. Os resultados obtidos apontam que modelos de carbonatação utilizando RNA's constituem uma importante alternativa para a estimativa da frente de carbonatação em estruturas de concreto, auxiliando no desenvolvimento de ferramentas e modelos de previsão para a determinação da durabilidade destas estruturas.

Palavras chave: Carbonatação do Concreto; Durabilidade; Modelagem; Redes Neurais Artificiais.

ABSTRACT

Control the depth of concrete's carbonation requires the use of models that represent the affect of the degradation process, in order to help their understanding. In this perspective, the carbonation of concrete was modelled as a mapping problem of the causative agents of carbonation in marine environments, considering the distance of the concrete structure to the sea. The developed model uses as a tool Artificial Neural Networks (ANN's). Thirty-five networks of *perceptron's* multilayer type were constructed based on the *backpropagation* training algorithm. The data used in this research are referents to the depth of carbonation of concrete exposed to different degradation for a period of four years in the city of Joao Pessoa in Paraiba. The results show that carbonation models using RNAs constitute an important alternative for the estimation of carbonation in concrete structures, assisting in the development of tools and forecasting models to determine the durability of these structures.

Keywords: Concrete's Carbonation; Durability; Modelling; Artificial Neural Networks.

1. INTRODUÇÃO

A durabilidade de uma estrutura é função de vários parâmetros, como as características das diversas etapas construtivas (projeto, especificações, materiais e manutenção), da agressividade do meio ambiente em que a estrutura está inserida, da forma do uso das estruturas e do seu tempo de vida (METHA, 1997).

Diversos trabalhos, onde o principal objetivo é estudar os danos das estruturas de concreto armado, foram realizados tanto em nível internacional quanto nacional. No Brasil, Dal Molin, 1988 e Andrade (1997), mostraram que as obras de engenharia apresentam uma degradação precoce, onde a corrosão de armaduras é o fenômeno responsável por grande parte dos danos às estruturas com um índice de ocorrência variando entre 27% e 64%.

O processo de corrosão em estruturas de concreto armado tem início com a ruptura da película protetora que envolve a armadura. Uma maneira de ocorrer essa ruptura é pela diminuição da alcalinidade do concreto, por reações físico-químicas entre o dióxido de carbono da atmosfera com os produtos da hidratação da pasta cimentícia, provocando a carbonatação (ANDRADE, 2001).

A carbonatação é um fenômeno físico-químico causado pela penetração do CO_2 da atmosfera nos poros do concreto pelo mecanismo de difusão deste gás. Ao adentrar, o CO_2 reage com o hidrato da pasta de cimento formando carbonatos e outros compostos, provocando algumas alterações como aumento da resistência à compressão, redução da permeabilidade e mudanças no módulo de deformação (NEVILLE, 1997). A carbonatação pode ser representada por intermédio da reação química causada pelo contato do CO_2 ao hidróxido de cálcio em um meio aquoso, como é apresentada em (1).

$$Ca(OH)_2 + CO_2 \rightarrow CaCO_3 \qquad (1)$$

A profundidade superficial de carbonatação aumenta com o tempo, sendo a taxa de crescimento da frente de carbonatação uma função de vários parâmetros intrínsecos do concreto e do meio ambiente, como a resistência à compressão, teor de CO_2 da atmosfera, proteção à chuva, entre outros. A Figura 1 representa o processo de carbonatação nas estruturas de concreto ao longo do tempo.



Figura 1: Representação da frente de carbonatação (TULA, 2000).

Conforme Tuutti (1982), a equação que determina a frente de carbonatação é regida pela 2º lei de Fick (2), que caracteriza a difusão de um gás em um meio ao longo do tempo. Onde *k*, é o coeficiente de difusão do CO_2 no concreto, *t* o tempo em anos e *e* a profundidade de carbonatação em cm.

$$d = k\sqrt{t} \qquad (2)$$

Existe uma grande dificuldade na utilização da equação 2, devido a obtenção da constante k, sendo que esta varia de caso à caso, impossibilitando muitas vezes a utilização da mesma.

Na literatura atual existem diversas equações que calculam a profundidade de carbonatação, porém a maioria delas não apresentam potencial de generalização, ou seja, não consegue representar a carbonatação para casos diversos. Isso ocorre, devido a grande dificuldade em modelar matematicamente as variáveis envolvidas no processo de carbonatação.

Em busca de modelos que representem de forma mais eficiente problemas que envolvam um grande número de variáveis, ferramentas computacionais como as Redes Neurais Artificiais (RNA's) vem sendo empregadas com mais frequência. As RNA's possuem como grande característica a capacidade de aprender problemas complexos de forma rápida e eficiente. Uma segunda característica que justifica a utilização destas redes para esse fim são os poderes de generalização dos resultados.

Neste sentido, o presente trabalho surge com o intuito de contribuir com modelos de previsão da frente de carbonatação de concreto, empregando para tal, Redes Neurais Artificiais.

2. REDES NEURAIS ARTIFICIAIS

As RNA's são estruturas inspiradas no cérebro humano e podem ser definidas como sistemas paralelos e distribuídos, compostos por unidades de processamento (neurônios). Várias

RNA's possuem a propriedade de aproximar funções matemáticas não lineares com alta generalidade.

Os neurônios são dispostos em uma ou mais camadas, onde estas são interligadas através de conexões, sendo que tais conexões estão associadas a pesos sinápticos que possuem a propriedade de armazenar o conhecimento.

As RNA's demonstram uma capacidade que vão além da função de mapear relações entre entradas e saídas, elas são capazes também de extrair informações não apresentadas à rede, fazendo interpolação dos resultados. O funcionamento destas redes tem como inspiração o cérebro humano (BRAGA, 2000).

As RNA's apresentam cinco elementos básicos, mostradas da Figura 2, onde estes se assemelham com as redes biológicas (HAYKIN, 2001), estes elementos são:

- Um conjunto de entradas e saídas, onde cada um carrega o seu respectivo peso;
- Um somador, para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio;
- Uma função de ativação, para restringir a amplitude da saída;
- Um bias, responsável por aumentar ou diminuir a entrada líquida da função de ativação (equivalente a uma translação horizontal do gráfico da função de ativação);
- Uma saída gerada pela rede, que representa um axônio;

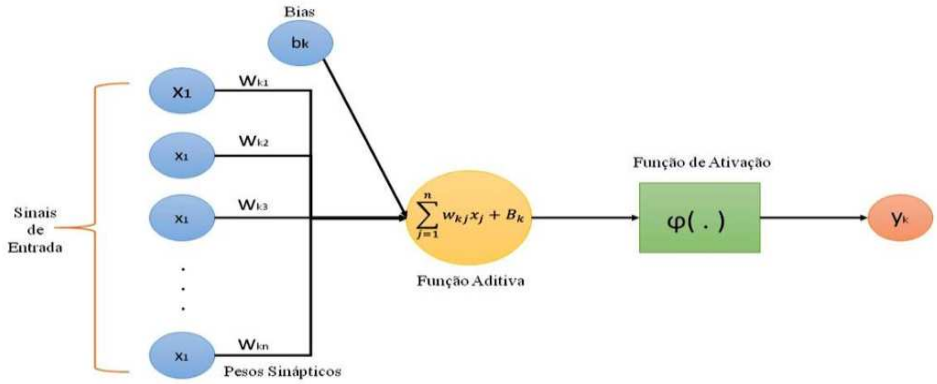


Figura 2: Representação de uma RNA do tipo perceptron.

De modo geral pode-se equacionar a saída de um neurônio k de uma RNA do tipo perceptron através da seguinte equação:

$$y_k = \varphi\left(\sum_{j=1}^{m} w_{kj}x_j + b_k\right) \qquad (3)$$

Onde, y_k representa a saída do neurônio k, φ é a função de ativação, w_{kj} são os pesos, x_j as entradas e b_k representa o bias.

Para que a rede venha aproximar uma função à mesma deve passar por um processo de aprendizado. O processo mais utilizado é o aprendizado supervisionado, mostrado na Figura 3, sua denominação vem do fato que a rede é controlada inicialmente por um supervisor, onde este apresenta os dados à rede, passando a esta o objetivo de encontrar uma relação entre os pares de entradas e saídas fornecidas.

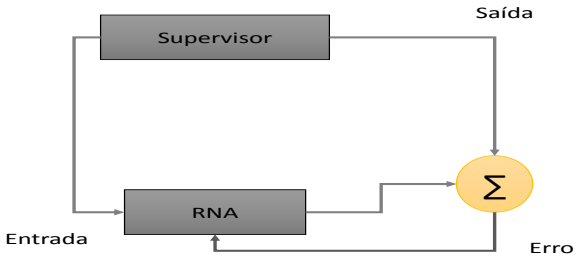


Figura 3: Método do aprendizado supervisionado.

Para a minimização do erro entre as saídas calculadas pela rede e as reais (observadas), utiliza-se um algoritmo de treinamento. Um algoritmo muito eficiente é o *backpropagation*. O *backpropagation* é um algoritmo supervisionado. O termo *back*, vem do fato que o algoritmo faz a correção dos pesos de traz para frente, sendo primeiro ajustado os pesos da última camada, e assim de traz para frente são ajustados todos os pesos das camadas anteriores. Este processo é realizado até obter um erro aceitável pelo supervisor.

As Redes *perceptron* caracterizam-se por apresentarem apenas uma camada de processamento. Esta camada apresenta apenas um neurônio. Estas redes são bastante simples por possuírem apenas a capacidade de resolver problemas linearmente separáveis. A Figura 2 apresenta um neurônio do tipo *perceptron*.

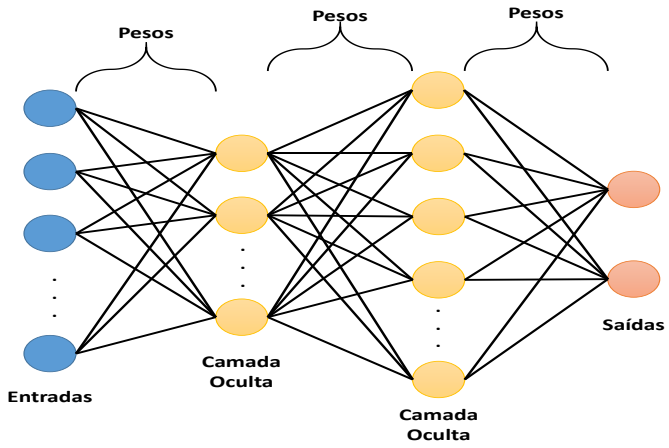


Figura 4: Representação de uma RNA do tipo MLP.

As redes *perceptron* multicamadas (MLP's do inglês *Multilayer Perceptron*), mostradas na Figura 4, se caracterizam por apresentarem uma ou mais camada(as) de neurônios oculta(as). Estas camadas garantem à rede a capacidade de mapear dados que não são linearmente separáveis (HAYKIN, 2001).

3. METODOLOGIA

3.1 Dados de degradação

O presente trabalho modelou com a utilização de RNA's do tipo MLP a profundidade de carbonatação em estruturas de concreto em ambientes marítimos, considerando a distância da estrutura em relação ao mar. Para tal fez-se necessário encontrar um conjunto de dados de profundidade de carbonatação de concretos que estivessem inseridos em tal ambiente e que ao mesmo tempo apresentasse resultados da profundidade de carbonatação em um período de tempo relevante.

Os dados de Meira, et al. (2006), referentes a profundidade de carbonatação de diferentes concretos expostos a degradação por um período de 4 anos na cidade de João Pessoa na Paraíba, foram empregados neste estudo. As estruturas empregadas pelos autores são caracterizadas por pilaretes de 15 x 15 x 140 cm, produzidos com concretos de relações água/cimento de 0,50, 0,57 e 0,60 e cimento comercial CP IIF 32. Os pilaretes foram expostos a distâncias de 10, 100, 200 e 500 m em relação ao mar, sendo que foram coletados dados de degradação referentes ao ataque por cloretos e a ação do CO_2. As medidas de profundidade de carbonatação do concreto foram realizadas nas idades de 6, 10, 14, 18 e 46 meses com a aplicação de solução de fenolftaleína.

3.2 Modelagem da degradação

Como em todo processo de modelagem, a seleção das variáveis do modelo são de suma importância, pois a seleção inapropriada pode dificultar ou fazer com que as RNA's não consigam realizar seu trabalho, não sendo possível realizar um mapeamento entre as variáveis de entrada e saída. Desta forma, as variáveis devem atender as necessidades do problema, ou seja, devem descrevê-lo adequadamente.

Neste trabalho optou-se por utilizar como variáveis de entrada a relação a/c, idade das estruturas e distância em relação ao mar. A relação a/c, foi utilizada pelo fato de fornecer informações sobre a quantidade de água no concreto, e consequentemente sua porosidade. A idade das estruturas fornece o avanço à frente de carbonatação do concreto com o passar do tempo. Já a distância das estruturas ao mar, fornece informações com relação ao tipo de

características do ambiente de exposição da estrutura, já que no caso em análise, estas estão inseridas em ambiente marítimo, onde se tem a presença de cloretos atuando conjuntamente e/ou em sinergia com o CO_2.

Para treinar as RNA's o conjunto de dados foi distribuído em três subconjuntos: conjunto de treinamento, conjunto de validação e o conjunto de teste. O primeiro conjunto é responsável por apresentar os pares de entradas e saídas para que a rede possa aprender. O segundo é responsável pela verificação e validação do treinamento da rede, bem como é utilizado para evitar o sobretreinamento. E o último é responsável por testar e verificar o potencial de generalização do modelo.

Neste trabalho a divisão do conjunto em três subconjuntos foi feito de modo a obter 60% dos dados no conjunto de treinamento, 20% no conjunto de validação e 20% no conjunto de teste. A Figura 5 representa sinteticamente a distribuição dos dados nos conjuntos de treinamento, validação e teste. Essa divisão foi feita de modo a representar o máximo possível todo o conjunto de dados em cada subconjunto.

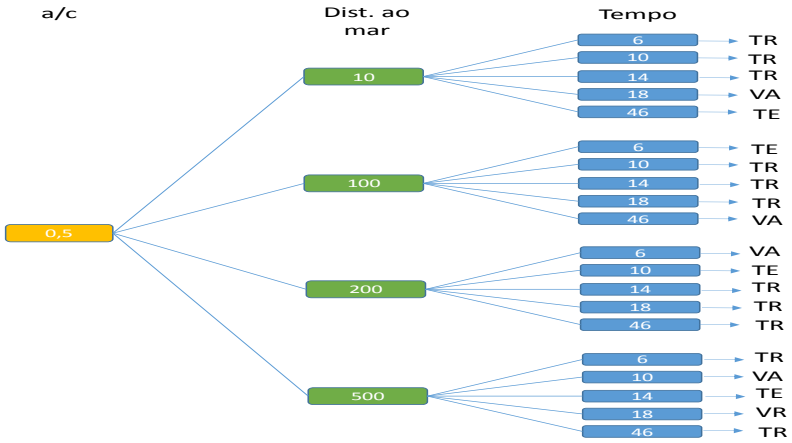


Figura 5: Divisão dos dados nos conjuntos de treinamento (TR), validação (VA) e teste (TE).

Neste trabalho foram projetadas 35 diferentes arquiteturas de rede do tipo MLP, que diferem quanto ao número de camadas ocultas (uma ou duas). No caso das redes com uma camada oculta, foram construídas 10 redes variando-se o número de neurônios na camada entre 1 a 19. Já as redes com duas camadas ocultas, apresentam em cada camada uma variação do número de neurônios de 1 a 9.

Para todas as RNA's foram determinadas *à priori* o valor da taxa de aprendizado. Esta taxa representa uma constante que está inteiramente ligada à convergência da rede em busca do erro mínimo da saída da rede. A taxa de aprendizado foi determinada após algumas simulações e o seu valor foi fixado em 0,40.

Para o treinamento das RNA's, utilizou-se como critério de convergência da rede à raiz do erro médio quadrático entre as saídas reais e às calculadas e o número máximo de interações, o RMSE, equação 4.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(x_i - \bar{x}\right)^2} \qquad (4)$$

Onde n é o número de saídas, x_i é o valor fornecido pela rede para a i-ésima saída e $\bar{x}$ é a média dos valores de todas as saídas.

Todas as RNA's foram criadas utilizando o pacote computacional project-yapy, criado e desenvolvido na UNILA, o qual apresenta linguagem orientada a objetos C++. A Figura 6 apresenta o resultado de um treinamento feito no pacote computacional.

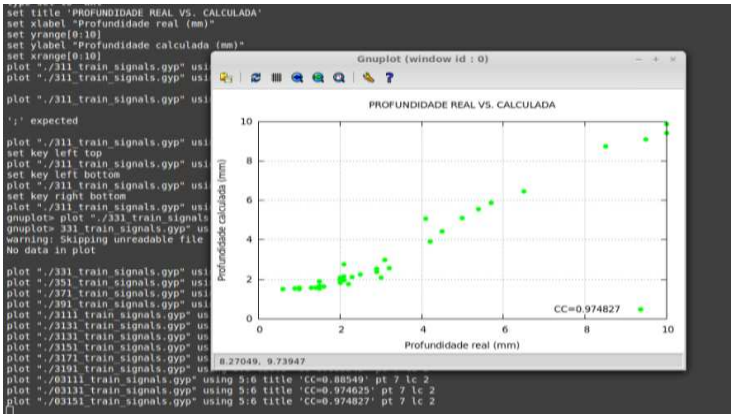


Figura 6: Plotagem do treinamento de uma RNA feita no pacote project-yapy.

O desempenho das RNA's foi analisado através de alguns parâmetros significativos como o coeficiente de correlação (R^2) e da raiz do erro médio quadrático (RMSE). Estes parâmetros foram analisados tanto na fase de treinamento quanto na fase de validação.

4. RESULTADOS

Neste trabalho foram determinadas diferentes RNA's com o intuito de demonstrar a capacidade de generalização das redes na modelagem da frente de carbonatação do concreto.

A Figura 7 apresenta o R^2 para todas as arquiteturas tanto na fase de treinamento quanto de validação, assim como, a Figura 8 apresenta o RMSE. A notação aqui utilizada para representar as RNA's foi: x_y_z, onde x representa o número de neurônios na camada de

entrada, y o número de neurônios na camada oculta e z o número de neurônios na camada de saída.

As três melhores RNA's estão referenciadas nas Figuras 7-8, e estas possuem as seguintes arquiteturas: [3-15-1], [3-7-5-1] e [3-9-3-1].

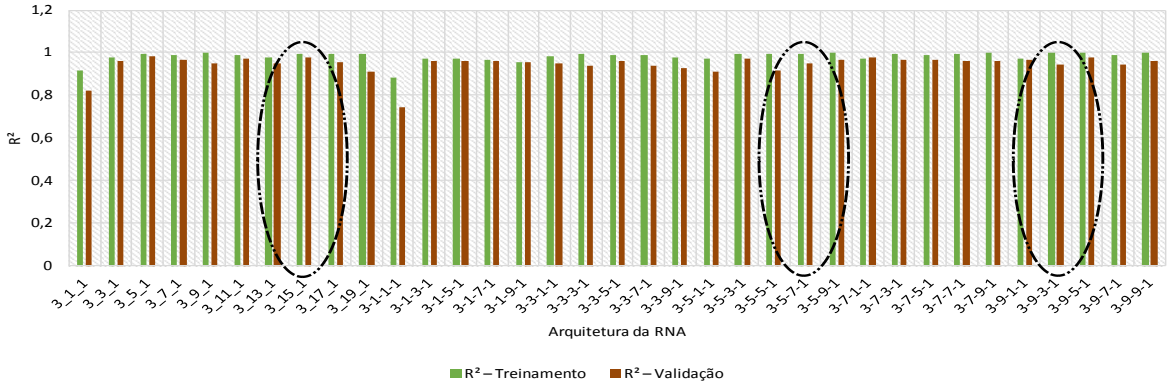


Figura 7: Correlação das 35 RNA's.

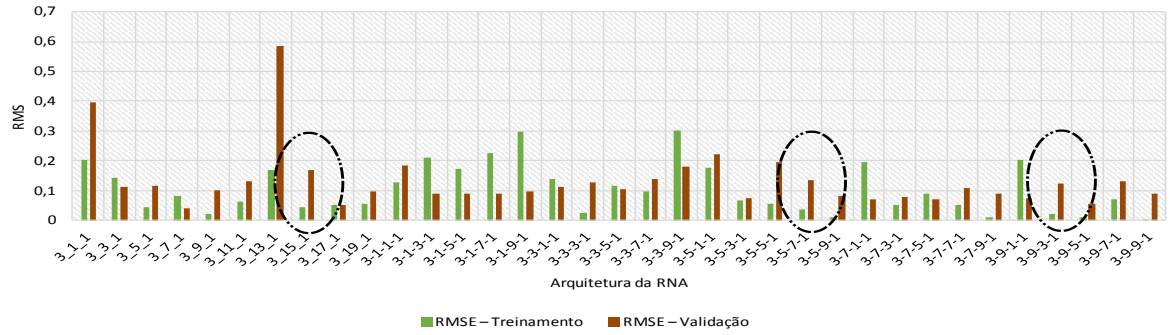
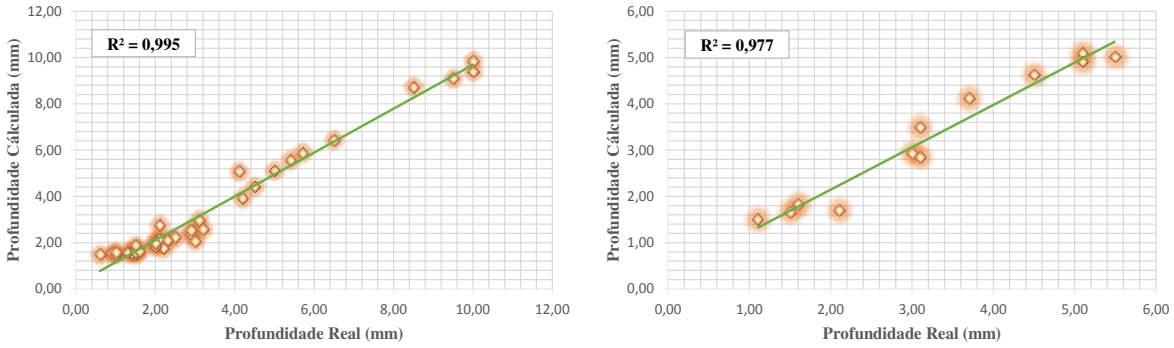


Figura 8: Raiz do erro médio quadrático das 35 RNA's.

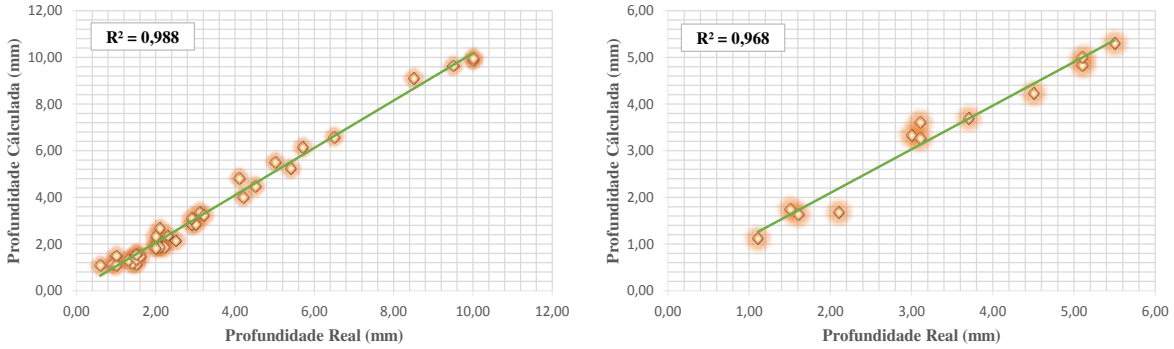
A arquitetura da rede [3-15-1] que se baseia na seguinte estrutura: três neurônios na camada de entrada, 15 neurônios na camada oculta, e um neurônio na camada de saída. As correlações de treinamento e validação são apresentadas na Figura 9.



a) b)

Figura 9: a) Correlação no treinamento e b) Correlação na validação da rede [3-15-1].

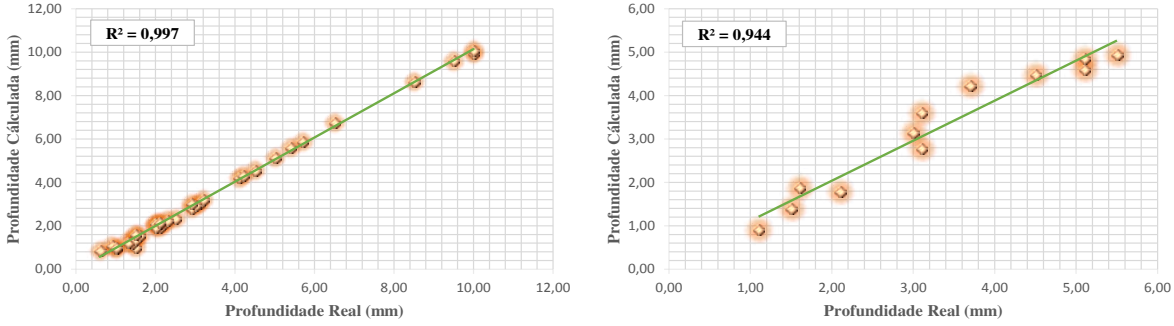
A segunda rede [3-7-5-1] apresenta diferenças nas camadas ocultas, sendo: 7 neurônios na primeira camada oculta e 5 neurônios na segunda camada oculta. As correlações do treinamento e validação são apresentadas na Figura 10.



a) b)

Figura 10: a) Correlação no treinamento e b) Correlação na validação da rede [3-7-5-1].

A terceira rede [3-9-3-1] apresenta diferenças nas camadas ocultas, sendo: 9 neurônios na primeira camada oculta e 3 neurônios na segunda camada oculta. As correlações do treinamento e validação são apresentadas na Figura 11.



a) b)

Figura 11: a) Correlação no treinamento e b) Correlação na validação da rede [3-9-3-1].

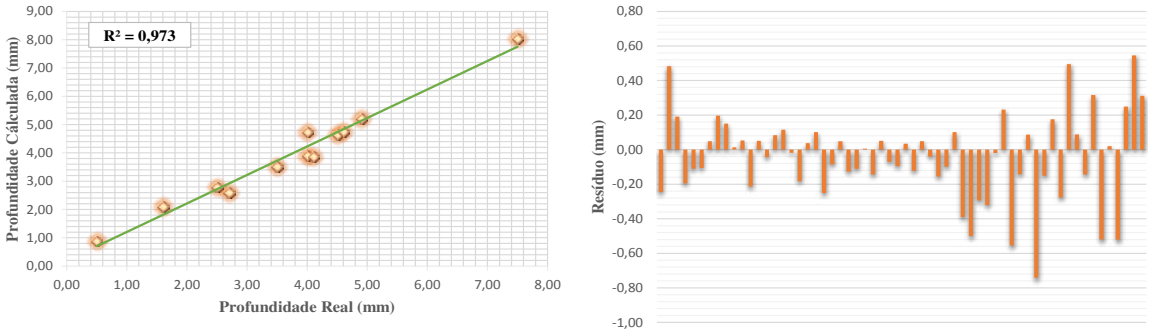
Os três modelos apresentaram resultados satisfatórios tanto no treinamento quanto na validação. A Tabela 1 apresenta em resumo os resultados de cada rede. Como se observa a terceira rede com a arquitetura [3-9-3-1], demonstrou o melhor resultado entre todas as 35 RNA's, essa decisão é tomada comparando o resultado das redes na fase de teste.

Tabela 1: Desempenho das três melhores RNA's.

Arquitetura	Treinamento		Validação		Teste	
	RMSE	R^2	RMSE	R^2	RMSE	R^2
[3-15-1]	0,044	0,995	0,169	0,977	0,181	0,942
[3-7-5-1]	0,089	0,988	0,069	0,968	0,500	0,951
[3-9-3-1]	0,021	0,997	0,123	0,944	0,130	0,973

Com o objetivo de confirmar a confiabilidade da RNA modelada e eleita como a melhor, apresentou-se ao pacote computacional project-yapy o conjunto de dados da fase de teste.

O modelo apresentou ótimos resultados, sendo apresentada uma correlação de 0,97 e RMSE de 0,13. Como pode ser analisado o RSME é de 0,13 cm, sendo bem menor que o erro instrumental que é ± 1,0 cm, confirmando a calibração da RNA. Os resultados comprovam o poder de generalização do modelo frente a situações reais, situações estas, que podem não estar contidas entre as oferecidas pela rede na fase de treinamento. A Figura 12 apresentam a correlação na fase de teste e os resíduos.



a) b)

Figura 12: a) Correlação no treinamento e b) Correlação na validação da rede [3-9-3-1].

5. CONCLUSÕES

A partir dos resultados obtidos é possível chegar as seguintes conclusões:

- Os resultados demonstram a potencialidade das Redes Neurais Artificiais para a geração de modelos de estimativa da profundidade de carbonatação do concreto.

- Os resultados apresentados pelo melhor modelo, cujo RMSE foi de 0,13 mm, recomendam que as RNA's podem ser consideradas ferramentas numéricas robustas e flexíveis para a determinação da frente de carbonatação do concreto, possibilitando gerar modelos probabilísticos eficientes e fáceis de utilizar.
- O modelo gerado pode sem empregado para a determinação do cobrimento mínimo de uma estrutura de concreto armado, auxiliando nas definições de projeto da estrutura, colaborando para durabilidade e garantia da vida útil.
- O presente trabalho demonstra ainda a grande capacidade das RNA's aprenderem problemas complexos e não lineares.

6. REFERÊNCIAS

GUIMARÃES, A. T. C. **Vida útil de estruturas de concreto armado em ambientes marítimos.** 2000, 203f. Tese (Doutorado em Engenharia) – Departamento de Engenharia Civil, Escola Politécnica da Universidade de São Paulo, São Paulo, 2000.

CARMONA T.G. **Modelos 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.

POSSAN, E; Andrade, Jairo J. de O.; Dal Molin, Denise C. C. **Proposição de um modelo para a estimativa da profundidade de carbonatação do concreto**. Anais do 52 congresso Brasileiro do Concreto, IBRACON, outubro 2010.

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

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.

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.

PADE, C.; GUIMARÃES, M. **The CO_2 uptake of concrete in a 100 year perspective.** Cement and Concrete Research, v 37, p. 1348–1356, 2007.

JORDÃO, F. R**. Caracterização de variáveis que influenciam na vida útil das estruturas de concreto. 2006.** Dissertação (mestrado em Engenharia) – Faculdade de Engenharia Civil, Universidade Federal de Uberlândia, Uberlândia, 2006.

ISAIA, G. C. **Carbonatação do concreto: uma revisão.** In: WORKSHOP SOBRE CORROSÃO DA ARMADURA DO CONCRETO, 1999, Colloquia. Anais... São José dos Campos, 1999.

ANDRADE, J. J. O. **Contribuição da vida útil das estruturas de concreto armado atacadas pela corrosão de armaduras: iniciação por cloretos.** 2001, 256f. Tese (Doutorado em Engenharia) – Curso de Pós-graduação em Engenharia Civil, Universidade Federal do Rio grande do Sul, Porto Alegre, 2001.

ANDRADE, C. Manual **para diagnostico de obras deterioradas por corrosão de armaduras.** Tradução e adaptação: Antonio Carmona e Paulo Helene. São Paulo: Pini, 1992. 104 p.