



MODELAGEM COMPUTACIONAL DA PROFUNDIDADE DE CARBONATAÇÃO DO CONCRETO EMPREGANDO RNA'S

Emerson Felipe Felix

Thays Car Feliciano de Oliveira

Edna Possan

Glaucia Maria Dalfré

emerson.felipe.felix@gmail.com

thayscar.04@gmail.com

epossan@gmail.com

gmdalfre@gmail.com

Universidade Federal da Integração Latino-Americana - UNILA

Av. Tancredo Neves, 6731, 85867-900, Foz do Iguaçu, Paraná, Brasil

Resumo. No presente trabalho modelou-se a profundidade de carbonatação do concreto empregando Redes Neurais Artificiais (RNA's) do tipo Multi-Layer Perceptron (MLP) com diferentes algoritmos de treinamento (Backpropagation Classic, Backpropagation Momentum e o Backpropagation Delta-Bar-Delta) implementados em linguagem orientada a objetos C++. Ao total foram treinadas, validadas e testadas 1200 redes, divididas entre os três algoritmos e com diferentes características quanto às suas arquiteturas. A rede com o melhor comportamento obteve um erro médio quadrático de 0,84 mm de profundidade de carbonatação no treinamento e 1,57 mm na validação, gerando uma correlação de 0,994 e 0,981, respectivamente. Pela análise do gráfico de resíduos verificou-se um erro máximo de 3,381 mm e um erro mínimo de 0,004 mm, indicando a aplicabilidade das RNA's para modelar a frente de carbonatação do concreto, uma vez que o erro aceitável na literatura para essa determinação é de 5,0 mm.

Palavras-chave: Carbonatação, Estruturas de concreto, Modelagem, Redes Neurais Artificiais

1 INTRODUÇÃO

O concreto armado é uma associação inteligente de diferentes materiais (rocha, aglomerante, agregados e aço), porém está sujeito à deterioração devido à ação de diferentes mecanismos de degradação. Uma das principais causas para sua deterioração, e a mais frequente, é a corrosão das armaduras, que além de prejuízos estéticos, pode levar a estrutura ao colapso. No Brasil, vários autores verificaram a existência de um índice de ocorrência de corrosão que varia entre 14 e 64%, (CARMONA & MAREGA, 1988; DAL MOLIN, 1988; ANDRADE, 1992; ARANHA, 1994), o que denota a importância deste tema.

O ingresso de dióxido de carbono (CO_2) através do concreto é um dos principais causadores da corrosão das armaduras, uma vez que a penetração desse gás no concreto, em presença de umidade, possibilita a ocorrência das reações de carbonatação, o que despassiva a armadura deixando-a suscetível à degradação.

Com o objetivo de determinar e explicar os fatores relacionados à carbonatação e também obter modelos matemáticos para a previsão da frente de carbonatação, diversos modelos matemáticos foram criados nos últimos anos, que em geral, apresentam duas abordagens, uma determinística e a outra probabilística (POSSAN, 2010). A primeira oferece uma estimativa máxima ou média da degradação, já a segunda considera a existência da probabilidade da ocorrência dos principais fatores que interferem na vida útil. Grande parte destes modelos representam a penetração dos agentes agressivos no interior do concreto, principalmente da penetração do dióxido de carbono (CO_2) e de íons cloreto (Cl^-).

Uma alternativa para contornar as dificuldades da modelagem é a utilização de ferramentas computacionais, como as Redes Neurais Artificiais (RNA's). As RNA's são ferramentas computacionais robustas similares às Redes Neurais Biológicas, possuindo como característica principal a capacidade de mapear e modelar problemas complexos e não lineares sem levar em conta todos os fatores que influenciam o problema em estudo (MARTINS, 2011). Estas possuem como característica a capacidade de aprender problemas complexos de forma rápida e eficiente, além de possuírem capacidade de generalização dos resultados.

Neste sentido o presente trabalho tem como intuito contribuir com modelos de previsão da frente de carbonatação do concreto por meio do emprego das RNA's, demonstrando que estas redes podem ser usadas em outras áreas da engenharia para possibilitar a modelagem de problemas complexos e não lineares.

1.1 Carbonatação do concreto

A carbonatação é um fenômeno físico-químico, que pode ser representada por intermédio da reação química vista na Eq. (1), onde, em meio aquoso, o CO_2 reage com o hidróxido de cálcio ($\text{Ca}(\text{OH})_2$) presente da pasta de cimento e formando carbonato de cálcio (CaCO_3), provocando algumas alterações como aumento da resistência à compressão, redução da permeabilidade e mudanças no módulo de deformação (NEVILLE, 1997).



Além disso, esse processo reduz o pH do concreto (de 12,5 a 9), o que destrói a camada passivadora que envolve a armadura e a deixa suscetível à degradação ao longo do tempo.

A profundidade de carbonatação do concreto aumenta com o tempo (Fig. 1), estando o seu crescimento em função de vários parâmetros intrínsecos do concreto e do meio ambiente, por exemplo, a resistência à compressão, o teor de CO_2 na atmosfera, a proteção a chuvas, e outros.




Figura 1. Representação da frente de carbonatação ao longo do tempo

A carbonatação pode afetar a durabilidade das estruturas de concreto e, consequentemente, a útil de projeto (VUP), uma vez que a durabilidade é a propriedade associada à capacidade de suportar as ações de degradação para as quais as estruturas foram projetadas, sendo função de vários parâmetros, como das características das 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 tempo (MEHTA, 1991).

Existem hoje na literatura diversos trabalhos que visam determinar e explicar os fatores relacionados à carbonatação e também obter modelos matemáticos para a previsão da frente de carbonatação (HAMADA, 1969; SMOLCZIK, 1969; HELENE, 1981; TUUTTI, 1982; PAPADAKIS ET AL., 1991; ANDRADE, 1992; HYVERT, 2009; POSSAN, 2010). Porém, muitos dos modelos destinados à determinação da profundidade carbonatada são baseados em equações simplificadas, limitando o seu domínio de aplicação, enquanto que os modelos mais sofisticados, com maiores domínios de aplicabilidade, apresentam dificuldades quanto à obtenção das variáveis de entrada. Por este motivo, a produção de modelos matemáticos que possuem dados de entrada de fácil obtenção (baixo custo de aquisição) e que contemplem um amplo domínio de aplicação apresenta uma grande procura por pesquisadores e, para tal, vem-se utilizando nos últimos anos ferramentas computacionais como, por exemplo, as Redes Neurais Artificiais (RNA'S).

Na engenharia, as RNA's vêm sendo aplicadas nas áreas de geociência (GALO, 2000; ANDRADE; CENTENO, 2003; ESPINHOSA, 2004; GALVÃO; MENEZES, 2005), geologia (FLECK; PEDREIRA, 2003), análise sísmica (SANTOS, 2008), em estudos com concreto (MARTINS, 2011; FELIX; POSSAN; KONZEN, 2014; SUCAPUCA; POSSAN; KONZEN, 2014), em estudos com pavimentos (KASEKO; RITCHIE, 1993; FWA; CHAN, 1993; HUA; FAGHRI, 1993; BREGA, 1996; FAXINA, 2005), e em hidrologia (SANTOS; PEREIRA, 2003).

No que se refere ao estudo da durabilidade, em especial à modelagem da carbonatação do concreto, existem poucos estudos na literatura, sendo a maioria deles no exterior (JEPSEN, 2002; UKRAINEZYK; BANJAD; UKRAINEZYK, 2004; UKRAINEZYK; MATUSINOVÍČ, 2005; MUTHUPRIYA; SUBRAMANIAN; VISHNURAM, 2009; MARTINS, 2011; LUO; NIU; DONG, 2014), indicando a aplicabilidade das RNAs para este fim.

1.2 Redes Neurais Artificiais

As RNA's são similares às redes neurais biológicas e podem ser definidas como sistemas paralelos e distribuídos, compostos por unidades de processamento (analogia aos neurônios). Essas redes possuem como característica principal a capacidade de mapear e modelar problemas complexos e não lineares sem levar em conta todos os fatores que influenciam o problema em estudo (MARTINS, 2011).

As RNA's demonstram uma capacidade que vai 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 et al., 2000), onde os neurônios, dispostos em uma ou mais camadas, estão interligadas por conexões, sendo que tais conexões estão associadas a pesos sinápticos que possuem a propriedade de armazenar o conhecimento.

Haykin (2001) destaca que as RNA's apresentam cinco elementos básicos (Fig. 2), que se assemelham às redes biológicas, a saber:

- I. Um conjunto de entradas e saídas, onde cada um carrega o seu respectivo peso;
- II. Um somador, para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio;
- III. Uma função de ativação, para restringir a amplitude da saída;
- IV. 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);
- V. Uma saída gerada pela rede, que representa um axônio.




Figura 2. Representação de uma RNA do tipo *perceptron*

Assim, de modo geral, pode-se representar matematicamente um neurônio com n entradas (Fig. 2) através da Eq. (2).

$$y_n = f\left(\sum_{i=1}^m w_{nj}x_i + b_n\right) \quad (2)$$

Cada entrada $x_i \in \mathbb{R}$, $i = 0, 1, \dots, n-1$, é pesada (ponderada) por meio de um correspondente $w_i \in \mathbb{R}$ formando o vetor de pesos $w = (w_0, w_1, \dots, w_{n-1})^T$. O neurônio possui ainda um bias $b \in \mathbb{R}$ que é somado a cada entrada multiplicada com seu respectivo

peso, que forma a entrada a ser informada à função de ativação $f: \mathbb{R} \rightarrow \mathbb{R}$, obtendo a saída $y_n \in \mathbb{R}$.

Braga et al. (2000) relatam que a arquitetura de uma RNA tem grande importância sobre o comportamento e funcionamento da mesma, uma vez que é a arquitetura que limita o tipo de problema que pode ser solucionado. Redes contendo apenas uma camada de processamento podem resolver apenas problemas linearmente separáveis, enquanto que as redes recorrentes podem resolver problemas de processamento temporal. Nas Figuras 3 e 4, são apresentados dois exemplos de arquiteturas onde diferenciam-se pelo número de camadas ocultas, onde as variáveis $x_1, x_2, \dots, x_n$ representam as entradas e as variáveis $y, y_1, y_2, \dots, y_n$ a(s) saída(s).




Figura 3. Rede com uma camada




Figura 4. Rede com duas camadas

Para Silva et al. (2004), alguns dos fatores que influenciam os ajustes feitos para determinar a melhor topologia da rede são: i) o número de exemplos de treinamentos; ii) a quantidade de ruído; e, iii) a complexidade da função e a distribuição dos dados (os dados também podem acarretar o mal condicionamento da rede, como em qualquer modelagem matemática).

A capacidade de aprender é uma das características mais importantes das RNA's. O processo de aprendizado mais utilizado é o supervisionado. Sua denominação vem do fato que a rede é controlada inicialmente por um supervisor, que apresenta os dados à rede, passando a esta o objetivo de encontrar uma relação entre os pares de entradas e saídas fornecidos. Ao encontrar tal relação, a rede calcula todas as saídas e faz uma comparação com as apresentadas pelo supervisor. No caso destas saídas divergirem, a rede ajusta os pesos das conexões de modo a minimizar as diferenças (erros).

Existem hoje diversos modelos de redes neurais artificiais, diferenciados quanto às estruturas (arquiteturas), quanto ao método de aprendizagem e pela forma em que se alcança o objetivo principal da rede, objetivo este de fornecer uma relação implícita para um determinado problema.

No presente trabalho foram utilizadas redes Multi-Layer Perceptron (MLP) (ver Fig. 5) (em português refere-se ao *Perceptron* de múltiplas camadas), por apresentarem mais de uma camada de processamento, possibilitando resolver problemas não-lineares e consequentemente complexos, como é o caso do avanço da frente de carbonatação do concreto no tempo.




Figura 5. Modelo de uma rede MLP

2 MODELAGEM EMPREGANDO RNAs

Com o objetivo de desenvolver um modelo que representasse a frente de carbonatação do concreto ao longo do tempo mediante o uso das RNA's, adotou-se a metodologia apresentada na Fig. 6.




Figura 6. Fluxograma para a modelagem da profundidade de carbonatação do concreto com RNA's

Em síntese, na primeira etapa foi realizada a determinação do banco de dados e a definição de alguns dos parâmetros da rede, por exemplo, a função de ativação e a taxa de aprendizado. Na segunda etapa determinou-se a tipologia da rede e, em seguida, fez-se o treinamento e a validação da rede, gerando um modelo. Na terceira e última etapa foi feita a seleção dos modelos mais representativos da degradação do concreto por carbonatação.

2.1 Dados da carbonatação do concreto

O presente trabalho modelou a profundidade de carbonatação em estruturas de concreto em ambientes urbanos com a utilização de RNA's do tipo MLP, considerando diversos fatores, por exemplo, a umidade relativa do ar, o tipo de cimento, o teor de adições, o fator de exposição da estrutura, a taxa de CO₂ presente no ambiente e a resistência à compressão do concreto, uma vez que segundo a literatura (PAULETTI, 2009; POSSAN, 2010) esses fatores apresentam maior influência na carbonatação do concreto. Para tal fez-se necessário encontrar um conjunto de dados de profundidade de carbonatação de concretos que estivessem inseridos em tais ambientes e que ao mesmo tempo apresentassem resultados da profundidade de carbonatação em um período de tempo relevante.

O banco de dados foi formado com dados de profundidade de carbonatação natural e informações compiladas por Possan (2010) dos trabalhos de Isaia (1999), Vieira et al. (2009) e Meira et al. (2006).

Para que fosse possível realizar a modelagem utilizando as RNA's foi necessário fazer a conversão ou representação de todas as variáveis em algarismos, como é o caso das variáveis de entradas: tipo de cimento (CP II-E, CP II-F, CP II-Z, CP III, CP IV e CP V ARI), sendo estes enumerados em ordem crescentes de 1 a 6. A condição de exposição de ambiente interno protegido da chuva, externo protegido da chuva e externo desprotegido da chuva, foi representada, respectivamente, por 1,30, 1,00 e 0,65, conforme determinado por Possan (2010). Este processo possibilita também a definição do domínio de aplicabilidade do modelo. Na Tabela 1, apresentam-se os intervalos de cada variável.

Tabela 1. Domínios das variáveis do conjunto de dados

Variável	Domínio
Tipo de cimento	[1, 2, 3, 4, 5, 6]
Umidade Relativa do ar (%)	[30 - 70]
Fator de exposição da estrutura	[1,30, 1,00, 0,65]
Teor de adições (%)	[0-30]
Taxa de CO ₂ no ambiente (%)	[0,01-3,0]
Resistência à compressão (MPa)	[20-90]
Tempo (anos)	[0-50]

A determinação deste domínio possibilita informar qual será o limite de utilização do modelo, uma vez que as RNA's não possuem a capacidade de extrapolar resultados, sendo possível apenas para elas o mapeamento e o aprendizado de padrões dentro do domínio de treinamento.

Na modelagem com as RNA's é necessário fazer a divisão do conjunto de dados em três subconjuntos, um para o treinamento das redes, outro para a validação das redes e mais um para a fase de teste do modelo gerado. A Figura 7 apresenta a proporção dos dados alocados em cada subconjunto.




Figura 7. Proporção dos dados nos subconjuntos

Cada um destes subconjuntos (treinamento, validação e teste) foi utilizado em uma etapa do processo de modelagem com as RNA's. O primeiro 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 sobre-treinamento. E o terceiro é responsável por testar e verificar o potencial de generalização do modelo.

2.2 Modelagem da carbonatação do concreto

Neste trabalho foram criadas 1200 RNA's, sendo estas diferenciadas pela taxa de aprendizado (0,1, 0,2, 0,3 e 0,4), pelo número de entradas (4, 5 e 7) (ver Fig. 8), pela arquitetura interna da rede (que poderia ter uma ou duas camadas internas) e pelo número de neurônios contido em cada camada (de 0 a 9 neurônios). Foi realizada, portanto, a combinação de todas as possibilidades de configuração das redes ($4 \times 3 \times 10 \times 10$), o que gerou as 1200 RNA's.




Figura 8. Arquiteturas bases com 4, 5 e 7 entradas

Para o treinamento das RNA's, utilizou-se como critério de convergência a raiz do erro médio quadrático (RMSE, Eq. (3)) entre as saídas reais e as calculadas e o número máximo de interações (10^6) permitidas.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

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.

O algoritmo de treinamento utilizado corresponde ao *Backpropagation Classic*, porém foram também utilizados dois outros algoritmos derivados do clássico, o *Backpropagation*




Figura 10. Correlação no treinamento




Figura 11. Correlação na validação

Nas Figuras 12 e 13 são apresentadas, respectivamente, as correlações do treinamento e da validação da rede com arquitetura [5-4-3-1], que se baseia na seguinte estrutura: cinco entradas, quatro neurônios na primeira camada oculta, três neurônios na segunda camada oculta e uma saída.




Figura 12. Correlação no treinamento




Figura 13. Correlação na validação

Nas Figuras 14 e 15 são apresentadas, respectivamente, as correlações do treinamento e da validação da rede com arquitetura [7-4-1], que se baseia na seguinte estrutura: sete entradas, quatro neurônios na camada oculta e uma saída.




Figura 14. Correlação no treinamento




Figura 15. Correlação na validação

Os três modelos apresentaram resultados satisfatórios, tanto no treinamento quanto na validação. Porém, à medida que o número de variáveis de entrada é aumentado, a correlação entre a profundidade de carbonatação real e a profundidade calculada pelo modelo também aumenta. Tal fato demonstra que quanto maior e mais significativo for o conjunto de variáveis de entrada, maior será a capacidade das RNA's em aprender o comportamento da carbonatação do concreto. Percebe-se ainda que com a utilização do maior número de variáveis de entrada significativas para o estudo da carbonatação, a rede conseguiu associar de forma mais fácil a relação entre as variáveis de entrada e a saída desejada, gerando um modelo melhor (menor erro), garantindo correlações semelhantes na fase de treinamento e de validação. Outro aspecto relevante é que a medida que foi aumentado o número de entradas diminuiu-se o número de neurônios necessários nas camadas de processamento, demonstrando a otimização do aprendizado pela rede.

A Tabela 2 apresenta os resultados referentes às análises realizadas durante a fase de teste com cada um dos três modelos selecionados.

Tabela 2. Resultados do teste com os melhores modelos

Arquitetura	RMSE	R^2	$E_{\max}$	$E_{\min}$
[4-7-5-1]	1,199	0,849	5,944	0,054
[5-4-3-1]	1,053	0,882	4,564	0,012
[7-4-1]	0,840	0,994	3,381	0,004

Analisando a Tabela 2, nota-se que a rede de arquitetura [7-4-1] apresenta a melhor correlação frente à fase de teste, assim como nas fases de treinamento e validação (Figuras 14 e 15). É possível verificar ainda que esta rede apresenta os menores erros (RMSE, $E_{\max}$ e $E_{\min}$), sendo escolhida como o melhor modelo dentre todas as 1200 redes projetadas neste trabalho.

Como objetivo de confirmar a confiabilidade da rede modelada e eleita como melhor, apresenta-se na Fig. 16 o gráfico de resíduos do modelo na fase de teste.




Figura 16. Resíduos da diferença entre a profundidade real e a calculada pelo modelo

O melhor modelo apresentou resultados excelentes, sendo que o mesmo obteve uma correlação na fase teste de 0,994 e RMSE de 0,840 mm. Desta forma, o erro médio apresentado pelo modelo para a estimativa da profundidade de carbonatação dentro do domínio de aplicabilidade é inferior a 1 mm, o que corresponde à medida de erro de um paquímetro digital (instrumento de medida da profundidade carbonatada), enquanto que o erro máximo ao qual o modelo está submetido é de 3,38 mm. Estes resultados comprovam o poder de interpolação e aprendizado das RNA's frente a problemas complexos.

Por fim, apresenta-se nas Fig. 17 e 18 a utilização do modelo para estimar a profundidade de carbonatação ao longo do tempo para duas estruturas de concreto (Tabelas 3 e 4) ao longo do tempo (50 anos). Em ambas as figuras são apresentadas ainda as profundidades reais (extraídas da tese de Possan (2010)) de modo a demonstrar a potencialidade do modelo.




Tabela 3. Estrutura I

Resistência à compressão (Mpa)	20
Taxa de CO ₂ (%)	0,01
Teor de adições (%)	0
UR (%)	70
Fator de exposição	1,3
Tipo de cimento	CP II-F




Tabela 4. Estrutura II

Resistência à compressão (Mpa)	31
Taxa de CO ₂ (%)	0,01
Teor de adições (%)	0
UR (%)	70
Fator de exposição	1,3
Tipo de cimento	CP II-F

Figura 18. Estimativa da profundidade de carbonatação do concreto – estrutura II

Para as duas aplicações acima, verifica-se que a modelagem da carbonatação do concreto empregando RNA's apresenta boa aderência aos dados reais, apresentando um erro médio de 0,72 mm, com potencial de aplicabilidade para este fim.

4 CONCLUSÕES

A partir dos resultados obtidos foi possível chegar às seguintes conclusões:

- Os resultados apresentados pelo melhor modelo, cujo RMSE foi de 0,84 mm, indicam 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 de fácil utilização.
- As RNA's mostraram-se sensíveis às variáveis de entrada, conduzindo a erros menores quando considerado um maior número de variáveis de influência.
- O modelo gerado também pode ser empregado para a determinação do cobrimento mínimo de uma estrutura de concreto armado, auxiliando nas definições de projeto da estrutura e colaborando para durabilidade e garantia de sua vida útil.
- Os resultados indicam a potencialidade das Redes Neurais Artificiais no aprendizado de problemas complexos e não lineares, como a geração de modelos de estimativa da profundidade de carbonatação do concreto.

AGRADECIMENTOS

Ao Centro de Estudos Avançados em Segurança de Barragens (CEASB) e à Fundação Parque Tecnológico de Itaipu (FPTI) pelas bolsas de Iniciação Científica e pelo fomento oferecido à pesquisa.

REFERÊNCIAS

Andrade, C. *Manual para diagnóstico de obras deterioradas por corrosão de armaduras*. Trad. De Antonio Carmona e Paulo Helene. São Paulo, Pini, 1992.

Andrade, A. F., Faria, M. B., Centeno, J. A. S. Classificação de Imagens de Alta Resolução Integrando Variáveis Espectrais e Forma Utilizando Redes Neurais Artificial. In: *XI Simpósio Brasileiro de Sensoriamento Remoto*, 2003, Belo Horizonte. Anais do XI Simpósio Brasileiro de Sensoriamento Remoto. 2003.

Aranha, P. M. *Contribuição ao estudo das manifestações patológicas em estruturas de concreto armado na região Amazônica*. 1994, 161f. Dissertação (Mestrado em Engenharia) – Curso de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1994.

Braga, A. P., Ludermir, T. B., & Carvalho, A. C. *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora, 2000. 262p.

Brega, J. R. F. *A utilização de redes neurais artificiais em um sistema de gerência de pavimentos*. São Carlos. Tese (Doutorado). Escola de Engenharia de São Carlos. Universidade de São Paulo, 1996.

Carmona, A. F., & Marega, A. Retrospectiva da Patologia no Brasil: Estudo Estatístico. In: *Jornadas en Español y Português sobre Estructuras y Materiales*, Madrid, 1988. Colloquia 88. Madrid, CEDEX, IETcc, mayo 1988, p. 325-48.

Dal Molin, D. C. C. *Fissuras em estruturas de concreto armado: análise das manifestações típicas e levantamento de casos ocorridos no Estado do Rio Grande do Sul*. 1988. Dissertação (Mestrado em Engenharia) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1988.

Espinhosa, M. C. *Utilização do Sensoriamento Remoto Orbital e Redes Neurais Artificiais no mapeamento de macrófitas aquáticas emersas em grandes reservatórios*. 2004. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia. Universidade Estadual Paulista “Júlio Mesquita Filho”, Presidente Prudente.

Faxina, A. L. et al. (2005). Aplicação de redes neurais artificiais e de modelagem estatística para a previsão de propriedades convencionais de asfaltos; In: *36ª Reunião Anual de Pavimentação*, p. 1-12; Curitiba – PR.

Felix, E. F.; Possan, E.; Konzen, P. H. A. Modelagem da frente de carbonatação do concreto em ambientes marítimos empregando RNA's. In: *Congresso Brasileiro de Patologia das Construções*, Foz do Iguaçu. 2014. Anais do 1º Congresso Brasileiro de Patologia das Construções, 2014.

Fleck, E. M.; Pedreira, C. E.; Santos, R. Agrupamento de dados sísmicos através do algoritmo de Kohonen. In: *Congresso Brasileiro de Redes Neurais*, 6. São Paulo. Anais. São Paulo, 2003.

Fwa, T. F.; Chan, W. T. Priority rating of highway maintenance needs by neural networks. *Journal of Transportation Engineering of the ASCE*, v. 119 n° 3 p. 419-432, 1993.

Galo, M. L. B. T. *Aplicações de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo*. 2005. Tese (Doutorado), Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, 2005.

Galvão, W. S.; Meneses, P. R. Geração de mapa de potencial à alocação de estações na bacia do rio São Francisco como um produto estratégico de apoio às ações de planejamento de redes fluviométricas, através do uso e do classificador neural supervisionado. *Simpósio Brasileiro de Sensoriamento remoto*, 12 Goiânia. Anais. Goiânia: INPE, 2005.

Hamada, M. Neutralization (carbonation) of concrete and corrosion of reinforcing steel. In: *International Symposium on the Chemistry of Cement*, 5, 1969. Tokyo. Proceedings... Tokyo, 1969, Part III, v. II/4, p.343-369.

Haykin, S. *Redes Neurais: Princípios e Práticas*. Porto Alegre: Editora Bookman, 2001. 900p.

Helene, P. R. L. Corrosão das Armaduras em Concreto Armado. In: *Simpósio de Aplicação da Tecnologia do Concreto*, 4, Campinas, 1981. SIMPATCON: QDLV_Campinas, Concrelix, 1981.

Hua, J.; Faghri, A. Dynamic traffic pattern classification using artificial neural network. *Transportation Research Record* 1399, p 14-19, 1993.

Hyvert, N. *Application de l'approche probabiliste à la durabilité des produits préfabriqués en béton*. Thèse de doctorat, Université Paul Sabatier, Toulouse, 2009.

Isaia, G. C. Carbonatação do concreto: uma revisão. In: *workshop sobre corrosão da armadura do concreto*, 1999, Colloquia. Anais... São José dos Campos, 1999.

Jepsen, M. T. Predicting concrete durability by using artificial neural network. In: *Durability of Exposed Concrete containing Secondary Cementitious Materials*. Hirtshals, 2002.

Kaseko, M. S.; Ritchie, S. G. A neural network-based methodology for pavement crack detection and classification. *Transportation Research* v. 1 n° 4, p. 275-291, 1993.

Luo, D.; Niu, D.; Dong, Z. Application of neural network for concrete carbonation depth prediction. In: *4th International Conference on the Durability of Concrete Structures*. West Lafayette, USA, 2014.

Martins, C. A. C. *Estimativa da Profundidade de Carbonatação do Concreto com Uso de Redes Neurais*. 2011. Dissertação (Mestrado em Engenharia) - Escola de Engenharia, Programa de Pós-Graduação em Engenharia Civil, UNICAP, Recife.

Meira, G. R., Padaratz, I. J., & Borba Júnior, J. C. Carbonatação natural de concretos: resultados de cerca de quatro anos de monitoramento. In: *Encontro Nacional De Tecnologia Do Ambiente Construído*, XI, 2006, Florianópolis. Anais... Porto Alegre: Antac, 2006, 9p.

Mehta, P. K. Durability of Concrete: fifty years of progress? In: *Seminário Qualidade E Durabilidade Das Estruturas De Concreto*, 1991, Porto Alegre. Anais... Porto Alegre: NORIE/CPGEC/UFRGS, 1991, 33p.

Muthupriya, P.; Subramanian, K.; Vishnuram, B. G. Prediction of compressive strength and durability of high performance concrete by artificial neural networks. In: *International Journal of Optimization in Civil Engineering*, v.1, 189-209, 2011.

Neville, A M. *Propriedades do concreto*. São Paulo: PINI, 1997, 828p.

Papadakis, V. G., Vayenas, C. G., & Fardis, M. N. Fundamental Modeling and Experimental Investigation of Concrete Carbonation. *ACI Journal*, v.88, n.4, July-Auguste, 1991.

Pauletti, C. *Estimativa da carbonatação natural de materiais cimentícios a partir de ensaios acelerados e de modelos de previsão*. 2009. Tese de Doutorado em co-tutela (Doutorado em Engenharia) – Escola de Engenharia, Programa de Pós-Graduação em Engenharia Civil, UFRGS, Porto Alegre e École Doctorale Mécanique, Energétique, Génie Civil et Procédés, Institut National des Sciences Appliquées, Toulouse.

Possan, E. *Modelagem da carbonatação e previsão de vida útil de estruturas de concreto em ambiente urbano*. 2010. Tese (Doutorado em Engenharia) - Escola de Engenharia, Programa de Pós-Graduação em Engenharia Civil, UFRGS, Porto Alegre.

Santos, A. F. *Aplicação de redes neurais artificiais no controle eficiente do motor de indução trifásico*. 2008, 114f. Dissertação de (Mestrado em Engenharia Elétrica) Universidade Federal de Pernambuco. Recife.

Santos, C. C.; Pereira, A. J. Modelagem hidrológica urbana por meio de redes neurais artificiais: uma aplicação para a bacia do rio Tamanduateí em São Paulo. In: *Revista Brasileira de Meteorologia*, v.18, n.2, 149-159, 2003.

Silva, A., Ramos, R., Zouza, L., Rodrigues, D., & Mendes, J. *Uma plataforma para*

introdução de técnicas emergentes no planejamento urbano regional e de transportes: uma ferramenta 3D para análise ambiental urbana, avaliação multicritério e redes neurais artificiais. São Carlos: Editora dos Autores, 2004. 221p.

Sucapuça, L. A. A.; Possan, E.; Konzen, P. H. A. Emprego de RNA's para a estimativa da profundidade de carbonatação do concreto: estudo preliminar. In: *Congresso Brasileiro de Patologia das Construções*, Foz do Iguaçu. 2014. Anais do 1º Congresso Brasileiro de Patologia das Construções, 2014.

Smolczyk, H. G. Written Discussion. In: *The International Symposium on the Chemistry of Cement*, V. Tokyo, 1969. Proceedings... Tokyo, 1969, Part III, v. II/4, p.369-384.

Tuutti, K. *Corrosion of Steel in Concrete*. Swedish Cement and Concrete Research Institute. Stockholm, Suecis, 1982. 30p.

Ukrainczyk, N.; Banjad, P. I.; Ukrainczyk, V. Application of Neural Network: Predicting Damage of Concrete Structures Caused by Chlorides. In: *International Symposium Durability and Maintenance of Concrete Structures*, Dubrovnik, Croatia, 2004.

Ukrainezyk, U.; Matusinović U. Use of Neural Network to Evaluate Rebar Corrosion. In: *Continental Environment, 3th Int. Conf. Construction Materials*, Vancouver, 2005.

Vieira, R. M, Meira, G. R., Marques, V. M., & Padilha Jr, M. Carbonatação natural e acelerada de concretos – influência de fatores ambientais e do material. In: *Congresso Brasileiro Do Concreto*, 51º, 2009, Curitiba. Anais... São Paulo : Ibracon, 2009. v. 1.