

Uso do aprendizado de máquina na previsão da frente de carbonatação: uma trajetória dos anos 90 aos dias atuais

TIAGO FERREIRA CAMPOS NETO – MESTRE EM ENGENHARIA CIVIL*

ORCID: <https://orcid.org/0000-0002-9618-2763>

OSWALDO CASCUDO – PROFESSOR DOUTOR

ORCID: <https://orcid.org/0000-0003-1879-6396>

HELENA CARASEK – PROFESSORA DOUTORA

ORCID: <https://orcid.org/0000-0002-1170-0980>

PROGRAMA DE PÓS-GRADUAÇÃO EM GEOTECNIA, ESTRUTURAS E CONSTRUÇÃO CIVIL, UNIVERSIDADE FEDERAL DE GOIÁS – UFG

RESUMO

A PREOCUPAÇÃO EM PREVER A VIDA ÚTIL DAS ESTRUTURAS DE CONCRETO ARMADO ESTÁ LIGADA À GARANTIA DO SEU DESEMPENHO EM FUNÇÃO DO TEMPO. A IMPLANTAÇÃO DE SISTEMAS DE MONITORAMENTO DA DURABILIDADE ESTRUTURAL TORNA-SE UMA ALTERNATIVA INTERESSANTE SOB A ÓTICA DA PREDIÇÃO DE VIDA ÚTIL. ESTE TRABALHO BUSCA ELENCAR PRÁTICAS RECENTES APLICADAS À AVALIAÇÃO DA DURABILIDADE COM BASE NA DETERIORAÇÃO DO CONCRETO, DISCRIMINANDO COM

DETALHES OS PROCESSOS DE AVALIAÇÃO DAS FRENTES DE CARBONATAÇÃO E OS MODELOS DE PREDIÇÃO DA VIDA ÚTIL DAS ESTRUTURAS, COM ÊNFASE NO USO DO APRENDIZADO DE MÁQUINA. NAS PESQUISAS CATALOGADAS, CONSTATOU-SE A ACURÁCIA DO APRENDIZADO DE MÁQUINA NA PREDIÇÃO DA PROFUNDIDADE DE CARBONATAÇÃO DO CONCRETO ARMADO, DESDE QUE SEJA REALIZADA SELEÇÃO ADEQUADA DOS PARÂMETROS DE ENTRADA E DO ALGORITMO DE TREINAMENTO.

Palavras-chave: concreto armado, durabilidade, vida útil, carbonatação, machine learning.

I. INTRODUÇÃO

A corrosão do aço é a fonte mais comum e difundida de degradação das estruturas de concreto, podendo ser uma consequência direta da carbonatação, processo que induz redução no pH da matriz cimentícia, despassivação do aço e no conseqüente início dos processos corrosivos. A carbonatação é, portanto, um mecanismo chave para

se determinar a vida útil de edificações em concreto armado.

A previsão de vida útil pode ser definida como a ação de prever o período de tempo desde o instante da construção até o momento em que houver, nas armaduras, uma elevada concentração de agentes agressivos, suficiente para que se inicie o processo de corrosão, ou mesmo a diminuição do pH do concreto, deixando as barras suscetíveis à corrosão

(decorrentes da despassivação do aço). Este é o conceito de vida útil de projeto, que diz respeito ao período de tempo para o qual a estrutura é projetada, atendendo aos níveis de desempenho, considerando a periodicidade dos processos de manutenção. Além desse período, os mecanismos patológicos de deterioração se instalarão, sendo uma questão de tempo a ocorrência de danos que culminará no término da vida útil de serviço

* tiagocampos.eng@gmail.com

(HELENE, 1993; CASCUDO, 1997). Em Portugal, edifícios monumentais devem ter vida útil nominal maior que 100 anos (BS EN 206-1: 2016) e, na Inglaterra, edifícios novos e obras de artes devem ter a vida útil nominal mínima de 120 anos (BS 7543: 2015). Já no Brasil, as normativas contemplam um período mínimo de 50 anos para os sistemas estruturais (ABNT NBR 15575-1: 2021).

Para garantia da vida útil é importante pensar na implantação de sistemas de monitoramento da durabilidade em estruturas de concreto armado. Essa ação pode permitir a identificação dos processos de deterioração em estágios iniciais e monitorar a evolução do dano. Os dados coletados pelo sistema de monito-

ramento devem ser analisados de forma eficiente para que sejam adequadamente utilizados na estimativa da vida útil restante da estrutura ou elemento estrutural. Um método alternativo para análise desses dados é o uso do aprendizado de máquina, ou *machine learning*, pois este permite a avaliação de informações complexas e fornece resultados e interpretações mais precisas que permitirão orientar futuras decisões, em tempo real, sem intervenção humana direta, por exemplo, no diagnóstico de falhas.

Portanto, o objetivo deste artigo é elencar e discutir as recentes práticas aplicadas na avaliação da durabilidade com foco na carbonatação do concreto, discriminando com detalhes os

processos de avaliação das frentes de carbonatação e as técnicas de predição da vida útil das estruturas com uso do aprendizado de máquina.

2. DURABILIDADE DO CONCRETO E O APRENDIZADO DE MÁQUINA

Muitos são os agentes que influenciam o desenvolvimento da carbonatação, podendo ser divididos em internos e externos. Os fatores internos estão relacionados à composição e microestrutura do concreto, como, por exemplo, o tipo de cimento Portland, a presença de adições minerais, o consumo de cimento e a relação água/cimento (a/c), além da estrutura e dimensão dos macro, meso e microporos, incluindo os

► Quadro 1 – Algumas das pesquisas nacionais fundadas na predição de vida útil

Autor(es)	Ano e local de publicação	Objetivo geral	Métodos e principais resultados
CARMONA (orientação Helene)	2005 Dissertação de mestrado USP	Analisar diferentes modelos de previsão do período de iniciação da corrosão em estruturas de concreto sujeitas à carbonatação e desenvolver um sistema computacional capaz de prever o período de iniciação por métodos deterministas e probabilistas.	Elencaram-se doze modelos diferentes propostos nas décadas de 80 e 90, focando a aplicação do desenvolvimento do software em apenas três: CEB – 1996, Helene – 1997 e Papadakis – 1989. Os modelos, em especial de Helene, se mostraram eficientes. Entretanto, embora o sistema computacional, nomeado de Carambola, tenha sido desenvolvido com base no modelo de Helene, o autor deixa explícita a necessidade de calibrar o modelo a situações reais para que as profundidades de carbonatação estimadas se aproximem dos valores reais.
POSSAN (orientação Dal Molin e Andrade)	2010 Tese de doutorado UFRGS	Propor um modelo matemático de previsão de vida útil de projeto frente à carbonatação empregando opinião de especialistas e conceitos probabilísticos.	O modelo pode ser empregado como função do estado limite de durabilidade nos estudos probabilísticos, podendo ser utilizado para predições de vida útil de estruturas de concreto sujeitas à carbonatação. Entretanto, é deixada clara a possibilidade de aprimoramento do modelo inserindo parâmetros como, por exemplo, tempo de cura e fissuração do concreto.
CASTRO, FERREIRA e PIRES (orientação Cascudo e Carasek)	CASTRO – 2003, FERREIRA – 2010 e PIRES – 2014 Dissertações de mestrado UFG – Ref.: Cascudo et al. (2021)	Estudar o comportamento a longo prazo da carbonatação (por monitoramento da frente de carbonatação) em diferentes tipos de concreto com adições minerais.	Foram produzidos modelos empíricos-determinísticos de vida útil, do tipo “ $e=K \cdot \sqrt{t}$ ” (modelo de Tuutti), expressando o comportamento de 14 anos de variados concretos em exposição natural. Os modelos produziram excelentes ajustes aos dados experimentais, tendo-se obtido uma correlação significativa da carbonatação natural com a carbonatação acelerada.

poros capilares. Por sua vez, os fatores externos se relacionam às condições de exposição do elemento estrutural, como, por exemplo, a concentração de CO₂ na atmosfera, a temperatura e umidade relativa do ar, a exposição a chuvas, etc. Aspectos da execução do concreto na estrutura, notadamente falhas nos procedimentos de cura, podem produzir microfissuração que favorece a ocorrência de carbonatação.

No Brasil, os pesquisadores têm buscado investigar e aplicar modelos preditivos com diversos enfoques. De maneira a elucidar e exemplificar alguns estudos nacionais sobre a temática, o Quadro 1 lista os autores, locais e anos de publicação, os objetivos gerais, os métodos de pesquisa e os principais resultados.

As pesquisas descritas no Quadro 1 tratam da predição de vida útil de estruturas de concreto, no entanto, nenhuma delas utiliza o aprendizado de máquina como parte integrante do processo. Além disso, cada autor realiza a predição utilizando um modelo distinto, com diferentes parâmetros de análise.

Esses trabalhos científicos mostram

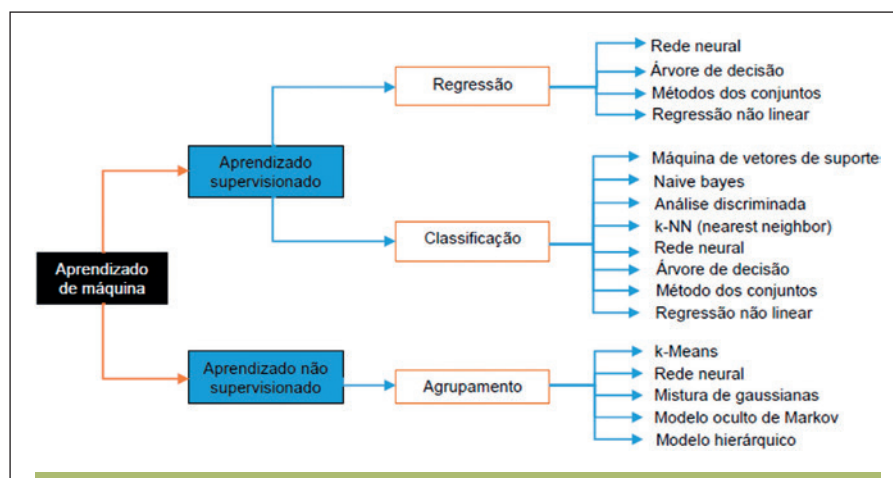
que a modelagem da evolução da carbonatação é um fator determinante da durabilidade das estruturas de concreto armado. Uma infinidade de modelos experimentais tem sido proposta, incluindo algumas revisões extensas da literatura. Assim, os modelos existentes podem ser divididos em diferentes categorias, como modelos empíricos, estatísticos, numéricos ou simulações.

Os modelos apresentados são determinísticos ou probabilísticos. Já os modelos de simulação aplicam redes neurais em inteligência artificial. Mas como a inteligência artificial poderia contribuir com os estudos de predição de vida útil de estruturas? A resposta é simples, porém de aplicação complexa. Redes neurais compreendem algoritmos que permitem a inserção de dados de entrada, cujo comportamento é treinado para resolver problemas como um cérebro humano. Cada rede possui nós ou unidades de processamento com interconexões com outras unidades por onde informações são transmitidas, simulando o comportamento dos neurônios, gerando dados de saída (respostas).

O algoritmo treinado pode ser empregado para realizar previsões para novos dados de entrada. Por isso, as redes neurais são populares nessa aplicação, pois possuem elevada acurácia e facilidade de uso e entendimento; toleram tarefas relativamente imprecisas ou incompletas, aproximando resultados e até mesmo *outliers* (pontos distantes dos demais dados) menos vulneráveis; ademais, permitem identificar os efeitos sinérgicos de diferentes mecanismos de deterioração do concreto por carbonatação (PAUL *et al.*, 2018). As redes neurais artificiais são sistemas maciços e paralelamente distribuídos formados por uma unidade de processamento simples, com capacidade natural de armazenamento de dados por conhecimento experimental. Entretanto, além das redes neurais é possível utilizar diferentes algoritmos no aprendizado de máquina.

O aprendizado de máquina pode ser aplicado de duas formas distintas: supervisionado, que aprende a executar tarefas a partir de modelos rotulados que apresentem uma condição a ser atingida; ou não supervisionado, que aprende a executar tarefas a partir de dados não rotulados, com base nos padrões semelhantes (TAFFESE; SISTONEN, 2017). A Figura 1 apresenta diferentes tipos de *machine learning* e classes de algoritmos, sendo o tipo supervisionado mais comumente utilizado.

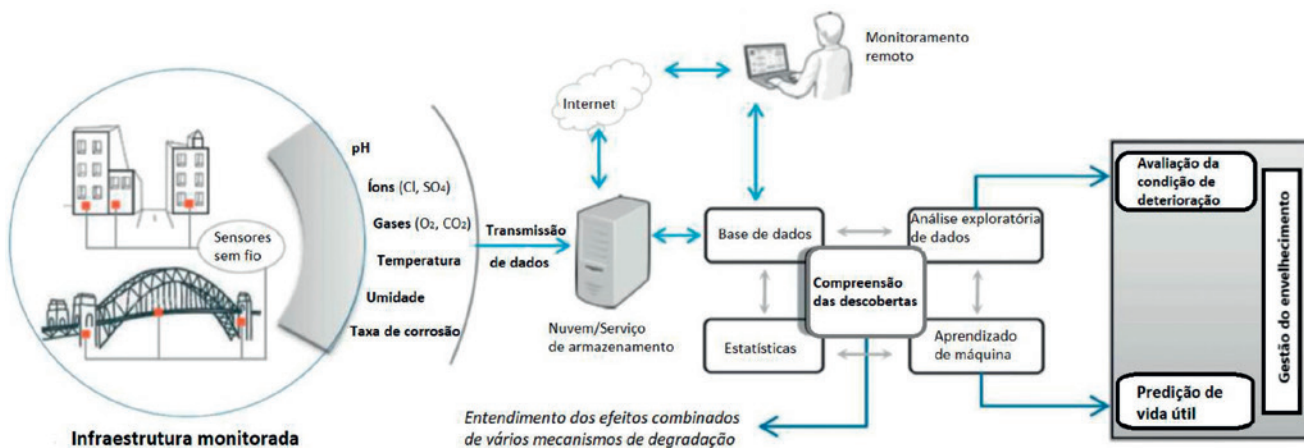
No aprendizado supervisionado, mais usado na predição de vida útil, duas classes de algoritmos são aplicáveis: regressão e classificação. Na regressão busca-se prever um valor numérico, isto é, identificar uma categoria em grandeza contínua ou uma probabilidade, ao passo que a classificação



► **Figura 1**
Tipos de aprendizado de máquina e os algoritmos comumente utilizados

Fonte: adaptada de Taffese e Sistonen (2017)





► **Figura 2**

Etapas de aplicação do aprendizado de máquina supervisionado. Atenção especial é dada à seleção dos dados de entrada e do tipo de algoritmo

Fonte: adaptada de Taffese e Sistonen (2017)

busca determinar a qual categoria pertence um exemplar do estudo. Enquanto, para o aprendizado não supervisionado, mais usado por empresas que buscam detectar as preferências de seus clientes, aplica-se o agrupamento ou clusterização. No agrupamento, o conjunto de dados analisados é segmentado em subgrupos, com base nas semelhanças encontradas, definidas por meio de formulações diversas.

Para aplicação do aprendizado de máquina é preciso seguir uma série de etapas, como mostrado na Figura 2. Após a seleção da edificação ou dos elementos estruturais a serem monitorados, instalam-se sensores que registram dados, que devem ser selecionados pelo pesquisador. Entre os dados de entrada que serão monitorados existe uma vasta lista e a seleção desses parâmetros pode alterar significativamente as respostas ou dados de saída. É exatamente aqui, na etapa de seleção dos dados de entrada, que a aplicação se torna complexa.


Em nível mundial, o uso do aprendizado de máquina na previsão da vida útil de estruturas com base na carbonatação do concreto é um assunto muito em voga e que teve início no final da década de 90.

3. CASOS DE APLICAÇÃO DE REDES NEURAIS PARA ESTIMAR FRENTE DE CARBONATAÇÃO

Buenfeld, Hassanein e Jones (1998) utilizaram redes neurais para prever a profundidade de carbonatação de elementos de concreto armado com base no monitoramento do desvio em relação à raiz quadrada do erro médio. Foram considerados 39 dados de entrada distintos, como, por exemplo, composição do cimento, adições minerais, traço do concreto, tipo de cura, condições climáticas e dados de ensaios acelerados. Os resultados da previsão foram comparados a resultados

de ensaios de carbonatação natural em corpos de prova expostos entre oito semanas e 25 anos. Observou-se que os valores obtidos foram próximos aos reais, abrindo espaço para futuras pesquisas na área.

Já nos anos 2000, Zhitao, Hongming e Shengli (2008), também com foco na previsão da vida útil de estruturas de concreto, utilizaram máquinas de vetores de suporte (detecção de padrão por classificação e regressão) e *backpropagation* (retropropagação com gradiente descendente) como algoritmos-base. Os parâmetros de entrada aplicados



► **Figura 3**

Comparação das profundidades de carbonatação reais e os valores estimados com os algoritmos aplicados na pesquisa

Fonte: adaptada de Zhitao, Hongming e Shengli (2008)

foram dados históricos reais, como relação a/c, consumo de cimento e tempo de exposição de diferentes edificações. Como resultado (Figura 3), notou-se que tanto a máquina de suporte vetorial quanto a *backpropagation* se mostraram eficazes; entretanto, o suporte vetorial mostrou-se mais preciso na predição.

No ano seguinte, de forma a confirmar resultados, Xiang (2009) utilizou os mesmos dados de entrada dos pesquisadores anteriores e replicou o experimento utilizando algoritmos de suporte vetorial e rede neural. Ao comparar os resultados obtidos com os da pesquisa anterior, constatou-se que o uso de redes neurais apresentou maior eficiência na predição de vida útil de estruturas de concreto armado.

Taffese *et al.* (2015) realizaram uma pesquisa utilizando quinze parâmetros de entrada distintos, incluindo dados dos constituintes do concreto e o tempo de exposição da estrutura. Optou-se por utilizar rede neural artificial como algoritmo base do aprendi-

zado de máquina. Observou-se que a avaliação do desempenho do modelo demonstrou que é possível prever razoavelmente bem com capacidade de generalização aprimorada, sendo o coeficiente de correlação igual a 0,98269 (Figura 4).

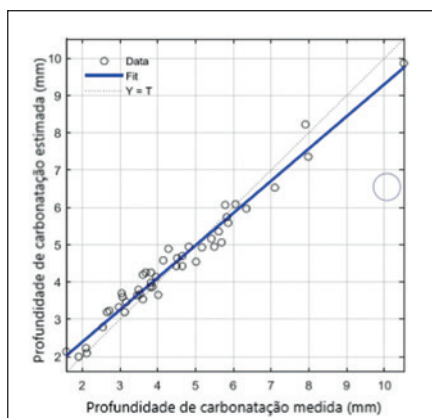
Ainda na mesma linha de pesquisa, Cho *et al.* (2016) aplicaram o sistema de inferência neuro-difuso adaptativo (ANFIS), um modelo de rede neural difusa (algoritmo que admite valores lógicos intermediários entre “verdadeiro” e “falso”), na predição de vida útil. Foram realizadas inspeções de campo em oito edifícios distintos, onde se determinou as frentes de carbonatação em diferentes elementos de cada edificação. Foi estudada a aplicabilidade de dois métodos distintos de predição: aprendizado de máquina e modelo de predição japonês normatizado. Foram consideradas também as influências do tipo de elemento estrutural (pilare, viga, laje ou parede), da resistência à compressão, da espessura do cobrimento e da abertura de fissuras na profundidade de carbonatação do concreto. Para aplicação do aprendizado de máquina, foram considerados como parâmetros de entrada o coeficiente de difusão e a concentração de CO₂, o coeficiente de difusão e a concentração de cloretos, a resistência à compressão e a abertura das fissuras. Como resultado, identificou-se alta precisão do aprendizado de máquina na predição da profundidade de carbonatação e um distanciamento dos valores obtidos pelo modelo japonês em relação aos dados reais, conforme ilustrado na Figura 5.

No Brasil, o uso de redes neurais artificiais na predição de vida útil teve

início nos anos 2000. Félix, Carrazedo e Possan (2017) analisaram a influência dos principais fatores que afetam a carbonatação, como tipo de cimento, umidade relativa do ar, condição de exposição, teor de sílica ativa, concentração de CO₂, resistência à compressão e tempo de exposição. No estudo foi utilizado o algoritmo do tipo multilayer perceptron (MLP), uma rede neural de classificação linear. Considerando quatro cenários distintos (Tabela 1), os autores utilizaram cinco modelos diferentes para comprovar o potencial da inteligência artificial, conforme apresentado na Figura 6.

Conclui-se que o modelo obtido com MLP se ajustou aos outros modelos, sendo comprovado seu potencial, além de ter se mostrado eficaz no estudo da predição da frente de carbonatação, por meio de avaliações dos fatores de exposição na frente de carbonatação.


Paul *et al.* (2018) buscaram determinar a profundidade de carbonatação do concreto baseada na



► **Figura 4**

Profundidades de carbonatação estimadas vs. Medidas

Fonte: adaptada de Taffese et al. (2015)



► **Figura 5**

Profundidades de carbonatação medidas em campo (círculo azul), estimadas pelo modelo japonês normatizado (triângulo verde) e estimadas pelo aprendizado de máquina (quadrado vermelho)

Fonte: adaptada de Cho et al. (2016)



► Tabela 1 – Cenários das estruturas de concreto sob carbonatação

Cenário	Teor de CO ₂ (%)	Umidade relativa (%)	Exposição à chuva	Tipo de cimento Portland	Resistência à compressão (MPa)
I	0,01	70	Protegido	CP II-F	30
II	0,01	70	Protegido	CP III	40
III	0,01	65	Desprotegido	CP IV	40
IV	0,01	65	Desprotegido	CP V	40

Em todos os cenários o teor de adição (no concreto) é zero e o tempo de análise é de 60 anos.

Fonte: adaptada de Félix, Carrazedo e Possan (2017)

composição dos materiais (relação água/ligante, relação agregados/ligante) e nas condições de exposição (concentração de CO₂ e tempo de exposição). O modelo preditivo foi realizado utilizando redes neurais artificiais (ANS) com variações nas configurações de aproximação (*multi-layer perceptron*).

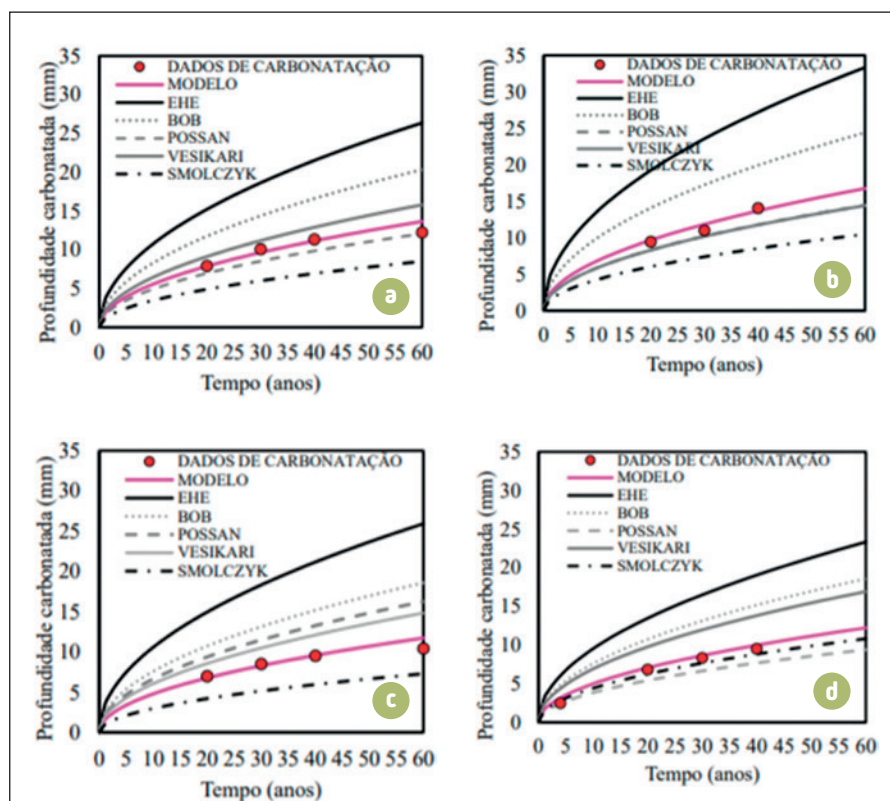
Constatou-se que a carbonatação do concreto é mais sensível à umidade relativa do ar do que a qualquer outro fator dentre os abordados no estudo, conforme ilustrado na Figura 7a. Na Figura 7b é possível visualizar a relação existente entre os valores de profundidade esperados (obtidos através de ensaios de carbonatação acelerada) e os valores atingidos pela aplicação do aprendizado de máquina. Nota-se que o coeficiente de correlação foi de 0,982, isto é, foi atingida uma relação positiva quase perfeita, constatando que a máquina apresenta elevada acurácia na predição de vida útil.

Recentemente, Lee, Lee e Suraneni (2020) também avaliaram a possibilidade de aplicação do aprendizado de máquina na predição do comportamento da carbonatação do concreto. Buscou-se comparar os resultados obtidos

pela inteligência artificial com dados atingidos por meio de método de carbonatação acelerada, pelo modelo do *Architectural Institute Japanese* (AIJ) e pelo método dos elementos finitos (FEM).

Para treinamento da rede neural profunda (algoritmos capazes de modelar abstrações de alto nível usando grafo profundo com várias camadas de processamento) foram considerados dados como traço do concreto, concentração de CO₂, período de medição da carbonatação e dados experimentais resultantes de ensaios acelerados. As misturas foram produzidas com diferentes relações a/c: 0,55 e 0,65, e os ensaios acelerados foram executados com temperatura de (20 ± 2)°C, umidade relativa do ar de (60 ± 5)% e concentrações de CO₂ de 5% e 20%.


Os resultados obtidos estão mostrados na Tabela 2, onde as diferenças



► Figura 6

Curvas de carbonatação obtidas com diferentes modelos para: (a) cenário I; (b) cenário II; (c) cenário III; e (d) cenário IV

Fonte: adaptada de Félix, Carrazedo e Possan (2017)



entre os valores estimados (AIJ, FEM e ML) e os valores obtidos experimentalmente (EXP) estão descritas entre os parênteses abaixo dos valores absolutos. De modo geral, os dados apontam que o aprendizado de máquina apresenta alta precisão na predição, com as menores diferenças entre seus resultados e os valores obtidos por ensaios acelerados, entre 0,01 e 0,10 mm/ano^{0,5}. Os resultados obtidos pelo FEM apresentaram diferenças superiores às do aprendizado de máquina, entre 0,08 e 1,04 mm/

ano^{0,5} e, por fim, o modelo com maiores diferenças foi o AIJ, entre 0,32 e 2,34 mm/ano^{0,5}.

4. CONCLUSÕES

Este trabalho buscou discutir o processo de deterioração do concreto por carbonatação e apresentar diferentes tipos de algoritmos e estratégias de aplicação do aprendizado de máquina na predição da vida útil das estruturas. Foi feito um fichamento cronológico da aplicação do aprendizado de máquina na

predição, em que foi possível observar a evolução dos algoritmos e dos parâmetros analisados.

Em todas as pesquisas foi constatada a acurácia do aprendizado de máquina na predição da profundidade de carbonatação de diferentes elementos em concreto armado utilizando-se as redes neurais. Entretanto, é relevante ressaltar a importância da seleção adequada dos parâmetros de entrada e do algoritmo de treinamento.

O aprendizado de máquina não permite a avaliação da detração do concreto, mas também possibilita realizar monitoramento contínuo da evolução dos danos e do desempenho do concreto armado, assim como conduzir estudos de previsão de vida útil, desde que consideradas as variáveis de influência. Além disso, permite que sejam aplicadas outras técnicas em conjunto que possibilitem aprimorar resultados e elevar a precisão dos dados obtidos, como por exemplo, ensaios de carbonatação acelerada, aproximando os dados experimentais do processo real da deterioração. 📌

► Tabela 2 – Resultados dos coeficientes de carbonatação obtidos pelos métodos AIJ, FEM, ensaios acelerados (EXP) e aprendizado de máquina (ML)

Relação a/c	CO ₂ (%)	Coeficiente de carbonatação (mm.ano ^{0,5})				Profundidade de carbonatação em 100 anos (mm)			
		AIJ	FEM	EXP	ML	AIJ	FEM	EXP	ML
0,55	5	2,07 (0,56)	1,43 (0,08)	1,51	1,58 (0,07)	20,70 (5,61)	14,30 (0,79)	15,09	15,76 (0,67)
	20	2,53 (0,59)	2,90 (0,22)	3,12	3,11 (0,01)	25,26 (5,94)	29,0 (2,20)	31,20	31,10 (0,10)
0,65	5	3,20 (0,32)	3,01 (0,13)	2,88	2,80 (0,08)	31,96 (1,34)	30,10 (1,34)	28,76	28,01 (0,75)
	20	6,08 (2,34)	7,38 (1,04)	8,42	8,32 (0,10)	60,84 (23,40)	73,84 (10,40)	84,24	83,20 (1,04)

Fonte: adaptada de Lee, Lee e Suranemi (2020)



▶ REFERÊNCIAS BIBLIOGRÁFICAS

- [1] BUENFELD, N.R.; HASSANEIN, N. M.; JONES, A. J. An artificial neural network for predicting carbonation Depth in concrete structures. In: FLOOD, I.; KARTAM, N. (Ed.). *Artif. Neural Networks Civ. Eng. Adv. Featur. Appl.* American Society of Civil Engineers, Reston, 1998.
- [2] CASCUDO, O. O Controle da corrosão de armaduras em concreto: inspeção e técnicas eletroquímicas. 1. ed. São Paulo, Pini; Goiânia, Editora UFG, 1997.
- [3] CASCUDO, O.; PIRES, P.; CARASEK, H.; CASTRO, A.; LOPES, A. Evaluation of the pore solution of concretes with mineral additions subjected to 14 years of natural carbonation. *Cement and Concrete Composites*, v. 115, p. 1/103858-13, 2021.
- [4] CHO, H. C.; JU, H.; OH, J. Y.; LEE, K. J.; HAHM, K. W.; KIM, K. S. Estimation of concrete carbonation depth considering multiple influencing factors on the deterioration of durability for reinforced concrete structures. *Advances in Materials Science and Engineering*, 2016.
- [5] FÉLIX, E. F.; CARRAZEDO, R.; POSSAN, E. Análise paramétrica da carbonatação em estruturas de concreto armado via redes neurais artificiais. *Revista de la Asociación Latinoamericana de Control de Calidad, Patología y Recuperación de la Construcción*, 2017.
- [6] HELENE, P. R. L. Contribuição ao estudo da corrosão em armaduras de concreto armado. São Paulo, 1993. Tese (Livre Docência) - Escola Politécnica, Universidade de São Paulo.
- [7] LEE, H.; LEE, H. S.; SURANENI, P. Evaluation of carbonation progress using AIJ model, FEM analysis and machine learning algorithms. *Construction and Building Materials*, n. 259, 2020.
- [8] PAUL, S. C.; PANDA, B.; HUANG, Y.; GRAG, A.; PENG, X. An empirical model design for evaluation and estimation of carbonation depth in concrete. *Measurement*, 124, 2018.
- [9] TAFFESE, W. Z.; AL-NESHAWY, F.; SISTONEN, E.; FERREIRA, M. Optimized neural network based carbonation prediction model. *Int. Symp. Non-destructive Test. Civ. Eng. (NDT-CE 2015)*, Bundesanstalt für Materialforschung und-prüfung (BAM), Berlin, 2015.
- [10] TAFFESE, W. Z.; SISTONEN, E. Machine learning for durability and service-life assessment of reinforced concrete structures: Recent advances and future directions. *Automation in Construction*, v. 77, 2017.
- [11] XIANG, R. Prediction of concrete carbonation Depth based on support vector regression. In: LIU, Q.; ZHU, M. (Ed.). *Third Int. Symp. Intell. Inf. Technol. Appl.* IEEE Computer Society, Los Alamitos, 2009.
- [12] ZHITAO, L.; HONGMING, H.; SHENGLI, Z. Research on support vector machine's prediction of concrete carbonization. In: LUO, Q. (Ed.). *Int. Semin. Bus. Inf. Manag.* IEEE Computer Society, Los Alamitos, 2008.

GARANTA A ESTANQUEIDADE E PROTEÇÃO DA SUA ESTRUTURA
TRAZENDO DURABILIDADE E AUMENTO DE VIDA ÚTIL

TechCrete
2500



**PRÊMIO EM 2020
NA WORLD OF CONCRETE**

**ESOLHIDO PELA INDÚSTRIA
COMO PRODUTO MAIS INOVADOR
PARA ESTRUTURAS DE CONCRETO**

OBRAS INDUSTRIAIS - RESIDENCIAIS - COMERCIAIS - INFRAESTRUTURA



SAIBA MAIS, ACESSE:

WWW.ALCHEMCO.COM.BR

(31) 3956-0461

(27) 3207-2994