

# Imputação de dados ausentes em séries temporais de carbonatação dos concretos

*Imputing missing data in time series of concrete carbonation*

Tiago Ferreira Campos Neto 

Oswaldo Cascudo 

## Resumo

O crescente uso de modelos contemporâneos de previsão de frentes de carbonatação, como redes neurais artificiais, exige maior rigor sobre a completude dos bancos de dados. Tratar os bancos de dados de profundidades de carbonatação como séries temporais é uma alternativa favorável à garantia da qualidade. Dessa forma, este artigo tem o objetivo de identificar a melhor técnica de imputação de dados ausentes em séries temporais de profundidades de carbonatação de concretos com diferentes composições. Como banco de dados foram utilizadas as informações coletadas de concretos submetidos à carbonatação natural ao longo de 20 anos de exposição pertencentes ao grupo GEDur/UFG. Foram experimentadas dez técnicas de imputação entre as quais destacam-se, *forward fill*, média móvel, interpolação e filtro de Kalman. Todas as técnicas e análises foram implementadas utilizando linguagem de programação em *python* dentro de um ambiente de desenvolvimento integrado. Com base nas métricas de desempenho e análise visual, constatou-se que a interpolação *spline* monotônica cúbica capturou o padrão da curva de profundidade de carbonatação em função do tempo com maior precisão e acurácia, alcançando índice de desempenho de 0,998 e RMSE entre 0,106mm e 0,863mm dependendo da amostra de concreto.

**Palavras-chave:** Concreto. Carbonatação. Séries temporais. Imputação de dados. Dados ausentes.

## Abstract

*The growing use of contemporary models for predicting carbonation fronts, such as artificial neural networks, requires greater rigor in terms of database completeness. Treating carbonation depth databases as time series is a favorable alternative for quality assurance. Therefore, the aim of this article is to identify the best technique for imputing missing data in time series of carbonation depths of concrete with different compositions. The database used was information collected from concretes subjected to natural carbonation over 20 years of exposure belonging to the GEDur/UFG. Ten imputation techniques were tried, such as forward fill, moving average, interpolation and Kalman filter. All the techniques and analyses were implemented using the Python programming language in an integrated development environment. Based on the performance metrics and visual analysis, it was found that monotonic cubic spline interpolation captured the pattern of the carbonation depth curve as a function of time with greater precision and accuracy, achieving a performance index of 0.998 and RMSE between 0.106 mm and 0.863 mm depending on the concrete sample.*

**Keywords:** Concrete. Carbonation. Time series. Data imputation. Missing data.

<sup>1</sup>Tiago Ferreira Campos Neto

<sup>1</sup>Universidade Federal de Goiás  
Goiânia - GO - Brasil

<sup>2</sup>Oswaldo Cascudo

<sup>2</sup>Universidade Federal de Goiás  
Goiânia - GO - Brasil

Recebido em 24/10/23

Aceito em 21/01/24

## Introdução

A carbonatação é o problema de durabilidade mais comum nas estruturas de concreto armado, pois, todas apresentam maior suscetibilidade à corrosão quando o fenômeno avança sobre o cobrimento do concreto e alcança as armaduras (Cascardo; Carasek, 2022). Assim, a carbonatação e sua previsão são questões relevantes no espectro das investigações de durabilidade. Ademais, com o aumento do tempo de serviço das estruturas, a importância da previsão da vida útil, a reparação, a manutenção e o cumprimento dos requisitos mínimos devem ser constantemente estudados e aprimorados (Medeiros; Andrade; Helene, 2022).

Atualmente, existem inúmeros modelos de previsão de vida útil, podendo ser de caráter determinístico, probabilístico, entre outros. Esses modelos geralmente consideram o tempo como uma variável subsidiária, sempre buscando linearizar a relação das frentes de carbonatação e o tempo, como por exemplo, optando por relacionar coeficientes – ao invés de profundidades – com o tempo. Essa estratégia pode não representar adequadamente as incertezas, ruídos e fatores aleatórios que afetam o sistema. Isso ocorre principalmente devido a parâmetros que influenciam na carbonatação e não são considerados nos modelos (Duan; Cao, 2022). Entre esses parâmetros é possível elencar a composição do material e condições climáticas/ambientais às quais as estruturas estão expostas. Parâmetros como temperatura, umidade relativa do ar e concentração atmosférica de CO<sub>2</sub>, também são dependentes do tempo, apresentando tendências e sazonalidades que podem afetar a dinâmica de avanço da carbonatação do concreto.

Alguns modelos recentes e parcamente explorados, como por exemplo, redes neurais artificiais (RNA) e análises de séries temporais (AST), também podem ser aplicados na previsão das frentes de carbonatação. O uso de RNA na previsão de frentes de carbonatação teve início na década de 90 e vem se mostrando como uma prática eficaz na solução de sistemas complexos de deterioração dos concretos. Entre as arquiteturas mais comumente utilizadas destacam-se *Multi-Layer Perceptron* (MLP) e *Long Short-Term Memory* (LSTM), que são capazes de cruzar os dados de entrada e definir modelos de previsão com elevada acurácia (Buenfeld; Hassanein, 1998; Félix; Carrazedo; Possan, 2021; Kwon *et al.*, 2022).

Toda sequência de observações coletadas de um sistema que evolui com o tempo pode ser considerada uma série temporal (ST). A dependência cronológica entre essas observações é uma das principais características de uma ST, sendo o interesse fundamental da AST. Trata-se de uma ciência que busca desenvolver e aplicar modelos estocásticos e dinâmicos capazes de diagnosticar comportamentos passados e prever comportamentos futuros (Box *et al.*, 2016).

Cientes da importância do tempo sobre o fenômeno, Yuan e Zhao (2000) aplicaram AST para avaliar a evolução dos coeficientes de carbonatação ( $k$ ) de concretos com diferentes relações água/ligante ( $a/lig$ ) submetidos a ensaios acelerados. Os diagramas das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) foram utilizados para determinar os valores das ordens (1,1,0) do modelo *Autoregressive Integrated Moving Average* (ARIMA). Os resultados registraram boa precisão das previsões dos coeficientes de carbonatação.

Em contrapartida, Li e Zhou (2013), com base em AST de profundidades de carbonatação ( $e_c$ ), aplicaram o modelo autoregressivo (AR) isoladamente. As profundidades foram obtidas por meio do modelo determinístico de Li-Ting (2007) com idades até 50, 65 e 80 anos, considerando intervalos regulares de cinco anos. Por meio da previsão até 100 anos, foi constatado que a precisão do modelo AR se eleva à medida em que a coleção de dados utilizada é aumentada, isto é, as previsões com 80 anos de dados observados apresentaram erros inferiores a 1,0 mm. Isso reafirma a importância da completude do banco de dados quando das realizações de previsões futuras.

Yang *et al.* (2019) aplicaram o modelo AR combinado com uma RNA com arquitetura MLP e algoritmo de treinamento *back propagation* (BP). As previsões foram feitas utilizando a RNA e os resultados foram corrigidos pelo modelo AR. Como sinais de entrada da RNA foram utilizadas 300 profundidades de carbonatação, além de variações do consumo de cimento, relação  $a/lig$ , temperatura, umidade relativa do ar e concentração atmosférica de CO<sub>2</sub>. Foram comparados os resultados alcançados com o modelo BP-AR com o modelo BP isolado. O modelo BP-AR apresentou melhor desempenho atingindo coeficiente de determinação (R<sup>2</sup>) de 0,997 e erros percentuais menores que 50%.

Contudo, para que os modelos de AST e RNA apresentem elevada precisão e exatidão, é fundamental que as séries temporais estejam completas, ou seja, não apresentem dados faltantes e/ou intervalos irregulares entre as observações. A ausência de dados pode ser causada por diversos fatores, como por exemplo, falhas de armazenamento ou inexecução de ensaio de campo, reduzindo drasticamente a qualidade desses modelos (Nielsen, 2021). Uma maneira de contornar essa situação é realizar a imputação dos dados ausentes.

A imputação de dados ausentes é uma etapa preliminar da análise de dados, que busca solucionar o problema da inexistência de observações, o que prejudicar a qualidade da análise e previsão, especialmente no âmbito das séries temporais (Hsieh; Hsiao; Yeh, 2011).

Existem diversas abordagens de imputação de dados, sendo importante determinar qual é a melhor com base no comportamento e/ou padrão da ST estudada, pois não há uma única técnica que seja superior às demais (Phan, 2020; Thomas; Rajabi, 2021). As técnicas de imputação podem ser baseadas em interpolação, na qual os valores ausentes são estimados com base nos valores observados mais próximos no tempo; média móvel, uma técnica de suavização que pode ser utilizada para preencher lacunas; algoritmos e redes neurais, como a *Gated Recurrent Unit* (GRU), capazes de capturar relações temporais mais complexas.

Dessa forma, fica evidenciada a importância da imputação de dados ausentes em séries temporais, como por exemplo, na relação entre a profundidade de carbonatação e o tempo. Trabalhos que utilizam modelos de previsão de carbonatação, incluindo RNA, tendem a não realizar a etapa de imputação de dados, o que pode eventualmente prejudicar a qualidade do resultado da previsão e, por este motivo, este trabalho tem o objetivo de estabelecer a melhor técnica de imputação de dados ausentes em séries temporais formadas por profundidades de carbonatação. Para isso, foram utilizadas séries compostas por dados extraídos de amostras de concretos com diferentes composições submetidas a carbonatação natural por vinte anos. As profundidades foram coletadas em momentos distintos, não apresentando intervalos regulares entre as aferições.

## Materiais e método

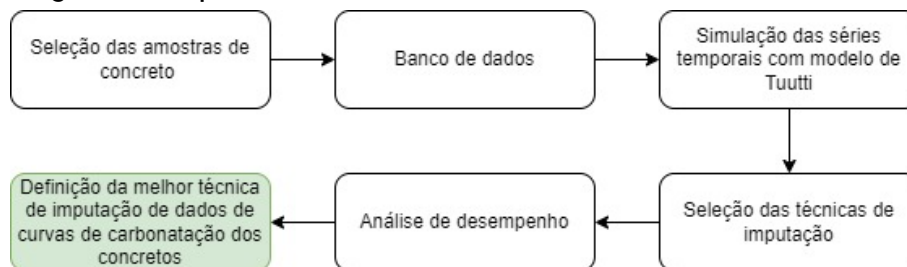
Este estudo seguiu as etapas descritas no fluxograma da Figura 1. É importante destacar que todos os processos de imputação de dados ausentes foram realizados em linguagem de programação *python* no ambiente de desenvolvimento integrado *Spyder*, disponibilizado pela plataforma *Anaconda*.

### Seleção das amostras de concreto

Para efetivação deste estudo foi utilizada uma coleção de dados de 20 anos de carbonatação natural de amostras de concreto produzidas e monitoradas pelo Grupo de Estudos em Durabilidade do Concreto (GEDur), uma parceria entre Furnas Centrais Elétricas, Agência Nacional de Energia Elétrica (ANEEL) e Universidade Federal de Goiás (UFG). Este trabalho integra o grupo de pesquisa e dá sequência aos estudos de durabilidade dos concretos. Os concretos foram produzidos em 2002 por Castro (2003) utilizando cimento Portland CP II-F-32, agregados miúdo natural de leito de rio e gráudo de micaxisto britado número 1. Todos os concretos foram produzidos sob as mesmas condições de preparo tendo algumas variáveis modificadas como segue:

- relação a/lig: 0,40, 0,55 e 0,70;
- condição de cura da superfície do concreto: úmida (28 dias de cura em câmara úmida com temperatura  $23 \pm 2$  °C e umidade do ar superior a 90%) e seca (sem realização de procedimentos de cura); e
- adição mineral: escória de alto forno (E – 65%), sílica ativa (SA – 10%), metacaulim (M – 10%), cinza volante (CV – 25%), cinza de casca de arroz (A – 10%) e referência (R – 0%). Os teores/porcentagens referem-se à substituição parcial em função do consumo de cimento.

Figura 1 - Fluxograma de etapas do estudo



Essas variações resultaram em 36 concretos diferentes divididos em 108 amostras prismáticas de concreto armado com dimensões de 20x20x50cm (Figura 2). As amostras prismáticas são armadas com quatro vergalhões longitudinais com diâmetro nominal de 10 mm e estribos de 5mm, garantindo cobertura de concreto de 25mm, conforme classe de agressividade referente ao ambiente de armazenamento estabelecida na NBR 6118 (ABNT, 2014). Todas as informações sobre caracterização dos materiais e detalhes do procedimento de produção das amostras de concreto estão disponíveis no trabalho de Castro (2003).

Para este estudo foram selecionadas aleatoriamente sete das 36 amostras, garantindo que todos os níveis adotados para cada variável fossem considerados conforme apresentado na Tabela 1. A seleção se fundou no princípio de que uma mesma técnica de imputação possa se ajustar adequadamente a concretos com diferentes composições, haja vista que se espera que, mesmo com diferentes profundidades, o padrão da curva de carbonatação dos concretos seja semelhante.

O ambiente de armazenamento está localizado na cidade de Aparecida de Goiânia/GO, nas instalações de Furnas Centrais Elétricas. As amostras prismáticas são frequentemente movidas e redistribuídas nas pilhas para garantir equidade na condição de exposição. Entre as condições de exposição monitoradas estão a temperatura, umidade relativa do ar e concentração atmosférica de CO<sub>2</sub> e, conforme valores registrados pelo *datalogger* IP-2000C, devidamente calibrado, todas as variáveis climáticas e ambientais estão equivalentes às registradas na cidade de Goiânia/GO. Os valores registrados são característicos das ilhas de calor urbanas, ou seja, as amostras de concreto estão expostas em um ambiente equivalente a uma zona urbana, com temperaturas anuais entre 15 °C e 34 °C, umidade entre 35% e 74% e concentrações de CO<sub>2</sub> entre 550ppm e 750ppm. É importante ressaltar que as amostras prismáticas estão em um ambiente coberto e fechado, não expostas à chuva e radiação direta.

## Banco de dados

Ao longo dos 20 anos de exposição, as amostras tiveram suas frentes de carbonatação aferidas em momentos com intervalos irregulares, conforme apresentado na Tabela 2. As aferições foram realizadas por integrantes do grupo GEDur e entre os estudos pode-se citar Ferreira (2013) e Pires (2016). A coleta de dados foi padronizada desde o estudo de Castro (2003) e os procedimentos foram replicados ao longo dos 20 anos, sendo coletadas mais de 2300 profundidades de carbonatação.

Figura 2 - Armazenamento das amostras prismáticas para ensaios de profundidade de carbonatação natural



Tabela 1 - Amostras de concreto consideradas no estudo

Identificação da amostra	Relação a/lig (identificação na amostra)	Condição de cura (identificação da amostra)	Adição mineral
R4H	0,40	Úmida (H)	R (referência – sem adição)
M5H	0,55		M (metacaulinita)
CV7H	0,70		CV (cinza volante)
A4H	0,40		A (cinza de casca de arroz)
R40	0,40	Seca (0)	R (referência – sem adição)
E70	0,70		E (escória de alto forno)
SA50	0,55		AS (sílica ativa)

Tabela 2 - Idades e datas de realização das medições das profundidades de carbonatação natural das amostras de concreto e quantidade de dados coletados por amostra

Idade/tempo de exposição (anos)	Mês/Ano	Quantidade de dados coletados por amostra
3	Abr/2005	3 a 9
7	Abr/2009	10
9	Abr/2011	12
10	Abr/2012	10 a 12
14	Abr/2016	4 a 6
20	Abr/2022	6

A coleta de dados foi realizada por meio do corte de fatias de 5,0cm com disco diamantado refrigerado com água retiradas das amostras prismáticas de concreto armado. A solução indicadora de pH utilizada foi a fenolftaleína, com faixa de viragem entre 8,3 e 10,0, aplicada sobre a superfície do concreto com pincel para espalhamento. A leitura foi realizada em três pontos distintos nas faces laterais das fatias, respeitando-se o cobrimento de 25,0mm das faces de topo e base.

Considerando que as séries temporais completas (0 a 20 anos) devem ser compostas por 21 observações (incluindo o ponto zero), vê-se que existem apenas seis observações aferidas (3, 7, 9, 10, 14 e 20 anos), o que totaliza 28,6% dos dados. Portanto, a imputação tem a função de preencher os vazios buscando estabelecer intervalos regulares entre as observações. Assim, com o banco de dados com intervalos regulares, é possível garantir maior qualidade dos resultados quando aplicados os modelos de previsão como AST e RNA.

Para este estudo optou-se por adotar intervalos regulares com escala anual. Assim, as medições não realizadas serão preenchidas com diferentes técnicas de imputação para as idades faltantes. Além disso, em cada idade foram realizadas diferentes quantidades de medições e, para estabelecer um valor médio da profundidade de carbonatação, foi executada uma criteriosa análise de dados espúrios (*outliers*). O refinamento do banco de dados iniciou-se com a verificação dos valores suspeitos por meio dos gráficos de box plot e testes de normalidade de Shapiro-Wilk e D'Agostino-Pearson. Posteriormente, os valores foram submetidos aos testes de Dixon e Grubbs unilateral e bilateral (ASTM, 2021) e, finalmente, foi realizada a análise com o algoritmo de k-vizinhos mais próximos (kNN), sendo possível determinar quais valores de fato representavam dados espúrios. Foram identificados 40 *outliers* na coleção de mais de 2300 profundidades de carbonatação, sendo a maior parte encontrada nas amostras de referência e com adição de cinza de casca de arroz.

## Simulação de séries temporais com modelo de Tuutti

Para avaliar a qualidade das técnicas de imputação de dados é fundamental que exista uma série temporal completa como referência. Neste caso, foi adotado o modelo de Tuutti (1982), pois este se baseia na determinação de um coeficiente ( $k$ ) de carbonatação que pode ser utilizado para determinar a profundidade em qualquer instante de tempo. Isso permite que as curvas de carbonatação sejam estimadas com precisão adequada para serem utilizadas como referência na análise de desempenho das técnicas de imputação. Além do mais, trata-se de um modelo utilizado como ponto de partida para determinações normativas, sendo amplamente validado em diversos estudos, especialmente naqueles em que se avalia a carbonatação após longos períodos de exposição (CEB, 2006; Ferreira, 2013; Pires, 2016; Ganthous *et al.*, 2017; Carevic; Ignjatovic; Dragas, 2019).

Assim, utilizando os valores de  $k$  para cada idade, foi determinado um valor médio global para toda a amostra, haja vista que o coeficiente tende a estabilizar ao longo dos anos (Casculo; Carasek, 2022). Utilizando o valor global de  $k$  foram determinadas as profundidades de carbonatação ( $e_c$ ) para cada ano ( $t$ ) ao longo dos 20 anos por meio da Equação 1.

$$e_c = k \cdot \sqrt{t} \quad \text{Eq. 1}$$

Preliminarmente, antes da simulação das séries temporais, foram realizadas análises de estacionariedade das séries temporais compostas pelos coeficientes de carbonatação. Foi realizado teste de Kwiatkowski-Phillips-Schmidt-Shin (KPSS) e essa análise permitiu influir se os valores globais dos coeficientes de carbonatação poderiam ser utilizados para determinar as profundidades ao longo dos anos. O teste KPSS se baseia no princípio de que a série temporal é estacionária em torno de uma tendência determinística, sendo calculada como a soma da tendência, passeio aleatório e erro aleatório estacionário (todos com médias e variâncias

constantes). A hipótese nula adota a série como estacionária, enquanto a hipótese alternativa considera a existência de raiz unitária (Kwiatkowski *et al.*, 1992).

Como resultados dos testes KPSS dos concretos, com base nas séries temporais dos coeficientes de carbonatação, observou-se que todas as amostras apresentam comportamento estacionário, ou seja, seus valores médios de  $k$  e as respectivas variâncias mantêm-se constantes ao longo dos anos. Os resultados dos testes de estacionariedade estão descritos na seção de resultados.

A Figura 3 ilustra o processo de simulação das séries temporais. A ST com intervalos anuais estimada pelo modelo de Tuutti (linha azul contínua) passou por uma redução de dados simulando as observações do domínio real (pontos em laranja). Posteriormente, a ST com dados faltantes foi preenchida com diferentes técnicas de imputação (linha cinza pontilhada).

## Seleção das técnicas de imputação

O processo de imputação de dados deve ser realizado utilizando técnicas específicas e que não afetem significativamente o padrão da série temporal. O uso de modelos preestabelecidos de carbonatação do concreto, como por exemplo, Tuutti (1982), pode enviesar os resultados, pois o coeficiente de carbonatação é tomado como constante ao longo do tempo de exposição. Assim, de forma a evitar quaisquer efeitos de modelos preestabelecidos nas curvas de carbonatação natural dos concretos, foram aplicadas técnicas específicas para imputação de dados ausentes.

De acordo com Entezami, Sarmadi e Behkamal (2023), a qualidade da técnica de imputação dependerá do padrão da série temporal, isto é, da natureza dos dados, da extensão das lacunas e da complexidade temporal. Dessa maneira, uma mesma técnica pode ser adequada para preencher dados de séries temporais de umidade relativa do ar, por exemplo, mas não ser adequada para séries de profundidades de carbonatação. Por esse motivo, foram selecionadas técnicas com diferentes fundamentos matemáticos, desde média móvel e interpolação à algoritmos mais robustos:

- (a) *Forward fill* (FF): trata-se de uma técnica simples cujos valores ausentes são imputados por meio da transferência do último valor conhecido para o valor ausente anterior (Nielsen, 2021);
- (b) Média móvel simples (MMS): os valores ausentes são preenchidos com as médias das observações disponíveis, considerando uma janela de dados aceitáveis (Rahman; Majunder, 2013). Neste estudo foi considerada uma janela de tamanho de doze devido aos intervalos irregulares entre as observações;
- (c) Interpolação linear (LINEAR): estabelece uma linha reta entre dois pontos, cuja convergência ocorre mais rapidamente do que nas demais técnicas de interpolação (Lepot; Aubin; Clemens, 2017);
- (d) Interpolação *spline* cúbica (S.CUB): se funda na implementação de polinômios cúbicos para interligar pontos adjacentes, realizando ajuste global dos dados (Yamamoto, 2020);
- (e) Interpolação *spline* quadrática (S.QUAD): similar à S.CUB, substituindo os polinômios cúbicos por quadráticos (Yamamoto, 2020);
- (f) Interpolação *spline* monotônica cúbica (M.CUB): similar às demais interpolações, contudo as curvas são ajustadas para garantir padrão monotônico da função de interpolação (Santos, 2021);
- (g) Interpolador do vizinho mais próximo (VIZINHO): replica o valor da observação mais próxima do dado ausente, priorizando maiores valores (Alves; Biudes; Vecchia, 2012);
- (h) Interpolação *spline* Akima (AKIMA): aplica polinômios cúbicos, porém com ajustes locais (Lim *et al.*, 2021);
- (i) Interpolação Piecewise: ajusta polinômios entre as observações, sendo flexível quanto aos graus dos polinômios entre os pares de observações (Pereira, 2022); e
- (j) Filtro de Kalman: prevê o estado de um sistema dinâmico por meio de observações incompletas, atuando como um sistema linear no espaço de estados. Neste estudo foi implementado um modelo simplificado com uma dimensão de observação e de estado (Betti, 2012).

## Análise de desempenho

Segundo Gasparetto *et al.* (2021), no espectro das séries temporais, utilizar apenas a raiz do erro quadrático médio (RMSE) para avaliar a qualidade dos dados imputados pode limitar a tomada de decisões. Por esse

motivo, paralelamente foram aplicadas outras métricas de desempenho de forma a garantir elevada qualidade dos resultados.

A análise de desempenho de Camargo e Sentelhas (1997) permite correlacionar o padrão de distribuição dos dados – com base no coeficiente de correlação de Pearson – e os respectivos diferenças entre os valores absolutos de duas séries de dados – com base no índice de concordância de Willmott *et al.* (1985) –, assim é possível determinar com maior rigor estatístico a similaridade entre as curvas estimadas pelo modelo de Tuutti e as curvas com dados imputados. Segue abaixo o procedimento das análises de desempenho:

- (a) raiz do erro quadrático médio (RMSE): calculado por meio da raiz da média dos quadrados das diferenças entre as observações ( $o_j$ ) e suas respectivas previsões ( $p_j$ ) conforme Equação 2. Menores valores de RMSE indicam menores erros em milímetros e, conseqüentemente, melhor desempenho do modelo:

$$RMSE = \sqrt{\frac{\sum_{j=1}^n (p_j - o_j)^2}{n}} \quad \text{Eq. 2}$$

- (b) índice de concordância de Willmott ( $d$ ): proposto por Willmott *et al.* (1985), avalia a exatidão do modelo tomando as diferenças ( $d_j$ ) entre as observações ( $o_j$ ) e as previsões ( $p_j$ ), além da diferença entre a média ( $\delta$ ) das observações e os valores previstos e observados (Equação 3). Varia entre 0 e 1, sendo que 1 indica a concordância perfeita entre os dados estimados e as observações:

$$d = \frac{\sum_{j=1}^n |d_j|^2}{\sum_{j=1}^n (|p_j - \delta| + |o_j - \delta|)^2} \quad \text{Eq. 3}$$

- (c) coeficiente de correlação de Pearson ( $R$ ): mensura a correlação entre duas coleções de dados, avaliando a relação linear entre elas. Varia entre -1 e 1, e quanto mais próximo de zero mais fraca é correlação entre as observações. Valores positivos indicam correlações crescentes e negativos são decrescentes;
- (d) índice de desempenho de Camargo e Sentelhas ( $c$ ): proposto por Camargo e Sentelhas (1997), trata-se de uma medida de desempenho assentada na relação entre o coeficiente de correlação de Pearson e o índice de Willmott. Seu resultado inclui a associação dos resultados de dispersão com  $R$  e exatidão das previsões com  $d$  (Equação 4). O índice varia entre 0 e 1 e a Tabela 3 apresenta os limites de interpretação dos resultados.

$$c = R \cdot d \quad \text{Eq. 4}$$

## Resultados e discussões

Primeiramente, com base nos resultados dos testes de KPSS, todas as séries temporais dos coeficientes de carbonatação apresentaram comportamento estacionário, ou seja, seus atributos estatísticos, como média e variância, se mantêm constantes ao longo dos anos. Na Tabela 4 estão apresentados os resultados, onde nota-se que todos os  $p$ -valores foram superiores aos 5% de nível de significância (0,05), constatando que a hipótese nula de que as séries temporais são estacionárias não pode ser rejeitada. É importante apontar que esse resultado só foi alcançado em decorrência do longo período de exposição (20 anos) considerados na análise, pois como já estabelecido na literatura, o coeficiente tende a apresentar grandes variações nas primeiras idades com posterior tendência à estabilização (Hills *et al.*, 2015).

A Tabela 5 apresenta os valores dos coeficientes de carbonatação natural globais das sete amostras após o refinamento do banco de dados e constatação da estacionariedade das séries temporais. É possível observar que as amostras de referência, independente da condição de cura, apresentaram coeficientes inferiores às demais. As misturas com adição de escória de alto forno e cinza volante tiveram os maiores valores de  $k$ , enquanto os concretos com adições pozolânicas apresentaram coeficientes intermediários.

No tangente ao efeito da relação  $a/lig$ , observa-se que quanto maior o teor de água de amassamento, maior será o coeficiente de carbonatação. Como constatado por Castro (2003), o aumento da relação  $a/lig$  resulta no aumento da porosidade do concreto, facilitando a difusão de  $CO_2$  para o interior do material, acelerando o processo de carbonatação. O tipo de cura, por sua vez, também tem efeito sobre a carbonatação, pois concretos com cura úmida apresentaram menores coeficientes. Isso se deve ao fato de que concretos não submetidos à cura tendem a sofrer retração, levando à formação de fissuras que podem comprometer a durabilidade do material.

É importante apontar que a amostra A4H apresentou o menor valor de  $k$ , mesmo sendo composta com 10% de cinza de casca de arroz, mostrando que essa adição pode não afetar significativamente o fenômeno da

carbonatação do concreto. O melhor desempenho do concreto com pozolana e baixa relação a/lig pode estar associado à sobreposição do efeito físico de refinamento dos poros sobre o efeito químico de redução da alcalinidade. Portanto, as reações pozolânicas podem ter contribuído efetivamente na redução da difusividade do CO<sub>2</sub> neste concreto.

Figura 3 - Curva de carbonatação estimada pelo modelo de Tuutti (em azul), observações realizadas pelo grupo GEDur (em laranja) e exemplo de simulação de curva com imputação de dados ausentes (em cinza)

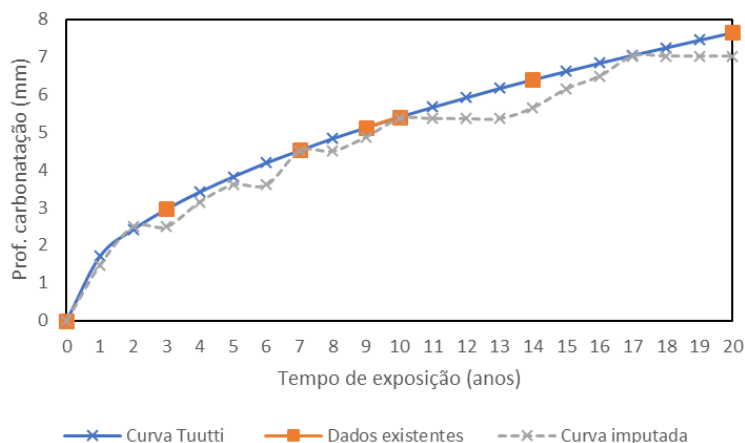


Tabela 3 - Índices de desempenho (c) e respectivos níveis de desempenhos

Índice <i>c</i>	Desempenho
> 0,85	Ótimo
0,76 a 0,85	Muito bom
0,66 a 0,75	Bom
0,61 a 0,65	Mediano
0,51 a 0,60	Sofrível
0,41 a 0,50	Mau
≤ 0,40	Péssimo

Fonte: Camargo e Sentelhas (1997).

Tabela 4 - *P*-valores resultantes do teste de estacionariedade das séries temporais de coeficiente de carbonatação natural após 20 anos de exposição

Condição de cura	Amostra	<i>p</i> -valor	Condição de cura	Amostra	<i>p</i> -valor
Úmida	R4H	0,082	Seca	R40	0,067
	M5H	0,100		E70	0,100
	CV7H	0,096		SA50	0,083
	A4H	0,100			

Tabela 5 - Coeficientes globais e desvios-padrões das amostras de concreto após 20 anos de exposição à carbonatação natural

Identificação da amostra	Coefficiente de carbonatação (mm/ano <sup>0,5</sup> )	Desvio-padrão (mm/ano <sup>0,5</sup> )
R4H	1,71	0,81
M5H	3,27	0,87
CV7H	8,13	1,47
A4H	1,51	0,72
R40	3,05	0,78
E70	12,11	5,07
SA50	6,75	0,74



No tocante às técnicas de imputação de dados ausentes, a Tabela 6 e Figura 4 lucidam os resultados das dez técnicas aplicadas às amostras de concreto apresentando os respectivos resultados das métricas de desempenho. Por meio de análise visual é perceptível que algumas técnicas, como por exemplo, FF (linha tracejada azul), MMS (linha tracejada rosa) e VIZINHO (linha tracejada laranja), não capturam adequadamente a tendência exponencial das curvas de carbonatação, apresentando padrões de evolução em degraus. Mesmo que seus índices de desempenho sejam superiores 0,92 – o que seria ótimo de acordo com Camargo e Sentelhas (1997) –, os valores de RMSE chegam a alcançar 5,941mm, 5,548mm e 2,894mm para FF, VIZINHO e MMS, respectivamente. Por exemplo, para a amostra E70, a técnica FF apresenta RMSE cerca de 600% superior à M.CUB, mostrando que FF apresenta precisão consideravelmente inferior.

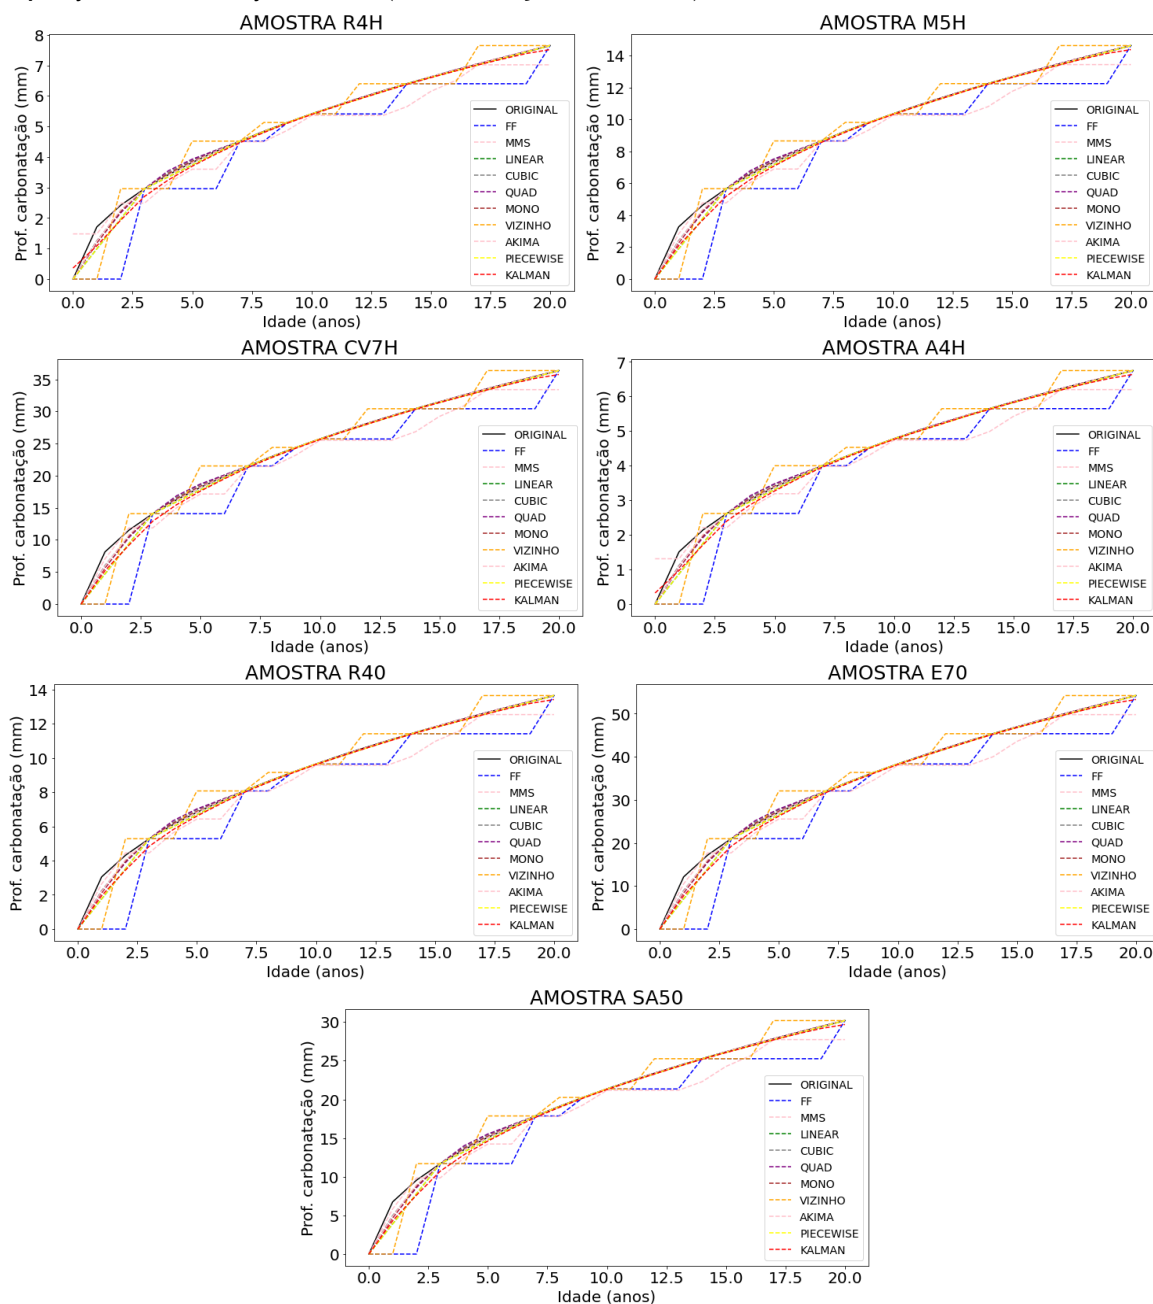
**Tabela 6 - Resultados das análises de desempenho das diferentes técnicas de imputação de dados ausentes nas ST's de profundidades de carbonatação anuais estimadas pelo modelo de Tuutti após 20 anos de exposição (Continua...)**

Identificação da amostra	Imputação	RMSE (mm)	<i>d</i>	R	<i>c</i>
R4H	FF	0,837	0,961	0,963	0,925
	MMS	0,522	0,981	0,980	0,961
	LINEAR	0,187	0,998	0,997	0,995
	S.CUB	0,110	0,999	0,999	0,998
	S.QUAD	0,132	0,999	0,998	0,997
	M.CUB	0,123	0,999	0,999	0,998
	VIZINHO	0,501	0,986	0,976	0,962
	AKIMA	0,108	0,999	0,999	0,998
	PIECEWISE	0,188	0,998	0,997	0,995
	KALMAN	0,207	0,997	0,996	0,994
M5H	FF	1,602	0,961	0,963	0,925
	MMS	0,781	0,989	0,993	0,983
	LINEAR	0,358	0,998	0,997	0,995
	S.CUB	0,209	0,999	0,999	0,998
	S.QUAD	0,251	0,999	0,998	0,997
	M.CUB	0,233	0,999	0,999	0,998
VIZINHO	0,957	0,986	0,976	0,962	
Amostra	Imputação	RMSE (mm)	<i>d</i>	R	<i>c</i>
M5H	AKIMA	0,208	0,999	0,999	0,999
	PIECEWISE	0,359	0,998	0,997	0,995
	KALMAN	0,365	0,998	0,998	0,996
CV7H	FF	3,986	0,961	0,963	0,925
	MMS	1,941	0,989	0,994	0,983
	LINEAR	0,891	0,998	0,997	0,995
	S.CUB	0,517	0,999	0,999	0,998
	S.QUAD	0,626	0,999	0,998	0,997
	M.CUB	0,580	0,999	0,999	0,998
	VIZINHO	2,380	0,986	0,976	0,962
	AKIMA	0,517	0,999	0,999	0,998
	PIECEWISE	0,891	0,998	0,997	0,995
	KALMAN	0,906	0,998	0,998	0,996
A4H	FF	0,740	0,961	0,963	0,925
	MMS	0,458	0,981	0,980	0,961
	LINEAR	0,165	0,998	0,997	0,995
	S.CUB	0,097	0,999	0,999	0,998
	S.QUAD	0,117	0,999	0,998	0,997
	M.CUB	0,106	0,999	0,999	0,998
	VIZINHO	0,441	0,986	0,976	0,96
	AKIMA	0,096	0,999	0,999	0,998
	PIECEWISE	0,165	0,998	0,997	0,995
	KALMAN	0,181	0,997	0,997	0,994

Tabela 6 - Resultados das análises de desempenho das diferentes técnicas de imputação de dados ausentes nas ST's de profundidades de carbonatação anuais estimadas pelo modelo de Tuutti após 20 anos de exposição (continuação)

Identificação da amostra	Imputação	RMSE (mm)	<i>d</i>	<b>R</b>	<i>c</i>
R40	FF	1,496	0,961	0,963	0,925
	MMS	0,728	0,989	0,993	0,983
	LINEAR	0,334	0,998	0,997	0,995
	S.CUB	0,195	0,999	0,999	0,998
	S.QUAD	0,234	0,999	0,998	0,997
	M.CUB	0,217	0,999	0,999	0,998
	VIZINHO	0,893	0,986	0,976	0,962
	AKIMA	0,194	0,999	0,999	0,998
	PIECEWISE	0,334	0,998	0,997	0,995
	KALMAN	0,339	0,998	0,998	0,996
E70	FF	5,941	0,961	0,963	0,925
	MMS	2,894	0,989	0,993	0,983
	LINEAR	1,328	0,998	0,997	0,995
	S.CUB	0,773	0,999	0,999	0,998
	S.QUAD	0,933	0,999	0,998	0,997
	M.CUB	0,863	0,999	0,999	0,998
	VIZINHO	3,548	0,986	0,976	0,962
	AKIMA	0,770	0,999	0,999	0,998
	PIECEWISE	1,328	0,998	0,997	0,995
	KALMAN	1,351	0,998	0,998	0,996
SA50	FF	3,308	0,961	0,963	0,925
	MMS	1,610	0,989	0,993	0,983
	LINEAR	0,740	0,998	0,997	0,995
	S.CUB	0,430	0,999	0,999	0,998
	S.QUAD	0,519	0,999	0,998	0,997
	M.CUB	0,481	0,999	0,999	0,998
	VIZINHO	1,976	0,986	0,976	0,962
	AKIMA	0,427	0,999	0,999	0,998
	PIECEWISE	0,740	0,998	0,997	0,995
	KALMAN	0,753	0,998	0,998	0,996

Figura 4 - Séries temporais de carbonatação estimadas pelo modelo de Tuutti (linha contínua em preto) e ST's preenchidas com diferentes técnicas de imputação das amostras de concreto com 20 anos de exposição à carbonatação natural (linhas tracejadas coloridas)



O RMSE mensura a precisão do modelo, enquanto o índice de desempenho avalia a combinação da dispersão e exatidão, logo, tomando essas métricas como balizadores, os três melhores resultados foram alcançados pelas técnicas de interpolação *spline* cúbica (S.CUB), *spline* monotônica cúbica (M.CUB) e AKIMA. Essas técnicas – destacadas em verde na Tabela 6 – apresentaram os menores valores de RMSE e maiores R,  $c$  e  $d$ . Em todas as amostras, os valores de R e  $d$  foram iguais a 0,999, indicando bons ajustes das técnicas de imputação às curvas de carbonatação estimadas pelo modelo de Tuutti. Portanto, a decisão sobre a melhor técnica foi tomada com base nos parâmetros de RMSE e  $c$ .

Observou-se que as diferenças estatísticas entre as técnicas são sutis, mostrando que todas seriam eficazes no preenchimento de dados ausentes de curvas de profundidade de carbonatação em função do tempo. Considerando S.CUB, M.CUB e AKIMA, os valores de RMSE variaram de 0,096mm a 0,863mm, apontando que os erros não chegaram nem mesmo a ultrapassar 1,0mm, estando dentro dos limites aceitáveis para a régua

de erros de previsão de frentes de carbonatação estabelecidas na literatura (Possan *et al.*, 2021). Além disso, os índices de desempenho – variando entre 0,998 e 0,999, isto é, ótimo desempenho (Tabela 3) – reafirmam a excelência das técnicas de imputação, o que garante qualidade do banco de dados de carbonatação, mesmo na presença de observações imputadas.

Todavia, conforme ilustrado na Figura 5, ao analisar isoladamente as curvas com os valores ausentes imputados, verificou-se que tanto a S.CUB (Figura 5a) quanto a AKIMA (Figura 5c) apresentaram flutuações das profundidades de carbonatação entre observações de algumas amostras, por exemplo, amostra R4H. Isso pode ser visto com mais clareza entre as últimas duas observações (14 e 20 anos) das curvas S.CUB e AKIMA, cujo comportamento não é característico do fenômeno.

Portanto, pode-se estabelecer que – considerando as métricas de desempenho associadas à análise visual – a técnica M.CUB é a mais indicada para preenchimento de dados ausentes de curvas de profundidade de carbonatação em função do tempo. Essa técnica foi capaz de capturar o padrão exponencial crescente das curvas de carbonatação, registrando ótimos resultados com índice de desempenho igual a 0,998 para todas as amostras e RMSE entre 0,106mm e 0,863mm.

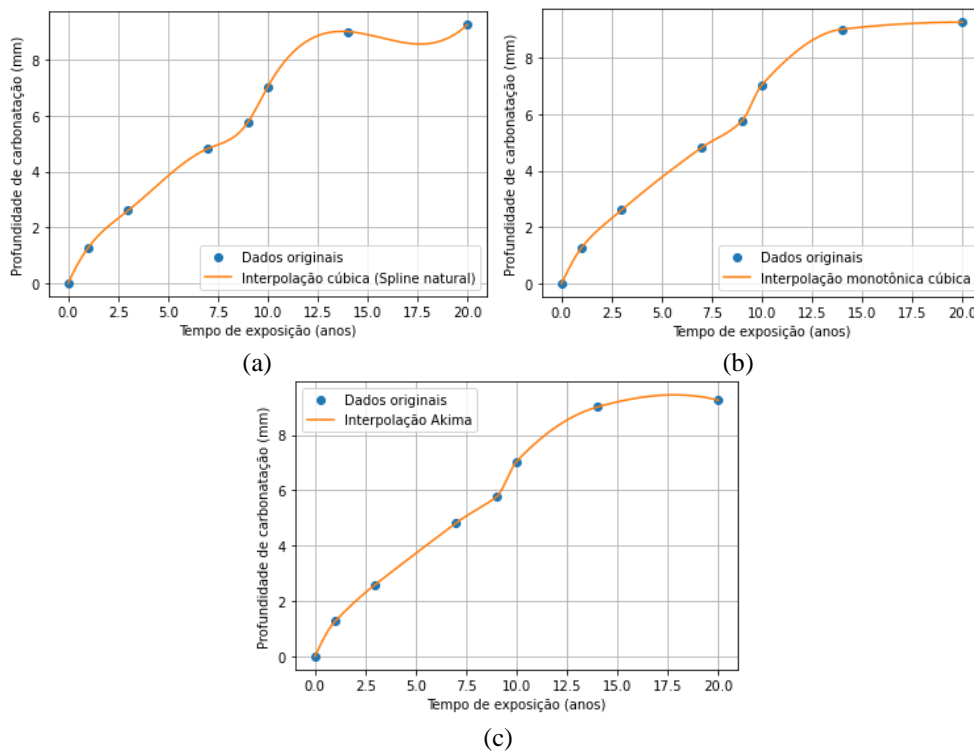
Tomando apenas os resultados de M.CUB e comparando-os entre as amostras é possível observar que os maiores valores de RMSE estão associados aos concretos com adições de escória de alto forno. Segundo Martins (2001), isso pode ser resultado do aumento da permeabilidade ao ar em concretos com escória de alto forno que contribui para o avanço irregular das frentes de carbonatação.

Assim como a adição mineral, tanto a relação a/lig como o tipo de cura influenciaram nos erros de imputação de dados ausentes, concretos com maiores relações a/lig e submetidos à cura seca tendem a apresentar maior RMSE. Isso pode ser resultado da maior flutuação de valores das profundidades de carbonatação ao longo dos anos, impactando no desempenho das técnicas de imputação.

## Conclusões

Cientes da relevância da completude dos dados nas análises e previsões de séries temporais e considerando a natureza dos dados e complexidade do padrão temporal das profundidades de carbonatação, verificou-se que, entre todas as técnicas avaliadas, a interpolação *spline* monotônica cúbica apresentou os melhores resultados com índices de desempenho da ordem de 0,998 e erros inferiores a 0,863mm.

Figura 5 - Resultados isolados de imputação de dados na amostra R4H utilizando S.CUB (a), M.CUB (b) e AKIMA (c)



Notou-se que parâmetros atrelados ao concreto, como relação a/lig, tipo de cura e adição mineral, têm influência sobre os resultados das métricas de desempenho da imputação de dados ausentes. Isso ocorre, pois eles afetam a qualidade do material e, conseqüentemente, a distribuição temporal dos dados, causando flutuações nas profundidades de carbonatação ao longo do tempo.

Viu-se também que as séries temporais formadas por coeficientes de carbonatação apresentam comportamento estacionário, ou seja, os valores médios e de variância dos coeficientes tendem a se manter constantes com o tempo. No entanto, essa conclusão só pôde ser constatada devido ao longo período de exposição considerado nas análises. Os 20 anos de exposição à carbonatação natural permitiu que os coeficientes alcançassem o patamar de estabilização previsto por modelos largamente validados na literatura, como por exemplo, o modelo de Tuutti.

Em suma, a garantia da qualidade das análises e previsões de frentes de carbonatação, em especial quando do uso de recursos contemporâneos como redes neurais artificiais, dependerá essencialmente da qualidade do banco de dados utilizado e da técnica de imputação aplicada. É fundamental que pesquisadores, ao trabalharem com modelos de previsão de carbonatação, estejam atentos à completude do banco de dados. É preciso garantir que a dependência e regularidade temporal entre as observações sejam atendidas por meio da aplicação da imputação de dados ausentes.

## Referências

- ALVES, E. D. L.; BIUDES, M. S.; VECCHIA, F. A. S. Interpolação espacial na climatologia: análise dos critérios que precedem sua aplicação. **Revista Geonorte**, v. 1, n. 5, 2012.
- AMERICAN SOCIETY FOR TESTING MATERIALS. **E 178-21**: standard practice for dealing with outlying observations. West Conshohocken, 2021.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6118**: projeto de estruturas de concreto: procedimento. Rio de Janeiro, 2014.
- BETTI, V. A. **Estudos teóricos na estimação em processos K-factor gama via modelo de espaço de estudos utilizando filtro de Kalman**. Porto Alegre, 2012. Dissertação (Mestrado em Matemática) – Programa de Pós-Graduação em Matemática, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012.
- BOX, G. E. P. *et al.* **Time series analysis**: forecasting and control. 5. ed. New York: John Wiley & Sons, 2016.
- BUENFELD, N.; HASSANEIN, N. Predicting the life of concrete structures using neural networks. **Proceedings of the Institution of Civil Engineers: Structures and Buildings**, v. 128, n. 1, 1998.
- CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v. 5, n. 1, 1997.
- CAREVIC, V.; IGNJATOVIC, I.; DRAGAS, J. Model for practical carbonation depth prediction for high volume fly ash concrete and recycled aggregate concrete. **Construction and Building Materials**, v. 213, 2019.
- CASCUDO, O.; CARASEK, H. Carbonatação no concreto. In: ISAIA, G. C. (ed.). **Concreto**: ciência e tecnologia. 3. ed. São Paulo: IBRACON, 2022.
- CASTRO, A. **Influência das adições minerais na durabilidade do concreto sujeito à carbonatação**. Goiânia, 2003. Dissertação (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Geotecnia, Estruturas e Construção Civil, Universidade Federal de Goiás, Goiânia, 2003.
- COMITÉ EURO-INTERNATIONAL DU BETÓN. **Model code for service life design**. Lausanne, 2006. Bulletin 34.
- DUAN, K.; CAO, S. Data-driven parameter selection and modeling for concrete carbonation. **Materials**, v. 15, n. 9, 2022.
- ENTEZAMI, A.; SARMADI, H.; BEHKAMAL, B. Long-term health monitoring of concrete and steel bridges under large and missing data by unsupervised meta learning. **Engineering Structures**, v. 279, 2023.
- FÉLIX, E. F.; CARRAZEDO, R.; POSSAN, E. Carbonation model for fly ash concrete based on artificial neural network: Development and parametric analysis. **Construction and Building Materials**, v. 266, 2021.

- FERREIRA, M. B. **Estudo da carbonatação natural de concretos com diferentes adições minerais após 10 anos de exposição**. Goiânia, 2013. Dissertação (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Geotecnia, Estruturas e Construção Civil, Universidade Federal de Goiás, Goiânia, 2013.
- GANTHOUS, R. M. *et al.* Effect of crack openings on carbonation-induced corrosion. **Cement and Concrete Research**, v. 95, 2017.
- GASPARETTO, S. C. *et al.* Comparação entre métodos de imputação de dados em diferentes intensidades amostrais na série de precipitação pluvial da ESALQ. **Revista Brasileira de Climatologia**, v. 29, 2021.
- HILLS, T. P. *et al.* Statistical analysis of the carbonation rate of concrete. **Cement and Concrete Research**, v. 27, 2015.
- HSIEH, T.; HSIAO, H.; YEH, W. Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm. **Applied Soft Computing**, v. 11, n. 2, 2011.
- KWIATKOWSKI, Y. *et al.* Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, 1992.
- KWON, T. H. *et al.* Long Short-term memory-based methodology for predicting carbonation models of reinforced concrete slab bridges: case study in South Korea. **Applied Sciences**, v. 12, 2022.
- LEPOT, M.; AUBIN, J. B.; CLEMENS, H. L. R. Interpolation in time series: an introductory overview of existing methods, their performance criteria and uncertainty assessment. **Water**, v. 9, 2017.
- LI, G.; ZHOU, X. The research of predicting the carbonation depth of concrete with time-series analysis. **Applied Mechanics and Materials**, v. 351-352, 2013.
- LIM, S. *et al.* A deep learning-based time series model with missing value handling techniques to predict various types of liquid cargo traffic. **Expert Systems with Applications**, v. 184, 2021.
- LI-TING, C. **Research on concrete carbonation model and its parameters**. Xian, 2007. Thesis (Master's Degree in Civil Engineering) – Xian University of Architecture and Technology, Xian, 2007.
- MARTINS, A. R. **Efeito da cura térmica e de cimentos com escória granulada de alto forno na durabilidade do concreto de cobrimento**. Campinas, 2001. Dissertação (Mestrado em Engenharia Civil) – Faculdade de Engenharia Civil, Universidade Estadual de Campinas, Campinas, 2001.
- MEDEIROS, M. H. F.; ANDRADE, J. J. O.; HELENE, P. Durabilidade e vida útil das estruturas de concreto. In: ISAIA, G. C. (ed.). **Concreto: ciência e tecnologia**. 3. ed. São Paulo: IBRACON, 2022.
- NIELSEN, A. **Análise prática de séries temporais: predição com estatística e aprendizado de máquina**. Rio de Janeiro: Alta Books, 2021.
- PEREIRA, B. M. F. **Estudo à seção de transesterificação na produção de biodiesel**. Lisboa, 2022. Dissertação (Mestrado em Engenharia Química e Biológica) – Departamento de Engenharia Química, Instituto Superior de Engenharia de Lisboa, Lisboa, 2022.
- PHAN, T.-T.-H. Machine learning for univariate time series imputation. In: INTERNATIONAL CONFERENCE ON MULTIMEDIA ANALYSIS AND PATTERN RECOGNITION, Ha Noi, 2020. **Proceedings [...]** Ha Noi, 2020.
- PIRES, P. F. **Estudo da carbonatação avançada em concretos contendo adições minerais**. Goiânia, 2016. Dissertação (Mestrado em Engenharia Civil) – Programa de Pós-Graduação em Geotecnia, Estruturas e Construção Civil, Universidade Federal de Goiás, Goiânia, 2016.
- POSSAN, E. *et al.* Model to estimate concrete carbonation depth and service life prediction. In: FREITAS, V. P.; COSTA, A.; DELGADO, J. M. P. Q. (ed.). **Hygrothermal behaviour and building pathologies: building pathology and rehabilitation**. Los Angeles: Springer, 2021. v. 14.
- RAHMAN, A.; MAJUMDER, A. K. Effects of missing value estimation methods in correlation matrix-a case study of concrete compressive strength data. **International Journal of Advanced Science and Technology**, v. 52, 2013.
- SANTOS, D. C. **Amostrador de Gibbs aproximado usando computação bayesiana aproximada e regressão quantílica via redes neurais artificiais**. Brasília, 2021. Dissertação (Mestrado em Estatística) – Departamento de Estatística, Universidade de Brasília, Brasília, 2021.

THOMAS, T.; RAJABI, E. A systematic review of machine learning-based missing value imputation techniques. **Data Technologies and Applications**, v. 55, n. 4, 2021.

TUUTTI, K. **Corrosion of steel in concrete**. Stockholm, 1982. Thesis (Doctoral Degree in Civil Engineering) – Division of Building Materials, Swedish Cement and Concrete Research Institute, Stockholm, 1982.

WILLMOTT, C. J. *et al.* Statistics for the evaluation and comparison of models. **Journal of Geophysical Research**, v. 90, n. C5, 1985.

YAMAMOTO, J. K. **Estatística, análise e interpolação de dados geoespaciais**. São Paulo: Paulo's, 2020.

YANG, X. *et al.* Research on concrete carbonation depth prediction algorithm based on BP-AR. **Earth and Environment Science**, v. 242, n. 6, 2019.

YUAN, Q.; ZHAO, G. Study on forecast model of time series analysis of concrete carbonization depth. **Journal of Dalian University of Technology**, v. 40, n. 3, 2000.

## Agradecimentos

Os autores, participantes do Grupo de Estudos em Durabilidade (GEDur), agradecem a Furnas Centrais Elétricas, Agência Nacional de Energia Elétrica (ANEEL) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ). O primeiro autor ainda agradece à Universidade de Rio Verde (UniRV) pela concessão de licença para capacitação com bolsa.

### Tiago Ferreira Campos Neto

Conceitualização, Curadoria de dados, Análise de dados, Recebimento de financiamento, Pesquisa, Metodologia, Desenvolvimento, implementação e teste de software, Validação de dados e experimentos, Design da apresentação dos dados, Redação do manuscrito original, Redação - revisão e edição.

Programa de Pós-Graduação em Geotecnia, Estruturas e Construção Civil | Universidade Federal de Goiás | Av. Universitária, Quadra 86, Lote Área 1488, Setor Leste Universitário | Goiânia - GO - Brasil | CEP 74605-220 | Tel.: (62) 98101-0095 | E-mail: tiagocampos.eng@gmail.com

### Oswaldo Cascudo

Curadoria de dados, Análise de dados, Recebimento de financiamento, Administração do projeto, Disponibilização de ferramentas, Supervisão, Redação - revisão e edição.

Programa de Pós-Graduação em Geotecnia, Estruturas e Construção Civil | Universidade Federal de Goiás | Tel.: (62) 98167-9778 | E-mail: ocascudo@ufg.br

Editor: **Marcelo Henrique Farias de Medeiros**

### **Ambiente Construído**

Revista da Associação Nacional de Tecnologia do Ambiente Construído

Av. Osvaldo Aranha, 99 - 3º andar, Centro

Porto Alegre - RS - Brasil

CEP 90035-190

Telefone: +55 (51) 3308-4084

www.seer.ufrgs.br/ambienteconstruido

www.scielo.br/ac

E-mail: ambienteconstruido@ufrgs.br



This is an open-access article distributed under the terms of the Creative Commons Attribution License.