UNIVERSIDADE ESTADUAL PAULISTA – UNESP

Faculdade de Engenharia e Ciências - Câmpus de Guaratinguetá

TOBIAS LOMBARDI GARCIA TIBÚRCIO BUENO

PREDIÇÃO DA VIDA ÚTIL DE PROJETO DE ESTRUTURAS DE CONCRETO ARMADO SOB CORROSÃO POR CARBONATAÇÃO: Abordagem Integrada de Aprendizado de Máquina e Monte Carlo

Guaratinguetá-SP

2026

TOBIAS LOMBARDI GARCIA TIBÚRCIO BUENO

PREDIÇÃO DA VIDA ÚTIL DE PROJETO ESTRUTURAS DE CONCRETO ARMADO SOB CORROSÃO POR CARBONATAÇÃO: Abordagem Integrada de Aprendizado de Máquina e Monte Carlo

Dissertação apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia e Ciências, Guaratinguetá, para obtenção do título de Mestre em Engenharia.

Área de Concentração: Mecânica

Orientador: Prof. Dr. Emerson Felipe Félix
Coorientador: Prof. Dr. Caio Gorla Nogueira

Guaratinguetá - SP
2026

Bueno, Tobias Lombardi Garcia Tibúrcio
B928p Predição da vida útil de projeto de estruturas de concreto armado sob corrosão por carbonatação: abordagem integrada de aprendizado de máquina e Monte Carlo / Tobias Lombardi Garcia Tibúrcio Bueno - Guaratinguetá, 2026
187 f : il.
Bibliografia: f. 169-186

Dissertação (Mestrado) – Universidade Estadual Paulista, Faculdade de Engenharia e Ciências de Guaratinguetá, 2026.

Orientador: Prof. Dr. Emerson Felipe Félix
Coorientador: Prof. Dr. Caio Gorla Nogueira

1. Concreto armado. 2. Redes neurais (Computação). 3. Durabilidade (Engenharia). 4. Monte Carlo, método de. I. Título.

CDU 624.012.45(043)

Luciana Máximo
Bibliotecária/CRB-8 3595

IMPACTO POTENCIAL DESTA PESQUISA

O impacto potencial da presente pesquisa na sociedade reside na disponibilização de uma ferramenta funcional, combinando técnicas de Aprendizado de Máquinas e Simulações Probabilísticas, de fácil aplicabilidade acadêmica e prática e de acesso gratuito, para avaliação da vida útil de estruturas em concreto armado, que estão amplamente presentes tanto no Brasil e quanto no mundo.

POTENTIAL IMPACT OF THIS RESEARCH

The potential impact of this research on society lies in providing a functional, freely accessible tool, combining Machine Learning techniques and Probabilistic Simulations, with easy academic and practical applicability, for assessing the service life of reinforced concrete structures, which are widely present both in Brazil and around the world.

TOBIAS LOMBARDI GARCIA TIBÚRCIO BUENO

MODELAGEM DA VIDA ÚTIL DE PROJETO DE ESTRUTURAS DE CONCRETO ARMADO SOB CORROSÃO POR CARBONATAÇÃO: Abordagem Integrada de Aprendizado de Máquina e Monte Carlo

Dissertação apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia e Ciências de Guaratinguetá, para obtenção do título de Mestre em Engenharia

Data da defesa: 22/06/2026

Banca Examinadora:

Documento assinado digitalmente
gov.br
EMERSON FELIPE FELIX
Data: 01/07/2026 10:42:53-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. EMERSON FELIPE FELIX

Orientador - UNESP

Documento assinado digitalmente
gov.br
ROGERIO CARRAZEDO
Data: 02/07/2026 08:43:46-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. ROGÉRIO CARRAZEDO

EESC

Documento assinado digitalmente
gov.br
JAIRO JOSE DE OLIVEIRA ANDRADE
Data: 02/07/2026 11:18:57-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. JAIRO JOSÉ DE OLIVEIRA ANDRADE

PUCRS

Dedico este trabalho a Deus, meus pais, minha namorada e aos profissionais atuantes na manutenção de construções em concreto armado, para que possam colher os frutos do conhecimento produzidos nessa linha de pesquisa.

AGRADECIMENTOS

A Deus, que proveu vida, inteligência, discernimento e tudo o mais de essencial para o desenvolvimento desse trabalho e da minha vida acadêmica.

Ao meu orientador, Emerson Felix, que há mais de dois anos tem atuado balizando os procedimentos de pesquisa, com muita didática e presença, e agregando muito valor com sua visão estética sobre as ilustrações.

Ao meu coorientador, Caio Gorla, que auxiliou com fundamentos estatísticos e visão crítica sobre a abordagem adotada, essenciais para o desenvolvimento da pesquisa e da ferramenta probabilística.

À Carol, que não lembro como ou quando conheci, mas que tem sido amiga, namorada, parceira e companheira, com quem tenho escrito a história pela qual sempre rezei e construído o futuro com o sentimento de paz com que sempre sonhei.

Aos meus pais, João Bosco e Patrícia, e aos meus avós, Vô Paulo, Vó Letícia, Vó Dita e Vô Carlos (*in memoriam*), que transmitiram os valores que possuo, os conselhos que pude seguir, os ensinamentos através do exemplo e todo o suporte emocional ao longo dos últimos 25 anos.

Ao Mateus, ao Thesary, ao PG, ao Ricardo, ao Lorran, ao Colicença, ao Bilf, ao Pedro, ao Arthur e à Camila.

Aos meus alunos particulares de matemática, que me proporcionam gratas oportunidades de contribuir, de alguma maneira, com suas vidas acadêmicas.

À equipe de pesquisa. Sozinho é possível ir rápido, mas é em equipe que se chega longe.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Processo nº 88887.940827/2024-00.

E ao Tobias, que, como qualquer outra pessoa, tem seus perrengues pra resolver e sabe que Deus dá o frio conforme o cobertor. Que busca construir uma história e um futuro pelos quais se orgulhar, com a alegria de poder, com seus esforços, desempenhar e desenvolver os dons recebidos de Deus.

“Queime lenha velha, beba vinho envelhecido, leia livros antigos, mantenha velhos amigos” (Afonso X, Rei de Leão e Castela no século XIII)

RESUMO

A carbonatação é um dos principais mecanismos de degradação do concreto armado, pois reduz o pH da matriz cimentícia e desencadeia a corrosão das armaduras, comprometendo a durabilidade das estruturas. Embora diversos modelos analíticos tenham sido propostos, muitos não consideram o efeito de variáveis climáticas, em especial da temperatura média do ambiente, além de se basearem em ensaios acelerados que não refletem fielmente as condições naturais de exposição. Este estudo busca propor um modelo preditivo da profundidade de carbonatação, construído exclusivamente a partir de dados de concretos expostos a condições reais de degradação, acoplado a uma ferramenta probabilística de análise da vida útil por meio de simulações de Monte Carlo. O banco de dados utilizado reuniu mais de 2300 registros de carbonatação. Foram avaliadas arquiteturas de redes neurais artificiais (RNAs) com até três camadas ocultas, utilizando métricas como coeficiente de determinação (R^2), raiz do erro quadrático médio (RMSE) e erro absoluto médio (MAE). As melhores arquiteturas multicamadas alcançaram R^2 médio de 0,85 e RMSE de aproximadamente 0,84 mm/ano^{0,5}, modelo este selecionado para ser acoplado ao método de simulação de Monte Carlo. A análise paramétrica evidenciou fatores críticos para a carbonatação, como umidade relativa entre 50% e 60%, relação água/aglomerante elevada, ambientes internos e maiores teores de adições minerais, além de mostrar que a temperatura exerce efeito indireto e dependente da interação com outras variáveis, a exemplo da umidade relativa. A incorporação do modelo à simulação de Monte Carlo resultou em estimativas mais conservadoras de vida útil de projeto, entre 20 e 50 anos, em comparação com as de 50-80 anos obtidas em análises determinísticas. Como principais contribuições da pesquisa, destacam-se a proposição de um modelo preditivo, baseado em dados reais e considerando variáveis climáticas, e a consolidação de uma ferramenta de fácil aplicação para análise probabilística da vida útil de projeto de estruturas de concreto armado sob corrosão por carbonatação.

Palavras-chave: Durabilidade; Despassivação por Carbonatação; Estruturas de Concreto Armado; Redes Neurais Artificiais; Monte Carlo.

ABSTRACT

Carbonation is one of the main degradation mechanisms in reinforced concrete, as it lowers the pH of the cementitious matrix and triggers corrosion of the reinforcement, compromising the durability of structures. Although several analytical models have been proposed, many fail to adequately account for the effects of climatic variables, particularly average ambient temperature, and are often based on accelerated tests that do not faithfully represent natural exposure conditions. This study aims to propose a predictive model for carbonation depth, built exclusively from data on concretes exposed to real-world degradation conditions, coupled with a probabilistic service-life analysis tool using Monte Carlo simulations. The database used comprised more than 2,300 carbonation records. Artificial neural network (ANN) architectures with up to three hidden layers were evaluated using performance metrics such as coefficient of determination (R^2), root mean square error (RMSE) and mean absolute error (MAE). The best multilayer architectures achieved an average R^2 of 0.85 and RMSE of approximately 0.84 mm/year$^{0.5}$, with the selected model integrated into the Monte Carlo simulation method. Parametric analysis highlighted critical factors for carbonation, such as a relative humidity between 50% and 60%, a high water-to-binder ratio, indoor exposure conditions, and higher mineral-addition contents. It also showed that temperature exerts an indirect effect dependent on its interaction with other variables, such as relative humidity. The incorporation of the model into Monte Carlo simulations resulted in more conservative service-life estimates, ranging from 20 to 50 years, compared with 50–80 years obtained in deterministic analyses. The main contributions of this research include the development of a predictive model based on real data and incorporating climatic variables, as well as the development of an easy-to-apply tool for probabilistic service-life analysis of reinforced concrete structures under carbonation-induced corrosion.

Keywords: Durability; Carbonation-Induced Depassivation; Reinforced Concrete Structures; Artificial Neural Networks; Monte Carlo.

LISTA DE FIGURAS

Figura 1 - Representação do (a) neurônio biológico e (b) do *Perceptron*.....18
Figura 2 - Vida útil de estruturas de concreto armado.....26
Figura 3 - Processo de corrosão eletroquímica do aço. 29
Figura 4 – Esquema ilustrativo de seção transversal de concreto armado com armaduras corroídas. 30
Figura 5 - Diagrama de Pourbaix para o sistema Fe-H_2O. 31
Figura 6 - Esquema ilustrativo da corrosão por pites. 31
Figura 7 - Esquema ilustrativo da corrosão uniforme. 32
Figura 8 - Carbonatação em função da umidade e ambiente de exposição. 38
Figura 9 - Esquema ilustrativo para a influência dos ciclos de molhagem e secagem na carbonatação. 39
Figura 10 - Probabilidade de despassivação de estrutura em função do tipo de cimento Portland. 47
Figura 11 - Estrutura de um neurônio único. 68
Figura 12 – Modelo simplificado de um neurônio biológico. 69
Figura 13 - Estrutura de uma rede genérica de múltiplas camadas. 69
Figura 14 - Topologias de RNA de camadas únicas e múltiplas. 71
Figura 15 - Esquema Genérico de Rede Neural Recorrente. 72
Figura 16 - Esquema Genérico de Rede Neural Convolucional. 72
Figura 17 – Fluxograma ilustrativo do algoritmo de *backpropagation.* 74
Figura 18 - Funções de ativação. 83
Figura 19 - Metodologia genérica para a construção de um modelo de RNA. 84
Figura 20 - Países contemplados no banco de dados. 93
Figura 21 – Distribuições brutas das variáveis contínuas do banco de dados. 94
Figura 22 – Gráfico Boxplot da distribuição da taxa de carbonatação na base de dados bruta. 97
Figura 23 – Distribuições tratadas das variáveis contínuas do banco de dados. 100
Figura 24 - Gráfico boxplot da distribuição da taxa de carbonatação na base de dados tratada. 101
Figura 25 - Matriz de correlação de Pearson entre as variáveis. 101
Figura 26 - Fluxograma do processo de busca pela arquitetura de melhor desempenho.....103

Figura 27 – Performance de treino e teste das 40 redes de camada única. 107
Figura 28 - Performance de treino e teste das 400 redes de 2 camadas. 109
Figura 29 – Desempenho das RNAs de 3 camadas usadas na primeira fase do Random Grid Search. 111
Figura 30 – Mapas de calor para visualização simplificada das regiões de melhor performance na primeira etapa do Random Grid Search. 111
Figura 31 – Restrição de domínio com base nas melhores RNAs da primeira triagem.....112
Figura 32 - Performance das 495 redes de 3 camadas treinadas na segunda triagem.....113
Figura 33 - Mapas de calor para a visualização simplificada das regiões de melhor desempenho na segunda triagem. 113
Figura 34 - Restrição de domínio com base nas 1% melhores redes da segunda triagem. 114
Figura 35 - Desempenho das 162 redes de 3 camadas treinadas na terceira triagem.....115
Figura 36 - Mapas de calor para a visualização simplificada das regiões de melhor desempenho na terceira triagem. 116
Figura 37 – Melhores redes do último domínio de busca com 3 camadas ocultas. 117
Figura 38 - Gráfico dos resíduos do modelo proposto. 118
Figura 39 – Gráfico de dispersão entre os valores reais e os valores preditos pelo modelo proposto. 118
Figura 40 – Vistas da ponte do estudo de caso. 121
Figura 41 – Resultados dos modelos de predição em contraste com valores medidos em campo da a) Longarina e b) Transversina. 124
Figura 42 – Análise paramétrica da umidade relativa versus a temperatura. 127
Figura 43 – Análise paramétrica da umidade relativa versus a relação A/A. 127
Figura 44 – Análise paramétrica da temperatura versus a relação A/A. 128
Figura 45 – Carbonatação em função da umidade relativa e do ambiente de exposição. 131
Figura 46 – Carbonatação em função da temperatura e do ambiente de exposição.....131
Figura 47 – Carbonatação em função da relação água/aglomerante e do ambiente de exposição. 132

Figura 48 – Análise paramétrica da umidade relativa versus o teor de adição mineral.....133
Figura 49 – Análise paramétrica da temperatura versus o teor de adição mineral..133
Figura 50 – Análise paramétrica da relação A/A versus o teor de adição mineral. .134
Figura 51 - Fluxograma ilustrativo do cálculo da probabilidade de despassivação. 139
Figura 52 – Probabilidade de despassivação em função do valor de N. 143
Figura 53 – Coeficiente de variação da probabilidade de falha em função de N.....144
Figura 54 - Visão geral da interface web. 146
Figura 55 – Região para parâmetros de distribuição das variáveis aleatórias. 147
Figura 56 – Exemplo de validação de dados.....148
Figura 57 – Exemplo de saída da análise determinística da interface web. 148
Figura 58 – Exemplo de *output* probabilístico da interface *web.* 149
Figura 59 – Distribuição da profundidade de carbonatação e do cobrimento no cenário padrão. 150
Figura 60 - Análise probabilística: Clínquer + Gesso. 151
Figura 61 - Análise determinística: Clínquer + Gesso. 152
Figura 62 - Distribuição da profundidade de carbonatação e de cobrimento para a viga do viaduto, considerando um cimento com CG+ = 85%. 153
Figura 63 - Análise probabilística: Umidade relativa. 154
Figura 64 - Análise determinística: Umidade relativa. 155
Figura 65 - Distribuição da profundidade de carbonatação e do cobrimento da viga da ponte, considerando uma umidade relativa média de 50%. 156
Figura 66 - Análise probabilística: Temperatura. 157
Figura 67 - Análise determinística: Temperatura. 158
Figura 68 - Análise probabilística: Ambiente de exposição. 159
Figura 69 - Análise determinística: Ambiente de exposição. 159
Figura 70 - Análise determinística: Relação água/aglomerante. 161
Figura 71 - Análise probabilística: Relação água/aglomerante. 161

LISTA DE TABELAS

Tabela 1 - Classe de agressividade ambiental (CAA). 36
Tabela 2 - Cobrimento do concreto em função da classe de agressividade ambiental..... 36
Tabela 3 - Siglas e classes do cimento Portland. 45
Tabela 4 - Limites de composição química do cimento Portland. 45
Tabela 5 - Requisitos químicos do cimento Portland. 46
Tabela 6 – Relação de autores e quantidades de dados extraídos da literatura. 89
Tabela 7 - Codificação de valores para variáveis discretas. 96
Tabela 8 - Restrições ao domínio do modelo. 98
Tabela 9 – Exemplo de linhas existentes no banco de dados tratado. 99
Tabela 10 - Parâmetros estatísticos das variáveis contínuas do banco de dados tratado. 100
Tabela 11 - Valores fixos de hiperparâmetros. 104
Tabela 12 – Parâmetros de entrada do estudo de caso. 122
Tabela 13 - Profundidades de carbonatação da longarina. 123
Tabela 14 - Profundidades de carbonatação da transversina. 123
Tabela 15 – Parâmetros de distribuição dos dados medidos *in loco* 125

SUMÁRIO

1 INTRODUÇÃO 16

1.1 OBJETIVOS 20

1.2 DELIMITAÇÃO DE ESCOPO 20

1.3 CONTEÚDO E ORGANIZAÇÃO DO TRABALHO 21

1.4 METODOLOGIA DA PESQUISA 22

2 VIDA ÚTIL DE ESTRUTURAS EM CONCRETO ARMADO 25

2.1 CORROSÃO DO AÇO IMERSO NO CONCRETO 27

2.1.1 Princípios da corrosão 27

2.1.2 Mecanismos de transporte do CO_2 no concreto 32

2.1.2.1 Permeabilidade 33

2.1.2.2 Absorção capilar 34

2.1.2.3 Difusão 34

2.1.3 Agressividade ambiental e cobrimento da armadura 35

2.1.4 Fatores que influenciam na difusão de CO_2 no concreto 37

2.1.4.1 Umidade relativa do ar e proteção e incidência de chuvas 37

2.1.4.2 Concentração de CO_2 40

2.1.4.3 Temperatura 41

2.1.4.4 Resistência à compressão e relação água-aglomerante 42

2.1.4.5 Composição química do aglomerante e adições minerais 43

2.2 MÉTODOS DE PREDIÇÃO DA VIDA ÚTIL DE PROJETO 47

2.2.1 Modelos analíticos e empíricos 48

2.2.1.1 Modelo de Tuutti 48

2.2.1.2 Modelo de Smolczyk 49

2.2.1.3 Modelo de Vesikari 50

2.2.1.4 Modelo de Papadakis, Vayenas e Fardis 50

2.2.1.5 Modelo de Bob e Afana 51

2.2.1.6 Modelo de EHE 51

2.2.1.7 Modelo de Possan 52

2.2.1.8 Modelo de Ekolu 53

2.2.1.9 Modelo de Liu, Yu e Chen 53

2.2.2 Modelagem numérica 54

2.3 CONSIDERAÇÕES DO CAPÍTULO 59

3 MODELO DE PREDIÇÃO DA FRENTE DE CARBONATAÇÃO 60

3.1 BREVE HISTÓRICO DO APRENDIZADO DE MÁQUINAS E RNAS 60

3.1.1 Histórico do mapeamento da carbonatação com RNAs 62

3.2 FUNDAMENTOS DAS RNAS 67

3.2.1 Topologia das redes neurais artificiais 70

3.2.2 Algoritmo de aprendizagem *backpropagation* 73

3.2.2.1 Algoritmo backpropagation 79

3.2.3 Funções de ativação 82

3.3 MODELAGEM COM REDES MLP 84

3.4 COLETA, ANÁLISE E PROCESSAMENTO DE DADOS 88

3.4.1 Construção do banco de dados 88

3.4.2 Processamento e análise dos dados tratados 96

3.5 PROPOSIÇÃO DO MODELO DE CARBONATAÇÃO 103

3.6 ANÁLISE DE PERFORMANCE DOS MODELOS 106

3.6.1 Redes de uma camada 106

3.6.2 Redes de duas camadas 108

3.6.3 Redes de três camadas 110

3.7 ESTUDO DE CASO COM APLICAÇÃO DO MODELO 121

3.8 ANÁLISE PARAMÉTRICA 126

3.8.1 Efeitos do ambiente de exposição 130

3.8.2 Efeitos da adição mineral 132

3.9 CONSIDERAÇÕES DO CAPÍTULO 134

4 DURAPASS-AI: SOFTWARE DE ANÁLISE PROBABILÍSTICA 136

4.1 FUNDAMENTAÇÃO TEÓRICA DAS SIMULAÇÕES DE MONTE CARLO 136

4.2 ACOPLAMENTO DE MONTE CARLO AO MODELO DE CARBONATAÇÃO 138

4.2.1 Estudo para definição do tamanho da amostragem aleatória 141

4.3 INTERFACE DO APP DURAPASS-AI 145

4.4 ANÁLISE DE APLICABILIDADE DO SOFTWARE 149

4.4.1 Efeito do teor de clínquer e gesso do cimento 150

4.4.2 Efeito da umidade relativa 153

4.4.3 Efeito da temperatura 157
4.4.4 Efeito do ambiente de exposição 158
4.4.5 Efeito da relação água/aglomerante 160
4.5 CONSIDERAÇÕES DO CAPÍTULO 162
5 CONCLUSÕES 164
5.1 LIMITAÇÕES E FUTUROS DESENVOLVIMENTOS 167
REFERÊNCIAS 169
DADOS CURRICULARES 187

1 INTRODUÇÃO

A durabilidade das estruturas de concreto armado depende de diversos fatores, como as características das etapas construtivas (projeto, especificações, materiais e manutenção), a agressividade do ambiente em que a estrutura está inserida, as condições de uso e a vida útil requerida (Mehta; Monteiro, 2014).

Possan e Andrade (2014) ressaltam a relevância de compreender as variáveis que influenciam a degradação do concreto, em especial o ambiente de exposição da edificação (marinho, urbano ou industrial) e o seu nível de agressividade, o qual pode ser expresso pelo teor de agentes deletérios presentes na atmosfera, como CO_2, íons cloreto, sulfatos e álcalis. Segundo Dal Molin *et al.* (2016), essas informações são fundamentais tanto para a análise da durabilidade quanto para a simulação da vida útil, uma vez que o ambiente de exposição interfere diretamente na intensidade e na velocidade dos processos de deterioração.

A redução da vida útil, associada à necessidade de reparos e manutenções, decorre de falhas de projeto, execução e, sobretudo, da ação de manifestações patológicas diversas. Considerando a segurança dos usuários, a vida útil de uma estrutura de concreto armado pode atingir até 120 anos, desde que reparos e manutenções periódicas sejam realizados (International Organization for Standardization, 2011). No Brasil, a norma de desempenho NBR 15575 (ABNT, 2013) estabelece, para os elementos estruturais de edifícios residenciais, uma vida útil mínima de 50 anos e máxima de 75 anos.

Entre as causas de manifestações patológicas no concreto armado, a corrosão das armaduras é a mais recorrente, representando o principal mecanismo de degradação responsável pela perda de desempenho e redução da vida útil do concreto armado (Taffese; Sistonen, 2013). Em regiões litorâneas, a corrosão está fortemente associada à presença de íons cloreto (Cl^-) oriundos da névoa salina atmosférica. Já em áreas urbanas, a principal causa é a ação do CO_2, que provoca o processo de carbonatação do concreto (Mehta; Monteiro, 2014).

Até a década de 1990, os modelos de difusão de CO_2 e Cl^- eram obtidos principalmente por regressão linear e não linear, considerando fatores como a relação água/cimento (a/c), o tipo de aglomerante e as condições de exposição (Kobayashi; Uno, 1990). Posteriormente, alguns pesquisadores (Ishida; Maekawa, 2000;

Maekawa; Ishida; Kishi, 2003; Papadakis; Vayenas; Fardis, 1991) incorporaram em seus modelos formulações físico-químicas relacionadas às reações de hidratação da pasta de cimento e à dissolução do CO_2 na matriz porosa do concreto, o que possibilitou maior precisão na determinação da frente de carbonatação. Entretanto, esses modelos apresentam elevada complexidade matemática e envolvem parâmetros de difícil mensuração, como o coeficiente de difusão do dióxido de carbono no concreto.

Com o avanço da computação e o desenvolvimento das técnicas de aprendizado de máquina, novas abordagens foram propostas (Akpinar; Uwanuakwa, 2016; Hamzehie *et al.*, 2014; Kwon; Song, 2010; Lu; Liu, 2009), com o objetivo de reduzir as incertezas inerentes aos modelos tradicionais. Dentre essas técnicas, o uso de redes neurais artificiais (RNA) tem se consolidado como uma estratégia promissora para a modelagem do fenômeno da carbonatação (Akpinar; Uwanuakwa, 2016; Felix *et al.*, 2019; Felix; Carrazedo; Possan, 2021; Kwon; Song, 2010; Lu; Liu, 2009; Majlesi *et al.*, 2023; Wei *et al.*, 2023).

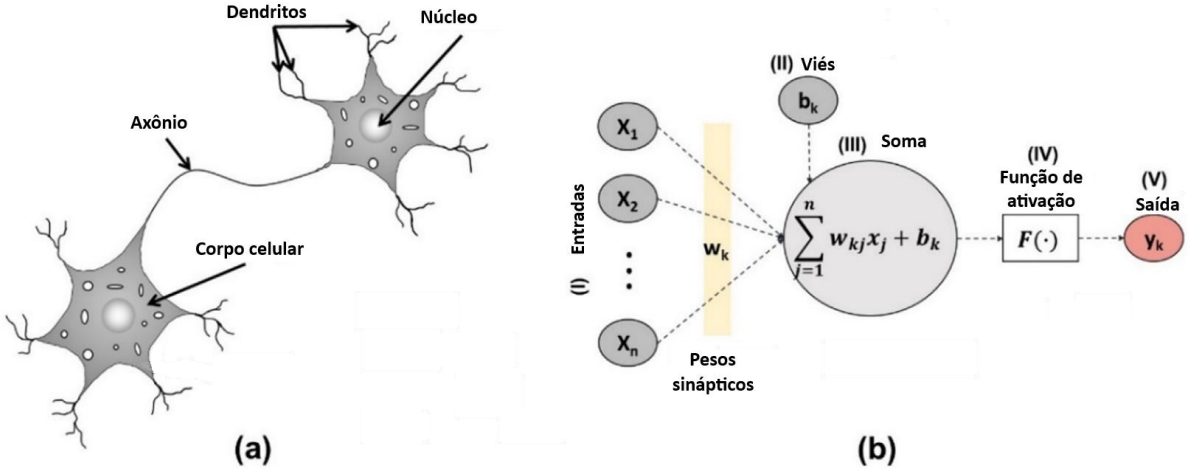
As RNA são sistemas compostos por unidades de processamento, chamadas de neurônios, que têm o seu funcionamento baseado no sistema nervoso humano (Figura 1) e possuem a propriedade de mapear funções complexas com alta generalidade (Haykin, 1999). Ademais, as redes neurais artificiais demonstram uma capacidade que vai além de mapear relações entre entradas e saídas, sendo capazes também de extrair informações não apresentadas à rede (Braga; Ludermir; Carvalho, 2000), sendo este o principal motivo da sua crescente empregabilidade em problemas correlatos às áreas da engenharia.

Como mencionado, as redes neurais artificiais são definidas por meio de um modelo numérico que as torna análogas às redes neurais biológicas (Figura 1), o que garante a capacidade de simular características básicas do sistema nervoso humano: o aprendizado, a classificação de padrões e o processamento de dados.

Uma das principais razões pelas quais as redes neurais artificiais (RNA) se tornaram amplamente conhecidas e aplicadas deve-se ao uso do algoritmo de treinamento *backpropagation* (Rumelhart; Hinton; Williams, 1986), de fácil implementação por meio da técnica de otimização via gradiente descendente. Devido à sua simplicidade, grande parte dos trabalhos publicados em engenharia civil que empregam RNA utiliza esse algoritmo no treinamento das redes (Abambres;

Lantsoght, 2019; Felix; Possan; Carrazedo, 2019; Lazarevska *et al.*, 2014; Majlesi *et al.*, 2023; Shafabakhsh *et al.*, 2015).

Figura 1 - Representação do (a) neurônio biológico e (b) do *Perceptron*.



Fonte: Adaptado de Felix, Carrazedo e Possan (2021).

Luo, Niu e Dong (2014) e Akpinar e Uwanuakwa (2016) destacam que modelos eficientes para a previsão da carbonatação do concreto podem ser desenvolvidos por meio de RNA. Ressaltam ainda que, a depender do algoritmo de treinamento adotado, o número de iterações necessárias à aprendizagem pode ser reduzido, otimizando o tempo de modelagem em comparação com outras técnicas.

Mais recentemente, Wei *et al.* (2023) propuseram um modelo de previsão da profundidade de carbonatação em concretos com adições minerais, utilizando técnicas de aprendizado de máquina. A pesquisa contou com um banco de dados com 17 atributos provenientes de ensaios de carbonatação. O algoritmo desenvolvido foi comparado a três modelos clássicos de previsão, e os resultados demonstraram que a RNA apresenta maior precisão que a máquina de vetores de suporte (SVM), além de superar os modelos tradicionais da literatura em termos de acurácia.

Apesar desses avanços, as formulações atuais ainda não representam de forma realista o período de iniciação da corrosão por carbonatação, isto é, o momento em que as armaduras sofrem despassivação. Isso se deve, em grande parte, ao fato de que a maioria dos modelos foi concebida a partir de experimentos com carbonatação acelerada.

Nesse contexto, o grupo de pesquisa DASMAE (*Research Group on Data Science and Machine Learning Applied to Engineering)* vem conduzindo uma coleta

de dados de carbonatação natural, composta, no início da presente pesquisa, por 1031 amostras de estruturas de 13 países, com até 41 anos de idade. Com esse banco de dados, associado a técnicas de aprendizado de máquina e a simulações de Monte Carlo, torna-se possível desenvolver modelos que representem a carbonatação de elementos sob condições naturais de degradação.

Além disso, deve-se destacar a necessidade de incorporar as incertezas inerentes às variáveis que influenciam o processo de carbonatação, sejam elas do ambiente de exposição ou intrínsecas ao material. Isso é explicitado por Qin e Wang (2023), que contrastaram um modelo determinístico com um modelo probabilístico, obtendo uma acurácia de até 44% maior para o segundo.

O estudo de Marani, Oyinkanola e Panesar (2024) também segue na mesma linha, desenvolvendo uma rede neural probabilística. Os autores desenvolveram duas redes neurais, uma para o cálculo da média e outra para o desvio padrão da profundidade de carbonatação, e ressaltam como as incertezas das predições são essenciais para reconhecer a confiabilidade e precisão de um modelo.

Assim considerando as lacunas observadas, as principais contribuições deste projeto consistiram em: (i) propor um modelo da frente de carbonatação do concreto baseado em técnicas de Aprendizado de Máquina utilizando apenas dados de carbonatação de concretos sob condições de degradação natural; (ii) acoplar a técnica de simulação de Monte Carlo ao modelo, para avaliar probabilisticamente a vida útil de projeto de elementos de concreto armado localizados em ambientes urbanos, considerando as incertezas de parâmetros do ambiente de exposição e do material. Além disso, o presente estudo tem como premissa facilitar o uso das ferramentas numéricas desenvolvidas no mestrado, por meio da criação de um app web que, ao final da pesquisa, estará disponível ao público.

Este trabalho também deu continuidade às pesquisas conduzidas pelo grupo DASMAE, que vêm avançando no desenvolvimento de modelos numéricos para a análise de deterioração de estruturas de concreto armado, de vida útil, de otimização estrutural e de proporcionamento automatizado, com ênfase na aplicação de Inteligência Artificial e de métodos numéricos.

1.1 OBJETIVOS

O objetivo geral deste estudo foi desenvolver uma ferramenta numérica para análise probabilística da vida útil de projeto de estruturas de concreto armado sujeitas à corrosão por carbonatação, acoplando um modelo preditivo da profundidade de carbonatação, baseado em redes neurais artificiais, à técnica de simulação de Monte Carlo.

Como objetivos específicos, citam-se:

- Coletar dados e ampliar o banco de dados do grupo DASMAE, associado à carbonatação do concreto sob condições naturais de degradação;
- Desenvolver um modelo de predição da taxa de carbonatação do concreto sob condições naturais de degradação usando redes neurais artificiais;
- Avaliar a capacidade de aprendizado de redes convencionais (com uma e duas camadas ocultas) e de aprendizado profundo (com mais de duas camadas de processamento) quanto à capacidade de aprendizado e generalização da taxa de carbonatação;
- Desenvolver uma ferramenta numérica para a análise probabilística da vida útil de projeto de estruturas de concreto armado sujeitas à corrosão por carbonatação.

1.2 DELIMITAÇÃO DE ESCOPO

O escopo da presente pesquisa englobou a coleta de dados de carbonatação natural na literatura existente para expansão de uma base de dados pré-existente e, utilizando essa base de dados, o desenvolvimento de um modelo determinístico de predição da taxa de carbonatação usando redes neurais artificiais. Além disso, também está incluso no escopo o acoplamento desse modelo determinístico em simulações probabilísticas de Monte Carlo, consolidando um modelo de predição da probabilidade de despassivação de estruturas de concreto armado. Por fim, foi implementada uma interface gráfica para fácil utilização dos

modelos determinístico e probabilístico desenvolvidos, de modo que seja ferramenta prática para outros pesquisadores e demais profissionais da área.

O trabalho se limita, portanto, à revisão bibliográfica sobre durabilidade de estruturas, em específico sobre aquelas sob corrosão por carbonatação, sem se aprofundar necessariamente em outros tipos de deterioração, como o ataque por cloretos ou a reação álcali-agregado. Os modelos desenvolvidos abrangem estimativas de idade para a vida útil de projeto (VUP), sem ser possível utilizar a ferramenta desenvolvida para análises de vidas úteis de serviço ou total.

Ainda é preciso ressaltar que o modelo foi desenvolvido tendo como base fundamental o banco de dados expandido. A precisão das predições realizadas com a ferramenta implementada, portanto, depende fortemente da qualidade dos dados e das faixas de representatividade de cada variável de entrada no banco, conforme é descrito no item 3.4.

1.3 CONTEÚDO E ORGANIZAÇÃO DO TRABALHO

Este trabalho é estruturado em cinco capítulos, cada qual abordando uma parte fundamental da pesquisa. No Capítulo 1, são apresentadas a introdução e contextualização do tema, destacando a relevância da pesquisa.

O Capítulo 2 aborda a fundamentação teórica necessária para compreender os processos envolvidos na avaliação da vida útil de projetos de estruturas de concreto armado e na modelagem com aprendizado de máquina.

O Capítulo 3 apresenta a metodologia de modelagem, os resultados e a discussão dos resultados referentes ao primeiro produto do estudo, o modelo de predição da taxa de carbonatação do concreto, que permitiu estimar, de forma determinística, a vida útil de projeto por meio da aferição da profundidade de carbonatação.

No Capítulo 4, é apresentada a fundamentação associada à análise probabilística via técnica de simulação de Monte Carlo, e o segundo produto da pesquisa, a ferramenta numérica de análise probabilística da vida útil de projeto de estruturas de concreto armado. No capítulo apresentam-se a metodologia empregada, os resultados obtidos e a discussão destes.

Por fim, o Capítulo 5 apresenta as conclusões da pesquisa, destacando as principais contribuições do estudo, bem como as limitações da ferramenta proposta e as sugestões para futuros desenvolvimentos.

1.4 METODOLOGIA DA PESQUISA

A metodologia utilizada no presente trabalho envolveu cinco etapas: (i) Revisão bibliográfica e ampliação do banco de dados do grupo de pesquisa referente à carbonatação do concreto sob condições naturais de degradação; (ii) Análise estatística e tratamento dos dados; (iii) Proposição de modelo de predição da taxa de carbonatação via RNAs; (iv) Proposição de ferramenta numérica para análise probabilística da vida útil de projeto e; (v) desenvolvimento dos textos da qualificação e defesa e de artigos para divulgação dos resultados do trabalho.

A seguir, descreve-se a metodologia seguida no trabalho:

I. **Revisão bibliográfica e ampliação do banco de dados:** Esta etapa, que se estendeu ao longo de todo o desenvolvimento da pesquisa, constituiu a base das demais fases. Foram coletados dados de carbonatação de concretos em ambiente natural de degradação, disponíveis na literatura, incluindo trabalhos de modelagem numérica, investigações experimentais e avaliações de durabilidade de estruturas em serviço. A busca foi realizada em bases de dados científicas como CAFe, Scielo, Scopus e Science Direct, e permitiu expandir os dados já pertencentes ao banco de dados do DASMAE;

II. **Análise estatística e tratamento dos dados:** Nesta etapa, foi implementado em linguagem Python, usando a IDE *Jupyter Notebook*, com bibliotecas *Scikit-learn*, *Seaborn*, *Pandas*, *Numpy* e *Matplotlib*, um programa que possibilita a análise e o tratamento dos dados. Nesta etapa, foi avaliada a existência de dados duplicados e de dados com informações que pudessem dificultar o treinamento das técnicas de aprendizado, denominados *outliers*. Nesta etapa também foi feita a manipulação do banco de dados, por meio do preenchimento de informações faltantes, a exemplo dos valores médios da umidade relativa do ar e da temperatura;

III. **Proposição de modelo de predição da taxa de carbonatação via RNAs:** Nesta etapa, foram implementados, treinados, validados e testados modelos de Redes Neurais Artificiais (RNAs) do tipo *feedforward*, com até três camadas ocultas e funções de ativação tangente hiperbólica ou sigmoide, utilizando o otimizador Adam. As modelagens foram conduzidas para cada configuração base (com uma, duas ou três camadas ocultas), com o número de neurônios variando entre 1 e 20. As modelagens foram realizadas considerando a divisão do banco de dados em 80% de dados de treinamento e 20% de dados de teste, por amostragem estratificada. Os modelos foram avaliados com validação cruzada (*k-fold*, k=7), considerando métricas de desempenho como erro médio quadrático (ou a raiz dele) e coeficiente de determinação;

IV. **Proposição de ferramenta numérica para análise probabilística da vida útil de projeto:** Foi proposta uma ferramenta numérica para avaliar a vida útil probabilística de estruturas de concreto armado, baseada na técnica de simulação de Monte Carlo. Essa abordagem permitiu a introdução e propagação das incertezas associadas às variáveis de projeto, às propriedades dos materiais e às condições de exposição do ambiente, fornecendo resultados mais robustos e representativos da realidade em comparação com modelos determinísticos. Foram consideradas variáveis aleatórias o cobrimento nominal das armaduras, a temperatura média, a umidade relativa média, a concentração de CO_2 e a resistência à compressão do concreto. Para a disseminação dos produtos desenvolvidos na pesquisa, foi desenvolvido um software final, com interface gráfica de fácil manipulação.

V. **Desenvolvimento dos textos da qualificação, da defesa e de artigos para divulgação dos resultados do trabalho:** Com o intuito de compartilhar os resultados obtidos neste estudo, dedicou-se à redação de artigos para promover a troca de informações com outros pesquisadores da área. Ao mesmo tempo, foram elaborados os textos relativos à qualificação e à defesa.

É importante salientar que, ao longo do texto, foi utilizado o modelo de linguagem Gemini Pro 3.1, da empresa Alphabet Inc., para revisão gramatical, adequação do vocabulário e redução de redundâncias verbais. O conteúdo intelectual, a análise e as interpretações desenvolvidas são de responsabilidade única e exclusivamente do autor.

2 VIDA ÚTIL DE ESTRUTURAS EM CONCRETO ARMADO

Na engenharia civil, a vida útil de projeto é entendida como o intervalo de tempo durante o qual as características de uma estrutura se mantêm preservadas sem a necessidade de intervenções corretivas relevantes, admitindo-se apenas manutenções preventivas. De acordo com a literatura, é possível distinguir pelo menos quatro tipos de vida útil aplicáveis às estruturas de concreto armado (ABNT, 2013; Helene, 1993).

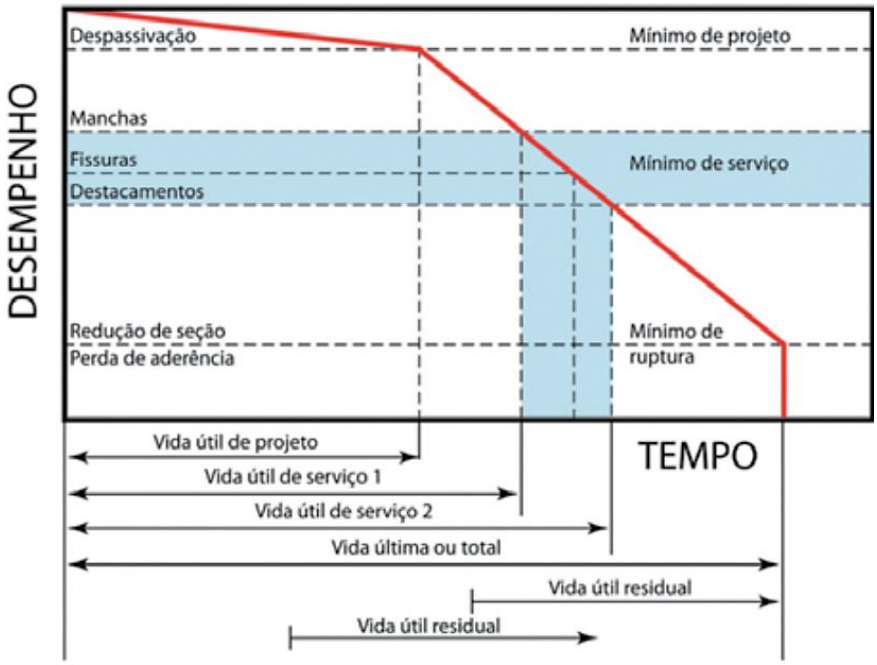
A primeira delas é a Vida Útil de Projeto (VUP), associada ao período necessário para que agentes agressivos, como dióxido de carbono ou íons cloreto, se difundam pelos poros do concreto e atinjam as armaduras. Esse intervalo, também denominado tempo de iniciação, encerra-se quando ocorre a despassivação das barras de aço (Medeiros; Andrade; Helene, 2011). Em seguida, tem-se a Vida Útil de Serviço (VUS), que corresponde ao período após o qual começam a manifestar-se patologias significativas, tais como manchas, fissuras, destacamentos ou deformações excessivas. O término dessa etapa depende das exigências de desempenho da estrutura, sendo caracterizado, sobretudo, pela perda da capacidade de cumprir sua função com segurança (Medeiros; Andrade; Helene, 2011).

A terceira definição é a Vida Útil Total (VUT), compreendida desde a conclusão da obra até o colapso parcial ou total da estrutura. O encerramento desse período é marcado por degradações mais severas, como a redução crítica da aderência entre aço e concreto ou a perda expressiva da seção resistente das armaduras (Medeiros; Andrade; Helene, 2011). Por fim, tem-se a Vida Útil Residual (VUR), iniciada a partir de uma vistoria ou diagnóstico em qualquer momento, estendendo-se até o fim de uma das vidas úteis anteriores. Assim, a VUR pode ser classificada como residual de projeto, de serviço ou total, dependendo da etapa considerada (Medeiros; Andrade; Helene, 2011). A Figura 2 ilustra a relação entre o desempenho estrutural e o tempo, indicando em qual fase a estrutura se encontra com base nas manifestações patológicas observadas.

A análise ou a predição da vida útil das estruturas pode ser realizada por diferentes abordagens. Helene (1997) descreve métodos baseados em experiências anteriores, a partir de dados de campo, ensaios de laboratório e testes acelerados que simulam artificialmente a ação do tempo. O autor também cita métodos

determinísticos, fundamentados em leis físicas como a Lei de Faraday, a Equação de Darcy e a Lei de Fick, além de métodos probabilísticos, frequentemente aplicados em estudos de confiabilidade envolvendo variáveis aleatórias. Na mesma direção, Possan (2010) relaciona a prática de análise do Custo do Ciclo de Vida (CCV) à predição da vida útil, ressaltando que ambas exigem conhecimentos multidisciplinares que abrangem engenharia, ciência dos materiais, engenharia de custos e processos estocásticos.

Figura 2 - Vida útil de estruturas de concreto armado.



Fonte: Medeiros, Andrade e Helene (2011).

A relevância do tema é reforçada pelos resultados recentes de Bueno *et al.* (2024), os quais mostram que a VUP estabelecida pela NBR 15575-1 (ABNT, 2013) encontra-se seriamente comprometida em estruturas expostas à carbonatação. Ao simular cenários atuais e futuros, os autores verificaram que o Estado Limite de Durabilidade (ELD) pode ser alcançado até 20 anos antes do prazo de 50 anos previsto na norma, o que evidencia a necessidade urgente de aprofundar os estudos sobre o tema.

Diante desse contexto, este capítulo busca conceituar o processo de carbonatação do concreto e seus efeitos na iniciação da corrosão das armaduras, discutindo como esses mecanismos impactam a vida útil das estruturas. Além disso,

é realizado uma descrição detalhada da literatura sobre modelos de carbonatação e métodos de predição da vida útil de projeto e de serviço, fornecendo subsídios para a compreensão do fenômeno e para o avanço das técnicas de modelagem aplicadas à área.

2.1 CORROSÃO DO AÇO IMERSO NO CONCRETO

Desde o seu surgimento, o concreto armado consolidou-se como um dos materiais mais utilizados no mundo, graças à combinação entre concreto e aço, que resulta em estruturas dúcteis, resistentes tanto à compressão quanto à tração e adaptáveis a diferentes propostas arquitetônicas. Além disso, sua composição, baseada em materiais de baixo custo e de ampla disponibilidade, como brita, areia e água, contribuiu para sua rápida difusão e aplicação em larga escala.

Apesar de suas inúmeras vantagens, o concreto armado apresenta vulnerabilidades quando exposto a ambientes agressivos, nos quais processos de deterioração podem ser desencadeados com mais facilidade. Entre os principais mecanismos de degradação, destacam-se fissuração, retrações, erosão, ataques por sulfatos e outros agentes químicos, além da corrosão das armaduras, fenômeno considerado um dos mais críticos para a durabilidade das estruturas (Cunha *et al.*, 2013).

Como o aço desempenha papel fundamental no desempenho estrutural, sua corrosão compromete diretamente a vida útil das construções em concreto armado, o que justifica a crescente atenção que esse tema vem recebendo na literatura científica e em estudos aplicados ao longo das últimas décadas.

2.1.1 Princípios da corrosão

A corrosão, de forma geral, pode ser definida como uma interação destrutiva entre um material e o meio em que está inserido. No caso específico do aço, esse processo se manifesta pela perda progressiva de material na superfície metálica, ou seja, nas barras de armadura imersas (ou não) no concreto (Matlakhov; Matlakhova, 2021). Segundo Bauer (2019), a corrosão corresponde a uma transformação não intencional do material metálico em contato com a atmosfera,

resultando na formação de compostos solúveis no meio e pouco aderentes. De acordo com Cunha *et al.* (2013), trata-se de um fenômeno natural, no qual o material tende a retornar à sua forma original encontrada na natureza, em um processo associado à redução do estado de energia, conhecido como Redução da Energia de Gibbs.

No contexto das estruturas de concreto armado, a corrosão das armaduras pode ocorrer por dois mecanismos principais: corrosão química (oxidação direta) e corrosão eletroquímica (Cascudo, 1999; Helene; Figueiredo, 1986). A corrosão química é geralmente um processo lento em temperaturas próximas de 25 °C, mas pode ser acelerada pela presença de gases atmosféricos agressivos. Nessa forma de degradação, ocorre uma reação direta entre o metal e o gás, originando uma película de óxido que recobre a superfície metálica (Cunha *et al.*, 2013; Helene; Figueiredo, 1986).

Por outro lado, a corrosão eletroquímica caracteriza-se pela transferência de íons e elétrons entre diferentes regiões do metal, formando uma célula ou pilha eletroquímica. Nesse processo, é necessária a presença de um eletrólito ao redor das armaduras, com a corrosão ocorrendo predominantemente em meio aquoso (Strehblow; Marcus, 2011). Em estruturas de concreto armado (com barras metálicas), a célula de corrosão é formada pela interação entre o oxigênio ou outros gases presentes na atmosfera, que atuam como agentes oxidantes (cátodo), e o aço, que funciona como agente redutor (ânodo) (Cunha *et al.*, 2013). Ainda segundo Cunha *et al.* (2013), o processo de corrosão generalizada do aço pode ser explicado pelo surgimento de múltiplas microrregiões de pilhas eletroquímicas onde ocorre o transporte de elétrons, o que acelera o processo corrosivo. Na Figura 3 é possível conferir um esquema ilustrativo dessas microrregiões tendo o oxigênio como gás atmosférico atuante.

Nas Equações (1) a (5), também é possível conferir, com mais detalhes, cada uma das reações eletroquímicas envolvidas.

$$Fe \rightarrow Fe^{2+} + 2e^{-} \quad (1)$$

$$O_2 + 2\,H_2O + 4e^{-} \rightarrow 4\,OH^{-} \quad (2)$$

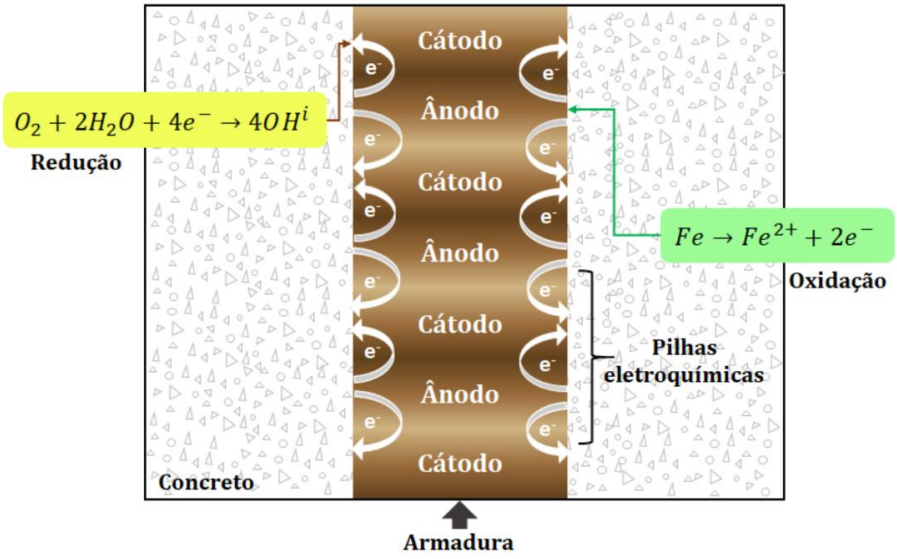
$$Fe^{2+} + 2\,OH^{-} \rightarrow Fe(OH)_2 \quad (3)$$

$$4Fe(OH)_2 + O_2 + 2\,H_2O \rightarrow 4Fe(OH)_3 \quad (4)$$

$$2Fe(OH)_3 \rightarrow Fe_2O_3 \cdot H_2O \quad (5)$$

Na Equação (1), é possível verificar a principal reação anódica, isto é, a oxidação do ferro, onde o elemento perde elétrons e há a liberação de íons Fe^{2+}, enquanto na Equação (2) é possível conferir a reação catódica, composta pela redução do oxigênio de formação de um hidróxido. Por fim, os íons Fe^{2+} da reação anódica reagem com os hidróxidos da reação catódica, formando hidróxido de ferro (Equação (3)), que posteriormente será ainda mais oxidado (Equação (4)) tendo como resultado os produtos de corrosão (Equação (5)) (Mehta; Monteiro, 2014).

Figura 3 - Processo de corrosão eletroquímica do aço.



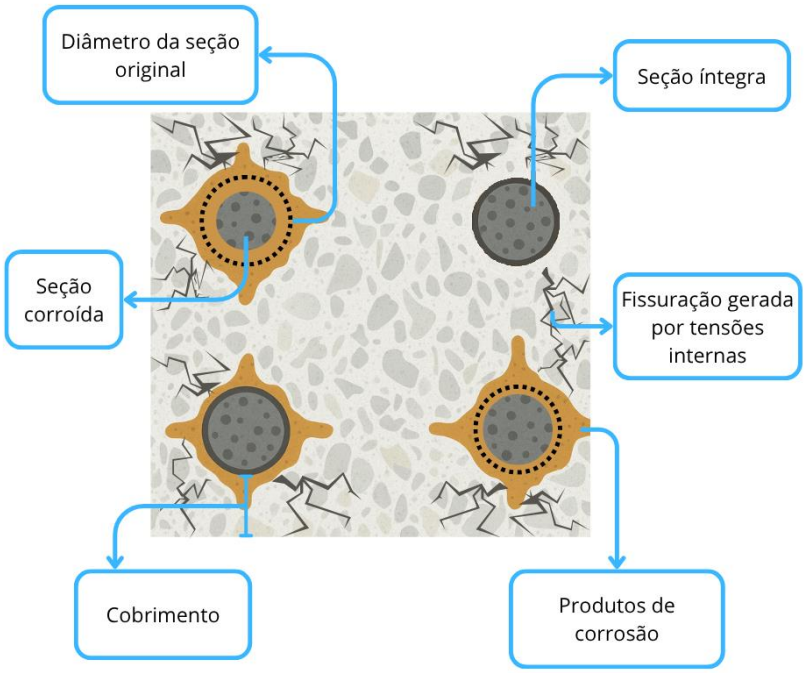
Fonte: Felix (2018).

Assim, ao mesmo tempo em que a barra de aço tem sua seção reduzida pela corrosão, há uma expansão confinada do volume de ferro devido aos produtos de corrosão. Dessa forma, há, simultaneamente, perda de resistência mecânica da estrutura e geração de tensões internas no concreto, podendo provocar fissuração e desplacamento, conforme a Figura 4.

Cunha *et al.* (2013) destacam que a corrosão do aço em estruturas de concreto armado pode ser compreendida a partir de três pilares fundamentais: o eletrólito, a pilha eletroquímica e o oxigênio. Já Helene e Figueiredo (1986) acrescentam que, além desses elementos, a presença de agentes agressivos é determinante para o avanço do processo corrosivo. Entre os principais agentes estão os íons cloreto e o dióxido de carbono, seguidos por outros compostos como sulfetos, nitritos, fuligem e gás sulfídrico. A relevância desses agentes está associada ao fato

de que eles aumentam a condutividade do eletrólito e, simultaneamente, reduzem a alcalinidade do meio. Esse duplo efeito provoca a desestabilização da camada protetora que normalmente recobre as armaduras, favorecendo o início da corrosão (Jiang *et al.*, 2017).

Figura 4 – Esquema ilustrativo de seção transversal de concreto armado com armaduras corroídas.



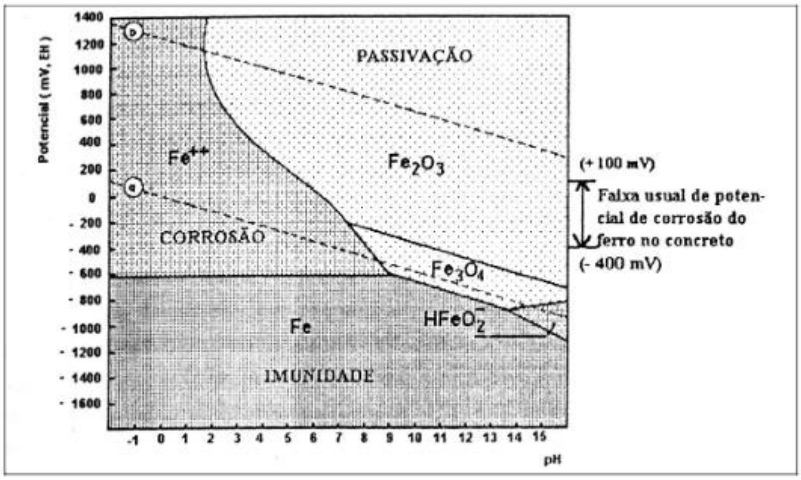
Fonte: Adaptado de OpenAI (2025).

Essa camada protetora, conhecida como filme passivo, forma-se quando o aço está imerso em um meio altamente alcalino, como ocorre no concreto recém-hidratado, cujo pH geralmente varia entre 12 e 14. O filme passivo é constituído por uma estrutura bicamada composta por óxidos e hidroxi-óxidos de ferro. Seu núcleo interno é predominantemente formado por íons ferrosos (Fe^{2+}), enquanto a camada externa é rica em íons férricos (Fe^{3+}), resultando em uma espessura que varia de 3 a 15 mm (Angst *et al.*, 2017).

Esse filme reduz a condutividade iônica e eletrônica da interface, limitando a oxidação do ferro. A camada protetora, entretanto, perde sua estabilidade caso o pH seja reduzido a valores abaixo da faixa de 9 a 10, de acordo com a Figura 5, o que ocorre no processo da carbonatação. No caso do ataque de cloretos, de maneira

distinta, a camada passivadora é rompida de modo localizado, mesmo que em meios alcalinos (Cunha *et al.*, 2013; Liu *et al.*, 2016).

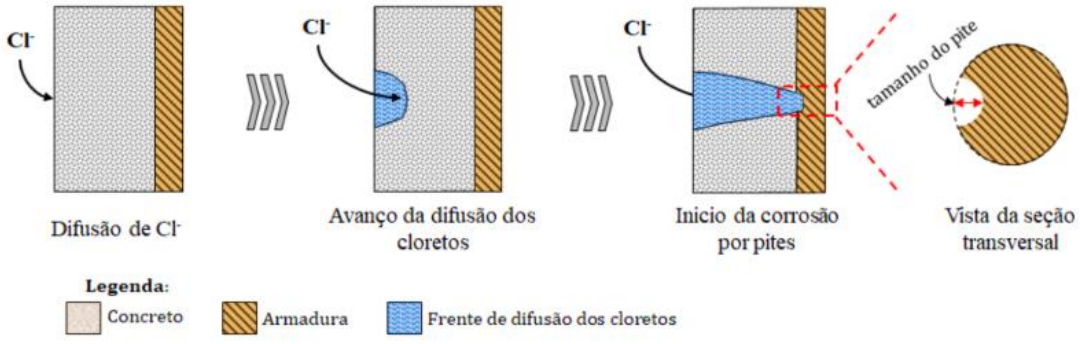
Figura 5 - Diagrama de Pourbaix para o sistema Fe-H_2O.



Fonte: Pourbaix (1974) *apud* Mennucci (2006).

A corrosão por íons cloreto é predominante em ambientes litorâneos e caracteriza-se como corrosão por pites. Como ilustrado na Figura 6, esse fenômeno ocorre de forma localizada e não uniforme na armadura, influenciado pela geometria da frente de difusão dos íons na matriz cimentícia (Cunha *et al.*, 2013).

Figura 6 - Esquema ilustrativo da corrosão por pites.

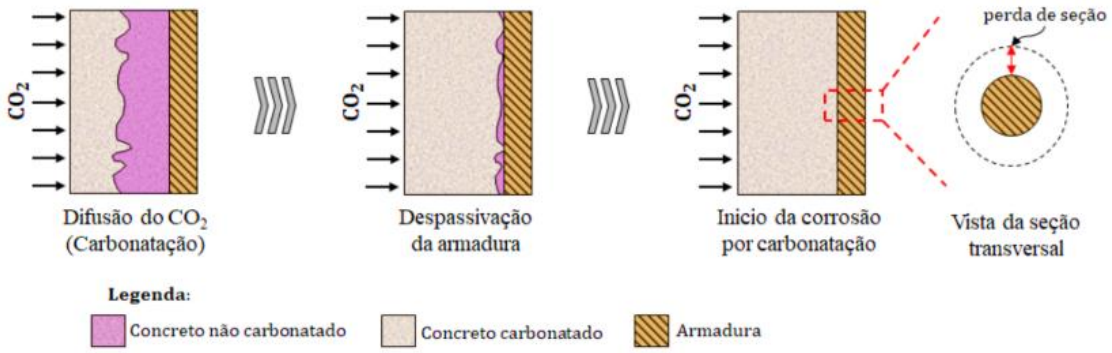


Fonte: Felix (2018).

Por outro lado, nos ambientes urbanos, o principal agente agressivo é o dióxido de carbono, e a corrosão é mais intensa em regiões com maior fluxo de veículos, como garagens, túneis e grandes avenidas e rodovias. Nesse caso, a

corrosão é uniforme, como pode ser conferido na Figura 7, tendo profundidade semelhante ao longo de todo o comprimento da armadura (Cunha *et al.*, 2013).

Figura 7 - Esquema ilustrativo da corrosão uniforme.



Fonte: Felix (2018).

Considerando os diferentes tipos de corrosão, e que para estruturas em ambiente urbano, distantes de regiões com alta concentração de íons cloretos, a carbonatação do concreto é o mecanismo que causa a deflagração da corrosão das armaduras, na sequência são descritos os mecanismos de transporte do CO_2 na matriz cimentícia e os parâmetros climáticos e intrínsecos ao material que interferem na difusão do CO_2.

2.1.2 Mecanismos de transporte do CO_2 no concreto

O processo de carbonatação consiste, essencialmente, na penetração do CO_2 na matriz cimentícia, avançando da superfície externa para o interior do concreto. Esse fenômeno pode ser melhor compreendido a partir da análise dos caminhos que o gás percorre ao longo do tempo até alcançar as armaduras de aço.

Uma vez que o aço é despassivado, a corrosão se desenvolve na presença de oxigênio e água. Na ausência de fissuração, esses agentes agressivos utilizam trajetórias semelhantes às do CO_2 para atingir as barras de reforço.

Nesse contexto, a baixa permeabilidade do concreto assume papel central, configurando-se como o principal fator de proteção das armaduras em elementos estruturais. Esse fator de proteção depende fundamentalmente da distribuição e do tamanho dos poros presentes na matriz pasta–agregados, ou seja, de sua porosidade (Mehta; Monteiro, 2014).

De acordo com Mehta e Monteiro (2014), a formação de vazios e de conexões entre eles no concreto decorre do excesso de água utilizado além da quantidade necessária para a hidratação do cimento. Esses vazios originam microcanais que permitem a penetração de agentes agressivos, como o dióxido de carbono.

Considerando essa microestrutura, torna-se evidente a importância de compreender os mecanismos de transporte responsáveis pela movimentação de gases e líquidos no concreto. Assim, o presente trabalho aborda, em detalhe, os mecanismos de permeabilidade, absorção capilar e difusão.

2.1.2.1 Permeabilidade

A permeabilidade pode ser definida como o fluxo de um fluido por conta de um gradiente de pressão, sendo caracterizada pela facilidade de fluir num sólido poroso quando submetido a um diferencial de pressão (Cunha *et al.*, 2013). No contexto do concreto, a permeabilidade é determinada de acordo com a permeabilidade da pasta de cimento, que por sua vez depende de diversos fatores, como relação água-cimento, composição química e grau de hidratação (Helene; Figueiredo, 1986).

Diferentes gases podem possuir diferentes velocidades de penetração para um mesmo sólido poroso, como é o caso do oxigênio e do dióxido de carbono no concreto.

A carbonatação ocorre de maneira lenta, uma vez que a permeabilidade diminui com o avanço da mesma que preenche os poros, com o CO_2 externo não avançando além da profundidade carbonatada (Tuutti, 1982).

Outro exemplo é a permeação de cloretos na matriz cimentícia, que ocorre de maneira indireta. Os cloretos se dissolvem na água, que por sua vez penetra nos poros do concreto, não havendo exatamente uma reação direta dos cloretos com compostos químicos do cimento.

2.1.2.2 Absorção capilar

A absorção capilar consiste no transporte de líquidos devido à tensão superficial que atua nos poros capilares do concreto. Ela ainda pode ser descrita como o fluxo de líquido induzido por um gradiente de umidade, mas tendo como mecanismo fundamental a sucção capilar (Mehta; Monteiro, 2014; Yu *et al.*, 2017).

De forma geral, canais capilares com menor diâmetro podem promover sucção inicial maior, ao mesmo tempo em que a permeabilidade total pode ser menor. Isso se relaciona diretamente com os efeitos da relação água-cimento que, em níveis menores, torna o concreto mais denso e menos poroso, porém com a possibilidade de ter uma gama de microporos com mais conexões, o que favoreceria o fluxo de água na matriz (Mehta; Monteiro, 2014; Yu *et al.*, 2017).

Se, por um lado, em concretos porosos a absorção é naturalmente maior, num contexto do material estar saturado, isto é, com todos os poros preenchidos com água, a absorção de água será nula. Com isso, também será nulo o ingresso de agentes agressivos por meio desse mecanismo (Mehta; Monteiro, 2014; Yu *et al.*, 2017).

2.1.2.3 Difusão

A difusão se dá por conta de uma diferença de potencial químico, muitas vezes associada à concentração de uma determinada substância de uma região mais concentrada para uma região menos concentrada. Esse mecanismo governa a penetração de cloretos e do dióxido de carbono, além do oxigênio que atua ativamente na formação da pilha de corrosão do aço (Tuutti, 1982).

A difusão ocorre em dois estágios de fluxo, o estacionário e o não estacionário. Enquanto o primeiro corresponde a um fluxo constante e é representado pela primeira lei de Fick (Equação (6)), o segundo conta com um fluxo em função da profundidade e do tempo de penetração e é descrito pela segunda lei de Fick, descritas pelas Equações (7) e (8) (Mehta; Monteiro, 2014; Tuutti, 1982).

$$q = -D\nabla C \tag{6}$$

$$\frac{\partial C}{\partial t} = -D\,\frac{\partial^2 C}{\partial x^2} \quad (7)$$

$$C(x,t) = C_s\left(1 - \mathrm{erf}\frac{x}{2\sqrt{Dt}}\right) \quad (8)$$

Em que *q* é o fluxo de massa, *x* e *t* são a profundidade e o tempo em que está ocorrendo o fluxo, C é a concentração, *D* é o coeficiente de difusão ou difusividade, C(x, t) é a concentração em função do tempo e da profundidade de fluxo e C_s é a concentração superficial em difusão.

É importante salientar que essas equações são válidas como solução considerando um sólido semi-infinito e, no caso do concreto, deve ser levado em consideração o Coeficiente de Difusão Aparente, um valor menor que a difusividade dos gases no ar, pois leva em conta fatores como tortuosidade dos poros, interações físico-químicas com a matriz do concreto, umidade, saturação e adsorção superficial, sendo influenciado essencialmente pela porosidade, relação água-cimento, teor e composição química do cimento, temperatura e umidade relativa do ar (Helene, 1993).

O processo de difusão ocorre, resumidamente, com o dióxido de carbono se dissolvendo na solução aquosa dos poros e reagindo com o hidróxido de cálcio. Com isso, todos os mecanismos de corrosão descritos no item 2.1.1 podem se consolidar, em especial em estruturas submetidas a atmosferas cada vez mais agressivas.

2.1.3 Agressividade ambiental e cobrimento da armadura

Considerando o que já foi discutido, o dióxido de carbono do concreto permeia através dos poros do concreto de modo a invadir gradualmente a matriz cimentícia e alcançar as barras de aço. Quando a frente de carbonatação alcança as barras de aço no interior da matriz cimentícia, isto é, ultrapassa a profundidade de cobrimento, pode-se dizer que o aço foi despassivado, tendo sua camada passivadora dissolvida de acordo com o processo descrito no item 2.1.1 (Mehta; Monteiro, 2014).

Para prevenir a despassivação precoce, a espessura de cobrimento é determinada em função do ambiente de exposição da estrutura. Nesse sentido, é definida uma classificação de atmosferas segundo sua agressividade frente à

carbonatação, dividindo-as em rural, urbana, industrial e marinha, conforme pode ser conferido na Tabela 1 extraída da NBR 6118 (ABNT, 2026).

Tabela 1 - Classe de agressividade ambiental (CAA).

Classe de agressividade ambiental	**Agressividade**	**Classificação geral do tipo de ambiente para efeito de projeto**	**Risco de deterioração da estrutura**
I	Fraca	Rural	Insignificante
		Submerso	
II	Moderada	Urbano	Pequeno
III	Forte	Marinho	Grande
		Industrial	
IV	Muito forte	Industrial	Elevado
		Respingos de maré	

Fonte: Extraído da NBR 6118 (ABNT, 2026).

Cada uma dessas categorias reflete diferentes níveis de concentração de poluentes, de umidade e de partículas em suspensão, afetando diretamente a taxa de entrada de CO_2. Atmosferas industriais e urbanas densas, por exemplo, são frequentemente associadas a elevadas concentrações de CO_2, além de apresentarem maior presença de outros agentes e uma combinação de fatores ambientais potencialmente agressivos.

Para determinação do cobrimento das estruturas, a norma de referência é a NBR 6118 (ABNT, 2026). Como se pode ver na Tabela 1, é possível avaliar a intensidade da agressividade em função do ambiente. Tal classificação de agressividade é aplicada na Tabela 2, auxiliando projetistas a elaborarem estruturas que atendam à vida útil de projeto prevista na NBR 15575 (ABNT, 2013).

Tabela 2 - Cobrimento do concreto em função da classe de agressividade ambiental.

Tipo de estrutura	**Componente ou elemento**	**Classe de agressividade ambiental**			
		I	II	III	IV
		Cobrimento nominal mm			
Concreto armado	Laje	20	25	35	45
	Viga/pilar	25	30	40	50
	Elementos estruturais em contato com o solo	30		40	50
Concreto protendido	Laje	25	30	40	50
	Viga/pilar	30	35	45	55

Fonte: Extraído da NBR 6118 (ABNT, 2026).

2.1.4 Fatores que influenciam na difusão de CO_2 no concreto

A carbonatação do concreto é um dos processos químicos mais relevantes de deterioração das estruturas cimentícias e ocorre majoritariamente por difusão de dióxido de carbono por meio dos poros da matriz. No campo da durabilidade, os mecanismos de deterioração podem ser classificados em quatro grupos principais: químicos, físicos, biológicos e mecânicos (Bolina; Tutikian; Helene, 2019). No caso da carbonatação, trata-se de um mecanismo químico, pois envolve reações entre agentes externos (CO_2 atmosférico) e os compostos hidratados do concreto, como a portlandita.

Diversos fatores podem influenciar o processo de carbonatação no concreto, afetando diretamente sua velocidade. Eles incluem tanto características intrínsecas do material quanto condições externas de exposição da estrutura.

Entre os parâmetros do concreto, destacam-se essencialmente a sua porosidade e o pH da matriz cimentícia, sendo afetados por sua vez pela composição química, relação água/cimento, o uso de adições minerais e a resistência à compressão. Já entre os fatores ambientais, exercem grande influência a concentração de CO_2 na atmosfera, a umidade relativa do ar, a presença ou ausência de proteção contra chuva, a quantidade de precipitação, a temperatura e até mesmo as condições de carregamento. Todos esses elementos estão entre os mais relevantes para o transporte e a difusão do gás carbônico no meio cimentício (Ferreira, 2013; Henriques; Tavares; Terceiro Neto, 2023; Tong; Cai; Liu, 2024; Torres-Acosta *et al.*, 2024).

2.1.4.1 Umidade relativa do ar e proteção e incidência de chuvas

De acordo com Elsalamawy, Mohamed e Kamal (2019), a água atua como um meio de transporte para o dióxido de carbono por meio dos poros do concreto. Com isso, tanto a umidade relativa quanto a incidência de chuvas estão diretamente relacionadas ao processo de carbonatação.

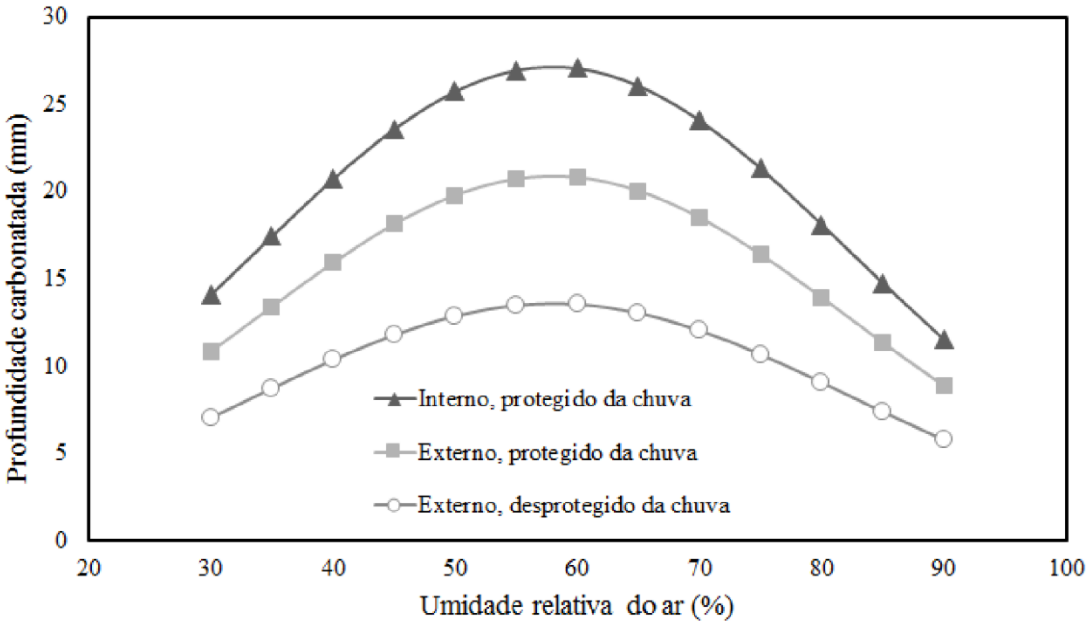
É interessante notar que não é a umidade relativa do ar, nem a maior nem a menor, que favorece o processo de carbonatação, mas sim uma faixa específica de umidade. Segundo Hou *et al.* (2025), enquanto poros completamente saturados inibem o processo de entrada do CO_2 do concreto, poros completamente secos

também desfavorecem a carbonatação, visto que o CO_2 não terá um meio de transporte dentro da matriz cimentícia.

A faixa de umidade indicada por Verbeck (1958) para uma aceleração da carbonatação está próxima de 50%. Para Liu, Chen e Yu (2020), os valores ficam entre 60% e 80%. No estudo de Felix, Carrazedo e Possan (2017), o valor de 60% é tido como aquele que mais favorece a entrada do CO_2 atmosférico, como pode ser conferido na Figura 8.

Do mesmo modo que a umidade, as precipitações afetam diretamente a quantidade de água nos poros do concreto, o que, por consequência, afeta o processo de carbonatação, como também é possível verificar na Figura 8. Nesse sentido, tanto a intensidade de chuvas ao longo do tempo como a maneira como uma estrutura são exposta a esse evento climático impactam essa questão.

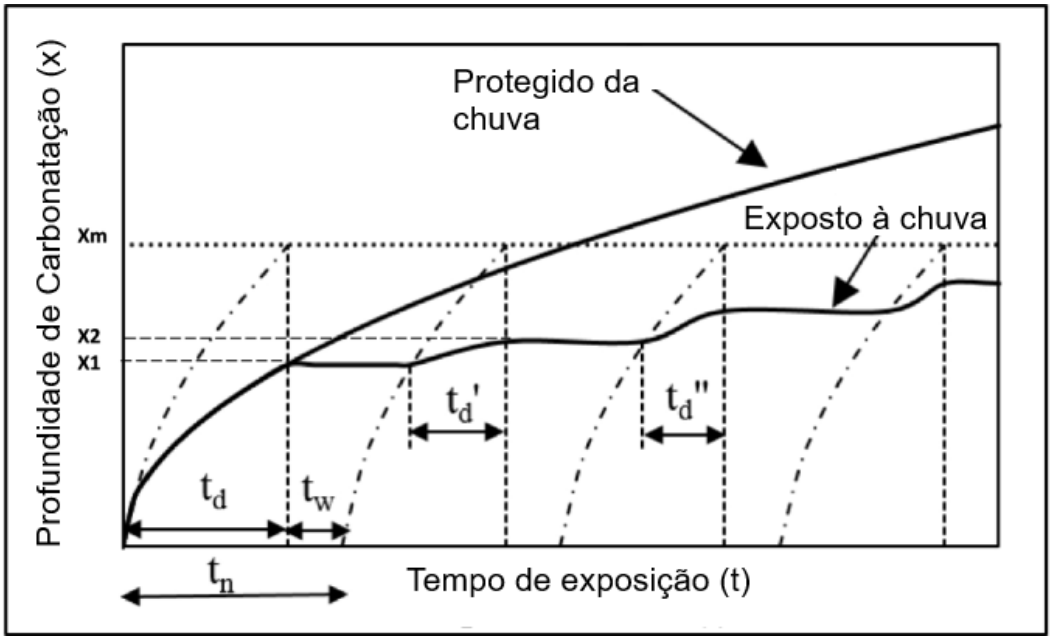
Figura 8 - Carbonatação em função da umidade e ambiente de exposição.



Fonte: Felix, Carrazedo e Possan (2017).

No estudo de Bakker (1988), um modelo de carbonatação foi desenvolvido considerando ciclos de molhagem e secagem, cuja abordagem embasou outros estudos, como o de Thiery, Cremona e Baroghel-Bouny (2012). Uma síntese desse estudo, no escopo da influência das chuvas na carbonatação, é apresentada na Figura 9.

Figura 9 - Esquema ilustrativo para a influência dos ciclos de molhagem e secagem na carbonatação.



Fonte: Adaptado de Thiery, Cremona e Baroghel-Bouny (2012).

Em que:

- t_d, t_d', t_d'' = períodos de seca a cada ciclo;
- t_w = período úmido;
- t_n = período de ciclo úmido/seco;
- X_1 = profundidade de carbonatação após o primeiro ciclo;
- X_2 = profundidade de carbonatação após o segundo ciclo;
- X_m = profundidade de carbonatação máxima.

Como se pode verificar, a carbonatação ocorre mais rapidamente quando o concreto está protegido da chuva. Por outro lado, estruturas constantemente molhadas (ou saturadas) têm um processo de carbonatação desacelerado.

É possível citar ainda o estudo de Gopinath, Alexander e Beushausen (2025), que modelaram analiticamente a carbonatação do concreto levando em conta principalmente fatores ambientais. Corroborando com os autores anteriores, os últimos reforçam que, quando um elemento estrutural está protegido da chuva, em especial em ambientes internos, e em equilíbrio com a umidade do ar, a taxa de carbonatação é maior. Por outro lado, para um elemento exposto diretamente à chuva,

a taxa de carbonatação é menor, devendo-se principalmente ao fato de que a saturação completa dos poros do material inibe a permeação do CO_2.

2.1.4.2 Concentração de CO_2

Outro fator determinante para o processo de carbonatação é a concentração de CO_2, que é diretamente proporcional à velocidade do processo. Como pode ser visto nos próximos parágrafos, a concentração de CO_2 é muitas vezes tida como um dos principais fatores de impacto dentre todos os estudados, sendo geralmente mais elevada em ambientes urbanos e com baixa ventilação, como estacionamentos fechados (Verbeck, 1958).

No estudo de Ghanooni-Bagha, YekeFallah e Shayanfar (2020), é feita uma análise probabilística de durabilidade de estruturas, considerando diferentes cenários futuros até o ano de 2100. Os autores variaram a concentração de CO_2 de acordo com diferentes níveis de uso de combustíveis fósseis na sociedade, indicando, em sua conclusão, que pequenos incrementos no cobrimento das armaduras reduzem a probabilidade de despassivação, especialmente em cenários mais pessimistas de poluição ambiental.

Seguindo a mesma ideia, Bueno *et al.* (2024) desenvolveram uma avaliação dos impactos das mudanças climáticas sobre a vida útil de estruturas de concreto armado. Com base em séries históricas, os autores projetaram os níveis futuros de CO_2 e aplicaram um modelo preditivo inovador, que combina redes neurais artificiais e simulações de Monte Carlo. Por fim, verifica-se que pequenas variações atmosféricas não comprometem significativamente a durabilidade das estruturas, enquanto tendências persistentes impactam a vida útil delas.

Ainda é possível citar Kazemi (2024) que aplica um modelo híbrido de redes neurais, com otimização de hiperparâmetros baseada em biogeografia, para a predição de carbonatação em concreto armado. Analisando seis variáveis de entrada, os autores concluem que a concentração de CO_2 é uma das mais influentes no processo estudado, ficando atrás apenas do tempo de exposição e à frente da relação água-aglomerante, por exemplo.

2.1.4.3 Temperatura

A temperatura se coloca como mais um fator que pode intensificar ou mitigar a carbonatação do concreto. Apesar de ser indicada como um dos fatores com menor impacto na carbonatação (Papadakis; Vayenas; Fardis, 1991), a temperatura é objeto de estudo em pesquisas na área e está presente na Equação de Arrehnius (Equação (9)) para determinação do coeficiente de difusão de gases em um meio sólido, que pode ser usada para descrever o processo em questão (Atkins; Paula; Keeler, 2018).

$$k = Ae^{-E_a/RT} \tag{9}$$

Em que k é a velocidade da reação (no caso, o transporte do CO_2 através dos poros do concreto), A é a constante de frequência, E_a é a energia de ativação da reação, R é a constante universal dos gases e T é a temperatura.

Avaliando o impacto de diversas variáveis ambientais no processo de carbonatação, Xu *et al.* (2022) realizam uma síntese sobre os mecanismos exercidos pela temperatura na carbonatação. De acordo com os autores, num contexto de temperaturas elevadas, ao mesmo tempo em que há diminuição da solubilidade de íons de cálcio e do CO_2 e inibição da reação de carbonatação, existe também uma intensificação do processo pelo aumento do vapor d'água nos poros do concreto e pela taxa de difusão do CO_2. Com a revisão de literatura desenvolvida, entretanto, é relatada a ausência de conclusões consistentes sobre os efeitos da temperatura no processo em questão, apesar dos mecanismos detalhados.

O impacto da temperatura é ressaltado por Uwanuakwa (2021), sendo indicada como responsável pelo aumento da energia cinética das moléculas e, por consequência, pelo aumento da velocidade da reação em questão. Nesse sentido, o autor indica que a correlação entre a temperatura e a carbonatação é diretamente proporcional.

Seguindo a mesma linha, Majlesi *et al.* (2023) utilizam a temperatura como um dos parâmetros de entrada no modelo desenvolvido em seu estudo. De acordo com os autores, seu impacto reside no fato de que, mesmo sob umidades elevadas, estruturas podem permanecer suficientemente secas quando expostas a altas

temperaturas, o que facilita a entrada de CO_2 e reforça a importância da interação entre a temperatura e a água presente nos poros do concreto.

2.1.4.4 Resistência à compressão e relação água-aglomerante

Estando diretamente ligadas entre si e à porosidade do concreto, a resistência à compressão e a relação água-aglomerante têm se mostrado entre os principais fatores de influência sobre a taxa de carbonatação de estruturas de concreto armado. A seguir, é possível constatar a forte correlação entre essas grandezas e o processo em estudo.

No estudo de Kazemi (2024), foi desenvolvido um modelo híbrido de predição da carbonatação em concretos com adição de cinzas volantes, combinando redes neurais com otimização baseada em biogeografia. Nesse contexto, o autor destaca a relevância da relação água-aglomerante como parâmetro de entrada, sendo ela “considerada uma variável essencial na modelagem” e com forte influência sobre a profundidade de carbonatação, superada apenas pelo tempo de exposição e pela concentração de CO_2. A rede neural de melhor desempenho contou com uma única camada oculta de 16 neurônios e considerou fatores como o teor de cinzas volantes, o teor de cimento, a umidade relativa e o tempo de exposição.

No mesmo sentido, Felix *et al.* (2024) integraram RNAs com simulações probabilísticas de Monte Carlo para prever a profundidade de carbonatação tendo como parâmetros de entrada, dentre diversas variáveis intrínsecas ao material e ao ambiente, a relação água-aglomerante e a resistência à compressão. Na análise de correlação dos parâmetros de entrada, observa-se que tanto o primeiro quanto o segundo apresentam correlação moderada com a profundidade de carbonatação, com influências muito semelhantes entre si e atrás apenas do tempo de exposição.

No estudo de Felix e Carrazedo (2021), foi mesclado aprendizado de máquinas com simulações probabilísticas de Monte Carlo para descrever a difusão do CO_2 em lajes de concreto armado e sua capacidade portante após a iniciação da corrosão das armaduras. As variáveis aleatórias aplicadas nas simulações probabilísticas foram a umidade relativa do ar, o teor de dióxido de carbono, a resistência à compressão e o cobrimento nominal da armadura, sendo a resistência à

compressão uma das de maior sensibilidade frente à falha por flexão nas estruturas sob corrosão por carbonatação.

A resistência à compressão também se mostrou relevante para a durabilidade de pontes de concreto armado contra a fissuração induzida pela carbonatação. Isso pode ser verificado no trabalho de Sun *et al.* (2020), que aprimoraram modelos preditivos tanto da carbonatação do concreto quanto da corrosão do aço.

2.1.4.5 Composição química do aglomerante e adições minerais

Um fator intrínseco ao material que se destaca entre os principais influenciadores da carbonatação é a composição química do cimento, incluindo o tipo de cimento Portland empregado. Diversos trabalhos também relatam o impacto do uso de adições minerais na composição das misturas, com o objetivo de substituir parcialmente o cimento tradicional e produzir concretos mais sustentáveis (Huy Vu *et al.*, 2019; Malami *et al.*, 2024; Witkowski; Koniorczyk, 2020). Entre essas adições estão a sílica ativa, escória de alto-forno, cinzas volantes, fíler calcário, entre outros materiais pozolânicos.

Apesar de trazerem benefícios ambientais e técnicos, essas substituições também podem impactar negativamente a durabilidade frente à carbonatação. Isso ocorre porque tais adições tendem a consumir maiores quantidades de hidróxido de cálcio nas reações pozolânicas, o que resulta em uma redução significativa do pH dos poros do concreto. Essa queda no pH facilita a difusão do dióxido de carbono no meio cimentício, acelerando o processo de carbonatação (Lu *et al.*, 2018; Saillio *et al.*, 2021; Von Greve-Dierfeld *et al.*, 2020).

O tipo de material aglomerante e as adições minerais são relatados de diferentes maneiras na literatura existente, ora explicitamente separados, ora confundidos como uma coisa só. De um jeito ou de outro, a influência da substituição de parte do cimento Portland por aglomerantes alternativos e da variação do tipo de cimento Portland tradicional tem sido investigada ao longo dos últimos anos por diversos autores (Bueno *et al.*, 2024; Felix; Possan; Carrazedo, 2019; Marani; Oyinkanola; Panesar, 2024; Uwanuakwa, 2021).

Na Tabela 3, é possível conferir os tipos de cimento Portland comercializados de acordo com suas respectivas adições minerais. Do mesmo modo, é possível verificar na Tabela 4 os limites de composição e, na Tabela 5, os requisitos químicos para cada tipo. Essas tabelas foram todas retiradas da NBR 16697 (ABNT, 2018).

No estudo de Marani, Oyinkanola e Panesar (2024), um modelo de aprendizado profundo de máquinas é desenvolvido tendo como parâmetros de entrada, dentre outros, os teores de óxido de cálcio, óxido de ferro, sílica e óxido de alumínio de diversos tipos de cimento e suas respectivas adições minerais, como escória de alto-forno, cinzas volantes e fíler calcário, com uma proporção de substituição do cimento de até 60%. Os autores indicam, em diversas ocasiões, que o aumento da proporção de substituição do cimento Portland por materiais suplementares provoca, de forma consistente, a aceleração do processo de carbonatação.

Ainda de acordo com os autores, níveis de substituição acima de 20% contribuem significativamente para a aceleração da carbonatação, enquanto níveis moderados podem promover o refinamento dos poros e mitigar parcialmente a permeação do dióxido de carbono. Isso pode ser explicado pelo fato de que os produtos da hidratação do cimento como hidróxido de cálcio (CH) e silicato de cálcio hidratado (CSH) atuam como agentes tamponantes ao reagir com CO_2, aumentando a resistência à carbonatação. Quando há a substituição do cimento Portland, o teor de clínquer, fonte de CH, é reduzido, além da ativação de reações pozolânicas que consomem esse composto (Sisomphon; Franke, 2007).

No estudo de Elsalamawy, Mohamed e Kamal (2019), a variação entre CEM I 42.5N e CEM III/A 42.5 N é investigada. Os autores, além de explicitarem as diferenças de composição química entre os dois tipos, reforçam como o tipo de cimento impacta diretamente a resistência à carbonatação do concreto e os efeitos que variações na composição química do cimento têm sobre a absorção de água, a resistência à compressão e, consequentemente, a carbonatação.

Tabela 3 - Siglas e classes do cimento Portland.

Designação normalizada (tipo)	Subtipo	Sigla	Classe de resistência	Sufixo
Cimento Portland comum	Sem adição	CP-I	25, 32 ou 40	RS ou BC
	Com adição	CP I-S		
Cimento Portland composto	Com escória granulada de alto forno	CP II-E		
	Com material carbonatático	CP II-F		
	Com material pozolânico	CP II-Z		
Cimento Portland de alto forno		CP III		
Cimento Portland pozolânico		CP IV		
Cimento Portland de alta resistência inicial		CP V	ARI	
Cimento Portland branco	Estrutural	CPB	25, 32 ou 40	
	Não Estrutural	CPB	-	-

Fonte: Extraído da NBR 16697 (ABNT, 2018).

Tabela 4 - Limites de composição química do cimento Portland.

Designação normalizada		Sigla	Classe de resistência	Sufixo	Clínquer + sulfatos de cálcio	Escória granulada de alto-forno	Material pozolânico	Material carbonático
Cimento Portland comum		CP I	25, 32 ou 40	RS ou BC	95 – 100	0 – 5		
		CP I-S			90 – 94	0	0	6 – 10
Cimento Portland composto com escória granulada de alto-forno		CP II-E			51 – 94	6 – 34	0	0 – 15
Cimento Portland composto com material pozolânico		CP II-Z			71 – 94	0	6 – 14	0 – 15
Cimento Portland composto com material carbonático		CP II-F			75 – 89	0	0	11 – 25
Cimento Portland de alto forno		CP III			25 – 65	35 – 75	0	0 – 10
Cimento Portland pozolânico		CP IV			45 – 85	0	15 – 50	0 – 10
Cimento Portland de alta resistência inicial		CP V	ARI		90 – 100	0	0	0 – 10
Cimento Portland branco	Estrutural	CPB	25, 32 ou 40		75 – 100	-	-	0 – 25
	Não estrutural		-	-	50 – 74	-	-	26 – 50

Fonte: Extraído da NBR 16697 (ABNT, 2018).

Tabela 5 - Requisitos químicos do cimento Portland.

Sigla	Resíduo insolúvel (RI)	Perda ao fogo (PF)	Óxido de magnésio (MgO)	Trióxido de enxofre (SO_3)
CP I	≤ 5,0	≤ 4,5	≤ 6,5	4,5
CP I-S	≤ 3,5	≤ 6,5	≤ 6,5	4,5
CP II-E	≤ 5,0	≤ 8,5	-	4,5
CP II-Z	≤ 7,5	≤ 12,5	-	4,5
CP II-F	≤ 18,5	≤ 8,5	-	4,5
CP III	≤ 5,0	≤ 6,5	-	4,5
CP IV	-	≤ 6,5	-	4,5
CP V	≤ 3,5	≤ 6,5	≤ 6,5	4,5
CPB Estrutural	≤ 3,5	≤ 12,0	≤ 6,5	4,5
CPB Não estrutural	≤ 7,0	≤ 27,0	≤ 10,0	≤ 4,5

Fonte: Extraído da NBR 16697 (ABNT, 2018).

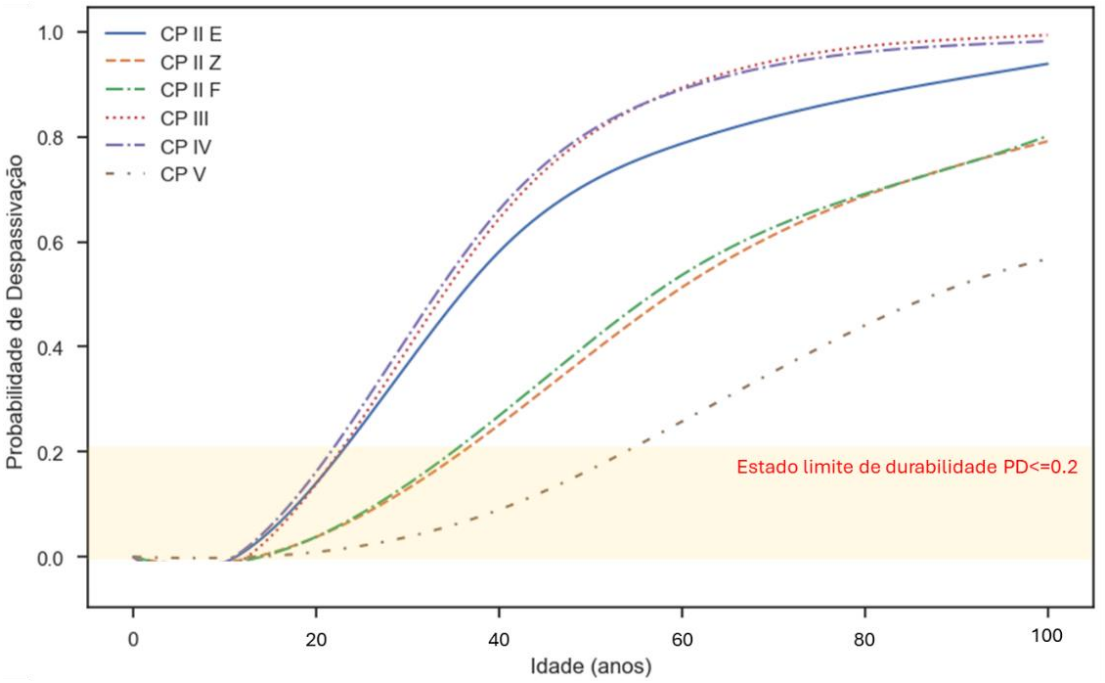
Ao mesmo tempo, Bueno *et al.* (2024) compararam, dentre outros fatores, diversos tipos de cimento, com ênfase em suas respectivas proporções de clínquer e gesso, e diversos tipos de adições minerais, como escória de alto-forno, cinzas volantes, fíler calcário, sílica ativa e outros materiais pozolânicos. Aplicando simulações de Monte Carlo em uma estrutura real na cidade de Foz do Iguaçu-PR e extrapolando os resultados para um cenário futuro, os autores explicitam como estruturas que contêm CP II, III e IV têm uma probabilidade de despassivação consideravelmente maior quando comparadas àquelas que contêm CP V, que tem maior teor de clínquer e gesso.

Esse comportamento pode ser explicado pelo fato do clínquer ser a principal fonte de C-S-H e CH, formando esses compostos ao ser hidratado, que atuam refinando a microestrutura e fechando os poros da matriz cimentícia. O gesso, por sua vez, contribui para a formação inicial de etringita, auxiliando também no refinamento dos poros nas idades iniciais, dificultando o processo de carbonatação (Reddy; Melaku; Park, 2022; Von Greve-Dierfeld *et al.*, 2020).

Na Figura 10, é possível verificar os resultados do estudo de caso desenvolvido e avaliar a relevância das diferentes composições químicas do cimento no processo de carbonatação. De modo semelhante, Felix, Possan e Carrazedo (2019) realizaram uma busca pela otimização de hiperparâmetros de redes neurais artificiais aplicadas à carbonatação de estruturas de concreto, tendo o tipo de cimento como parâmetro de entrada. Os autores caracterizam, entretanto, os tipos de cimento de acordo com suas adições, e não de acordo com seu teor de clínquer e gesso. Apesar de não haver contraste explícito entre as profundidades nominais de

carbonatação de cada tipo de cimento, o estudo reforça a relevância da consideração dessa variável de entrada em modelos numéricos de predição.

Figura 10 - Probabilidade de despassivação de estrutura em função do tipo de cimento Portland.



Fonte: Bueno *et al.* (2024).

No mesmo sentido, Uwanuakwa (2021) desenvolveu um modelo de aprendizado profundo com redes neurais recorrentes para predição da profundidade de carbonatação em concretos com adição de cinzas volantes em diferentes proporções. Nos dados de entrada usados no modelo, dentre outros, constam a composição química tanto do Cimento Portland quanto das cinzas volantes, assim como a proporção de cada um dos aglomerantes. Ao descrever a sensibilidade das predições, o autor ressalta que o conteúdo e composição do aglomerante é um dos principais parâmetros de influência no processo de estudo, com destaque para o teor de óxido de cálcio (CaO) do Cimento Portland.

2.2 MÉTODOS DE PREDIÇÃO DA VIDA ÚTIL DE PROJETO

Tendo em mente o fenômeno da corrosão por carbonatação e, em especial, a carbonatação descrita até aqui, é perceptível a importância de se possuir modelos

que retratem de maneira mais realista o avanço desses mecanismos. Ao longo dos anos, diversos pesquisadores desenvolveram métodos para prever a profundidade de carbonatação e a evolução da corrosão do aço imerso no concreto.

Nesse contexto, as seções 2.2.1 e 2.2.2 se aprofundam em diferentes metodologias de modelagem aplicadas por pesquisadores para determinar a despassivação do aço pela carbonatação e, assim, a vida útil de projeto. Dentre as principais classificações dessas técnicas, estão a modelagem analítica (Ekolu, 2018; Possan, 2010; Tuutti, 1982), que se embasa em leis físicas clássicas de transporte de massa, e modelagem numérica (Cabrera, 1996; Maruya *et al.*, 2003; Shodja; Kiani; Hashemian, 2010; Teodoro; Carrazedo, 2024; Yu *et al.*, 2017) que destaca técnicas computacionais aplicadas à resolução do fenômeno completo da corrosão das armaduras. Além disso, pode-se classificar os modelos em determinísticas (Ngo *et al.*, 2021; Papadakis; Vayenas; Fardis, 1991; Ta *et al.*, 2016), que considera valores fixos para as variáveis, o que permite análises mais diretas, e modelos probabilísticos (Felix *et al.*, 2023; Šomodíková *et al.*, 2016; Stewart; Rosowsky, 1998; Wang *et al.*, 2019), que incorpora a variabilidade inerente aos parâmetros em estudo, como as variáveis climáticas e as dos materiais.

2.2.1 Modelos analíticos e empíricos

Alguns autores propõem formulações matemáticas, desenvolvendo equações que consideram variáveis modeladas de acordo com o esforço experimental da comunidade científica. Essas funções relacionam parâmetros atmosféricos e do material para fornecer a taxa de carbonatação desejada.

2.2.1.1 Modelo de Tuutti

O modelo de Tuutti (1982) descreve a penetração do CO_2 no concreto, baseando-se na difusão de um gás no meio poroso, conforme a Equação (10).

$$y = k\sqrt{t} \tag{10}$$

Em que:

- y = profundidade de carbonatação (mm);

- k = taxa de carbonatação (mm/ano^{0,5});
- t = tempo de exposição (anos).

Essa equação consiste numa simplificação, isto é, não captura todas as nuances da carbonatação sob diferentes condições, essencialmente pela dificuldade de determinação do coeficiente k. Nesse sentido, a comunidade científica passou a buscar formas alternativas de descrever o fenômeno, correlacionando a taxa de carbonatação com parâmetros intrínsecos ao material.

2.2.1.2 Modelo de Smolczyk

Na Equação (11) está descrita a profundidade de carbonatação para uma estrutura de concreto em função da resistência à compressão e do tempo de exposição, que é o modelo proposto por Smolczyk (1976).

$$y = a.\left(\frac{1}{\sqrt{f_c}} - \frac{1}{\sqrt{f_{clim}}}\right).\sqrt{t} \qquad (11)$$

Em que:

- y = profundidade de carbonatação (mm);
- a = velocidade de carbonatação (mm/semana^{0,5});
- fc = resistência à compressão do concreto (kgf/cm²);
- f_{clim}= valor limite da resistência à compressão do concreto que pode ser carbonatada (kgf/cm²);
- t = tempo de exposição (semanas).

Nesse modelo, em contraste com o modelo de Tuutti (1982), a resistência à compressão é um fator relevante para o fenômeno descrito. No entanto, assim como o mesmo modelo anterior, onde precisa-se que seja determinado o coeficiente k, o modelo de Smolczyk (1976) tem como principal impasse a determinação da velocidade de carbonatação a.

2.2.1.3 Modelo de Vesikari

O modelo de Vesikari (1988) busca a determinação do coeficiente k de modo a complementar o modelo de Tuutti (1982). Na Equação (12), é possível identificar que o autor se baseia na relação água-cimento:

$$k = 26.(ac - 0{,}3)^2 + 1{,}6 \quad (12)$$

Em que:

- k = taxa de carbonatação (mm/ano^{0,5});
- ac = relação água-cimento (no domínio de 0,45 a 0,75).

O autor ainda salienta a necessidade de majorar o coeficiente k, de acordo com o ambiente de exposição da estrutura.

2.2.1.4 Modelo de Papadakis, Vayenas e Fardis

O modelo desenvolvido por Papadakis, Vayenas e Fardis (1991) apresenta traços de maior complexidade, ao mesmo tempo em que proporcionou maior precisão do que os demais modelos da época, conforme se vê na Equação (13).

$$y = \sqrt{\frac{2D_{CO_2}[CO_2]^0}{[Ca(OH)_2]^0 + 3[CSH]^0 + 3[C_3S]^0 + 2[C_2S]^0}\,t} \quad (13)$$

Em que:

- y = profundidade de carbonatação (m);
- CO_2 = concentração molar do CO_2 (mol/m³);
- D_{CO_2} = coeficiente de difusão efetivo do CO_2 no material carbonatado (m²/s);
- $Ca(OH)_2$ e CSH = concentração molar dos hidratos (mol/m³);
- C_3S e C_2S = concentração molar dos anidros (mol/m³);
- Índice 0 (zero): indica concentrações iniciais.

Com esse modelo, pela primeira vez foi possível calcular a taxa de carbonatação k de Tuutti (1982).

2.2.1.5 Modelo de Bob e Afana

O modelo de Bob e Afana (1993) foi desenvolvido com base em uma campanha experimental e pode ser consultado na Equação (14).

$$y = 150.\left(\frac{c.k.d}{f_c}\right).\sqrt{t} \quad (14)$$

Em que:

- y = profundidade de carbonatação (mm);
- c = coeficiente do tipo de cimento;
- k = coeficiente dependente da umidade relativa do ar;
- d = coeficiente referente à quantidade de CO_2;
- f_c = resistência média à compressão (MPa);
- t = tempo (anos);

Os autores descreveram a profundidade de carbonatação em função do tipo de cimento, da umidade relativa do ar, da resistência à compressão e do teor de CO_2. Com isso, percebe-se a consideração de mais variáveis e de modo diferente daquele adotado por Papadakis, Vayenas e Fardis (1991).

2.2.1.6 Modelo de EHE

No modelo definido pela norma EHE-08 (2010), exposto na Equação (15), há a consideração da presença de ar nos poros da matriz cimentícia do concreto. Essa variável não havia sido utilizada nos modelos anteriormente propostos.

$$y = C_{amb}.C_{ar}.a.f_{cm}^{b}.\sqrt{t} \quad (15)$$

Em que:

- y = profundidade de carbonatação (m);
- f_{cm} = resistência média à compressão (Mpa);
- C_{amb} = coeficiente do ambiente;

- C_{ar} = coeficiente do ar incorporado;
- a, b = parâmetros em função do tipo de aglomerante.

É notável a semelhança com o modelo de Tuutti (1982), de modo que o modelo da norma em questão seja uma versão em que o cálculo da taxa de carbonatação é explicitado pelo produto dos quatro primeiros fatores do segundo membro da Equação (15).

2.2.1.7 Modelo de Possan

A formulação proposta por Possan (2010), exposta na Equação (16), leva em conta uma diversa lista de fatores que podem, de acordo com a autora, influenciar no processo de carbonatação.

Em contraste com os modelos anteriores, observa-se uma combinação de parâmetros relacionados ao tipo de cimento e suas adições, tipo de exposição à chuva e demais variáveis atmosféricas. Esses fatores não haviam sido todos combinados simultaneamente para descrição do fenômeno até então.

$$y = k_c.\left(\frac{20}{f_c}\right)^{k_{fc}}.\left(\frac{t}{20}\right)^{\frac{1}{2}}.exp\left[\left(\frac{k_{ad}.ad^{\frac{3}{2}}}{40+f_c}\right)+\left(\frac{k_{CO_2}.CO_2^{\frac{1}{2}}}{60+f_c}\right)-\left(\frac{k_{UR}.(UR-0{,}68)^2}{100+f_c}\right)\right].k_{ce} \quad (16)$$

Em que:

- y = profundidade de carbonatação (mm);
- f_c = resistência média à compressão (MPa);
- k_c = fator dependente do tipo de cimento;
- k_{fc} = fator de resistência à compressão do concreto, em função do cimento;
- t = tempo (anos);
- ad = teor de adição pozolânica no concreto (% em relação à massa do concreto);
- k_{ad} = fator dependente das adições, em função do cimento
- UR = umidade relativa do ar (%*0,01);
- k_{UR} = fator dependente da umidade relativa do ar, em função do cimento;

- CO_2 = teor de dióxido de carbono no ambiente (%);
- k_{CO_2} = fator dependente do teor de dióxido de carbono, em função do cimento;
- k_{ce} = fator dependente do ambiente de exposição (protegido ou desprotegido), em função das condições de exposição do concreto.

2.2.1.8 Modelo de Ekolu

O modelo de Ekolu (2018), por sua vez, tem embasamento em funções matemáticas que consideram a influência tanto da composição do concreto quanto das condições ambientais de exposição da estrutura, como se pode verificar na Equação (17).

$$y = e_h . e_s . e_{co} . cem\left(F_{c(t)}\right)^g . \sqrt{t} \quad (17)$$

Em que:

- y = profundidade de carbonatação (mm);
- e_h = coeficiente de umidade relativa;
- e_s = coeficiente de condição de exposição a chuva;
- e_{co} = coeficiente da concentração de CO_2;
- cem = fator escalar do cimento;
- g = fator de condutância do cimento;
- $F_{c(t)}$ = função de crescimento da resistência do concreto;
- t = tempo (anos).

O desenvolvimento da formulação e sua calibração utilizaram resultados de um estudo de 10 anos de carbonatação sob condições de degradação natural em ambientes externos (protegidos ou desprotegidos da chuva).

2.2.1.9 Modelo de Liu, Yu e Chen

Outro modelo de predição baseado em campanha experimental é o de Liu, Yu e Chen (2020). Os autores realizaram experimentos de carbonatação acelerada e sintetizaram os resultados na Equação (18), levando em conta a quantidade de

aglomerante e suas adições, assim como condições atmosféricas de temperatura, umidade e concentração de CO_2.

$$y = K_x.\left(\frac{w}{c} - 0.106\right).(C_e^2 - 508.351\,.C_e - 1195.624).(F + 112.460).(T - 277.662).\left(C_d^{0.538}\right).(RH^2 - 125.410RH + 2351.806).\sqrt{t} \quad (18)$$

Em que:

- y = profundidade de carbonatação (mm);
- C_e = teor de cimento (kg/m³);
- F = teor de aditivo (kg/m³);
- T = temperatura de carbonatação (Kelvin);
- C_d= concentração de CO_2 (%);
- RH = umidade relativa (%).

2.2.2 Modelagem numérica

Ao longo das últimas décadas, diferentes autores propuseram modelos numéricos voltados especificamente para representar o processo de carbonatação em estruturas de concreto armado, com avanços progressivos nas abordagens adotadas.

Como exemplo, Papadakis, Vayenas e Fardis (1991) apresentaram resultados experimentais de termogravimetria de corpos de prova submetidos à carbonatação acelerada. A partir desses experimentos, expandiram um modelo matemático para abranger diferentes condições de umidade relativa do ar, embora sem considerar a variabilidade estocástica dos parâmetros envolvidos.

Posteriormente, Bary e Sellier (2004) analisaram a carbonatação considerando a evolução da umidade relativa no material poroso. O modelo, baseado em equações de balanço de massa, descreveu processos de difusão e permeabilidade da água, do dióxido de carbono na fase gasosa e do cálcio dissolvido na solução dos poros, permitindo estimar a profundidade de carbonatação ao longo do tempo.

No trabalho desenvolvido por Lu e Liu (2009), foram propostas duas redes neurais artificiais para previsão da profundidade de carbonatação em concretos protendidos submetidos a diferentes níveis de tensão. A primeira é uma rede neural

de retropropagação e a segunda, uma rede neural de função de base radial. Para elaboração dos dados de teste e treinamento das ANNs, foi conduzido um experimento acelerado de carbonatação, no qual 19 amostras foram geradas. Ambos os modelos demonstraram alta capacidade de previsão e generalização, e os maiores erros percentuais absolutos foram de 10,88% para a rede neural de retropropagação e de 8,46% para a rede de base radial.

O estudo de Luo, Niu e Dong (2014) seguiu uma vertente similar. Foram desenvolvidas duas redes neurais diferentes: uma de retropropagação simples e outra otimizada com o algoritmo de enxame de partículas. Para treinamento, foram utilizados 30 dados de carbonatação acelerada, enquanto 5 amostras foram coletadas em uma ponte na China para validação. A rede otimizada apresentou desempenho superior, com erro relativo máximo de 3,5%, em comparação com 12,8% do modelo sem otimização.

Taffese, Sistonen e Puttonen (2015) propuseram modelos de previsão de carbonatação integrando quatro diferentes técnicas de aprendizado de máquina, a partir do projeto Finnish DuraInt. Foram aplicadas redes neurais artificiais, árvores de decisão e modelos ensemble (*bagged* e *boosted decision trees*). As redes neurais apresentaram melhor desempenho, com MSE de 0,2417, RMSE de 0,4916 e MAE de 0,2860.

Avanços nesse campo incluem o trabalho de Ta *et al.* (2016), que desenvolveram um metamodelo determinístico não numérico, fundamentado na Primeira Lei de Fick. O modelo foi aplicado exclusivamente a ensaios naturais de carbonatação, ressaltando que as taxas nesses ensaios são superiores às observadas em ensaios acelerados. Para simplificação, os autores assumiram uma frente de carbonatação bem definida, uma reação instantânea do CO_2 com o hidróxido de cálcio e a difusão em regime estacionário, destacando a importância futura de parâmetros estocásticos.

Yu *et al.* (2017) modelaram a carbonatação supercrítica em materiais cimentícios, incorporando variações aleatórias da porosidade. Foram utilizadas metodologias baseadas na função de densidade de probabilidade (PDF) e na função de autocorrelação elipsoidal (EAF), sendo esta última mais precisa para descrever frentes irregulares de carbonatação.

No mesmo ano, Pukl *et al.* (2017) combinaram elementos finitos não lineares com análises probabilísticas e redes neurais, calibrando os modelos com resultados experimentais. O objetivo foi prever a fissuração, a evolução do dano e a capacidade estrutural em diferentes concretos sujeitos à carbonatação.

No trabalho de Felix e Possan (2018), redes neurais artificiais foram aplicadas para previsão da profundidade de carbonatação em ambientes marítimos. Foram implementadas 91 redes Perceptron multicamadas, treinadas com dados coletados por Meira, Padaratz e Borba Junior (2006) em João Pessoa (PB). O melhor resultado atingiu RMSE de 0,130, R^2 de 0,973 e erro médio de 0,54 mm.

No estudo conduzido por Malami *et al.* (2021), diferentes métodos de inteligência artificial foram aplicados à modelagem da carbonatação, incluindo ANFIS, ELM, SVM e regressão multilinear. O banco de dados contou com 10 estruturas de concreto (interior e região costeira de Chipre), com idade máxima de 41 anos. O modelo ANFIS obteve os melhores resultados, com RMSE de 0,0238 e R^2 de 0,9997 na calibração, e RMSE de 0,2919 e R^2 de 0,9998 no teste.

Ngo *et al.* (2021), por sua vez, implementaram um modelo determinístico no software COMSOL Multiphysics, considerando dados climáticos reais de Toulouse (França). Foram simulados processos acoplados, como a penetração de CO_2, a difusão de íons de cálcio, as transferências de calor e a alteração da porosidade do concreto, embora os autores apontem limitações em cenários de longo prazo.

Ao mesmo tempo, Nunez e Nehdi (2021) propuseram um modelo de árvore de regressão por impulso de gradiente (GBRT) para estimar a profundidade de carbonatação em concretos com agregados reciclados e adições minerais. O banco de dados contou com 713 registros, atingindo R^2 de 0,9707 e RMSE de 1,5139 no teste.

Na mesma linha, Liu *et al.* (2021) desenvolveram e compararam modelos híbridos de redes neurais artificiais otimizados por diferentes algoritmos. O melhor desempenho foi obtido pelo modelo WOANN, otimizado com o Whale Optimization Algorithm, que alcançou R^2 de 0,947 e RMSE de 2,012.

No trabalho de Biswas *et al.* (2022), foram desenvolvidos modelos híbridos combinando regressão por vetores de suporte (SVR) com quatro algoritmos metaheurísticos: CSO, GWO, PSO e SOA. Utilizando 300 dados de carbonatação

acelerada, o modelo CSO-SVR foi o mais eficiente, alcançando R^2 de 0,9871 e MSE de 1,074 no treino, e R^2 de 0,9593 e MSE de 3,987 no teste.

Mais recentemente, De Domenico, Messina e Recupero (2022) integraram ensaios de campo e simulações numéricas para avaliação de tabuleiros de pontes em concreto. Ensaios de carbonatação, de ultrassom e de carregamento calibraram um modelo incremental não linear de elementos finitos.

No estudo de Huo, Wang e Huang (2023) foram desenvolvidos modelos híbridos ensemble de aprendizado de máquina para previsão da carbonatação, com banco de dados de 532 registros. O modelo baseado em variância inversa apresentou melhor desempenho, com $R^2 = 0,975$ e RMSE de 2,978 mm.

De modo semelhante, Kumar *et al.* (2023) propuseram um modelo híbrido 1D-CNN-LSTM, treinado com dados de carbonatação acelerada em laboratório. Os resultados indicaram R^2 de 0,800 e RMSE de 0,448 para a previsão da carbonatação, e R^2 de 0,960 e RMSE de 0,169 para a resistência à compressão.

Majlesi *et al.* (2023), por sua vez, aplicaram redes neurais artificiais em dados do projeto DURACON (10 países, até 8 anos de exposição). Após testar 8420 arquiteturas, o melhor modelo (3 camadas) obteve R^2 de 0,98 e RMSE de 3,027 na fase de teste.

Na sequência, Somodíková *et al.* (2023) propuseram metodologia de confiabilidade para pontes ferroviárias, acoplando análises numéricas não lineares e modelos analíticos de deterioração por carbonatação e crivastorrosão.

No mesmo ano, Zhang *et al.* (2023) desenvolveram modelos híbridos de LSSVM com algoritmos metaheurísticos para prever carbonatação em concretos com cinzas volantes, utilizando 500 dados experimentais. O melhor modelo (LSSVM + lobos cinzentos) alcançou R^2 de 0,9819 e RMSE de 1,7309.

Ainda em 2023, Zucca *et al.* (2023) analisaram os efeitos das mudanças climáticas sobre a carbonatação de viadutos rodoviários, considerando variáveis ambientais como temperatura, umidade e concentração de CO_2. Os resultados indicaram aceleração significativa do processo em cenários futuros.

Concha (2024) propôs um modelo de previsão da carbonatação em concretos com agregados reciclados, utilizando 445 dados de carbonatação natural e acelerada, com exposição máxima de 10 anos. O modelo 8-10-1 apresentou MSE de 2,00 e coeficiente de correlação de 0,97.

No Brasil, Nogueira, Yoshio e Zacchei (2023) abordaram o contexto de corrosão por ataque de cloretos em vigas de concreto armado. No estudo, os autores propuseram tanto uma abordagem determinística quanto uma probabilística para predição da perda de resistência a esforços cortantes e a momentos fletores, de modo a estimar a vida útil total dos elementos.

Teodoro e Carrazedo (2024) propuseram um modelo numérico baseado no Método dos Elementos Finitos Posicional (MEF-P) aplicado à corrosão induzida por carbonatação em vigas de concreto armado. O modelo considerou não linearidades físicas e geométricas, redução uniforme da seção das armaduras e os efeitos da carbonatação no concreto.

Dando continuidade, os mesmos autores (Teodoro; Carrazedo, 2025) analisaram o impacto das mudanças climáticas no contexto brasileiro, fundamentados na NBR 6118 (ABNT, 2023). Avaliaram estágios de deterioração, como despassivação e fissuração inicial, considerando diferentes espessuras de cobrimento e diâmetros de armaduras. Os resultados indicaram que um aumento de apenas 5 mm no cobrimento pode reduzir a probabilidade de despassivação em 20 anos em até 50%, enquanto o aumento do diâmetro das armaduras apresentou efeito ambíguo: maiores bitolas anteciparam a fissuração, mas reduziram a probabilidade de falha estrutural.

Recentemente, no estudo de Lavinicki *et al.* (2025) foi investigada a previsão da profundidade de carbonatação em concretos expostos a ambientes naturais de degradação por meio de técnicas de ensemble de aprendizado de máquina do tipo Stacking. A pesquisa utilizou um banco de dados com mais de 1000 medições de carbonatação e dez variáveis ligadas à composição do concreto e às condições ambientais. Inicialmente, 120 modelos individuais de redes neurais artificiais foram treinados; dos quais, os cinco melhores foram selecionados para compor o modelo ensemble. Os resultados mostraram que a abordagem Stacking superou os modelos individuais, alcançando um erro médio de 1,17 mm, com melhoria de 14% na precisão e de 91,4% na generalização em testes com dados inéditos. Como contribuição prática, os autores desenvolveram uma ferramenta computacional com interface gráfica, disponibilizada no site do grupo DASMAE, para apoiar engenheiros e projetistas nas avaliações de durabilidade e no aumento da vida útil de estruturas de concreto.

2.3 CONSIDERAÇÕES DO CAPÍTULO

A vida útil das estruturas de concreto armado constitui um amplo campo de pesquisa, impulsionado tanto pelas mudanças climáticas quanto pela importância do tema para a preservação e a evolução da sociedade. Entre os fatores mais estudados, destaca-se a carbonatação do concreto, fenômeno complexo que impacta diretamente a durabilidade das construções existentes e futuras.

Diversos modelos vêm sendo desenvolvidos para descrever esse processo ao longo do tempo, abrangendo formulações analíticas, abordagens probabilísticas e modelagens avançadas com elementos finitos e técnicas de aprendizado de máquinas. Enquanto os modelos probabilísticos tratam das incertezas inerentes aos sistemas estruturais e o MEF permite detalhar o comportamento do material, métodos mais complexos, como o aprendizado de máquinas, têm se mostrado promissores por lidarem com múltiplas variáveis e aprenderem a partir de grandes volumes de dados, oferecendo previsões mais robustas.

Essa evolução metodológica reflete não apenas um maior entendimento do fenômeno, mas também o avanço tecnológico observado nas primeiras décadas do século XXI. A integração de diferentes abordagens aumenta a confiabilidade das previsões e fortalece a engenharia como um todo.

Ainda assim, persistem desafios relevantes, sobretudo quanto à escassez de dados sobre a carbonatação de elementos de concreto em condições naturais, em idades avançadas (elementos com mais de 10 anos de exposição ao CO_2). Também deve ser destacada a incipiência de trabalhos que consideram o efeito da temperatura no mapeamento da carbonatação do concreto, especialmente quando se considera o efeito sinérgico da temperatura e da umidade, indicando que a continuidade das pesquisas experimentais e, em especial, de longa duração, é essencial para enriquecer os bancos de dados disponíveis e aprimorar as modelagens de longo prazo, consolidando previsões mais seguras.

3 MODELO DE PREDIÇÃO DA FRENTE DE CARBONATAÇÃO

Para a apresentação do modelo de predição da frente de carbonatação desenvolvido neste trabalho, faz-se necessário, em primeiro lugar, contextualizar o surgimento, a evolução e os fundamentos teóricos no campo do aprendizado de máquinas, em especial das redes neurais artificiais (RNAs).

O capítulo inicia com um panorama histórico das formulações e modelos que deram origem às primeiras abordagens na área e serviram de base para avanços posteriores no aprendizado de máquinas. Na sequência, apresenta-se uma revisão da literatura, reunindo os principais estudos das últimas décadas que utilizaram RNAs especificamente para mapear a carbonatação do concreto.

Em seguida, são detalhados os conceitos fundamentais que sustentam a estrutura e o funcionamento de uma RNA, como a noção de neurônio artificial, pesos sinápticos, topologias de rede, funções de ativação e algoritmos de aprendizado, com ênfase no algoritmo de retropropagação (*backpropagation*). A partir desses fundamentos, descreve-se o processo genérico de modelagem e otimização de RNAs, abrangendo as etapas de coleta e preparação dos dados, definição da arquitetura global, ajuste de hiperparâmetros e as principais métricas de avaliação de desempenho.

Na sequência, é apresentada a metodologia específica empregada neste estudo, destacando os procedimentos de coleta e tratamento de dados utilizados no treinamento, os critérios para a definição do domínio do modelo e a estratégia de busca por topologias mais adequadas. Os resultados obtidos são então discutidos, evidenciando a eficiência, a capacidade de generalização e a relevância do modelo proposto para o mapeamento da carbonatação em elementos de concreto.

3.1 BREVE HISTÓRICO DO APRENDIZADO DE MÁQUINAS E RNAS

Para compreender as redes neurais artificiais (RNAs), é necessário, inicialmente, apresentar o conceito de inteligência artificial (IA). A IA pode ser definida como a arte de se construir programas que se adaptem e aprendam (Vicari, 2018) ou como o estudo de como fazer computadores realizarem coisas que, atualmente, os humanos fazem melhor (Rich; Knight, 1993).

Segundo Russell e Norvig (2020), a IA abrange diferentes subáreas, como visão computacional, robótica, processamento de linguagem natural, IA generativa e aprendizado de máquina. O presente trabalho insere-se nesta última vertente.

No campo dos métodos numéricos de predição (descritos no item 2.2.2), o aprendizado de máquina representa um avanço significativo, pois permite não apenas modelar relações lineares, mas também capturar interações não lineares complexas entre variáveis. Com o uso de grandes bases de dados experimentais, tais algoritmos alcançam elevada precisão preditiva e apresentam flexibilidade para se adaptar a novas informações. É nesse contexto que se situam as RNAs (Haykin, 1999).

O desenvolvimento das RNAs remonta à década de 1940, mais precisamente a 1943, quando Warren McCulloch e Walter Pitts propuseram o primeiro modelo matemático inspirado no funcionamento dos neurônios biológicos (McCulloch; Pitts, 1943). Esse modelo simplificado consiste em um somatório ponderado de entradas, que resultava na emissão de uma saída.

Ele, ao mesmo tempo que apresentava limitações como o número de camadas de rede e o valor fixo para os pesos de ponderação, foi pioneiro e serviu como base para estudos subsequentes para superar tais limites, através de novas arquiteturas e métodos com o objetivo de expandir sua aplicabilidade (Moura, 2006). Em 1958, Frank Rosenblatt introduziu a rede Perceptron, considerada a primeira aplicação prática das RNAs (Rosenblatt, 1958).

O principal avanço do autor residiu na possibilidade de ajuste dos pesos sinápticos por meio do aprendizado supervisionado, que permitia a resolução de problemas envolvendo reconhecimento de padrões (Rêgo, 2013). Com isso, houve um grande entusiasmo inicial na comunidade científica em relação ao reconhecimento do potencial de aplicação desse tipo de modelo.

Em 1969, entretanto, o campo de pesquisa sofreu uma crise substancial, quando Marvin Minsky e Seymour Papert publicaram Perceptrons, livro no qual evidenciaram diversas limitações teóricas do modelo de Rosenblatt. Os autores evidenciaram a incapacidade de resolver problemas não lineares, como a função XOR, além de apontarem uma falta de sustentação matemática robusta (Minsky; Papert, 1969). Tais críticas resultaram em descrédito e no chamado “inverno das redes neurais” durante a década de 1970.

O interesse pela área de pesquisa foi retomado nos anos 1980, impulsionado por avanços tecnológicos e por novos modelos. Em 1982, John Hopfield apresentou uma arquitetura capaz de resolver problemas de otimização e memória associativa, em contraponto aos argumentos de Minsky e Papert (Hopfield, 1982). Em 1986, Gail Carpenter e Stephen Rosenberg propuseram a Teoria da Ressonância Adaptativa (ART), introduzindo o conceito de aprendizado não-supervisionado e auto-organização (Carpenter; Grossberg, 1986).

De modo a culminar nas redes que conhecemos hoje, o grande marco decisivo foi a difusão do algoritmo de retropropagação (*backpropagation*), resultante da contribuição de diversos autores. No trabalho de David Rumelhart, Geoffrey Hilton e Ronald Williams, o algoritmo de retropropagação de erro foi consolidado e popularizado com base em simulações computacionais e exemplos práticos. Os autores mostraram que redes com múltiplas camadas podiam aprender representações complexas e resolver problemas não lineares através de adaptação iterativa dos pesos (Rumelhart; Hinton; Williams, 1986).

Outro autor com significativa contribuição no algoritmo *backpropagation* foi Yun Cun, que aprofundou o entendimento prático e teórico sobre ele e ainda o reformulou sob a perspectiva da teoria de gradientes adjuntos e do controle ótimo. Essa reinterpretação com tais ferramentas matemáticas já consolidadas em outras áreas de engenharia fundamentou de maneira mais sólida o método, que pode então ser avaliado com mais rigor sobre sua convergência (Cun, 1988).

Com esse algoritmo consolidado, as redes multicamadas puderam ser exploradas, estudadas e evoluídas sistematicamente ao longo das últimas décadas, com sua aplicabilidade expandida para diversas áreas.

3.1.1 Histórico do mapeamento da carbonatação com RNAs

Felix *et al.* (2019) desenvolveram 120 redes neurais com diferentes arquiteturas para predição da profundidade de carbonatação do concreto, utilizando 278 dados de carbonatação não acelerada obtidos na literatura, a fim de determinar a melhor arquitetura. Os autores dividiram o banco de dados em 60% para treino, 20% para validação e 20% para teste e avaliaram seis tipos de cimento, umidade relativa de 30 a 70%, tipo de exposição da estrutura (interno, externo protegido da chuva e

externo desprotegido), porcentagem de adições no concreto até 50%, tempo de exposição até 50 anos e resistência à compressão de 20 a 70 MPa como variáveis de entrada. As melhores arquiteturas são avaliadas com apenas uma camada oculta, variando a quantidade de entradas, assim como com quatro métodos de ajuste de pesos ao longo das redes. A melhor rede obtida apresentou coeficiente de determinação R^2 de 0,925 para seis neurônios na camada oculta e sete parâmetros de entrada, com o método de Levenberg–Marquardt como melhor método de ajuste de peso.

Ao mesmo tempo, o estudo realizado por Kellouche *et al.* (2019) aplica as redes em concretos com adição de cinzas volantes para investigar a carbonatação, considerando cobrimento, teor de material ligante, razão água/ligante, umidade relativa, concentração de CO_2 e tempo de exposição como variáveis de entrada. O banco de dados possuía 300 dados de carbonatação acelerada obtidos na literatura, divididos em 60-20-20% para treino, teste e validação. Essa organização foi a responsável pela variabilidade de desempenho da rede neural, que sempre teve oito neurônios em sua única camada oculta, taxa de aprendizado constante de 0,05 e função de ativação tangente sigmoide, obtendo um R^2 próximo de 0,98. Os autores concluem que a taxa de carbonatação é diretamente proporcional à relação água/aglomerante e à proporção de cinza volante adicionada, especialmente quando ultrapassados 25% de material ligante. O efeito da umidade relativa também foi avaliado, sendo a faixa de 70% a mais crítica para carbonatação acelerada, e mais branda quando a umidade se aproxima de 100%, graças ao preenchimento dos poros do concreto, que inibe o processo de difusão do gás.

Akpinar e Uwanuakwa (2020) buscaram melhorar a precisão de uma rede neural artificial para predição de carbonatação com uma camada oculta, de 10 neurônios fixos, e uma base de dados com 378 casos de 12 estudos da literatura, contendo dados acelerados e naturais. Os autores variaram a proporção de divisão do banco de treino/teste em 40:60%, 50:50% e 60:40%, com 20.000 iterações, buscando MSE (erro médio quadrático) < 0,001, aplicando validação cruzada e comparando ainda Levenberg-Marquardt Backpropagation (LM) com Scaled Conjugate Gradient (SCG). Concluíram que aumentar a proporção de dados de treino melhora o desempenho do modelo e que os algoritmos SCG e LM são indiferentes em termos de precisão, sendo o SCG mais lento a convergir. Além disso, os autores

verificaram que aumentar o teor de CaO do cimento utilizado na mistura acelera a carbonatação, assim como o de SiO_2. A umidade relativa do ar acelera a carbonatação quando está na faixa de 55% a 75%, e desacelera quando em valores maiores. Observa-se, ainda, que um teor maior de cimento na mistura reduz a tendência à carbonatação, efeito oposto ao da adição de cinza volante, este último mais pronunciado em idades avançadas. Para estudos futuros, os autores recomendam analisar as composições químicas do cimento, os dados dos agregados, as perdas na ativação de ligantes e possíveis aditivos, além de aplicar deep learning e algoritmos heurísticos.

No estudo desenvolvido por Londhe *et al.* (2021), a base de dados foi maior, com 827 registros, compostos tanto por dados acelerados quanto naturais. A modelagem foi desenvolvida com RNAs e também com Programação Genética, comparadas ainda com Regressão Linear Múltipla (MLR). Os autores realizaram também uma "Extração de Conhecimento", isto é, a análise da influência de cada input sobre a variável resposta após o treinamento, avaliando os pesos e o *bias* da rede para elucidar, dentro do possível, o processo de aprendizado de um algoritmo "caixa-preta". As redes neurais foram compostas por três camadas ocultas, treinadas pelo algoritmo de Levenberg-Marquardt, com função de ativação Log-Sigmoide da primeira para a segunda camada e linear da segunda para a terceira, e a base foi dividida em 70:15:15% para treino, teste e validação. Concluíram que a resistência à compressão e a relação água/aglomerante são determinantes na carbonatação e que os resultados da extração de conhecimento estão de acordo com a literatura, com coeficientes de correlação $r = 0{,}94$ e determinação $R^2 = 0{,}88$, tanto para RNAs quanto para Programação Genética, ambas superiores à MLR.

O banco de dados usado por Wu *et al.* (2021), composto exclusivamente por dados de carbonatação em condição de teste acelerada, foi bastante reduzido, com 28 registros. O modelo de predição da profundidade de carbonatação contou com apenas uma camada oculta e teve como variáveis de entrada a concentração de CO_2 atmosférico (20%), o tempo de exposição (28 a 90 dias), a temperatura (20 °C), a resistência à compressão (12 a 55 MPa) e a relação água/aglomerante (0,35 a 0,75). Desses, 24 dados foram utilizados para treino e 4 para teste (85:15). Para identificar o melhor número de neurônios na camada oculta, os autores avaliaram diferentes configurações em função das entradas e saídas. A arquitetura ótima foi de oito

neurônios, com taxa de aprendizado de 0,01, resultando em erro médio de 12% nos testes. Ressalta-se que os extremos da base (90 dias de exposição e 12 MPa de resistência) estavam no conjunto de treino, o que reduziu a confiabilidade.

O modelo de Malami *et al.* (2021) baseou-se em dados de 10 estruturas em condições naturais de degradação, situadas em Chipre, obtidos por meio da extração de corpos de prova em ensaios destrutivos. As variáveis de entrada incluíram o tempo de exposição, a resistência à compressão, a densidade do concreto e a profundidade de carbonatação medida. Metade das amostras era de regiões costeiras e metade do interior da ilha, com idades entre 10 e 41 anos. Diferenças na profundidade de carbonatação entre amostras com o mesmo tempo de exposição evidenciaram a influência da resistência à compressão e do ambiente de exposição. A partir desses dados, os autores desenvolveram modelos de Sistema de Inferência Neuro-Fuzzy Adaptável (ANFIS), Extreme Machine Learning (ELM), Support Vector Machine (SVM) e Regressão Multilinear (MLR), treinados com 100 dados extrapolados com base em correlações estatísticas. Os modelos de IA superaram a regressão linear, destacando o potencial de modelos híbridos e *ensembles* para otimizar o desempenho.

Com uma diversidade maior de países, Majlesi *et al.* (2023) utilizaram dados de 24 estações em 10 países diferentes, provenientes de estruturas com mais de 10 anos, para desenvolver modelos de RNA com dados exclusivamente naturais. Foram criadas 8.420 redes de 1, 2 e 3 camadas ocultas, com 1 a 20 neurônios em cada camada, treinadas com 75% dos dados, testadas com 10% e validadas com 15%, usando o algoritmo Adam (*Adaptive Moment Estimation*). Apesar de ser menos robusto do que o Gradiente Descendente, esse algoritmo converge mais rapidamente e requer menos ajustes de hiperparâmetros. As redes com melhor desempenho possuíam, em sua maioria, mais neurônios nas duas primeiras camadas e menos na terceira, sendo a melhor arquitetura a de 14, 12 e 9 neurônios nas três camadas, respectivamente, com R^2 de 0,95. O modelo de RNA foi comparado a árvores de regressão e MLR, apresentando desempenho superior. Os autores destacam que a umidade relativa influencia o estágio inicial da carbonatação, mas a temperatura e a precipitação acumulada são determinantes em idades avançadas. Quanto ao material, o teor de CaO foi considerado crucial, pois influencia a porosidade e, consequentemente, a absorção capilar e a interação com água atmosférica.

Marani, Oyinkanola e Panesar (2024) destacam a escassez de estudos com dados em condições naturais de degradação, bem como a incapacidade de descrever as incertezas envolvidas. Nesse sentido, desenvolveram uma rede neural probabilística (PNN) em *Deep Learning*, composta por duas redes (uma para a média e outra para o desvio padrão), cada uma com três camadas ocultas, além de uma camada conjunta de *outputs* (média e desvio). O modelo foi comparado ao algoritmo *Natural Gradient Boosting* (NGB), que permite aprendizado *ensemble*, calibração iterativa de hiperparâmetros e quantificação de incertezas. Foram variados o número de neurônios, a taxa de *dropout*, taxa de aprendizado, o tamanho do lote e o número de épocas. A técnica de *dropout* colaborou para evitar *overfitting*, tornando a rede mais flexível aos dados (Srivastava *et al.* 2014). A base de dados de mais de 2.000 casos de carbonatação natural de 10 países foi dividida em 80% para treino e 20% para teste. O modelo PNN obteve melhor desempenho do que o NGB e foi validado em estruturas expostas em Toronto e Vancouver, com R^2 próximo de 0,95. As análises paramétricas permitiram inferir que o aumento da relação água/aglomerante e a substituição do cimento Portland por materiais suplementares tendem a acelerar a carbonatação. O concreto com escória de alto-forno apresentou carbonatação mais branda do que o com cinzas volantes, e combinações ternárias de cimento Portland, escória e cinzas apresentaram desempenho superior ao de cimento com metacaulim ou fíler calcário.

Além disso, Kazemi (2024) desenvolveu um modelo híbrido de RNAs com otimização baseada na biogeografia, aplicado à predição da carbonatação em concretos com cinzas volantes. A técnica, inspirada na movimentação e na mutação de espécies entre biomas, oferece simplicidade, eficiência computacional e flexibilidade, auxiliando no treinamento de redes neurais por meio da busca por hiperparâmetros ótimos. O autor utilizou 532 dados de carbonatação acelerada para treinar uma rede com uma única camada oculta de 16 neurônios, a configuração de melhor desempenho. As variáveis mais influentes foram a concentração de CO_2, o tempo de exposição e a relação água/aglomerante. Como próximos passos, recomenda-se aplicar a técnica em bases maiores e com mais variáveis relevantes ao processo de carbonatação.

Recentemente, no estudo de Lavinicki *et al.* (2025) foi investigada a previsão da profundidade de carbonatação em concretos expostos a ambientes

naturais de degradação por meio de técnicas ensemble de aprendizado de máquina, do tipo Stacking. A pesquisa utilizou um banco de dados com mais de 1000 medições de carbonatação e 10 variáveis relacionadas à composição do concreto e às condições ambientais. Inicialmente, 120 modelos individuais de redes neurais artificiais foram treinados; destes, os cinco melhores foram selecionados para compor o modelo ensemble. Os resultados mostraram que a abordagem Stacking superou os modelos individuais, alcançando um erro médio de 1,17 mm, com melhoria de 14% na precisão e de 91,4% na generalização em testes. Como contribuição, os autores desenvolveram uma ferramenta computacional com interface gráfica, disponibilizada no site do grupo DASMAE, para apoiar engenheiros e projetistas em avaliações de durabilidade e no aumento da vida útil de estruturas de concreto.

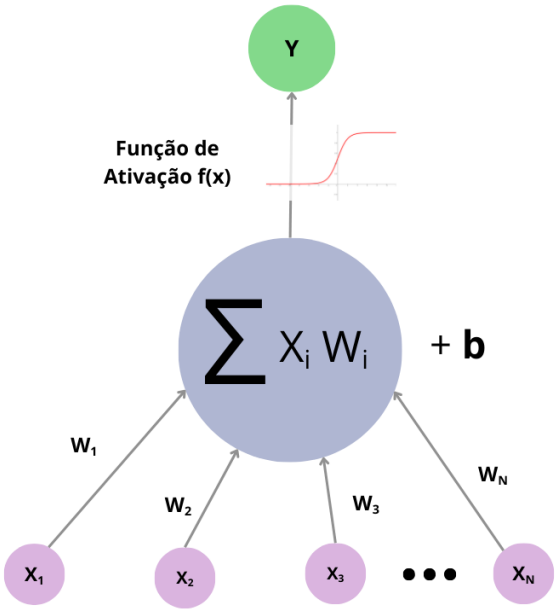
Em consonância com o que foi apresentada, na revisão realizada por Wang *et al.* (2024), são levantados diversos métodos de predição da profundidade de carbonatação do concreto. Na pesquisa, além de contrastarem a eficiência dos modelos desenvolvidos com a falta de suporte teórico para a determinação do número de neurônios nas camadas ocultas, os autores citam diversos estudos das últimas décadas, sendo um dos principais métodos as aplicações de redes neurais artificiais. Alguns autores ainda aplicam o Deep Learning, que envolve a modelagem do fenômeno de carbonatação com um maior número de camadas ocultas nas RNAs (a partir de três). Os resultados da literatura mostram que não há consenso sobre qual é a topologia ideal para o mapeamento da carbonatação do concreto, uma vez que, ao mudar o domínio de modelagem (domínio das variáveis e quantidade e tipos de parâmetros de entrada), altera-se o problema.

3.2 FUNDAMENTOS DAS RNAS

A Rede Neural Artificial (RNA) pode ser definida como um modelo computacional cujo funcionamento se baseia no sistema nervoso humano. É um tipo de sistema composto por unidades de processamento, ou neurônios artificiais, que podem ser distribuídos em diversas camadas, sendo capazes de mapear funções não lineares com interconexões associadas a pesos sinápticos com capacidade de armazenar informações (Haykin, 1999).

Na Figura 11, é possível conferir a estrutura típica de um neurônio único que compõe uma rede neural, originalmente denominada Perceptron. Ele possui determinados valores de entrada com seus respectivos pesos sinápticos, um bias, que consiste no viés embutido no modelo, uma função de ativação específica e um valor de saída, obtido pela soma de cada valor de entrada ponderado por seu respectivo peso, somado ao bias, e posteriormente processado pela função de ativação, como pode ser conferido na Equação (19) (Haykin, 1999).

Figura 11 - Estrutura de um neurônio único.



Fonte: Autor.

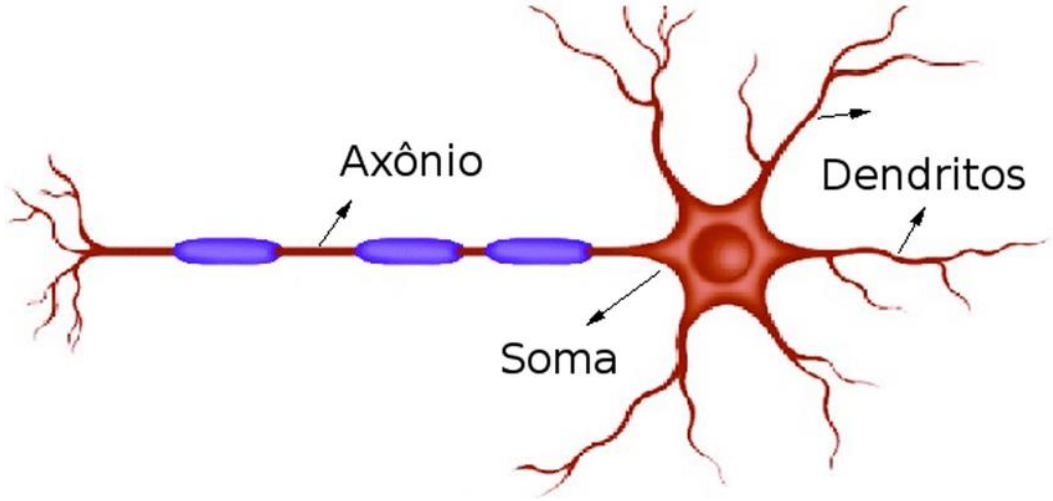
$$y = f\left(\sum_{i=1}^{n}(x_i \cdot w_i) + b\right) \tag{19}$$

Em que:

- n: número de valores de entrada naquele neurônio;
- x_i: cada um dos valores de entrada;
- w_i: cada um dos pesos sinápticos atrelados a cada um dos valores de entrada;
- b: bias ou viés;
- f: função de ativação;
- y: valor de saída do neurônio.

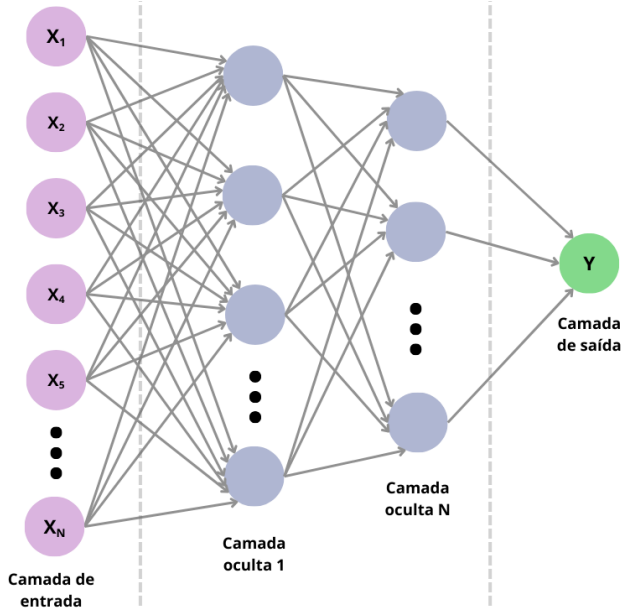
A estrutura da Figura 11 pode ser comparada à de um neurônio biológico. Nesse caso, o conjunto de entradas com pesos sinápticos seria um paralelo aos dendritos; o somatório das entradas ponderadas, com o viés (ou bias), seria o corpo celular; a função de ativação seria o processamento realizado na estrutura; e a saída gerada seria um axônio, como pode ser visto na Figura 12.

Figura 12 – Modelo simplificado de um neurônio biológico.



Fonte: Borges *et al.* (2015).

Figura 13 - Estrutura de uma rede genérica de múltiplas camadas.



Fonte: Autor.

A estrutura global de uma rede neural composta por diversos neurônios pode ser observada na Figura 13. Ela deve possuir uma camada de entrada, com os

valores a serem processados, uma ou mais camadas ocultas, onde ficam os neurônios interconectados entre si, e uma camada de saída, que fornecerá o valor resultante da sequência de processamentos entre os neurônios. O nome dado à rede de neurônios com múltiplas camadas é Multilayer Perceptron (MLP).

A seguir, são descritas as principais características de uma rede MLP, como a topologia, o método de aprendizado, a função de ativação e os demais hiperparâmetros, que definem e controlam uma rede neural.

3.2.1 Topologia das redes neurais artificiais

A topologia de um RNA consiste na disposição de seus componentes, sendo definida principalmente pelo número de camadas, pelo número de neurônios por camada e pelo tipo de conexão entre os neurônios. O conceito de topologia é frequentemente tratado como sinônimo de arquitetura de RNAs, sendo tanto um quanto outro uma descrição da estrutura global da rede. Essa estrutura tem grande importância sobre o comportamento e funcionamento da rede neural, sendo determinante para o tipo de problema que poderá ser resolvido com uma determinada configuração (Furtado, 2019).

Diversos trabalhos na literatura relatam como estruturar uma RNA de acordo com a natureza e complexidade de um problema, sem haver necessariamente um padrão exato para a decisão de qual arquitetura utilizar (Bueno *et al.*, 2024; Felix *et al.*, 2024; Felix; Possan; Carrazedo, 2019; Majlesi *et al.*, 2023). O processo de definição da topologia é usualmente iterativo e empírico, isto é, com base em tentativa e erro com sucessivos refinamentos do modelo, buscando a melhor configuração para o problema em questão (Fausett, 1993; Wang *et al.*, 2024).

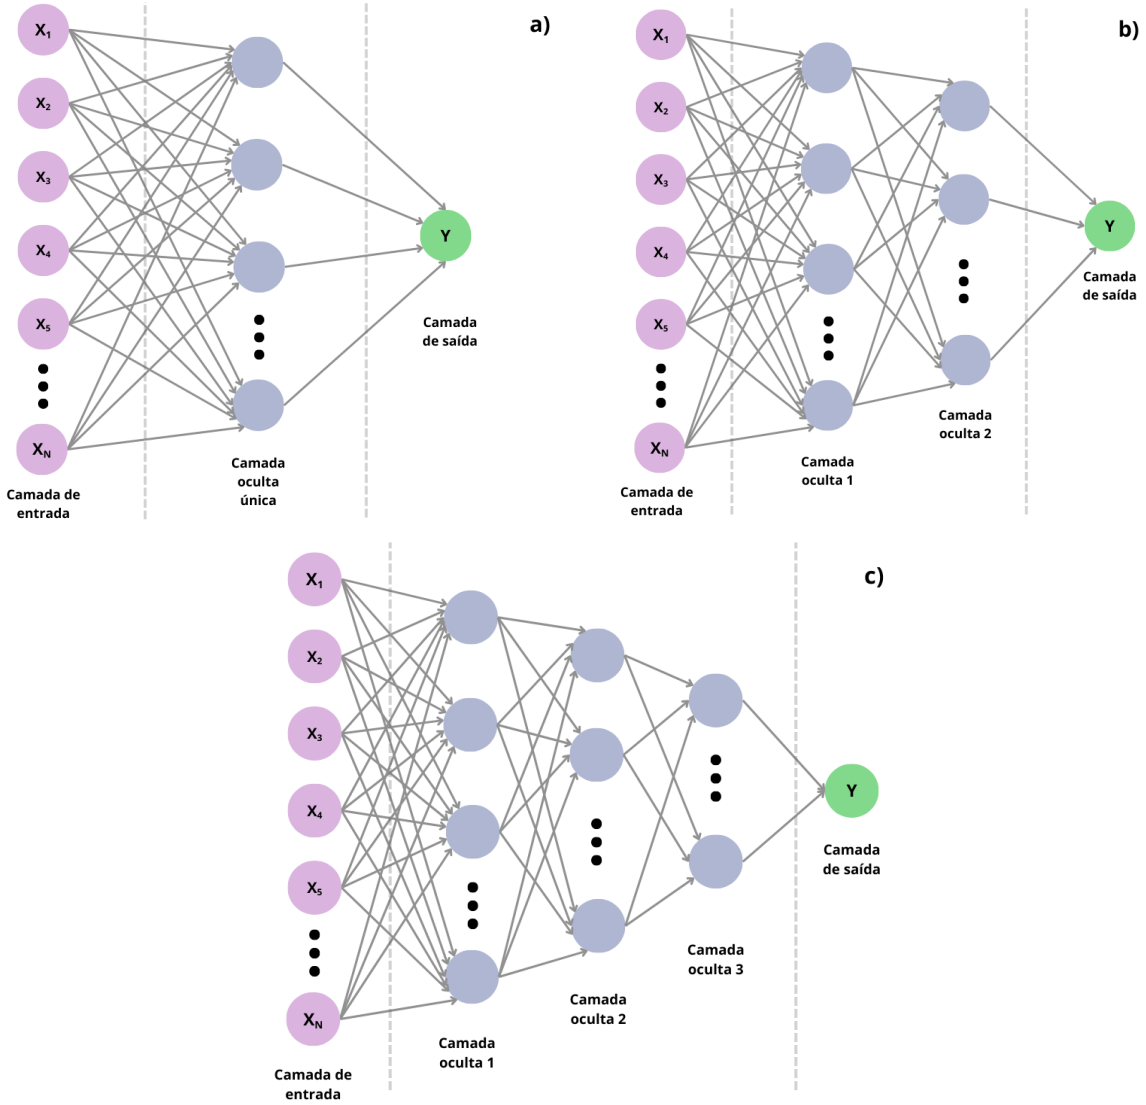
O número de neurônios e de camadas não pode ser excessivo, nem muito pequeno, devendo, portanto, ambos estar em um intervalo razoável. Isso se deve ao fato de a rede tanto num extremo quanto no outro perder sensibilidade de aprendizado e precisão no reconhecimento de padrões, diminuindo sua capacidade de generalização de dados de saída (Braga; Ludermir; Carvalho, 2000). Na Figura 14, é possível conferir algumas topologias usuais de redes neurais.

A Figura 14.a apresenta uma topologia de rede de uma camada, capaz de resolver problemas não lineares. A Figura 14.b e Figura 14.c apresentam,

espectivamente, arquiteturas de 2 e 3 camadas, que podem resolver problemas mais complexos com melhor precisão.

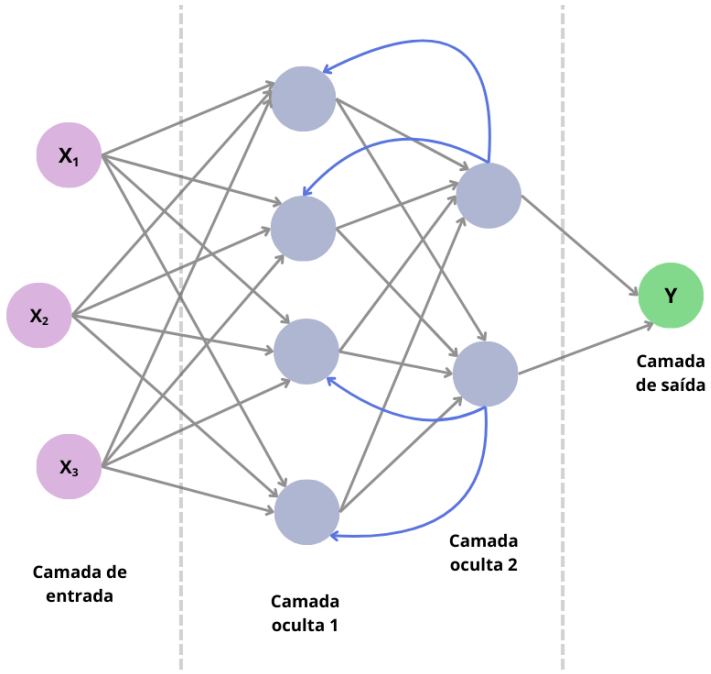
No que diz respeito ao tipo de conexão existente entre os neurônios, pode-se citar diversos tipos, como as redes *feedforward* (Figura 14), recorrentes (Figura 15), convolucionais (Figura 16). No caso das redes *feedforwards*, a informação flui em um único sentido, sem ciclos ou retroalimentação, indo da camada de entrada em direção à camada de saída (Felix; Carrazedo; Possan, 2021).

Figura 14 - Topologias de RNA de camadas únicas e múltiplas.



Fonte: Autor.

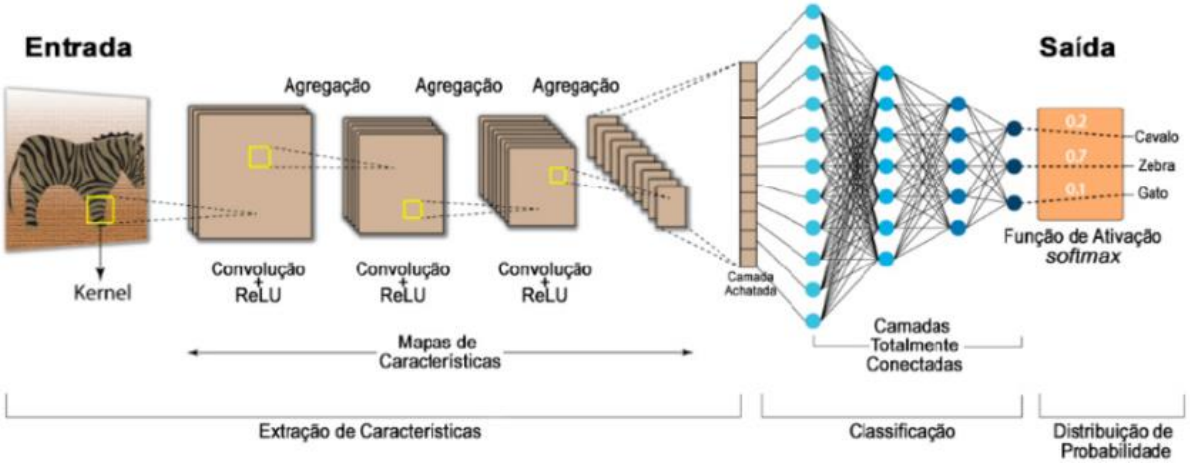
Figura 15 - Esquema Genérico de Rede Neural Recorrente.



Fonte: Autor.

Nas redes recorrentes, cada neurônio pode enviar sinais no sentido contrário ao fluxo natural e até para si mesmo. Esse tipo de interconexão permite a presença de loops, ou laços, com informações anteriores influenciando cálculos atuais (Uwanuakwa, 2021).

Figura 16 - Esquema Genérico de Rede Neural Convolucional.



Fonte: Ferreira *et al.* (2023).

As redes neurais convolucionais, por sua vez, possuem camadas de convolução que aplicam filtros (kernels) para extrair padrões locais, com cada

neurônio conectando-se a apenas uma região da entrada, em vez de a todos os neurônios da camada anterior. A aplicação desse tipo de rede reside especialmente no reconhecimento de imagens, áudio e texto, bem como na detecção de objetos (Giulietti *et al.*, 2021).

3.2.2 Algoritmo de aprendizagem *backpropagation*

Além da topologia, o método de aprendizado, ou treinamento, é outro aspecto extremamente relevante para o desempenho das redes neurais. A estratégia adotada está diretamente associada à habilidade de adaptação da rede e de seus pesos sinápticos ao longo do seu treinamento.

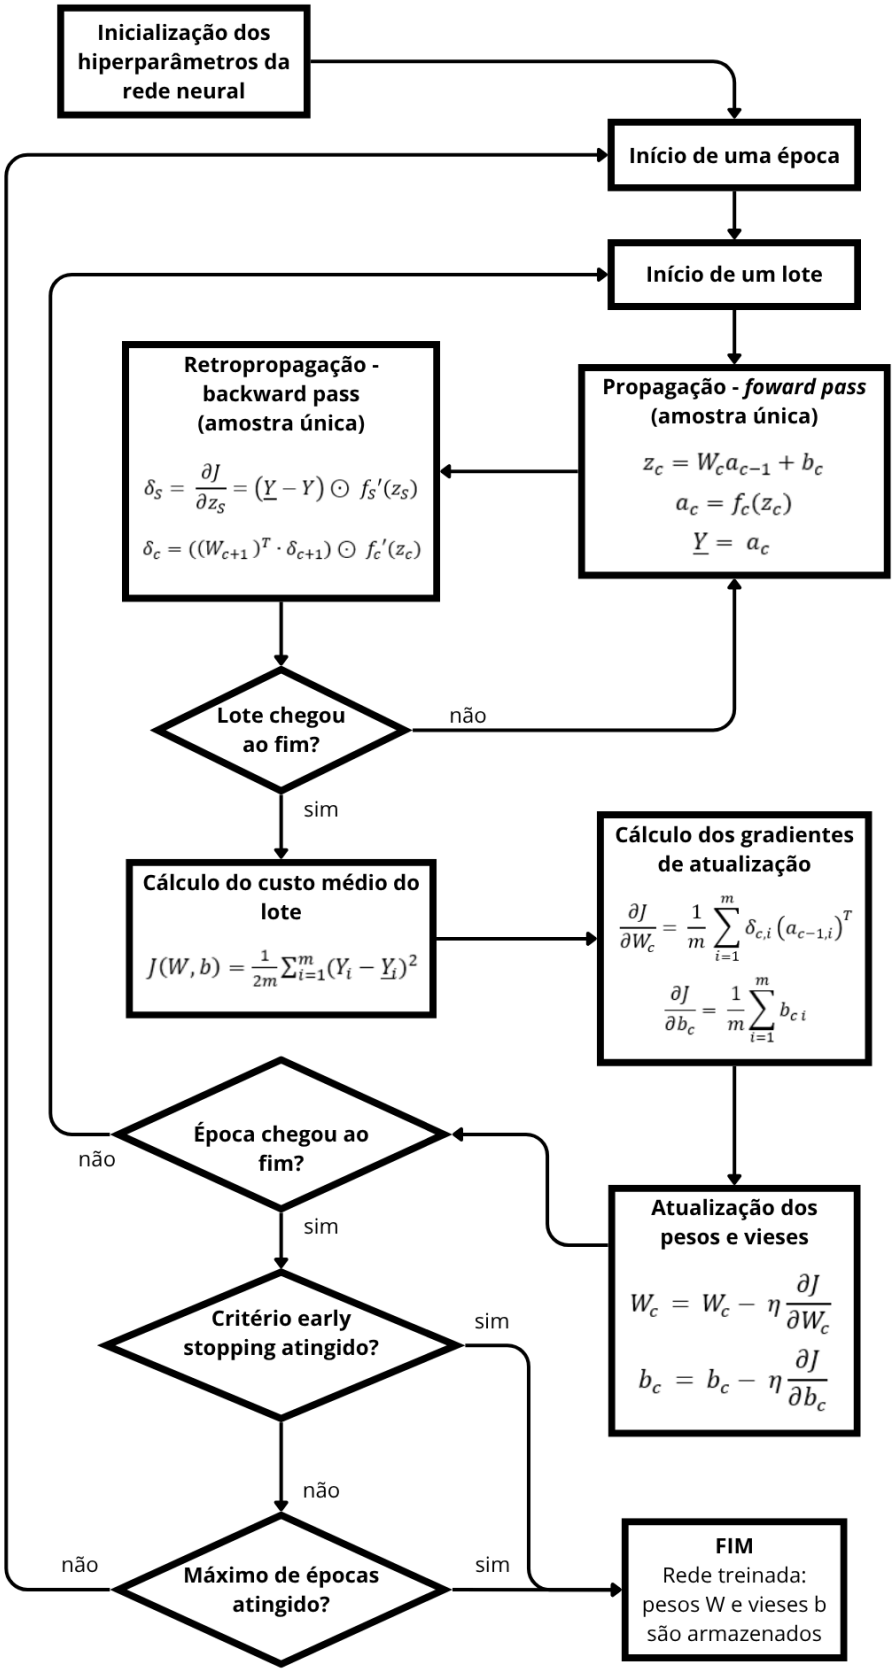
A técnica de treinamento mais clássica e difundida é a de *backpropagation*, cujo resumo pode ser conferido na Figura 17, tendo como fundamento principal o uso do método do gradiente descendente para ajustar os pesos da rede. A ideia central é minimizar uma função de custo através da atualização iterativa de pesos e vieses com foco na redução do erro essencialmente em duas fases, sendo elas a propagação e a retropropagação, durante milhares ou milhões de iterações, a depender dos hiperparâmetros da rede (Rumelhart; Hinton; Williams, 1986).

Antes de definir o algoritmo, é importante entender os conceitos de lote e de época. Época entende-se como uma iteração completa sobre todas as amostras da base de dados atribuídas à fase de treinamento, enquanto lote é um subconjunto dos dados de treinamento, tendo a época, portanto, um número determinado de lotes.

Ao final de cada lote, os pesos sinápticos e os vieses são atualizados e, ao final de cada época, compara-se o custo atual ao da época anterior para verificar o critério de parada adotado. A quantidade de épocas, o tamanho dos lotes e o critério de parada são definidos pelos hiperparâmetros da rede.

Com a inicialização dos hiperparâmetros da rede, inicia-se uma época e, dentro dessa época, um lote. Dentro desse lote, é lida uma quantidade determinada de amostras e, para cada amostra, é calculada uma soma ponderada entre o viés do neurônio para aquele parâmetro e o produto do peso sináptico do neurônio para aquele parâmetro pelo valor de entrada da rede (ou pelo valor de saída da camada anterior), conforme a Equação (20).

Figura 17 – Fluxograma ilustrativo do algoritmo de *backpropagation.*



Fonte: Autor.

$$z_c = W_c a_{c-1} + b_c \quad (20)$$

Em que:

- c: camada intermediária;
- z_c: é o valor de saída da camada c;
- W_c: é a matriz de pesos da camada c;
- a_c: é a saída (ativação) da camada c;
- a_{c-1}: é a saída (ativação) da camada imediatamente anterior à camada c;
- b_c: é o viés da camada c;

A saída do neurônio é definida em seguida, aplicando o resultado da soma ponderada à função de ativação, conforme as Equações (21) e (22). Esse processo, isto é, o cálculo da saída de um neurônio com base na saída da camada anterior ou da camada de entrada da rede, ocorre em todos os neurônios de todas as camadas adjacentes, até que a camada de saída seja alcançada, com um valor predito como *output*. Esse processo de calcular a soma ponderada e o seu respectivo valor ativado constitui a primeira fase, de processamento de uma amostra, que é a propagação direta, ou *forward pass* (Goodfellow; Bengio; Courville, 2016).

$$a_c = f_c(z_c) \quad (21)$$

$$\underline{Y} = a_c \quad (22)$$

Em que:

- c: camada intermediária;
- z_c: é o valor de saída da camada c;
- a_c: é a saída (ativação) da camada c;
- f_c: é a função de ativação (sigmoide, tangente hiperbólica, ReLU etc);
- $\underline{Y}$: saída calculada pela rede;

A segunda fase de processamento de uma amostra é a retropropagação do erro, ou *backward pass*. Nessa etapa, calcula-se o gradiente individual de erro tanto para a camada de saída quanto para cada neurônio de cada camada oculta. Na

camada de saída, conforme a Equação (23), o gradiente de erro é calculado como o produto Hadamard (elemento a elemento) entre a matriz de discrepâncias entre saídas reais e saídas preditas e a matriz de valores provenientes da derivada da função de ativação, tomando como argumento o resultado da soma ponderada, isto é, o valor da saída do parâmetro antes de ser submetido à função de ativação.

$$\delta_S = \frac{\partial J}{\partial z_S} = \left(\underline{Y} - Y\right) \odot f_S'(z_S) \tag{23}$$

Em que:

- S: camada de saída;
- z_S: é o valor de saída da camada de saída S;
- f_S: é a função de ativação (sigmoide, tangente hiperbólica, ReLU etc);
- $\underline{Y}$: saída calculada pela rede;
- Y: saída real esperada (de acordo com a base de dados);
- J: custo
- δ_S: gradiente de erro na camada de saída;
- $\odot$: produto de Hadamard (elemento a elemento);

Com o gradiente de erro da camada de saída calculado, é possível calcular também o gradiente de erro das camadas ocultas, conforme a Equação (24). O cálculo é semelhante ao gradiente de erro da camada de saída, com a diferença de que o primeiro termo do produto Hadamard agora é o erro propagado pela camada seguinte, ou seja, a matriz resultante do produto entre a matriz transposta dos pesos sinápticos da camada seguinte e a matriz de gradientes de erro da camada seguinte.

$$\delta_c = ((W_{c+1})^T \cdot \delta_{c+1}) \odot f_c'(z_c) \tag{24}$$

Em que:

- c: camada intermediária;
- z_c: é o valor de saída da camada c;
- c+1: camada imediatamente posterior à camada c

- W_{c+1}: matriz de pesos da camada imediatamente posterior à camada c;
- ${W_{c+1}}^T$: matriz transposta
- f_c': derivada da função de ativação;
- δ_c: gradiente de erro numa camada intermediária c;
- δ_{c+1}: gradiente de erro na camada intermediária imediatamente posterior à camada c;
- $\odot$: produto de Hadamard (elemento a elemento);

Ao final de um lote, calcula-se o custo médio de suas amostras, conforme a Equação (25), derivada da fórmula do MSE, usualmente aplicada como função de custo em modelos de redes *Multilayer Perceptron* (MLP). Com o custo médio do lote calculado, calculam-se os gradientes de atualização dos pesos e vieses, que consistem nas derivadas parciais do custo em relação a cada uma dessas grandezas, conforme as Equações (26) e (27).

$$J(W,b) = \frac{1}{2m}\sum_{i=1}^{m}(Y_i - \underline{Y_i})^2 \tag{25}$$

$$\frac{\partial J}{\partial W_c} = \frac{1}{m}\sum_{i=1}^{m}\delta_{c,i}\left(a_{c-1,i}\right)^T \tag{26}$$

$$\frac{\partial J}{\partial b_c} = \frac{1}{m}\sum_{i=1}^{m}b_{c,i} \tag{27}$$

Em que:

- c: camada intermediária;
- m: tamanho de 1 lote;
- W_c: é a matriz de pesos da camada c;
- a_c: é a saída (ativação) da camada c;
- b_c: é o viés da camada c;
- $\underline{Y_i}$: saída calculada pela rede;
- Y_i: saída real esperada (de acordo com a base de dados);
- $J(W,b)$: custo em função dos pesos e vieses (adotado erro quadrático médio como exemplo usual para modelos de regressão);
- δ_c: gradiente de erro numa camada intermediária c;

- $\frac{\partial J}{\partial W_c}$: gradiente para atualização dos pesos;
- $\frac{\partial J}{\partial b_c}$: gradiente para atualização dos vieses;

Por fim, há a atualização das matrizes de pesos e vieses de cada camada da rede, que ocorre pela subtração entre a matriz do lote imediatamente anterior e o produto da taxa de aprendizado pelo gradiente de atualização, conforme as Equações (28) e (29). É importante salientar que, nessa atualização, a operação realizada é a de subtração pelo fato de que as derivadas parciais calculadas ($\frac{\partial J}{\partial W_c}$ e $\frac{\partial J}{\partial b}$) apontam para a direção de maior crescimento da função de custo (de acordo com a definição de gradiente), o que demanda, portanto, que se siga na direção oposta para alcançar a minimização.

$$W_c = W_c - \eta \frac{\partial J}{\partial W_c} \tag{28}$$

$$b_c = b_c - \eta \frac{\partial J}{\partial b_c} \tag{29}$$

Em que:

- c: camada intermediária;
- W_c: matriz de pesos da camada c;
- b_c: viés da camada c;
- $\frac{\partial J}{\partial W_c}$: gradiente para atualização dos pesos;
- $\frac{\partial J}{\partial b_c}$: gradiente para atualização dos vieses;
- η: taxa de aprendizado (determina o quão rápido cada peso e viés são atualizados em função dos gradientes de erro).

Após a atualização dos pesos, ocorre uma iteração sobre um novo lote dessa época e, ao final da época, isto é, após a iteração sobre todos os lotes dessa época, verifica-se se o critério de *early stopping* foi atingido. Tal critério será alcançado uma vez que haja um determinado número de épocas seguidas sem diminuição

significativa no custo da rede, em que diminuição significativa pode ser entendida como uma diminuição superior a um determinado valor de tolerância.

Uma vez alcançado o *early stopping* ou o número máximo de épocas de treinamento, o treinamento da rede é interrompido. O número máximo de épocas, o critério de parada e o valor de tolerância são hiperparâmetros da rede.

Esse algoritmo combina, portanto, princípios de cálculo diferencial e otimização numérica para que seja possível o treinamento de redes profundas e a modelagem de relações complexas e não lineares em diversos domínios (Goodfellow; Bengio; Courville, 2016).

3.2.2.1 Algoritmo backpropagation

Como descrito anteriormente, a minimização da função de custo envolve, resumidamente, seguir o caminho oposto ao gradiente da função de custo em relação aos pesos e vieses, uma vez que o gradiente, por definição, aponta para a direção do maior aumento da função. Para calcular esse gradiente, no entanto, é necessário aplicar a regra da cadeia, uma vez que a função de custo depende da saída de cada neurônio, que, por sua vez, depende da função de ativação, cujo argumento depende dos pesos e dos vieses (Thomas; Weir; Hass, 2012).

Como visto a seguir, é possível deduzir as fórmulas resultantes dessa aplicação da regra da cadeia tanto para a camada de saída quanto para as camadas intermediárias da rede. Na Equação (30), é apresentada a aplicação da regra da cadeia no cálculo da derivada parcial do custo em relação ao peso sináptico.

$$\frac{\partial J}{\partial W} = \frac{\partial J}{\partial \underline{Y}} \frac{\partial \underline{Y}}{\partial z} \frac{\partial z}{\partial W} \tag{30}$$

Em que:

- W: peso sináptico;
- z: soma ponderada dos vieses com o produto entre entradas e pesos;
- $\underline{Y}$: saída ativada de um neurônio;
- J: função de custo (usualmente MSE).

Nas Equações (31), (32) e (33), é possível conferir as definições da soma ponderada, da saída ativada de um neurônio e da função de custo.

$$z_c = W_c a_{c-1} + b_c \tag{31}$$

$$\underline{Y} = a_c = f(z_c) \tag{32}$$

$$J = \frac{1}{2}\,(Y - \underline{Y})^2 \tag{33}$$

Em que:

- z_c: soma ponderada dos vieses com o produto entre entradas e pesos na c-ésima camada da rede neural;
- W_c: peso sináptico de um neurônio na c-ésima camada da rede neural;
- b_c: viés de um neurônio na c-ésima camada da rede neural;
- a_c: saída ativada da c-ésima camada da rede neural;
- a_{c-1}: saída ativada proveniente de 1 camada anterior à c-ésima camada da rede neural;
- Y: saída esperada na rede neural (proveniente da base de dados);
- $\underline{Y}$: saída predita pela rede neural (calculada após processamento em todas as camadas).

É importante ressaltar que, como as equações resultantes para a camada de saída e para as camadas intermediárias são razoavelmente distintas entre si, as fórmulas são deduzidas primeiro para a saída da rede e, posteriormente, para uma camada intermediária qualquer.

Aplicando a derivada parcial em cada uma das funções (substituindo as Equações (31), (32) e (33) na Equação (30)), tem-se:

$$\frac{\partial J}{\partial w} = \left(\underline{Y} - Y\right) . f'(z) . (a_{c-1})^T \tag{34}$$

Na sequência, define-se o gradiente de erro da camada de saída δ_S, que é a derivada parcial da função de custo na variável z_S.

$$\delta_S = \frac{\partial J}{\partial z_S} = \left(\underline{Y} - Y\right) \odot f_S'(z_S) \tag{35}$$

Para uma camada intermediária, entretanto, a aplicação das derivadas parciais na Equação (30) demanda manipular as formulações conforme Equações (36), (37) e (38).

$$z_{c+1} = W_{c+1} a_c + b_{c+1} \tag{36}$$

$$\frac{\partial J}{\partial w} = \frac{\partial J}{\partial z_{c+1}} . \frac{\partial z_{c+1}}{\partial a_c} . f'(z_c) . (a_{c-1})^T \tag{37}$$

$$\frac{\partial J}{\partial w} = \frac{\partial J}{\partial z_{c+1}} (W_{c+1})^T . f'(z_c) . (a_{c-1})^T \tag{38}$$

O gradiente de erro δ_c para uma camada intermediária é então definido pela Equação (39) ou sua equivalente, Equação (40).

$$\delta_c = \frac{\partial J}{\partial z_c} = \frac{\partial J}{\partial \underline{Y}} \frac{\partial \underline{Y}}{\partial z} \tag{39}$$

$$\delta_c = \frac{\partial J}{\partial z_c} = \left[\frac{\partial J}{\partial z_{c+1}} (W_{c+1})^T\right] . f'(z_c) \tag{40}$$

Considerando que o gradiente da camada sucessora é dado pela Equação (41), chega-se à Equação (42), que define o gradiente atualizado para uma camada interna da RNA.

$$\delta_{c+1} = \frac{\partial J}{\partial z_{c+1}} \tag{41}$$

$$\delta_c = \frac{\partial J}{\partial z_c} = \delta_{c+1} (W_{c+1})^T \odot f'(z_c) \tag{42}$$

Por fim, substituindo o gradiente de erro δ da camada (Equação (35) para a camada de saída ou Equação (42) para uma camada intermediária) nas Equações (34) e (38), respectivamente, obtém-se o cálculo do gradiente de atualização dos pesos sinápticos, que é aplicado na última etapa do processo de retropropagação, conforme Equação (43).

$$\frac{\partial J}{\partial W_c} = \delta_c \, . \, a_{c-1} \tag{43}$$

3.2.3 Funções de ativação

Outra característica determinante para o treinamento e a configuração de uma RNA é sua função de ativação, que compõe sua arquitetura, transformando o somatório ponderado das entradas em um sinal de ativação a ser transmitido ao neurônio seguinte. Além dessa conversão para o valor de saída, a função de ativação também influencia o comportamento interno do neurônio e a capacidade da rede de aprender, funcionando como um mecanismo de não linearidade da rede (Bishop, 2006; Haykin, 1999).

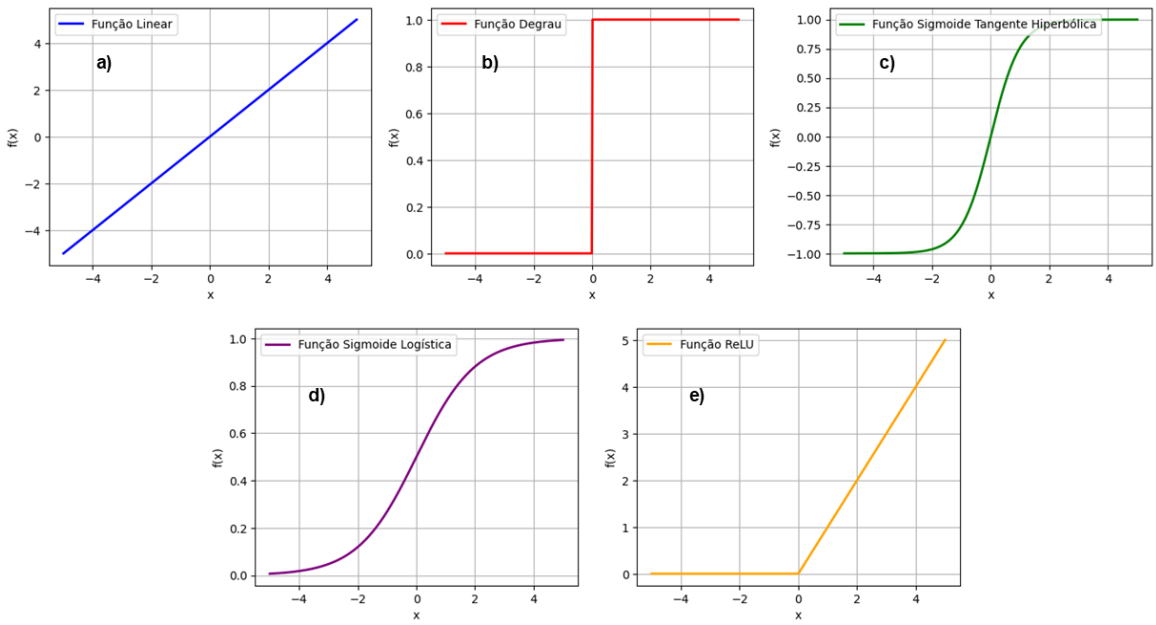
Cada unidade de processamento, ou neurônio, possui um estado de ativação definido por essas funções, que podem ser discretas ou contínuas em função do problema a ser descrito (Goodfellow; Bengio; Courville, 2016; Nair; Hinton, 2010). Também conhecidas como limiares lógicos, as funções de ativação mais comumente utilizadas podem ser conferidas na Figura 18 e são as seguintes:

- Função linear (Figura 18.a): utilizada para tarefas de regressão, sem limitar a saída do neurônio e armazenando dados contínuos de entrada e saída;
- Função degrau (Figura 18.b): utilizada em problemas de classificação simples, limitando a saída de cada neurônio a valores binários discretos (0 e 1, verdadeiro e falso);
- Função sigmoide tangente hiperbólica (Figura 18.c): restringe a saída do neurônio num intervalo contínuo entre -1 e 1, aplicado a fenômenos com valores centrados em zero, não podendo ser aplicado em redes muito profundas por sofrer com o chamado *Vanishing Gradient Problem*, isto é, o fenômeno de diminuição exponencial nos gradientes de atualização de pesos sinápticos de camadas anteriores durante o passo de retropropagação (como o gradiente presente na equação (26) por exemplo);

- Função sigmoide logística (Figura 18.d): limita a saída num intervalo contínuo entre 0 e 1 e pode ser utilizada em problemas probabilísticos, apesar de ter a mesma desvantagem da função sigmoide tangente hiperbólica com gradientes muito pequenos;
- Função ReLU (Rectified Linear Unit) (Figura 18.e): essa função mantém valores positivos iguais à entrada e zera os negativos, ficando no intervalo de 0 ao infinito, sanando a questão do gradiente desvanecido, mas podendo gerar “neurônios mortos”, permanecendo constantemente zerados.

As funções sigmoides foram as primeiras utilizadas na construção de RNAs, principalmente por terem características de simetria, monotonia, serem crescentes limitadas e de fácil derivação, o que contribui para a convergência na fase de treinamento das redes (Haykin, 1999; Malami *et al.*, 2021; Xi-Zhao *et al.*, 2013). Enquanto isso, a função ReLU também ganhou espaço relevante nos últimos anos, essencialmente pela sua simplicidade computacional, esparsidade de ativação (ao manter neurônios inativos em diversos momentos) e escalabilidade, podendo ser aplicada a redes muito profundas (Jung; Lee, 2019; Marani; Oyinkanola; Panesar, 2024; Nair; Hinton, 2010).

Figura 18 - Funções de ativação.



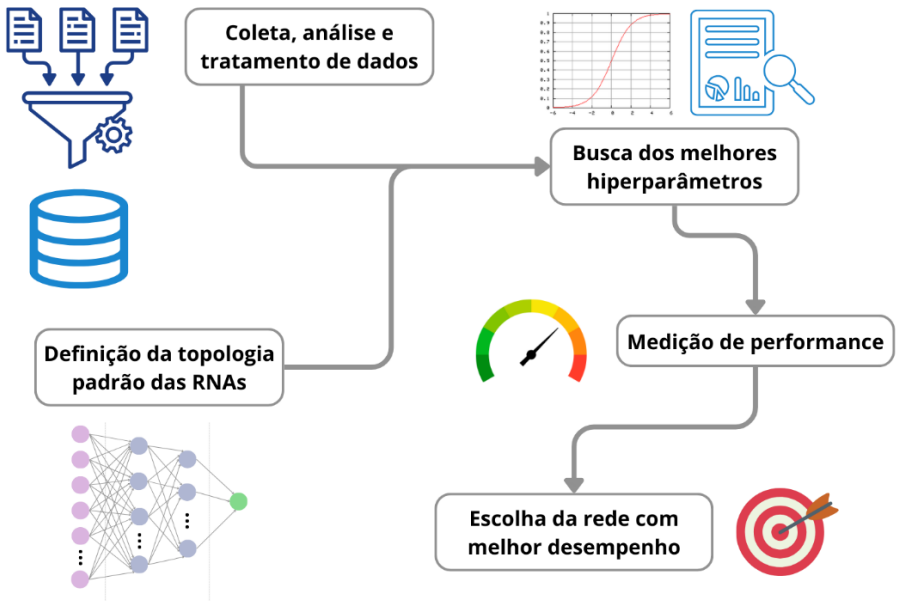
Fonte: Autor.

3.3 MODELAGEM COM REDES MLP

Tendo em mente os componentes e o funcionamento básico de uma RNA, é possível tomar conhecimento de como modelar problemas com esse recurso, assim como otimizar essa modelagem de acordo com um determinado objetivo (Haykin, 1999). Uma síntese dos passos de concepção, modelagem, otimização e aplicação de um modelo de RNA é apresentada na Figura 19.

A primeira etapa na construção de um modelo de redes neurais artificiais consiste na montagem de uma base de dados, que deve ser coletada a partir de experimentos realizados pelo próprio grupo ou de medições provenientes de outras pesquisas documentadas. Usualmente, quanto maior a quantidade de dados, maior a chance de que o aprendizado ocorra e maior a diversidade desses dados, proporcionando melhor generalização (Felix *et al.*, 2024; Malysz *et al.*, 2023; Marani; Oyinkanola; Panesar, 2024).

Figura 19 - Metodologia genérica para a construção de um modelo de RNA.



Fonte: Autor.

Esses dados serão a fonte de conhecimento do modelo sobre um determinado fenômeno e deverão conter todos os valores de entrada e de saída necessários à modelagem do problema em questão. Desse modo, o domínio de

funcionamento da RNA estará restrito ao domínio do banco de dados, isto é, qualquer cenário cujos fatores não estejam abrangidos completamente nos valores de todos os parâmetros de entrada ou saída de natureza contínua ou discreta da base de dados será um cenário para o qual a rede não terá sido treinada adequadamente para descrevê-lo (Almeida *et al.*, 2023; Bueno *et al.*, 2025; Felix *et al.*, 2024).

Após a montagem de um banco de dados, os dados devem ser analisados e tratados, de modo a reduzir vieses e ruídos e garantir uma descrição fiel do fenômeno em modelagem. Isso abrange, entre outras medidas:

- a verificação de parâmetros estatísticos (média, mediana, desvio padrão, máximos, mínimos etc.) de cada um dos parâmetros de entrada e saída;
- verificação da coerência dos dados com o domínio desejado de aplicação do modelo;
- verificação da presença e análise de *outliers*, isto é, valores discrepantes no conjunto que podem ou não enviesar o modelo e distorcer seus resultados;
- verificação da presença de duplicatas de entrada com saídas discrepantes;
- análise da distribuição de frequências de cada parâmetro.

Após essas verificações e análises, o banco de dados deve ser ajustado de modo que suas distribuições de frequências, seu domínio e todas as suas características fiquem dentro de padrões plausíveis para a natureza do problema de modelagem. Esses ajustes envolvem essencialmente a eliminação de dados incoerentes, inconsistentes, não representativos, de valor fora do usual em cenários de aplicação do modelo e restrições nos domínios das variáveis, além da eliminação de outliers quando forem considerados prejudiciais ao modelo (Almeida *et al.*, 2023).

Após o tratamento do banco de dados, a base de treinamento está pronta para uso. O próximo passo envolve a definição dos hiperparâmetros da rede, que controlam sua arquitetura, o processo de treinamento e de regularização e normalização dos dados (Bergstra; Bengio, 2012; Haykin, 1999).

A definição da arquitetura base tem como ponto de partida a revisão da literatura, com foco em modelagens do mesmo problema-alvo. A depender da natureza do problema, a rede deverá usualmente possuir mais ou menos camadas e ter uma determinada configuração de interconexão entre as unidades de processamento (Jung; Lee, 2019; Wang *et al.*, 2024). A função de ativação, por sua vez, deve ser definida com base em testes com todas as demais características da rede fixas, de modo a verificar com qual função o RNA descreve o fenômeno com maior precisão (Goodfellow; Bengio; Courville, 2016; Nair; Hinton, 2010).

A metodologia para determinar a quantidade ótima de neurônios em cada uma das camadas é, por sua vez, iterativa, por tentativa e erro (Felix *et al.*, 2024; Majlesi *et al.*, 2023; Marani; Oyinkanola; Panesar, 2024). Nessa metodologia, quando possível, são testadas todas as combinações possíveis de número de neurônios ou, quando o número de combinações atinge níveis exorbitantes, é testada uma fração delas por meio de um processo chamado Random Grid Search (Bergstra; Bengio, 2012; Goodfellow; Bengio; Courville, 2016; Wang *et al.*, 2025).

Nesse processo, a busca pela quantidade ideal de neurônios é realizada por meio de testes com amostragem aleatória da quantidade de neurônios em cada camada. Ele é dividido em quantas fases forem necessárias e, em cada uma delas, uma fração do total de combinações do número de neurônios por camada é testada aleatoriamente, fazendo com que, ao final, seja determinada a configuração da rede que minimiza o erro ou maximiza o desempenho.

As melhores performances de uma fase determinarão os limites de busca da fase seguinte, que terá um domínio menor, e assim sucessivamente. Isso ocorre até que seja alcançado um espaço amostral no qual seja razoável realizar o teste de todas as combinações possíveis e no qual, potencialmente, estará a combinação com melhor desempenho dentre todas as pesquisadas inicialmente.

Outros hiperparâmetros relevantes, além do número de neurônios em cada camada, número de camadas e função de ativação, também podem e devem ser otimizados (Bergstra; Bengio, 2012). Dentre os hiperparâmetros que devem ser determinados e interferem no aprendizado e generalização das redes são:

- taxa de aprendizado: quão rápido os pesos são ajustados;
- número de épocas: quantas vezes o conjunto de dados passa pela rede;

- tamanho do batch (lote): número de amostras usadas antes de atualizar os pesos;
- algoritmo de otimização de pesos: SGD, Adam, RMSProp, dentre outros;
- inicialização dos pesos: Xavier, He, aleatória, dentre outros;
- proporção entre treino, validação e teste;
- método de normalização e de estratificação dos dados para treino, validação e teste.

A otimização da configuração da rede, isto é, a busca pelos melhores hiperparâmetros (que geram a rede com melhor desempenho), deve ocorrer com base na avaliação do desempenho da rede. Essa avaliação pode ser conduzida por diferentes métricas, sendo as principais para problemas de regressão o erro quadrático médio (MSE, Equação (44)), a raiz do erro quadrático médio (RMSE, Equação (45)), erro absoluto médio (MAE, Equação (46)) e o coeficiente de determinação (R^2, Equação (47)) (Bishop, 2006; Bueno *et al.*, 2025; Marani; Oyinkanola; Panesar, 2024).

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(O_i - Y_i)^2 \tag{44}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(O_i - Y_i)^2} \tag{45}$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|Y_i - \underline{Y}| \tag{46}$$

$$R^2 = \left(\frac{\sum_{i=1}^{n}(O_i - \underline{O})(Y_i - \underline{Y})}{\sqrt{\sum_{i=1}^{n}(O_i - \underline{O})^2}\sqrt{\sum_{i=1}^{n}(Y_i - \underline{Y})^2}}\right)^2 \tag{47}$$

Em que:

- O_i: valor esperado (presente na base de dados);
- Y_i: valor estimado (calculado pelo modelo);
- $\underline{O}$: valor esperado médio;
- $\underline{Y}$: valor estimado médio;
- n: número de amostras na base de dados;

- i: i-ésima amostra na base de dados.

Com base nessas métricas, a RNA de melhor desempenho pode ser definida e, então, utilizada como ferramenta de predição do parâmetro-alvo.

3.4 COLETA, ANÁLISE E PROCESSAMENTO DE DADOS

Nesse item, é descrita em detalhes a consolidação da base de dados utilizada no treinamento do modelo, abrangendo desde a coleta dos valores até a análise de suas distribuições e o tratamento aplicado.

3.4.1 Construção do banco de dados

A primeira etapa da modelagem da taxa de carbonatação do concreto sob condições naturais de degradação e proposição de modelo preditivo da taxa foi a montagem do banco de dados que, neste trabalho em especial, consistiu na expansão de um banco de dados já existente. Considerando os desenvolvimentos do grupo de pesquisa DASMAE, o banco de dados inicialmente definido por Lavinicki (2024), contendo 1031 dados de concretos expostos exclusivamente à ação natural do CO_2, foi expandido para 2335 dados, todos satisfazendo a condição de os concretos serem expostos a ambientes naturais de degradação, isto é, sem carbonatação sob condição acelerada.

A coleta dos dados foi realizada considerando 29 bases de trabalhos acadêmicos e científicos, sendo elas: Alhassan, 2014; Ann *et al.*, 2010; Bouzoubaâ *et al.*, 2010; Carević; Ignjatović; Dragaš, 2019; Collepardi *et al.*, 2004; Cordoba *et al.*, 2022; Czarnecki; Woyciechowski, 2012; De Melo, 2022; Felix; Possan; Carrazedo, 2019; Ferreira, 2013; Garces-Vargas; Díaz-Cardenas; Martirena Hernandez, 2024; Huy Vu *et al.*, 2019; Khan; Nguyen; Castel, 2020; Liang; Huang; Fang, 2013; Liisma; Sein; Järvpõld, 2017; Lollini; Redaelli, 2021; Malysz *et al.*, 2023; Marani; Oyinkanola; Panesar, 2024; Meira; Padaratz; Borba Junior, 2006; Possan *et al.*, 2020; Radović *et al.*, 2024; Rathnarajan *et al.*, 2022; Ribeiro; Santos; Gonçalves, 2018; Shah; Bishnoi, 2018; Thomas; Matthews, 1992; Vieira *et al.*, 2009; Wang; Yang; Chen, 2017; Younsi; Turcry; Aït-Mokhtar, 2022; Yu *et al.*, 2023; Zhang; Wang; Chen, 2016. Na Tabela 6, é

possível conferir a quantidade de dados extraída de cada um dos trabalhos pesquisados.

Tabela 6 – Relação de autores e quantidades de dados extraídos da literatura.

Autor(es) e Ano	Quantidade de dados
Alhassan (2014)	27
Ann *et al.* (2010)	3
Bouzoubaâ *et al.* (2010)	48
Carević, Ignjatović e Dragaš, (2019)	12
Collepardi *et al.* (2004)	24
Cordoba *et al.* (2022)	30
Czarnecki e Woyciechowski (2012)	70
De Melo (2022)	32
Felix, Possan e Carrazedo (2019)	278
Ferreira (2013)	36
Garces-Vargas, Díaz-Cardenas e Martirena Hernandez, (2024)	18
Huy Vu *et al.* (2019)	677
Khan, Nguyen e Castel (2020)	1
Liang, Huang e Fang (2013)	33
Liisma, Sein e Järvpõld (2017)	11
Lollini e Redaelli (2021)	54
Malysz *et al.* (2023)	30
Meira, Padaratz e Borba Junior (2006)	24
Possan *et al.* (2020)	298
Radović *et al.* (2024)	17
Rathnarajan *et al.* (2022)	178
Ribeiro, Santos e Gonçalves (2018)	33
Shah e Bishnoi (2018)	15
Thomas e Matthews (1992)	287
Vieira *et al.* (2009)	40
Wang, Yang e Chen 2017	8
Younsi, Turcry e Aït-Mokhtar (2022)	40
Yu *et al.* (2023)	3
Zhang, Wang e Chen (2016)	8
Total	**2335**

Fonte: Autor.

Os parâmetros catalogados no banco de dados e, que são objeto de uso na modelagem da profundidade de carbonatação, foram: teor de clínquer e gesso

(CG+, em %), resistência à compressão aos 28 dias (Fc, em MPa), teor de adição mineral em relação ao consumo CG+ (Admix, em %), tipo de adição mineral (Tadmix, podendo ser: sem adição, escória de alto-forno, cinza volante, fíler calcário, sílica ativa ou outros materiais pozolânicos), concentração média de CO_2 atmosférico (CO2, em %), umidade relativa do ar média (UR em %), temperatura média (Temp, em °C), relação água/aglomerante (A/A, adimensional) e tipo do ambiente de exposição (Exp, podendo ser: ambiente externo exposto à chuva, ambiente externo protegido da chuva e ambiente interno) e a taxa de carbonatação (Kcarb em $mm/ano^{0,5}$), que é a variável objeto de predição.

No que diz respeito às variáveis ambientais (CO2, UR e Temp), é importante salientar que os valores considerados para cada predição são as médias de cada um desses parâmetros de entrada ao longo de todo o período de carbonatação, calculadas a partir de cada respectiva série histórica anual ou mensal, na maioria das vezes sendo referentes ao escopo de macroclima.

Para facilitar a extração de valores a partir de gráficos, utilizou-se o software Webplot Digitizer (Automeris LLC, 2024). Ao mesmo tempo, em boa parte dos estudos consultados não foram explicitados valores para todas as variáveis de entrada do modelo, fazendo-se necessária, portanto, a imputação de valores, isto é, o processo de estimar e preencher dados ausentes a partir de informações disponíveis em outras fontes.

Em alguns casos, os parâmetros associados ao ambiente de exposição, como a temperatura média, a umidade relativa do ar média e, principalmente, a concentração de CO_2 na atmosfera, não foram apresentados. Esses parâmetros foram imputados considerando bases meteorológicas de domínio público (Berkeley Earth, 2024; Dados Mundiais, 2024; Global Monitoring Laboratory, 2024) considerando os períodos de vida dos elementos de concreto, o período da publicação e o local de realização do estudo experimental.

Em outros casos, ainda foi necessário calcular o teor de clínquer e gesso do cimento utilizado no concreto, de acordo com a composição química em termos dos teores de SiO_2, CaO, Fe_2O_3 e Al_2O_3 fornecidos na literatura consultada. Para esse cálculo, foi utilizado o potencial de Bogue (Bogue, 1947), conforme as equações (48) a (51), que descreve estimativas do teor de cada um dos compostos anidros do

clínquer. Os valores de CG+ imputados na base de dados foram definidos como a soma dos teores desses compostos anidros.

$$C_3\mathrm{S} = 4{,}07\ \mathrm{CaO} - 7{,}60\ SiO_2 - 6{,}72\ \mathrm{Al_2O_3} - 1{,}43\ Fe_2O_3 \quad (48)$$

$$C_2\mathrm{S} = 8{,}60\ SiO_2 + 1{,}08\ Fe_2O_3 + 5{,}07\ \mathrm{Al_2O_3} - 3{,}07\ \mathrm{CaO} \quad (49)$$

$$C_3\mathrm{A} = 2{,}650\ \mathrm{Al_2O_3} + 1{,}692\ Fe_2O_3 \quad (50)$$

$$C_4\mathrm{AF} = 3{,}043\ Fe_2O_3 \quad (51)$$

Em algumas fontes de dados, a composição química detalhada não era fornecida, mas sim o tipo de cimento. Nessas situações, o teor de clínquer e gesso foi definido de acordo com a NBR 16697 (ABNT, 2018), mais especificamente de acordo com os valores médios da coluna “Clínquer + sulfatos de cálcio” da Tabela 4 apresentada no item 2.1.4.5 do presente trabalho.

Outra variável para a qual também foi necessária imputação, em alguns casos, foi a resistência à compressão aos 28 dias, uma vez que, em muitos casos, a resistência à compressão fornecida correspondia à data de medição da carbonatação. A fim de padronizar a propriedade mecânica, decidiu-se por calcular as resistências equivalentes aos 28 dias, utilizando o método apresentado pelo *fib Model Code* 2020, conforme as Equações (52) e (53) (Boni; Helene, 2024 apud CEB-FIP, 2023)

$$f_{c(t)} = \beta_{cc}(t).f_{c(t_{ref})} \quad (52)$$

$$\frac{f_{c(t)}}{f_{c(t_{ref})}} = e^{\left[S_c.\left(1-\sqrt{\frac{t_{ref}}{t}}\right).\sqrt{\frac{28}{t_{ref}}}\right]} \quad (53)$$

Em que:

- $f_{c(t)}$: resistência à compressão na idade t (MPa);
- $f_{c(t_{ref})}$: resistência à compressão na idade t_{ref} (MPa);
- $\beta_{cc}(t)$: função que representa o crescimento da resistência à compressão com o tempo (adimensional);
- S_c: coeficiente relacionado ao desenvolvimento da resistência do concreto que pode variar de 0,1 a 0,6 (adimensional);
- t: idade do concreto (dias), que pode ser ajustada em função da temperatura, conforme a Equação (54);
- t_{ref}: idade de controle e referência (geralmente 28 dias).

$$t = \sum_{i=1}^{n} \Delta t_i \, e^{\left[13{,}65 - \frac{4000}{273 + T_{(\Delta t_i)}}\right]} \tag{54}$$

Em que:

- Δt_i: número de dias nos quais a temperatura T prevalecer;
- $T_{(\Delta t_i)}$: temperatura média em °C durante o intervalo de tempo Δt_i, podendo variar entre -20 °C e 45 °C.

Em alguns casos, a variável-alvo do modelo de predição, a taxa de carbonatação, precisou ser determinada, já que apenas a profundidade de carbonatação era conhecida em determinado instante. A taxa de carbonatação foi então calculada de acordo com o modelo proposto por Tuutti (1982), apresentado na Equação (55).

$$y = k\sqrt{t} \tag{55}$$

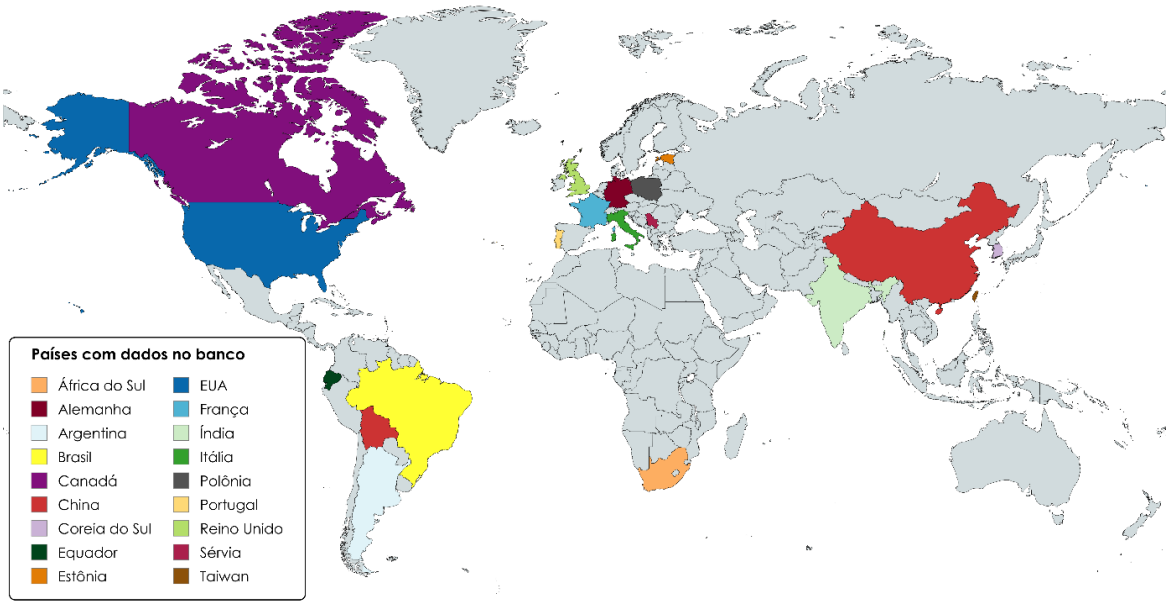
É importante salientar que a unidade de medida da taxa de carbonatação k, variável chave da presente pesquisa, é determinada justamente a partir desse modelo. Manipulando a equação (55), observa-se que o valor desse coeficiente é definido pela divisão da profundidade de carbonatação y (em milímetros) pela raiz do tempo ($\sqrt{t}$), justificando, portanto, a unidade de k (mm/ano^{0,5}), conforme a equação (56).

$$k = \frac{y}{\sqrt{t}} = \frac{mm}{\sqrt{ano}} \tag{56}$$

Além disso, como se pode ver na Figura 20, os dados são oriundos de 18 países (África do Sul, Alemanha, Argentina, Brasil, Canadá, China, Coreia do Sul, Equador, Estônia, EUA, França, Índia, Itália, Polônia, Portugal, Reino Unido, Sérvia e Taiwan), o que ressalta a diversidade climatológica presente nos dados de treinamento. Aqui, é importante pontuar uma das principais contribuições do estudo: a inclusão da temperatura média do ambiente para mapear a carbonatação,

considerando o processo sinérgico entre umidade relativa, temperatura e incidência de chuva.

Figura 20 - Países contemplados no banco de dados.



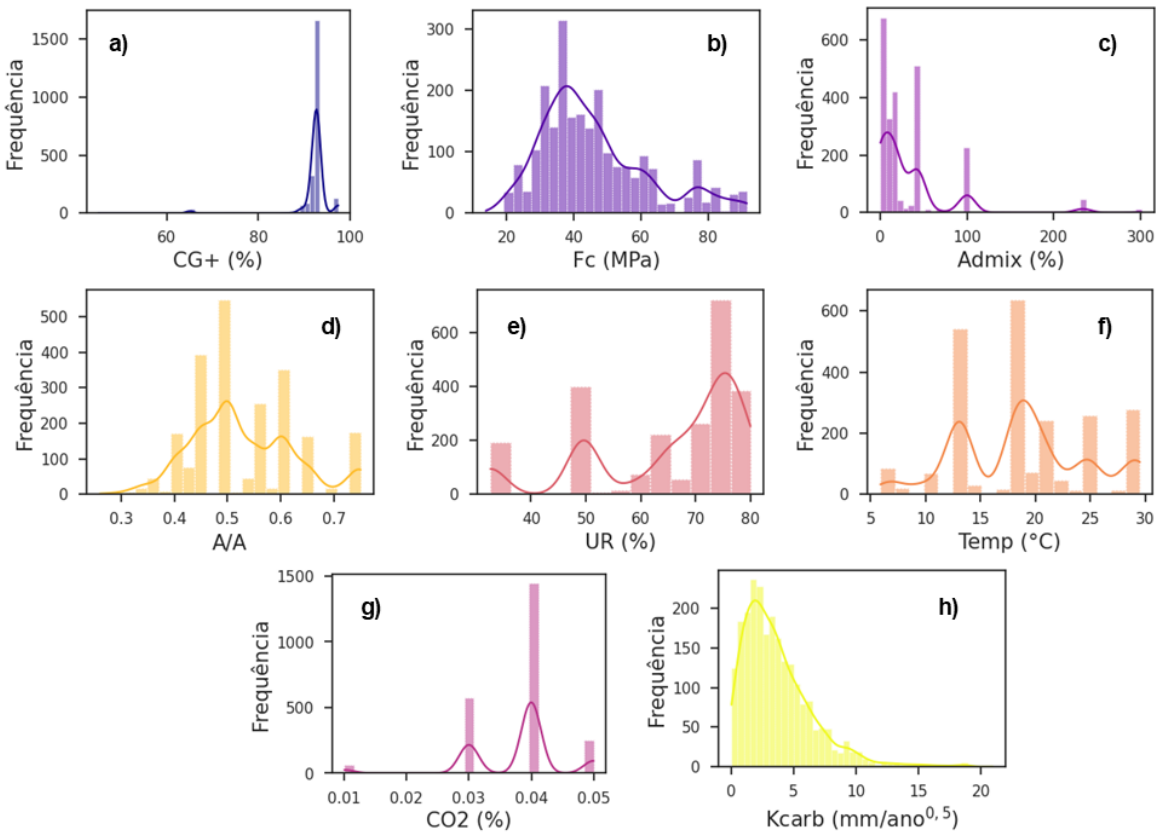
Fonte: Autor.

Após a coleta de dados em trabalhos nos quais era possível obter a maior parte dos parâmetros de entrada considerados na modelagem e na imputação dos valores faltantes, a base bruta foi finalizada com 2335 dados. A distribuição dos dados brutos pode ser conferida na Figura 21.

Na Figura 21.a, é possível perceber uma forte concentração de amostras na faixa entre 90% e 100% dos dados de teor de clínquer e de gesso do cimento utilizado nos concretos do banco de dados. Essa faixa de valores é usual para os cimentos Portland brasileiros dos tipos CP I (cimento Portland comum) e CP V (cimento Portland de alta resistência inicial) (ABNT, 2018).

A distribuição conta ainda, entretanto, com frequências quase imperceptíveis de valores mais baixos que 90%, tendo como mínimo o valor de 45%. Essa faixa de valores mais baixos de teor de clínquer e gesso abrange cimentos Portland brasileiros com outras composições, como CP II (cimento Portland composto), CP III (cimento Portland de alto forno) e CP IV (cimento Portland pozolânico).

Figura 21 – Distribuições brutas das variáveis contínuas do banco de dados.



Fonte: Autor.

Na Figura 21.b, é apresentada a distribuição de resistência à compressão do concreto aos 28 dias, com formato de curva semelhante ao de uma distribuição normal. A maior parte dos dados concentra-se em torno de 40 MPa, enquanto seus mínimos e máximos variam de valores inferiores a 20 MPa a valores próximos de 90 MPa.

Na Figura 21.c, por sua vez, é possível verificar a distribuição dos valores do teor de adição mineral (de diversos tipos) em cada dado. É perceptível que a maior parte dos dados se concentra entre 0% e 50%, com uma frequência significativa em 100% e ainda alguns dados com mais de 200% de adição.

Esses dados com alto teor de adição em relação ao consumo de cimento são provenientes do estudo de Younsi, Turcry e Aït-Mokhtar (2022). No estudo em questão, os autores indicam explicitamente que essa proporção de mistura não segue o definido pela norma (AFNOR, 2014).

A distribuição da relação água/aglomerante pode ser observada na Figura 20.d, acompanhando naturalmente a da resistência à compressão. A maior parte dos valores está na faixa entre 0,5 e 0,6, enquanto seu máximo é de 0,75 e seu mínimo, de 0,26.

Na Figura 21.e, está a distribuição dos valores de umidade relativa, que apresenta assimetria considerável, com picos entre 70% e 80%. O histograma, entretanto, ilustra uma quantidade de valores próximos de 30% e 50%, refletindo a diversidade climática da base de dados.

O mesmo acontece com a distribuição de valores de temperatura na Figura 21.f, com os valores distribuídos entre 5 e 30 °C. A maior parte dos valores está próxima a 13 e 18 °C, com alguns poucos dados em temperaturas mais baixas e uma quantidade maior em temperaturas acima dos 20 °C.

O histograma dos dados de concentração de dióxido de carbono é apresentado na Figura 21.g, onde é possível verificar a maior frequência no valor de 0,04%. Há dados com 0,03% e 0,05%, e ainda uma quantia menor com 0,01% de concentração. É importante ressaltar que, especificamente para essa variável de entrada, os valores na maior parte das vezes foram obtidos via bases de dados de domínio público com médias de concentração de CO_2 mundial, o que pode ter reduzido sua diversidade e continuidade.

Por fim, na Figura 21.h, é possível conferir a distribuição dos dados da taxa de carbonatação. A maior parte dos dados está concentrada entre 0 e 10 mm/ano^{0,5}, com uma “cauda” do gráfico à direita, abrangendo valores até a ordem de 20 mm/ano^{0,5}.

Foi definida, ainda, uma codificação para as variáveis discretas, que são os tipos de adição mineral e a condição de exposição à chuva. Foram atribuídos valores numéricos a cada um dos seus possíveis valores nominais para uso no modelo de predição, que podem ser consultados na Tabela 7. Os valores definidos para condição de exposição à chuva foram obtidos em Possan (2010), enquanto os valores de adição mineral foram definidos arbitrariamente com valores aleatórios de 1 a 5, e zero para ausência de adições.

Tabela 7 - Codificação de valores para variáveis discretas.

Variável	Codificação
Tipo de adição mineral (Tadmix)	0: sem adição 1: escória de alto-forno 2: cinzas volantes 3: fíler calcário 4: sílica ativa 5: outros materiais pozolânicos
Condição de exposição à chuva (Exp)	0,65: externo desabrigado da chuva 1,0: externo abrigado da chuva 1,30: interno

Fonte: Autor.

3.4.2 Processamento e análise dos dados tratados

Com o banco de dados bruto consolidado, os dados foram então tratados para a remoção de outliers. A determinação de outliers foi feita através do método do Interquartile Range (IQR), técnica estatística embasada na dispersão dos valores e utilizada para identificação dos outliers (Tukey, 1977).

Essa técnica consiste em tomar a parte central da distribuição dos dados como referência para descarte de dados muito distantes da média. Essa parte central é definida pela diferença entre o terceiro quartil (Q3) e o primeiro quartil (Q1), como se vê na Equação (57).

$$IQR = Q3 - Q1 \tag{57}$$

Em que Q3 é o valor abaixo do qual estão 75% dos dados e Q1 o valor abaixo do qual estão 25% dos dados. Desse modo, o IQR corresponde aos 50% centrais da distribuição e será utilizado no critério de exclusão de outliers.

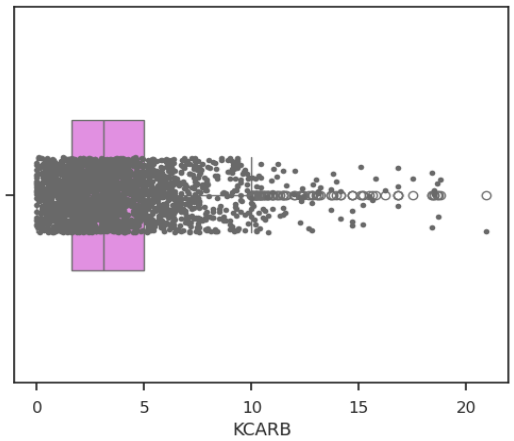
O critério de exclusão pode variar, mas tem como essência adotar uma faixa de tolerância acima dos limites de Q3 e Q1 e excluir os demais. As equações (58) e (59) descrevem o critério adotado na presente pesquisa para determinação dos valores a serem excluídos.

$$Outliers\ inferiores < Q1 - 1{,}5 \cdot IQR \tag{58}$$
$$Outliers\ superiores > Q3 + 1{,}5 \cdot IQR \tag{59}$$

O critério de IQR foi aplicado tendo como referência gráfica o boxplot de distribuição dos valores da variável-alvo de predição, a taxa de carbonatação, como pode ser conferido na Figura 22.

Conforme as equações (58) e (59), os limites inferior e superior para detecção dos outliers foram calculados, resultando em -3,38 e 10, respectivamente. Uma vez que não há valores negativos de Kcarb, o limite inferior foi ignorado. Observando a Figura 22, notam-se dois retângulos de coloração roxa, que compreendem a faixa central de concentração dos dados, isto é, os valores entre o primeiro e terceiro quartis, enquanto é possível perceber o limite superior definido por uma linha vertical acima do valor de 10 mm/ano^{0,5}.

Figura 22 – Gráfico Boxplot da distribuição da taxa de carbonatação na base de dados bruta.



Fonte: Autor.

Dados à direita desse valor, que, visivelmente, têm menor frequência, foram considerados outliers. Além disso, a remoção desses valores contribuiu para distanciar o domínio do modelo de predição de situações de carbonatação acelerada, que é justamente uma das contribuições do presente trabalho.

Além da remoção de outliers pelo critério de IQR, o banco de dados foi também podado de acordo com valores usuais da realidade da construção civil e de pesquisas acadêmicas. Isso foi feito essencialmente para que o modelo desenvolvido tenha seu domínio de funcionamento definido na aplicabilidade em cenários práticos de estudos acadêmicos e construções reais.

Para limitar o domínio de entrada e de saída do modelo para sua calibração e melhor desempenho em cenários mais próximos à realidade da construção civil e à

maioria das pesquisas acadêmicas, foram impostos os limites apresentados na Tabela 8.

Tabela 8 - Restrições ao domínio do modelo.

Variável	Limite imposto
CG+ (%)	Maior ou igual a 80,0
Fc (Mpa)	Menor ou igual a 60,0
Admix (%)	Menor ou igual a 100,0
A/A	Menor ou igual a 0,65
Kcarb ($mm/ano^{0,5}$)	Menor ou igual a 10,0

Fonte: Autor.

Além da remoção de outliers com base nos valores de Kcarb, a primeira restrição foi quanto ao teor de adições minerais, limitado a 100%. Ou seja, foram considerados apenas dados em que a quantidade de aditivo mineral fosse igual ou inferior à de cimento utilizada na produção do concreto.

A segunda restrição foi focada no teor de clínquer e de gesso do aglomerante, limitado ao mínimo de 80%. Isso foi feito para reduzir a assimetria da sua distribuição e tornar o modelo mais preciso no seu escopo de atuação, uma vez que, se fossem considerados os valores abaixo desse piso, o modelo poderia fornecer predições errôneas devido ao baixo volume de dados.

A terceira restrição consistiu na resistência à compressão aos 28 dias. De modo a não abranger concretos de alta resistência, o Fc foi limitado a, no máximo, 60 MPa.

A quarta restrição envolveu a relação água-aglomerante, com valor máximo de 0,65. Valores maiores tendem a resultar em porosidade elevada e resistências à compressão muito baixas.

Foi realizada, ainda, a eliminação de valores com profundidades de carbonatação distintas sob condições iguais de material, atmosfera e tempo de exposição, resultando, portanto, em taxas de carbonatação distintas para as mesmas condições de variáveis de entrada. O procedimento adotado foi calcular a média dos valores de output para os mesmos valores de input e eliminar os dados com valores de output divergentes.

Após a poda completa do banco de dados bruto, obteve-se o banco de dados tratado, com 1644 registros, que foi utilizado na modelagem das redes neurais.

Na Tabela 9, é possível conferir algumas linhas do banco de dados, a título de exemplificação didática de como se dispõem os dados no arquivo-fonte. É importante salientar que essa é uma pequena amostra extraída aleatoriamente da base de dados existente, centenas de vezes maior do que essa amostra, não sendo razoável utilizar esse subconjunto para realizar quaisquer inferências acerca da predominância de correlações entre as variáveis expostas.

Tabela 9 – Exemplo de linhas existentes no banco de dados tratado.

CG+ (%)	Fc (MPa)	Admix (%)	Tadmix	CO2 (%)	UR (%)	Temp (°C)	A/A	Exp	Kcarb ($mm/ano^{0,5}$)
97,5	19,52	0,0	0	0,05	70,0	21,0	0,63	1,00	4,37
97,5	37,00	30,0	3	0,04	75,0	13,0	0,61	1,00	5,20
93,2	59,47	11,1	5	0,03	32,6	24,9	0,60	1,30	2,56
92,6	56,40	17,7	1	0,04	65,0	20,7	0,50	0,65	0,21
92,0	40,00	0,0	0	0,01	70,0	24,3	0,53	1,00	1,58
93,1	50,00	17,87	2	0,05	70,0	29,5	0,50	0,65	3,46

Fonte: Autor.

As distribuições de variáveis contínuas podem ser conferidas na Figura 23 e seus respectivos parâmetros estatísticos na Tabela 10. As principais alterações nas distribuições residem exatamente nas que apresentaram limitações, conforme a Tabela 8.

O teor de adição mineral máximo da distribuição da Figura 23.c foi definido em 100% e a taxa de carbonatação máxima, em 10 $mm/ano^{0,5}$, conforme Figura 23.h. Na Figura 23.a, mudança no domínio de distribuição dos valores de CG+ foi perceptível, com os dados ainda concentrados fortemente nos arredores de 92,5%, mas agora sem nenhum valor abaixo de 85%.

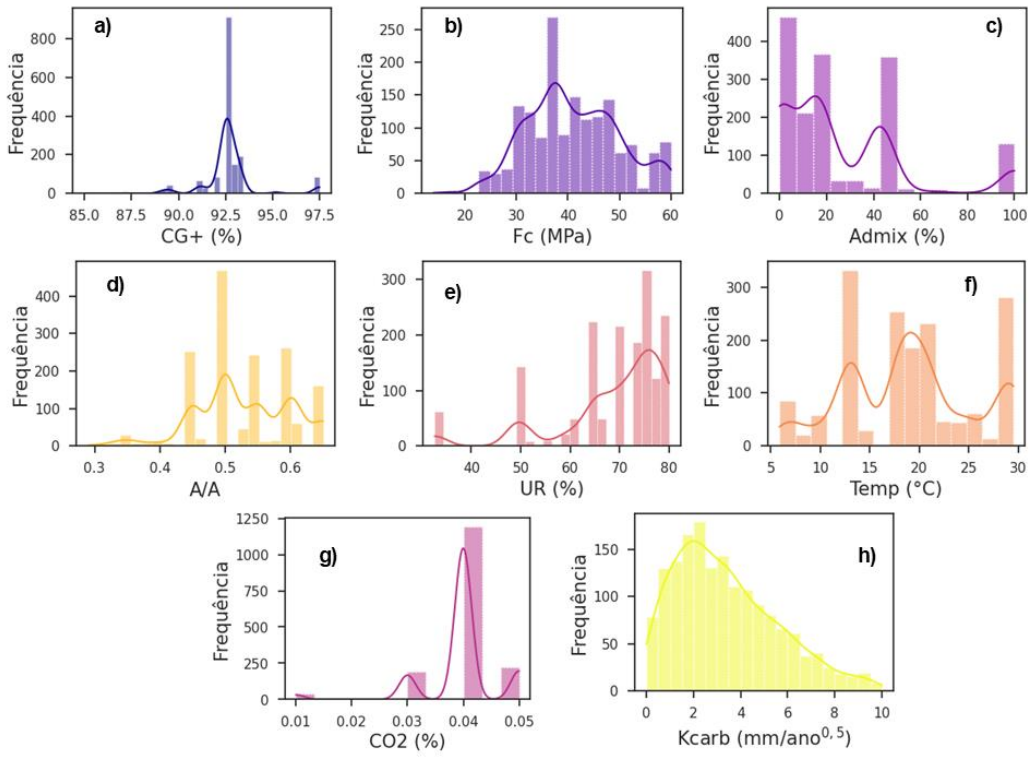
Na Figura 23.b, o histograma de Fc apresenta como valor máximo 60 MPa, enquanto, na Figura 22.d, a relação água-aglomerante apresenta como valor máximo 0,65. As restrições nessas duas variáveis também limitaram os menores valores de uma para a outra, uma vez que, ao remover altos valores de Fc, valores de A/A mais baixos também foram naturalmente eliminados, e vice-versa, devido à correlação direta entre as variáveis.

Tabela 10 - Parâmetros estatísticos das variáveis contínuas do banco de dados tratado.

Variáveis	Unidade	Mínimo	Máximo	Média	Desvio padrão	1° Quartil	3° Quartil
Clínquer + Gesso (CG+)	%	85,00	97,50	92,71	1,43	92,56	93,51
Resistência à Compressão média (Fc)	MPa	13,90	60,00	40,97	8,80	34,60	47,70
Teor de adição mineral (Admix)	%	0,00	100,00	25,48	27,58	0,00	42,86
Relação água-aglomerante (A/A)	-	0,29	0,65	0,53	0,07	0,50	0,60
Umidade relativa do ar (UR)	%	32,60	80,00	68,87	11,19	65,00	76,00
Temperatura (Temp)	°C	5,90	29,50	18,95	6,39	13,10	22,00
Concentração de CO_2 atmosférico (CO2)	%	0,01	0,05	0,04	0,01	0,04	0,04
Taxa de carbonatação (Kcarb)	mm / $ano^{0,5}$	0,00	10,00	3,37	2,18	1,70	4,73

Fonte: Autor.

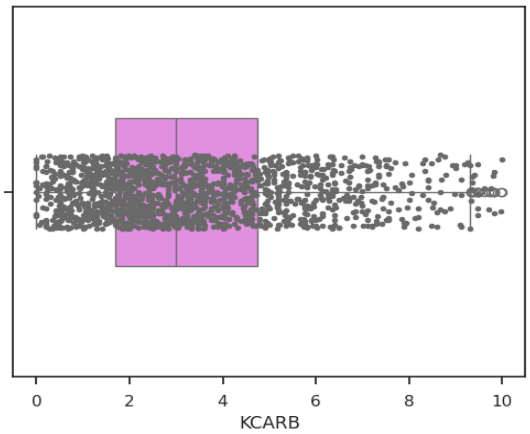
Figura 23 – Distribuições tratadas das variáveis contínuas do banco de dados.



Fonte: Autor.

É possível conferir ainda o gráfico boxplot resultante após o tratamento dos dados e a matriz de correlação de Pearson entre as variáveis na Figura 24 e na Figura 25.

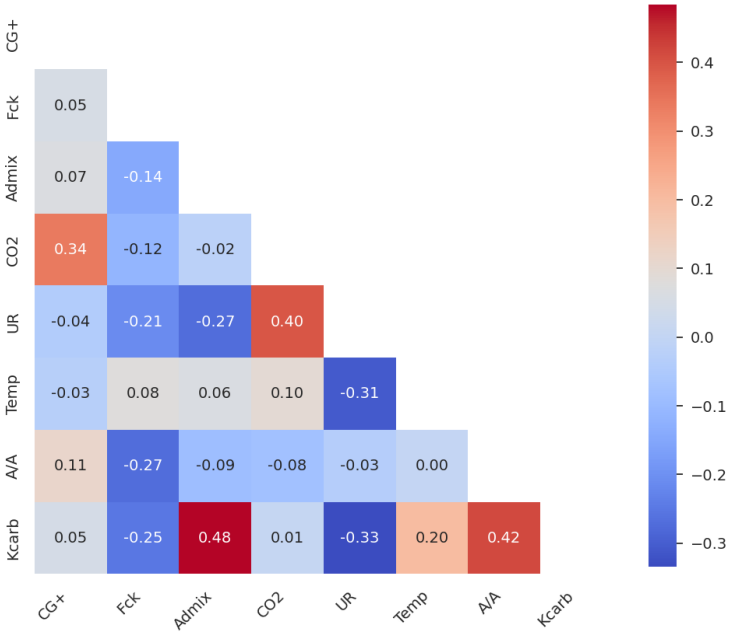
Figura 24 - Gráfico boxplot da distribuição da taxa de carbonatação na base de dados tratada.



Fonte: Autor.

Como pode ser observado na Figura 24, a distribuição dos dados de taxa de carbonatação agora se ajusta muito melhor aos limites de definição de outliers pelo método do IQR. Na Figura 25, por sua vez, é possível observar a correlação direta ou inversa entre as variáveis da base de dados.

Figura 25 - Matriz de correlação de Pearson entre as variáveis.



Fonte: Autor.

Primeiramente, percebem-se as maiores correlações com a taxa de carbonatação (Kcarb), sendo o teor de adição mineral (Admix) e a relação água-aglomerante (A/A) diretamente proporcional e a umidade relativa do ar (UR) inversamente. Correlações intermediárias da taxa de carbonatação são observadas com as variáveis de resistência à compressão (Fc) e temperatura (Temp). As correlações mais baixas com a taxa de carbonatação são as provenientes do teor de clínquer e de gesso, e do teor de dióxido de carbono na atmosfera.

No trabalho de Bueno *et al.* (2024), há um contraste com a base de dados em questão. Os autores relatam como o uso de cimentos Portland dos tipos II, III e IV, que possuem menor teor de clínquer e de gesso, afeta a probabilidade de despassivação das armaduras. Nesse caso, houve uma correlação significativa entre Kcarb e CG+, com carbonatação mais acentuada em estruturas com menor teor de clínquer e gesso.

Na análise de sensibilidade desenvolvida por Uwanuakwa (2021), a relação água-aglomerante, o conteúdo de cimento no concreto e a composição química do aglomerante se mostraram entre as variáveis com maior impacto na profundidade de carbonatação, enquanto a temperatura e o teor de CO_2 estiveram entre aquelas com menor impacto. Portanto, considerando a matriz de correlação exposta na Figura 25, pode-se afirmar que a maioria das variáveis da base de dados da presente pesquisa tem suas relevâncias coerentes com o observado no estudo descrito. A exceção reside apenas na variável CG+, que, como observado na Figura 25, tem correlação de magnitude 0,05 com a Kcarb, um dos menores valores em módulo da Matriz.

No estudo de Akpinar e Uwanuakwa (2020), os autores explicitam como, apesar do dióxido de carbono ser essencial para o processo de carbonatação, seu nível em si não interfere tanto na intensidade do processo quanto nas interações de outras variáveis. No estudo, os efeitos de altas temperaturas, valores de umidade em torno de 75% e altos valores de relação água-aglomerante são expostos, consoando com as correlações encontradas na base de dados do estudo em questão.

Para Kellouche *et al.* (2019), variações para mais ou para menos na concentração de CO_2 também pouco impactaram as profundidades de carbonatação, sendo pouco relevantes quando comparadas com outras variáveis como umidade relativa, temperatura e outros fatores intrínsecos ao material. Além disso, os autores

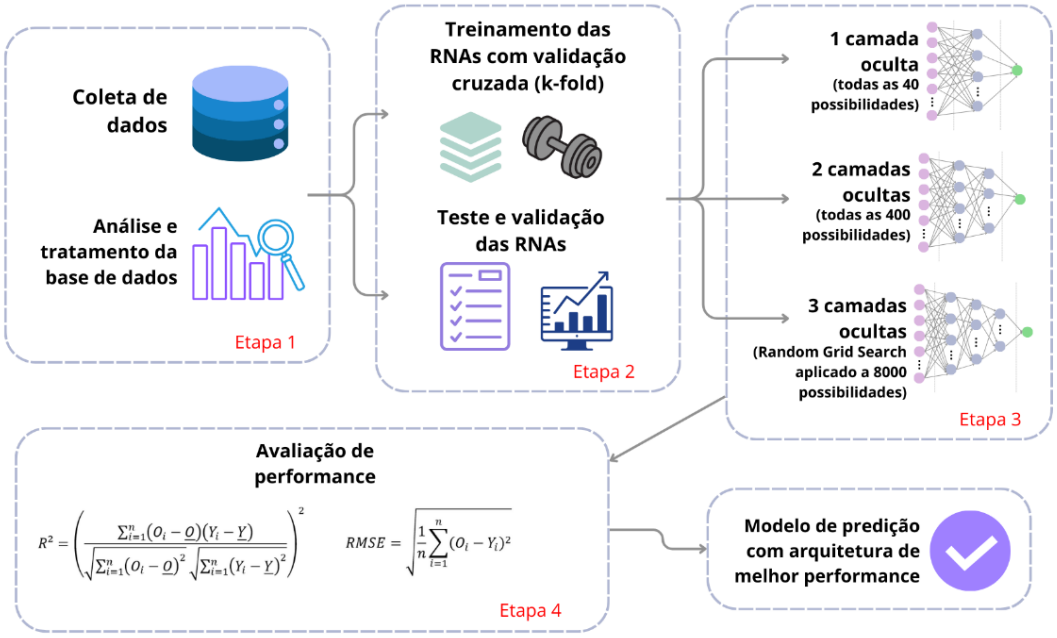
ressaltam como a adição de cinzas volantes afeta a taxa de carbonatação, destacando-se especialmente em idades de exposição do concreto mais avançadas.

3.5 PROPOSIÇÃO DO MODELO DE CARBONATAÇÃO

Com a base de dados tratada, é possível desenvolver a rede propriamente dita, definindo a sua arquitetura padrão inicial com base na literatura existente e buscando a melhor função de ativação e a quantidade de neurônios por camada. O processo utilizado neste estudo para a busca da rede de melhor desempenho é apresentado na Figura 26.

Para a modelagem e os testes das redes da presente pesquisa, foi utilizada a linguagem de programação Python na plataforma Jupyter do ambiente de desenvolvimento Anaconda. A biblioteca aplicada foi a Scikit-Learn, que é de código aberto, está disponível na linguagem adotada, é amplamente utilizada para simplificar a implementação de algoritmos de classificação e regressão (Pedregosa *et al.*, 2011) e cuja documentação pode ser consultada em SCIKIT-LEARN (2025).

Figura 26 - Fluxograma do processo de busca pela arquitetura de melhor desempenho.



Fonte: Autor.

É importante salientar que o escopo da modelagem se restringiu à otimização do número de camadas e de neurônios por camada. Os demais hiperparâmetros da RNA foram mantidos constantes, com base em resultados anteriores do grupo de pesquisa DASMAE e demais literatura consultada (Bueno *et al.*, 2025; Felix *et al.*, 2023, 2024; Majlesi *et al.*, 2023), cujos valores podem ser consultados na Tabela 11.

Tabela 11 - Valores fixos de hiperparâmetros.

Hiperparâmetro	Valor
Número máximo de épocas	10^6
Algoritmo de otimização	Gradiente descendente estocástico
Alpha (penalização L2 para pesos grandes)	10^{-5}
Ajuste da taxa de aprendizado	Adaptativa (mantém-se constante ou é reduzida quando necessário)
Critério de parada para *early stopping* (valor mínimo de melhora por época no erro)	10^{-5}
Early stopping	Ativado
Função de ativação	Sigmoide logística
Número de estratificações para treinamento e teste	7
Número máximo de épocas sem melhora	10^5
Proporção de dados para validação	13%
Proporção de dados para treino	72%
Proporção de dados para teste (para realização da avaliação de performance)	15%
Tamanho do lote para atualização dos pesos	200 amostras por lote (10 lotes por época)
Taxa de aprendizado inicial	0,3

Fonte: Autor.

Para o presente objetivo, que é a modelagem da taxa de carbonatação do concreto em função de fatores atmosféricos e fatores do material, o número de camadas ocultas varia de 1 a 3, conforme recomendações de outros estudos (Felix *et al.*, 2024; Majlesi *et al.*, 2023; Marani; Oyinkanola; Panesar, 2024; Wu *et al.*, 2021). Desse modo, foram definidas topologias padrão de redes com 1, 2 e 3 camadas.

O número de neurônios por camada variou em cada topologia global. Enquanto as redes de camada única tiveram de 1 a 40 neurônios, as redes de 2 e 3 camadas tiveram de 1 a 20 neurônios por camada. Desse modo, o total de combinações de redes de 1, 2 e 3 camadas foi, respectivamente, 40, 400 e 8000.

Para as redes de 1 e 2 camadas, todas as combinações possíveis foram formadas e treinadas, enquanto para as redes de 3 camadas ocultas, foi aplicado o método de Random Grid Search. Essa abordagem diferenciada para as redes de 3 camadas foi adotada pelo fato de haver um número significativo de arquiteturas possíveis. Na hipótese de serem testadas todas as possibilidades existentes, haveria uma demanda altíssima de recursos computacionais e de tempo, visto que algumas triagens demandaram mais de 48 horas de modelagem (Bergstra; Bengio, 2012). O processo citado pode ser consultado em mais detalhes na seção 3.6.

Para o treinamento de todas essas topologias, algumas medidas foram adotadas para melhorar a detecção de overfitting (superaprendizado) e, assim, preveni-lo. Esse fenômeno acontece quando a rede modela muito bem os dados com os quais foi treinada, mas apresenta dificuldade em generalizar, isto é, em obter resultados razoáveis com dados de entrada diferentes daqueles com os quais foi treinada.

A primeira medida foi a normalização dos dados, isto é, a ordem de grandeza de todos os valores da base foi homogeneizada. Essa é uma técnica amplamente difundida para o treinamento de RNAs pois, com ela, o aprendizado ocorre de maneira mais estável, sem que haja dominância de variáveis com grandes valores (como a resistência à compressão, por exemplo) sobre aquelas com valores na ordem dos décimos (como a relação água-aglomerante, por exemplo) (Marani; Oyinkanola; Panesar, 2024; Uwanuakwa, 2021).

A segunda foi a adoção da técnica de validação cruzada K-fold. Essa técnica consiste em dividir o banco de dados em k partes (*folds*) de tamanho semelhante, de modo que, a cada rodada de treinamento, uma dessas partes seja usada para validação e as demais para treino. Para o presente trabalho, o número de divisões utilizado foi igual a 7.

Ao final, a performance é medida pela média dos resultados obtidos em cada rodada. Essa estratégia proporciona maior diversidade de cenários de treinamento e teste, tornando a avaliação mais confiável e reduzindo a chance de o

modelo ser enviesado por uma partição específica do conjunto de dados, além de fornecer indícios mais claros sobre a ocorrência de overfitting (Aaron *et al.*, 2025; Bueno *et al.*, 2025; Géron, 2021).

Complementarmente, aplicou-se a técnica de estratificação dos dados na divisão dos conjuntos de treino e de validação. A estratificação garante que a distribuição de cada variável de interesse seja preservada em cada *fold*, assegurando que todas as partições reflitam, de forma representativa, o conjunto original. Esse cuidado é particularmente importante em bases de dados desbalanceadas ou com variáveis contínuas de ampla dispersão, uma vez que evita que determinados intervalos ou classes fiquem sub ou super-representados em algumas rodadas, melhorando a robustez estatística e a confiabilidade do treinamento da rede neural (Géron, 2021; Goodfellow; Bengio; Courville, 2016; Haykin, 1999).

3.6 ANÁLISE DE PERFORMANCE DOS MODELOS

Para que a performance das diferentes arquiteturas testadas pudesse ser avaliada, foram adotadas as métricas de coeficiente de correlação (R^2) e raiz do erro quadrático médio (RMSE), conforme as Equações (47) e (45), respectivamente. Para todas as redes, ambas as métricas foram calculadas tanto para os dados de treino quanto para os de teste. A avaliação e a definição da melhor rede (com melhor generalização e bom aprendizado) foram realizadas considerando métricas ponderadas, calculadas como a média ponderada de 40% da métrica obtida com os dados de treino e 60% da obtida com os dados de teste. Desse modo, as métricas R^2 e RMSE de treino e de teste são sintetizadas em R^2 e RMSE ponderados, atribuindo maior importância aos testes, por representarem a capacidade de generalização da rede sobre dados desconhecidos, o que é desejável ao gerar modelos preditivos.

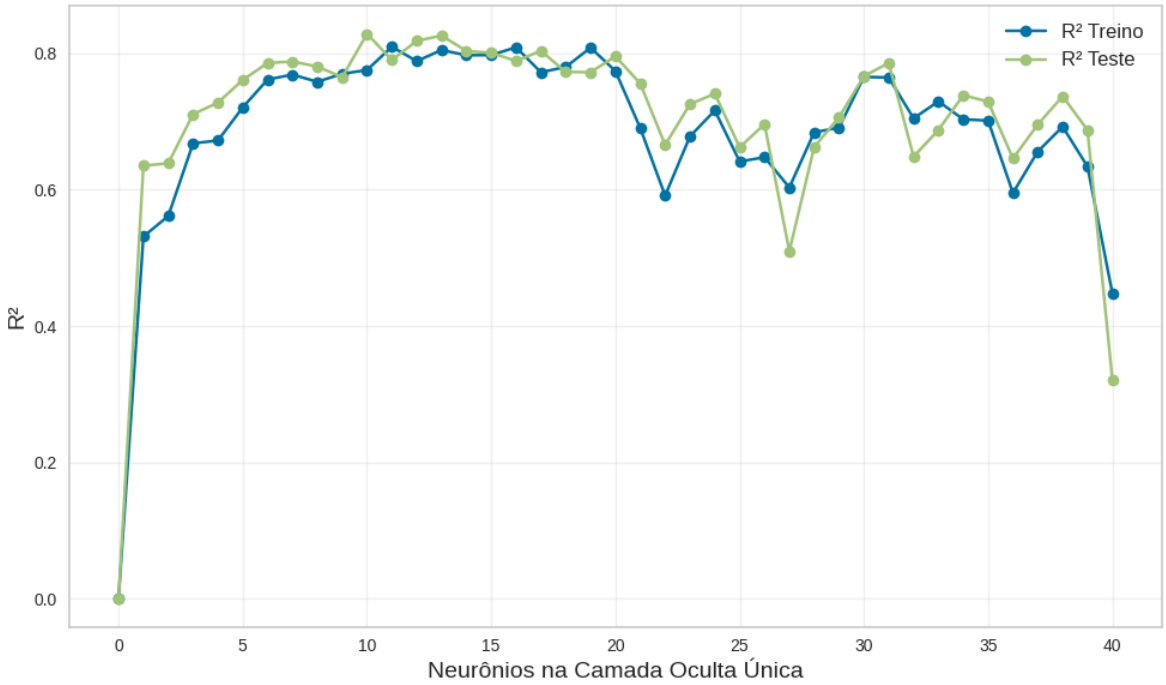
3.6.1 Redes de uma camada

As primeiras redes desenvolvidas foram as de camada única, e os desempenhos de treino e de teste podem ser observados na Figura 27. Como é possível perceber, a performance cresce rapidamente até o uso de 5 neurônios, mantendo-se na faixa de 0,75 a 0,80 até 20 neurônios. Durante o treinamento, o maior

valor de R^2 foi de cerca de 0,81 com 11 neurônios, enquanto, no teste, a melhor rede foi definida com 10 neurônios, atingindo R^2 de 0,83.

Já para redes com mais de 20 neurônios, há um aumento nítido na variabilidade das performances, assim como uma discrepância maior entre treino e teste. Além disso, é nítido o declínio na precisão nas redes com mais de 35 neurônios, com R^2 inferior a 0,70.

Figura 27 – Performance de treino e teste das 40 redes de camada única.



Fonte: Autor.

Desse modo, é possível afirmar que os resultados mais consistentes e robustos ocorrem nas redes de 10 a 20 neurônios em uma única camada. A melhor rede encontrada contém 13 neurônios, com R^2 de treino igual a 0,805 e de teste igual a 0,826 (R^2 ponderado = 0,818) e RMSE de treino e de teste iguais a 0,964 e 0,916 $mm/ano^{0,5}$, respectivamente. Pode-se citar também a rede de 10 neurônios, que alcançou R^2 de teste no valor de 0,829, ligeiramente maior que a de 13, mas ficando muito abaixo no R^2 de treino, com 0,776.

No trabalho de Felix, Possan e Carrazedo (2019), as topologias avaliadas variaram tanto no número de parâmetros de entrada (4, 5 e 7) quanto na quantidade de neurônios (1 a 10) na camada oculta única do modelo de RNA treinado com uma base de 278 dados de carbonatação não-acelerada. O número ótimo de neurônios na

camada oculta encontrado foi de 6, em conjunto com todos os 7 parâmetros de entrada possíveis, atingindo valores de R^2 iguais a 0,994 e 0,981 nas fases de treino e teste.

O estudo de Akpinar e Uwanuakwa (2016) avaliou redes de uma única camada com 5, 10 e 15 neurônios sendo treinadas por uma base de 225 dados de 9 estudos distintos. De acordo com os autores, o melhor desempenho da rede foi obtido com 10 neurônios.

No trabalho de Kazemi (2024), são investigadas as performances de redes com uma camada oculta com 8 a 20 neurônios treinadas com 532 dados de carbonatação acelerada. A arquitetura ótima atingiu R^2 acima de 0,99 tanto no treino quanto no teste e RMSE de 1,105 mm, com 16 neurônios na camada oculta.

Como pode ser visto na literatura consultada, o número ótimo de neurônios em redes com uma única camada geralmente situa-se em valores intermediários do conjunto explorado, variando essencialmente na faixa de 10 a 15 neurônios. Essa constatação é consoante com o encontrado na presente pesquisa, indicando a consistência dos resultados, apesar de desempenhos relativamente mais baixos, o que é esperado, dado que neste estudo está sendo modelada a carbonatação de estruturas em condições naturais de degradação, com concretos provenientes de diferentes partes do planeta, o que confere grande heterogeneidade ao banco de dados.

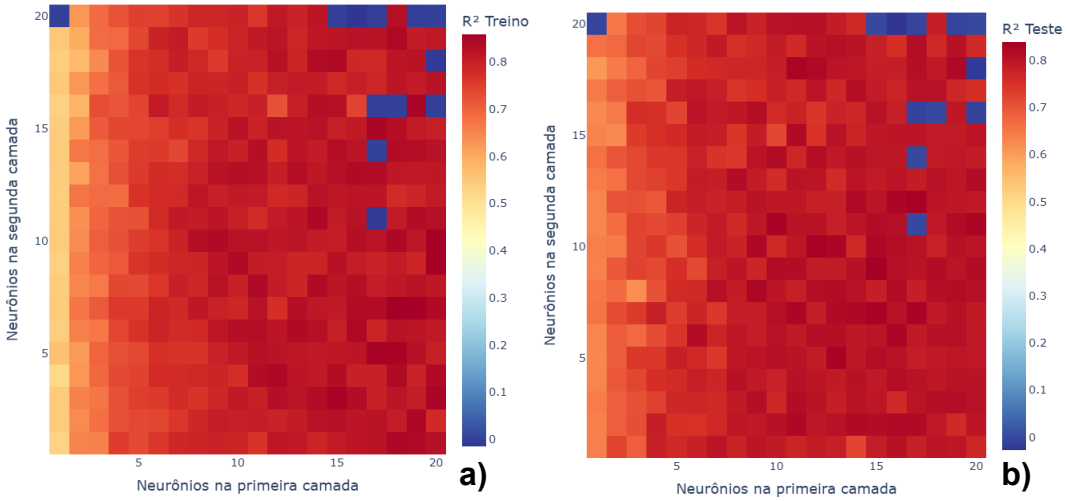
3.6.2 Redes de duas camadas

Após as redes de uma única camada, as redes desenvolvidas tiveram duas camadas ocultas, com 1 a 20 neurônios em cada uma. O desempenho de cada uma delas pode ser observado na Figura 28.

Como pode ser observado, algumas redes de duas camadas, especialmente entre aquelas com alto número de neurônios em ambas as camadas, apresentaram R^2 igual a zero, isto é, a simulação falhou, não sendo possível obter aprendizado de máquina com a arquitetura no número máximo de iterações permitido. Nas redes válidas, a arquitetura com melhor desempenho foi a 9-15-9-1 (9 neurônios na camada de entrada, 15 na primeira camada oculta, 9 na segunda camada oculta e 1 na saída), com R^2 de treino igual a 0,827, R^2 de teste igual a 0,839 (R^2 ponderado =

0,834), RMSE de treino igual a 0,908 mm/ano^{0,5} e RMSE de teste igual a 0,882 mm/ano^{0,5}.

Figura 28 - Performance de treino e teste das 400 redes de 2 camadas.



Fonte: Autor.

No estudo de Majlesi *et al.* (2023) foram desenvolvidos modelos de 1, 2 e 3 camadas, com até 20 neurônios por camada, obtendo como topologia ótima uma rede com 3 camadas. Entretanto, é explicitado, no escopo de 2 camadas, o número ótimo de neurônios como 10 na primeira e 7 na segunda camada oculta, com valores de R² de treino e teste iguais a 0,96 e 0,94, e de RMSE de treino e de teste iguais a 3,05 mm e 3,215 mm. Ainda de acordo com os autores, os resultados da pesquisa indicam que a quantidade mínima de neurônios necessária para obter um R² de teste superior a 0,85 é de 5 neurônios, tanto na primeira quanto na segunda camada.

Já no trabalho desenvolvido por Felix *et al.* (2024), são estudadas redes de duas camadas com até 10 neurônios por camada acopladas a simulações probabilísticas. Os autores encontraram como topologia ótima a presença de 6 neurônios tanto na primeira quanto na segunda camada, com valores de R² de treino iguais a 0,926 e de teste iguais a 0,81, com um RMSE médio de 1,288 mm.

Como pode ser visto, o resultado de arquitetura ótima para redes com duas camadas ocultas no presente estudo foi coerente com o relatado na literatura atual, com alguma margem de melhoria de desempenho. É possível verificar ainda que redes com mais de uma camada têm uma capacidade maior de descrever fenômenos não lineares complexos do que aquelas de camada única, como pôde ser constatado quando contrastados os resultados desse item com os do item 3.6.1.

3.6.3 Redes de três camadas

Para as redes de 3 camadas, conforme descrito no item 3.5, o processo de exploração de arquiteturas adotado foi o Random Grid Search. Esse processo foi realizado com a combinação dos processos de Random Search e de Grid Search.

Inicialmente, há a aplicação do Random Search, de modo que sejam geradas arquiteturas aleatórias para exploração e podas sucessivas no espaço de busca. Com esse espaço já razoavelmente restrito, então é aplicado o processo de Grid Search, onde todas as arquiteturas possíveis são testadas e, enfim, as melhores são encontradas. É importante salientar que o Grid Search é um processo exaustivo, que demandaria uma grande quantidade de tempo e custo computacional, e, por isso, foi aplicado exclusivamente na etapa final da busca.

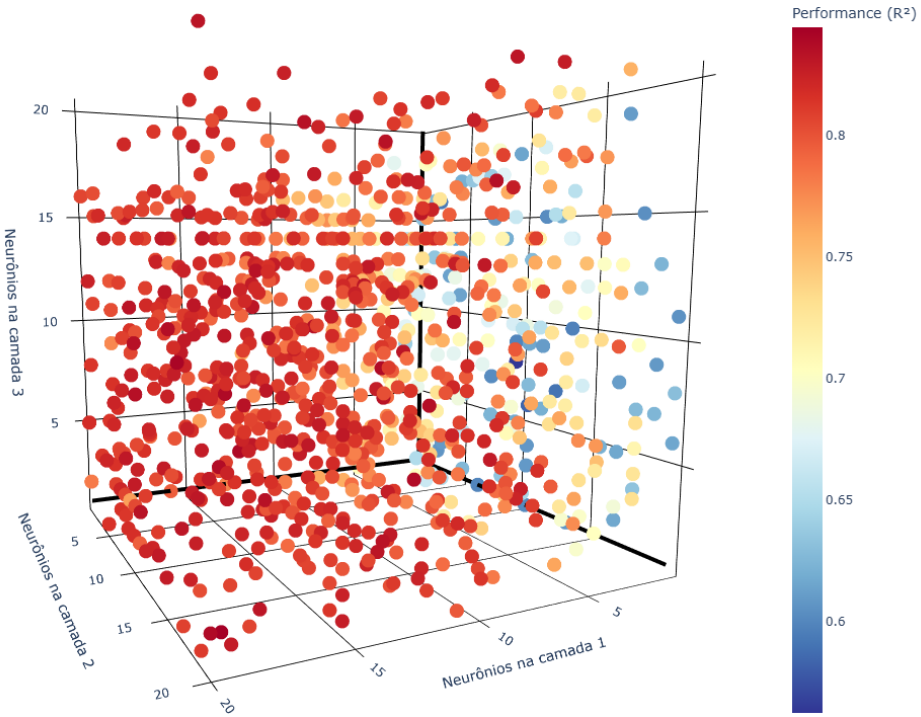
Na primeira etapa desse processo, foram treinadas 800 configurações aleatórias de neurônios, o que corresponde a 10% dos 8.000. Um gráfico tridimensional do desempenho dessas redes é apresentado na Figura 29, com metrificação pelo coeficiente R^2 ponderado. Nesse gráfico, é interessante notar o intervalo de valores presente na legenda, que varia desde valores de R^2 menores que 0,6 até maiores que 0,8. Ao longo de cada poda no espaço de busca é possível perceber como esse intervalo de valores vai sendo restrito, preservando valores maiores em detrimento dos menores.

Para melhor visualização, também foram plotados mapas de calor que mostram as correlações entre os números de neurônios de forma planificada, como pode ser visto na Figura 30. Desse modo, pode-se visualizar claramente regiões com melhor ou pior desempenho ao correlacionar as camadas entre si.

É notável como redes com poucos neurônios na primeira camada, isto é, na faixa de 1 a 10, apresentam desempenho inferior ao das demais. Essas redes com desempenho inferior estão destacadas em tons de azul e amarelo nos gráficos apresentados na Figura 30.a e na Figura 30.b.

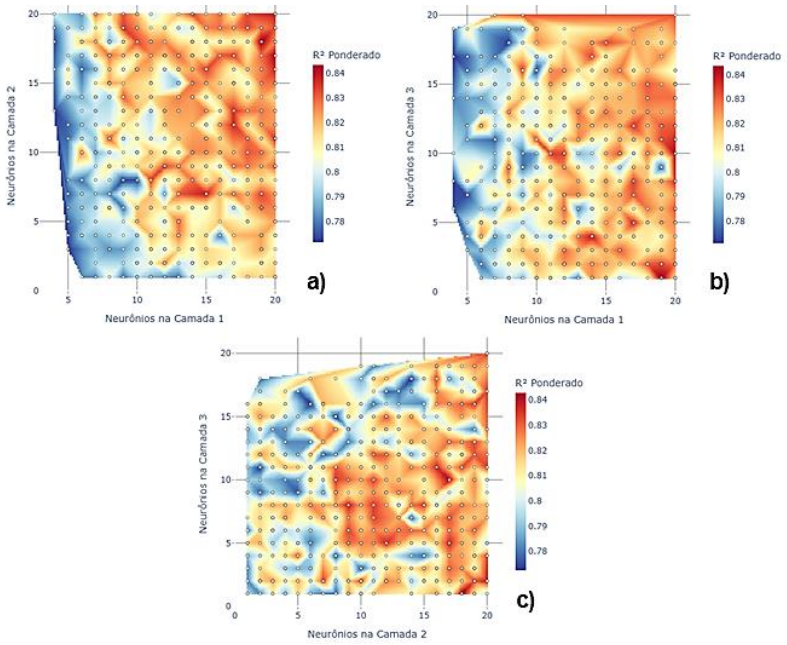
É possível detectar ainda, na Figura 30.b, como as melhores redes se concentram em arquiteturas cuja quantidade de neurônios na terceira camada é inferior à da primeira camada.

Figura 29 – Desempenho das RNAs de 3 camadas usadas na primeira fase do Random Grid Search.



Fonte: Autor.

Figura 30 – Mapas de calor para visualização simplificada das regiões de melhor performance na primeira etapa do Random Grid Search.

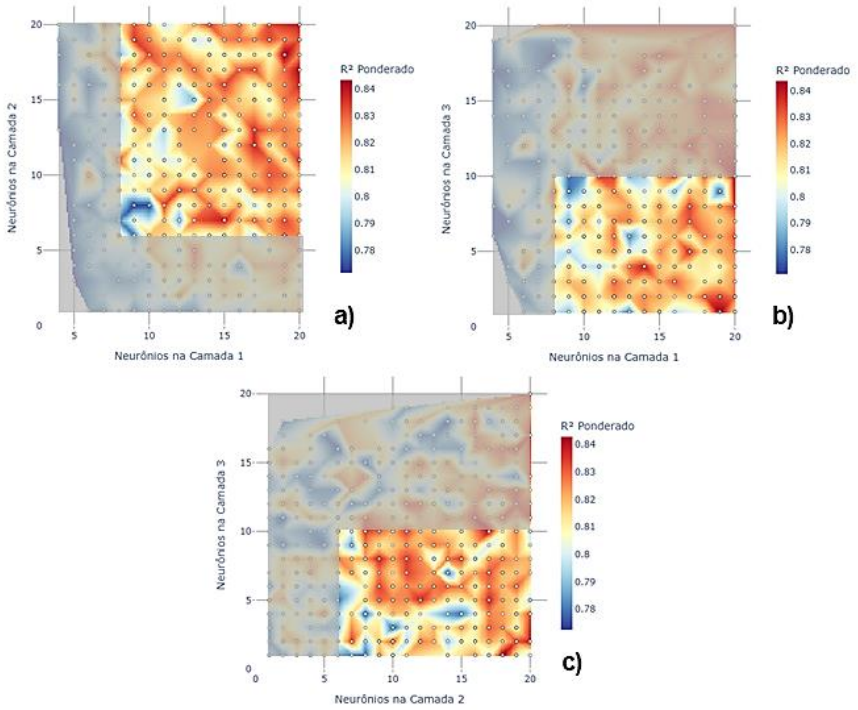


Fonte: Autor.

Das 800 redes treinadas, foram selecionadas as 8 com melhor desempenho (1% do total treinado), que serviram como base para a primeira triagem

no processo de Random Grid Search. As configurações de cada uma dessas redes foram 9-20-20-2-1, 9-19-18-1-1, 9-11-17-5-1, 9-17-12-5-1, 9-8-9-8-1, 9-20-17-10-1, 9-15-7-7-1 e 9-14-6-4-1. Com base nelas, o espaço de pesquisa, isto é, o intervalo máximo e mínimo de neurônios por camada, foi restringido às regiões traçadas em cada mapa de cor da Figura 31.

Figura 31 – Restrição de domínio com base nas melhores RNAs da primeira triagem.

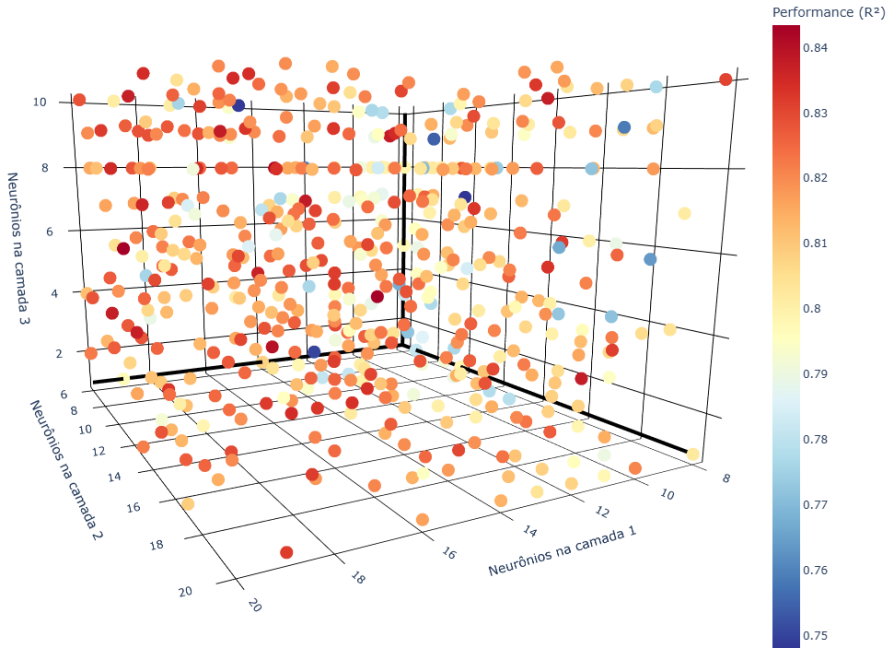


Fonte: Autor.

O segundo espectro de busca consistiu em 8 a 20 neurônios na primeira camada, 6 a 20 na segunda e 1 a 10 na terceira. O mais marcante nessa etapa de restrição foi a limitação acentuada do número máximo de neurônios na terceira camada, de 20 para 10, e o número mínimo na primeira, de 1 para 8.

O número total de possibilidades após a primeira restrição foi de 1950 arquiteturas. Dessa vez, a proporção treinada foi de 25%, ou seja, 495 configurações distintas contidas nesse segundo escopo, como se pode ver na Figura 32. Observando a escala de cores à direita do gráfico, é notável como os menores valores de R^2 agora são próximos a 0,75, sendo esse valor razoavelmente maior do que o mínimo da etapa anterior (que era menor do que 0,6).

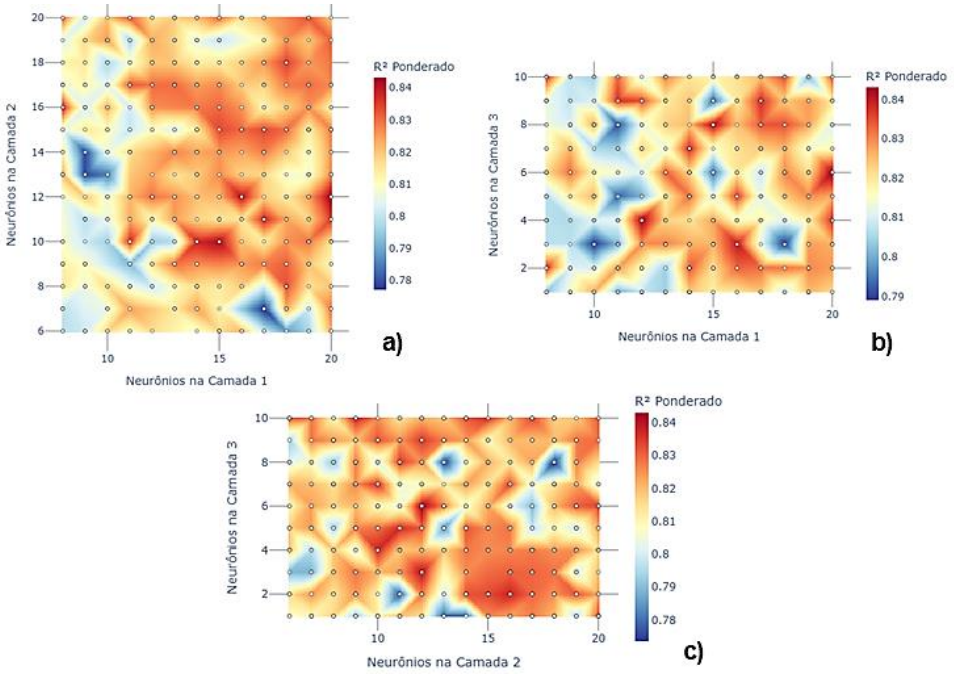
Figura 32 - Performance das 495 redes de 3 camadas treinadas na segunda triagem.



Fonte: Autor.

Do mesmo modo que na etapa anterior, foram plotados mapas de calor para identificar as regiões de melhor e pior desempenho, correlacionando as camadas entre si, conforme a Figura 33.

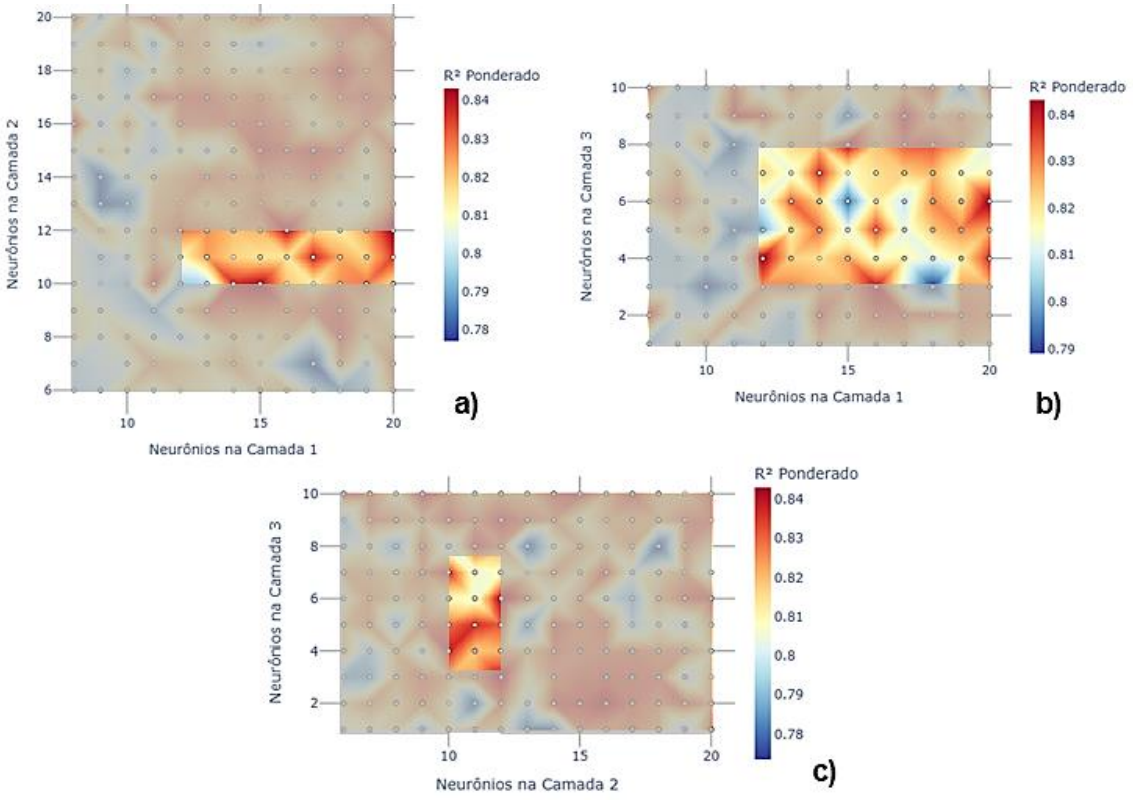
Figura 33 - Mapas de calor para a visualização simplificada das regiões de melhor desempenho na segunda triagem.



Fonte: Autor.

Após a segunda etapa de treinamento, ainda é possível observar uma maior presença de tons de azul (menor performance) na região com menos neurônios na primeira camada, o que reforça a hipótese da necessidade de uma quantidade maior de neurônios nessa mesma região. Além disso, mais uma vez foram tomadas as 1% melhores redes (total de 5) como base para a segunda restrição no domínio de busca. Essas 5 redes tinham as arquiteturas 9-12-11-4-1, 9-14-10-7-1, 9-15-10-8-1, 9-20-12-6-1 e 9-16-12-3-1, que serviram como base para a definição do terceiro escopo de pesquisa, como é exibido na Figura 34 através das regiões em cinza traçadas nos mapas de calor.

Figura 34 - Restrição de domínio com base nas 1% melhores redes da segunda triagem.



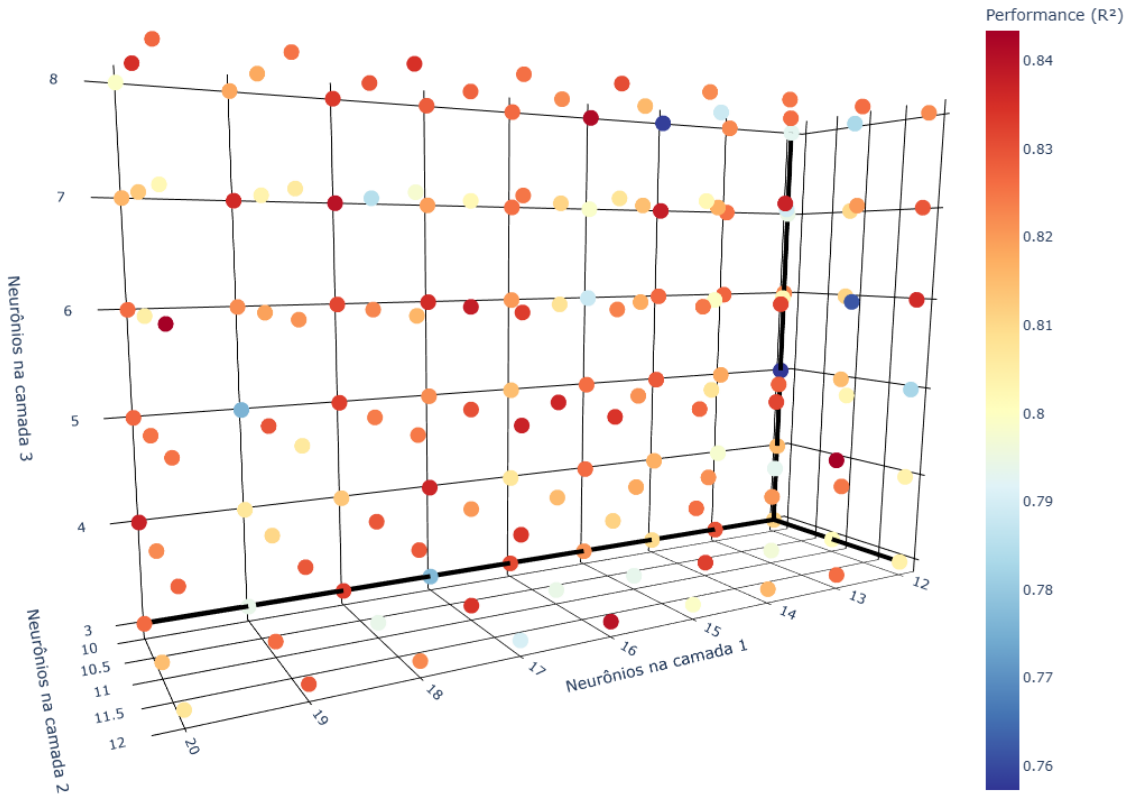
Fonte: Autor.

O terceiro espectro de busca, dessa vez, foi restringido a 12 a 20 neurônios na primeira camada, 10 a 12 na segunda e 3 a 8 na terceira. O número mínimo de neurônios na primeira camada foi novamente aumentado de 8 para 12, enquanto o escopo da segunda camada foi consideravelmente restrito. A terceira camada também

sofreu alguma poda, mantendo-se numa faixa de valores relativamente baixa em comparação com as demais.

Nesse terceiro domínio de busca, havia 162 topologias possíveis, todas treinadas. O resultado dessa etapa de treinamento pode ser conferido na Figura 35, onde constam o gráfico 3D e sua respectiva escala de cores, com valores mínimos em torno de 0,76, indicando mais vez melhoria, mesmo que pequena, no escopo de exploração. Na Figura 36, por sua vez, constam os mapas de calor para facilitar a visualização das performances.

Figura 35 - Desempenho das 162 redes de 3 camadas treinadas na terceira triagem.



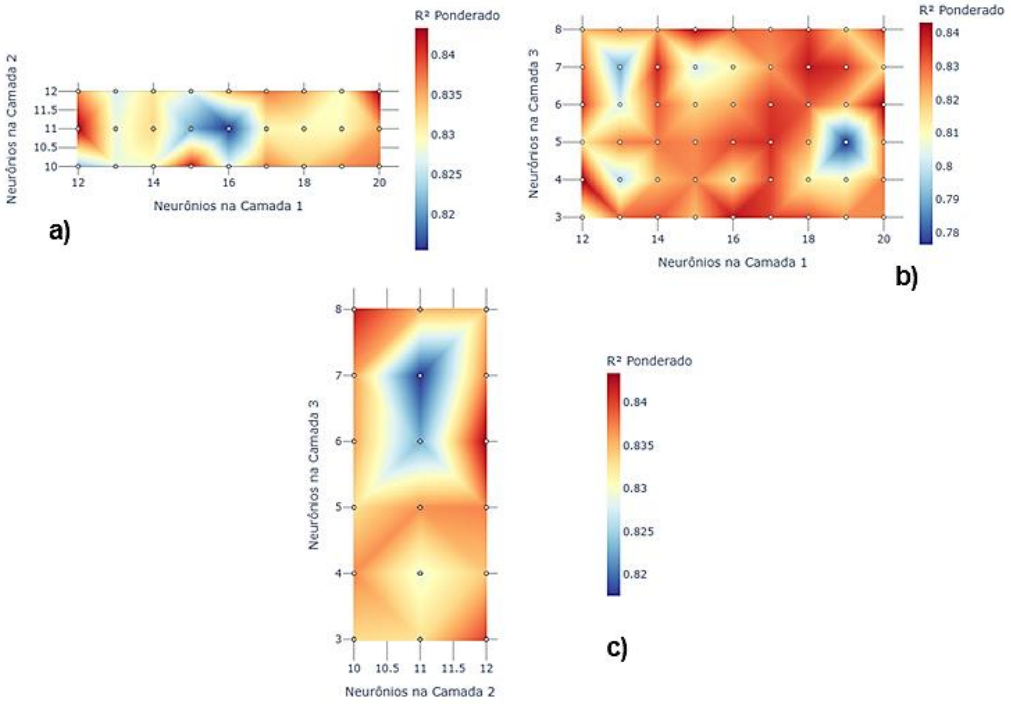
Fonte: Autor.

É interessante notar como, nessa etapa, existe uma dispersão de performances, isto é, não há mais em evidência faixas de quantidades de neurônios em nenhuma das camadas que apontem para uma melhora ou piora de performance, mesmo tendo sido treinadas todas as redes possíveis nesse escopo. Isso pode se dever ao fato de ser uma região de exploração bastante restrita e já otimizada.

Além disso, na Figura 37 são exibidas as 5 melhores redes dessa terceira e última fase de treinamento. Todas essas redes permaneceram em contato com as

extremidades do escopo de exploração, ou seja, o espaço de pesquisa não poderia ser restringido nem em uma unidade de neurônio em nenhuma das camadas para otimização do domínio de busca.

Figura 36 - Mapas de calor para a visualização simplificada das regiões de melhor desempenho na terceira triagem.

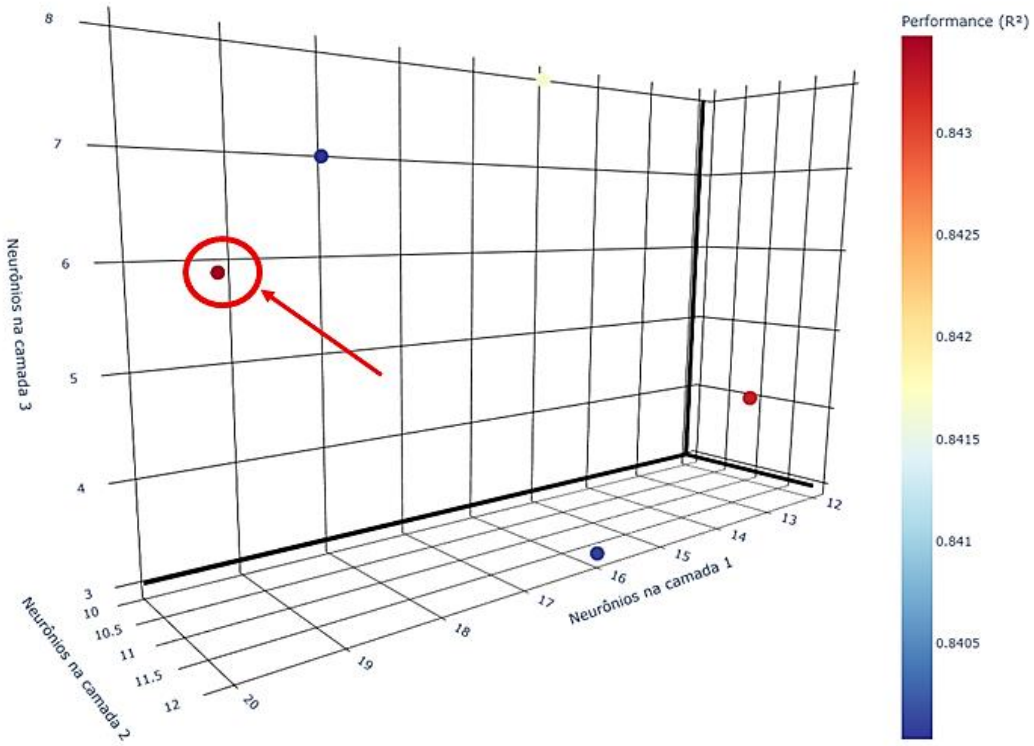


Fonte: Autor.

Ainda na Figura 37, destaca-se a rede com melhor desempenho nesse espaço, que possuía arquitetura 9-20-12-6-1. Essa quantidade de neurônios é coerente com o esperado, com uma grande quantidade na primeira camada e poucos na terceira, enquanto a segunda camada não apresentou influência explícita sobre o desempenho.

Devido à aleatoriedade na geração de topologias no processo de Random Grid Search, algumas redes com bom desempenho detectadas no início podem não ser detectadas no final do processo. Porém, para a escolha da melhor configuração, utilizou-se o histórico, considerando todas as redes treinadas. Na presente pesquisa, a arquitetura de 9-19-18-1-1 teve o melhor desempenho de todas as redes treinadas com 3 camadas e foi uma das redes treinadas na primeira etapa, mas não na segunda, e ficou, portanto, de fora da última região de exploração.

Figura 37 – Melhores redes do último domínio de busca com 3 camadas ocultas.



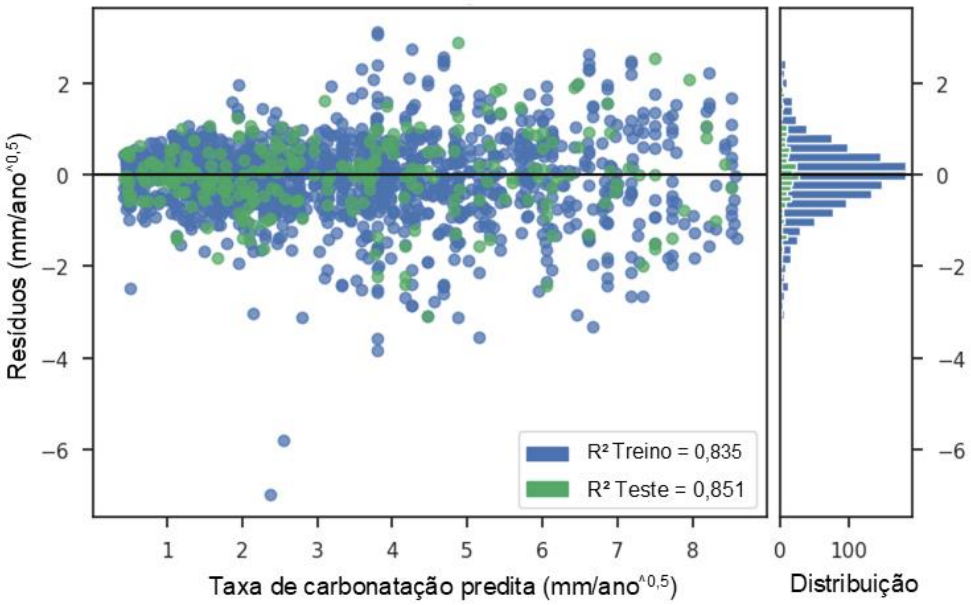
Fonte: Autor.

Considerando isso, o modelo final foi definido como a combinação das duas arquiteturas (9-19-18-1-1 e 9-20-12-6-1), tendo como output a média simples das predições dos dois modelos, bem como as métricas de performance e erro. Essas arquiteturas obtiveram as melhores performances entre todas as exploradas nas três etapas de busca do processo de *Random Grid Search*.

Os gráficos de resíduos com as respectivas frequências acumuladas e o gráfico de dispersão entre os valores preditos e os valores reais do modelo proposto para a predição da taxa de carbonatação podem ser conferidos nas Figuras 37 e 38, respectivamente.

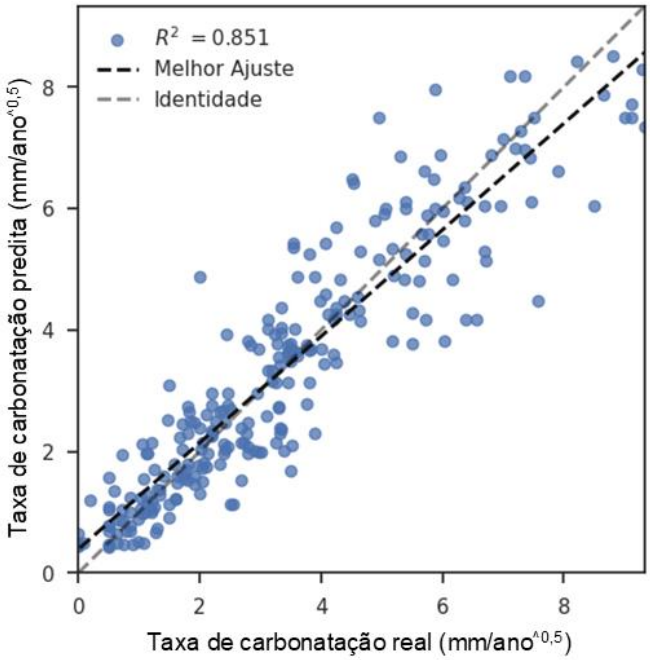
Esse modelo obteve R^2 de treino igual a 0,835 e de teste igual a 0,851 (R^2 ponderado = 0,845), enquanto seus RMSE de treino e de teste foram de 0,888 mm/ano^{0,5} e 0,847 mm/ano^{0,5} respectivamente. Além disso, o erro absoluto médio (MAE) de treino foi de 0,625 mm/ano^{0,5}, enquanto de teste, de 0,617 mm/ano^{0,5}.

Figura 38 - Gráfico dos resíduos do modelo proposto.



Fonte: Autor.

Figura 39 – Gráfico de dispersão entre os valores reais e os valores preditos pelo modelo proposto.



Fonte: Autor.

No que diz respeito à distribuição de neurônios ao longo das camadas, é possível dizer as arquiteturas ótimas estão coerentes com a literatura. Como é possível observar nos parágrafos a seguir, o esperado é que as melhores redes

tenham quantidade igual ou menor de neurônios a cada camada subsequente, o que foi observado durante a exploração das redes de 3 camadas.

Conforme descrito no item 3.6.2, no estudo de Majlesi *et al.* (2023), os autores exploraram redes de 1, 2 e 3 camadas para modelar a profundidade de carbonatação com 20 neurônios por camada. As dez melhores arquiteturas abrangem majoritariamente redes de 3 camadas, com poucos neurônios na terceira camada em comparação com as duas outras, sendo a melhor de todas as topologias a configuração 6-14-12-9-1, resultando em um coeficiente de determinação R^2 de treino igual a 0,96 e de teste igual a 0,94. Nesse caso, houve maior número de neurônios nas primeiras camadas e menor na terceira, de acordo com o encontrado na presente pesquisa.

Entretanto, Majlesi *et al.* (2023) trabalharam com uma base com 110 dados de até 10 anos de carbonatação, o que pode fornecer uma estabilidade maior de treinamento no domínio do modelo. Ao contrário dos autores em discussão, a presente pesquisa emprega uma quantidade de dados 20 vezes maior e com grande heterogeneidade em relação aos materiais e às condições de exposição, o que pode comprometer o aprendizado do problema devido à maior complexidade envolvida na correlação entre as variáveis de entradas e a taxa de carbonatação.

Outros contrastes entre a referência e o presente trabalho residem no algoritmo de otimização, na função de ativação e nos parâmetros de entrada. Majlesi *et al.* (2023) utilizaram o algoritmo Adam, função ReLU e 6 parâmetros de entrada, incluindo precipitação acumulada e absorção capilar, enquanto o presente trabalho se apropria do Gradiente Descendente Estocático (SGD) e da função sigmóide logística, utilizando 9 parâmetros de entrada.

É possível citar também Hassani *et al.* (2023) que aplicaram RNAs para prever as propriedades mecânicas de concretos e compósitos poliméricos. Os autores variaram de 8 a 15 neurônios em cada uma das 3 camadas, obtendo a arquitetura ótima de 6-13-13-11-1 com R^2 médio de 0,995, confirmando a consistência mais uma vez. Apesar da menor disparidade entre a quantidade de neurônios na terceira camada e as duas primeiras, a distribuição de neurônios ao longo das camadas ocultas foi semelhante à do presente trabalho.

No trabalho de Marani *et al.* (2024), por sua vez, o modelo de rede neural probabilística possuiu exclusivamente redes de 3 camadas, com as quantidades de

neurônios por camada exploradas sendo 32, 64, 128, 256, 512 e 1024. A melhor performance do estudo apresentou coeficientes R^2 de treino de 0,969 e de teste de 0,947, com topologia 512-512-64, sendo 512 neurônios na primeira e na segunda camadas e 64 na terceira. Essa topologia reforça ainda mais a tendência de distribuição de quantidades de neurônios observada na presente pesquisa, onde o número de neurônios diminui nas últimas camadas.

Do mesmo modo que Majlesi *et al.* (2023), Marani *et al.* (2024) obtiveram desempenho superior ao do presente trabalho, o que pode, inicialmente, ser explicado pelo fato de os autores terem proposto um modelo probabilístico de rede neural. Isso quer dizer que o modelo como um todo era composto por duas redes: uma com valores médios de output e outra com desvios-padrão, o que possibilitava a quantificação das incertezas. Tal abordagem mostra-se bastante eficiente para quantificar os possíveis erros e incertezas das medições e predições, quando comparada a modelos de RNA puramente determinísticos.

A quantidade de variáveis de entrada é outra discrepância com a presente pesquisa, que totaliza 24 no modelo de redes neurais probabilísticas (Marani; Oyinkanola; Panesar, 2024). Nessa base de dados, os autores segregaram a composição química do cimento, bem como os valores máximos, médios e mínimos de umidade relativa e temperatura, o que pode contribuir para um ajuste mais refinado do modelo.

Marani *et al.* (2024) explicitam ainda que foram criadas redes neurais secundárias para preencher lacunas nos dados sobre o grau de hidratação do concreto e a resistência à compressão. Há, por fim, a exploração de uma gama maior de neurônios (até 1024), de diferentes taxas de *dropout* nas duas primeiras camadas (que consiste em desligar um ou mais neurônios por época aleatoriamente para regularização do treinamento), de diferentes taxas de aprendizado e da variação nas quantidades de épocas e tamanhos dos lotes de dados treinados.

Em comparação, o presente trabalho tem apenas nove parâmetros de entrada, cujas informações podem ser facilmente determinadas, o que facilita o uso do modelo. Assim, o presente estudo considerou que não só o desempenho era importante, como também a capacidade de aplicação prática.

Desse modo, é possível perceber que, dada a complexidade envolvida no problema em questão, a performance encontrada nas arquiteturas ótimas apresenta

um nível razoável, ao mesmo tempo em que pode alcançar níveis mais altos de acurácia. Além disso, o modelo proposto considera um banco de dados altamente heterogêneo, com dados de degradação natural do concreto provenientes de diferentes regiões do planeta e sob distintas condições climáticas, o que amplia seu escopo de aplicabilidade.

3.7 ESTUDO DE CASO COM APLICAÇÃO DO MODELO

Para avaliar a aplicabilidade do modelo proposto, foi conduzido um estudo de caso, aplicando-o à análise da frente de carbonatação em uma estrutura real em estágio avançado de exposição ao CO_2. A estrutura consiste numa ponte de concreto armado localizada no município de Bauru-SP, no cruzamento da Rua Alto Purús com a Avenida Doutor Nuno de Assis, conforme a Figura 40.

Figura 40 – Vistas da ponte do estudo de caso.



Fonte: Conte (2024).

Na Figura 40.a, é possível verificar a vista inferior da ponte, enquanto na Figura 40.b há uma vista lateral, da altura da rua. Na Figura 40.c, por sua vez, é possível verificar a vista superior da localização.

A construção da ponte é datada de 1980, totalizando, portanto, entre 40 e 41 anos de idade na época da coleta de dados via ensaios destrutivos, conforme descrito por Conte (2024). A seleção da estrutura se deu devido à disponibilidade de dados de carbonatação, pacometria e esclerometria, além de dados de projeto.

Os elementos estruturais da ponte utilizados no exemplo foram uma viga longarina e uma transversina. As características utilizadas como dados de entrada do modelo podem ser consultadas na Tabela 12. É importante ressaltar que todos os dados dessa tabela foram extraídos da monografia citada, com exceção da

Concentração de CO_2 atmosférico, que foi adotado como 0,04% pelo fato dos dados coletados em séries históricas mundiais recentes para a presente pesquisa apontarem esse valor como a concentração média de CO_2 no período de exposição da estrutura em questão (Global Monitoring Laboratory, 2024).

Ainda de acordo com Conte (2024), o cobrimento das armaduras nos elementos estruturais era de 20 mm, sendo esse valor obtido por ensaio de pacometria. Ao comparar esse valor com os obtidos em campo, nota-se que, em boa parte de suas extensões, as vigas ainda não haviam sido despassivadas aos 41 anos.

Tabela 12 – Parâmetros de entrada do estudo de caso.

Variável	Valor
Clínquer + Gesso (CG+)	97,5%
Resistência à Compressão média (Fc)	42,82 MPa
Teor de adição mineral (Admix)	0
Relação água-aglomerante (A/A)	0,49
Umidade relativa do ar (UR)	73,71%
Temperatura (Temp)	22,96 °C
Concentração de CO_2 atmosférico (CO2)	0,04%
Tipo de adição mineral (Tadmix)	0 (sem adições)
Condição de Exposição à Chuva (Exp)	1,0 (externo abrigado da chuva)

Fonte: Adaptado de Conte (2024).

O estudo de Conte (2024) fornece ainda os dados de medições da profundidade de carbonatação, conforme a Tabela 13, na qual são apresentados os valores da longarina, e a Tabela 14, na qual estão os dados da transversina. Todos os dados foram obtidos a partir de uma série de medições realizadas em 4 testemunhos extraídos de cada viga, extraídos de faces não expostas à chuva.

Os dados em questão foram então aplicados não só ao modelo proposto, mas também aos modelos analíticos de Possan (2010) (Equação 16) e EHE-08 (2010) (Equação 15). Para a avaliação do desempenho dos modelos de predição, comparaou-se as predições com a média dos dados de cada elemento: 14,87 mm para a longarina e 15,10 mm para a transversina.

Tabela 13 - Profundidades de carbonatação da longarina.

Amostra	Profundidade medida (mm)
2	7,72
4	11,20
8	12,67
10	13,62
14	14,07
15	14,47
17	15,24
18	16,31
21	17,31
22	17,88
23	17,94
29	20,02

Fonte: Conte (2024).

Tabela 14 - Profundidades de carbonatação da transversina.

Dado	Profundidade medida (mm)
1	7,51
3	9,09
5	11,59
6	11,78
9	13,02
11	13,85
16	14,96
19	16,92
26	19,18
27	19,33
28	19,75
30	24,16

Fonte: Conte (2024).

A fim de considerar as incertezas inerentes à coleta de dados em campo e às variações presentes no banco de dados, foram consideradas margens de amplitude de 12,4% para Fc (variando de 37,51 MPa a 48,13 MPa), 10,4% para Temp (variando de 20,57 °C a 25,35 °C) e 29,7% para UR (variando de 51,82% a 80%, em que 80% é o valor máximo possível no domínio de aplicação do modelo), abrangendo

uma faixa de possíveis valores a serem preditos pelos modelos analíticos testados. Esses valores correspondem aos respectivos Coeficientes de Variação de cada variável, que é calculado de acordo com a Equação (60).

$$COV = \frac{\sigma}{\mu} \tag{60}$$

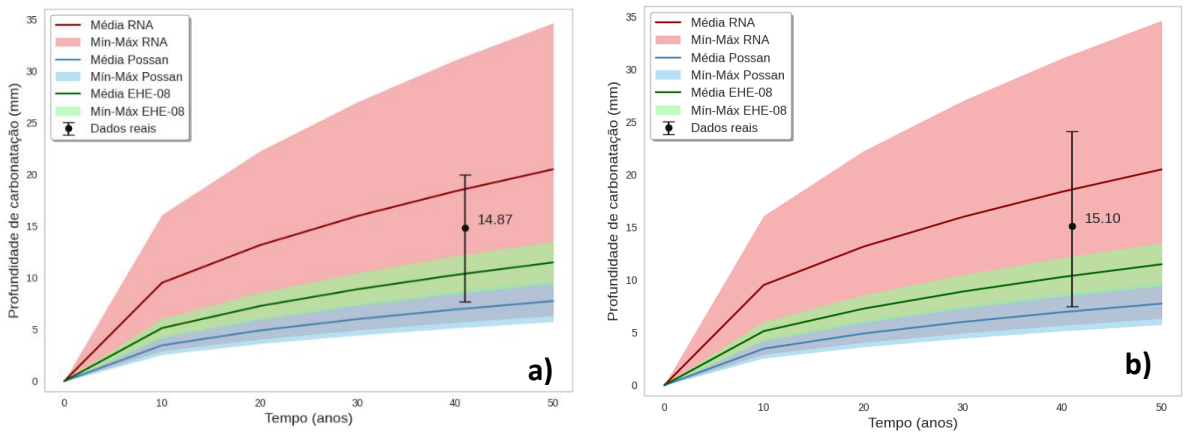
Em que:

- COV: coeficiente de variação do conjunto de dados;
- σ: desvio padrão dos dados do conjunto de dados coletados;
- μ: valor médio do conjunto de dados coletados.

Para a margem de amplitude do modelo de RNAs especificamente, foi utilizado o erro absoluto médio (MAE), de 0,61 mm/ano^{0,5}, que foi usado para o cálculo das profundidades de carbonatação ao longo do tempo. Os resultados das predições podem ser conferidos na Figura 41.

Conforme a Figura 41, tanto para a longarina quanto para a transversina, o valor médio da profundidade de carbonatação real está acima dos valores médios preditos pelos modelos analíticos e abaixo da média fornecida pelo modelo de RNAs. Ao mesmo tempo, considerando a amplitude dos dados reais indicada, pode-se dizer que todos os modelos descrevem de maneira razoável o comportamento do fenômeno.

Figura 41 – Resultados dos modelos de predição em contraste com valores medidos em campo da a) Longarina e b) Transversina.



Fonte: Autor.

No que diz respeito aos valores médios de profundidade de carbonatação, o modelo de RNA proposto estimou uma profundidade de 18,26 mm para a longarina e de 18,49 mm para a transversina aos 41 anos de idade, valores 22,4% maiores do que as profundidades médias de carbonatação observadas nos ensaios. Ao mesmo tempo, o modelo de Possan (2010) indicou 6,94 mm e 7,08 mm para a longarina e transversina respectivamente, que correspondem a profundidades 54% menores que a profundidade média real, enquanto o modelo EHE-08 (2010) indicou os valores de 10,13 mm e 10,35 mm, sendo 32% menores que o valor médio obtido nos ensaios.

É possível analisar, ainda, como os modelos descrevem a variação resultante das incertezas ao processo de carbonatação e suas variáveis de entrada. Na Tabela 15, é possível tomar como referência para essa análise os valores médios, de mediana, de 1° Quartil e 3° Quartil das profundidades de carbonatação medidos na longarina e na mediana.

Tabela 15 – Parâmetros de distribuição dos dados medidos *in loco*

Viga	Média (mm)	Mediana (mm)	1° Quartil (mm)	3° Quartil (mm)
Longarina	14,87	14,85	12,67	17,60
Transversina	15,10	14,41	11,69	19,26

Fonte: Autor.

Observa-se que a faixa de resultados fornecida pelo modelo EHE-08 (2010) toca valores entre o 1° Quartil e o mínimo dos valores medidos *in loco*, com sua margem de variação englobando os dois menores valores medidos na longarina e os quatro menores da transversina. Enquanto isso, o modelo de Possan (2010) abrange valores especificamente próximos ao mínimo das medições, tocando apenas a menor medição tanto na longarina quanto na transversina.

Por outro lado, percebe-se que a média fornecida pelo modelo de RNAs é próxima do valor do 3° quartil tanto para a longarina quanto para a transversina, com sua faixa de variação englobando completamente a faixa de variação das medições em campo nos dois conjuntos de dados. Com isso, sabendo das variabilidades intrínsecas à natureza das variáveis de entrada do fenômeno da carbonatação e da variação significativa das medições realizadas numa mesma estrutura, pode-se dizer

que o modelo é capaz de descrever adequadamente os resultados medidos em campo.

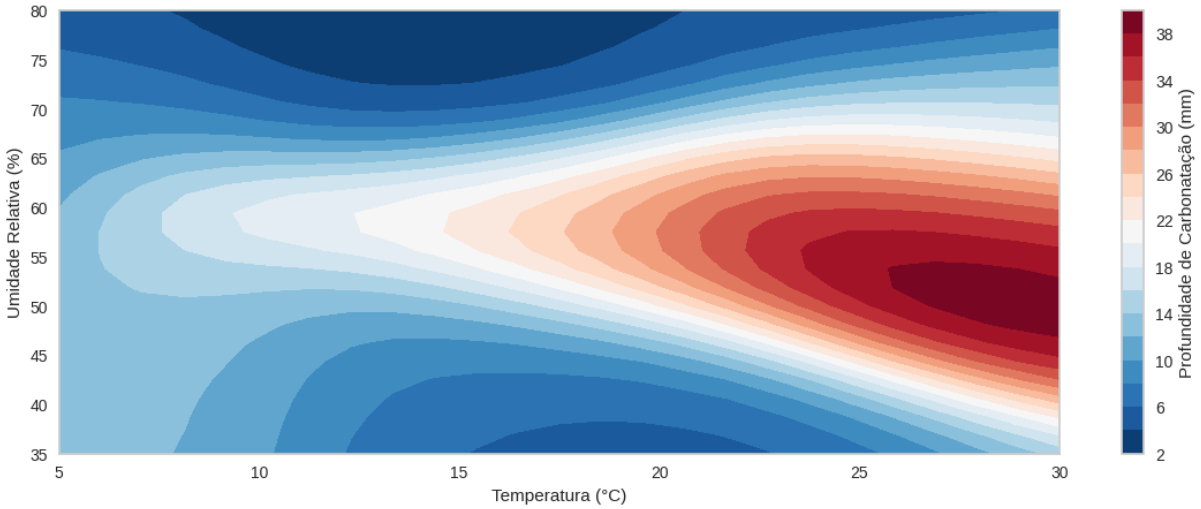
Visto a flutuação natural das profundidades lidas nos ensaios de Conte (2024), os resultados fornecidos pelos modelos a partir da variação inserida nos parâmetros de entrada demonstram tanto o risco de se avaliar exclusivamente a média determinística fornecida pelos modelos de predição quanto a necessidade de se analisar, principalmente, toda a faixa de variação da profundidade de carbonatação. Isso sugere, portanto, que os resultados a partir de uma análise probabilística potencialmente descreverão mais fielmente a condição de despassivação ou não de estruturas de concreto armado.

3.8 ANÁLISE PARAMÉTRICA

Com o modelo finalizado e validado no item anterior, foi realizada ainda uma análise paramétrica para avaliar o impacto de variáveis climáticas, da relação água-aglomerante, do ambiente de exposição e das adições minerais no processo de carbonatação, bem como avaliar como o presente modelo descreve esses comportamentos em contraste com outros estudos da literatura. Nessa análise, foram consideradas como parâmetros constantes de entrada os mesmos parâmetros do teste de aplicabilidade do modelo, fornecidos na Tabela 12, sendo eles: teor de clínquer e gesso = 97,5%; resistência à compressão aos 28 dias = 40,47 MPa; teor de adição mineral = 0; relação água/aglomerante = 0,49; umidade relativa = 73,71%; temperatura = 22,96 °C; teor de CO_2 = 0,04%; tipo de adição mineral = 0 (sem adições); ambiente de exposição = 1,0 (externo protegido da chuva).

As variáveis sob análise apresentaram valores flutuantes, mantendo as demais fixas em cada gráfico, de modo a capturar o espectro de profundidades de carbonatação em função de dois parâmetros. Com isso, foram desenvolvidos gráficos com discussões que podem ser conferidas nos próximos parágrafos. O primeiro gráfico teve como variáveis a umidade relativa e a temperatura (Figura 42), o segundo, a umidade relativa e a relação água/aglomerante (Figura 43), e o terceiro, a temperatura e a relação água/aglomerante (Figura 44).

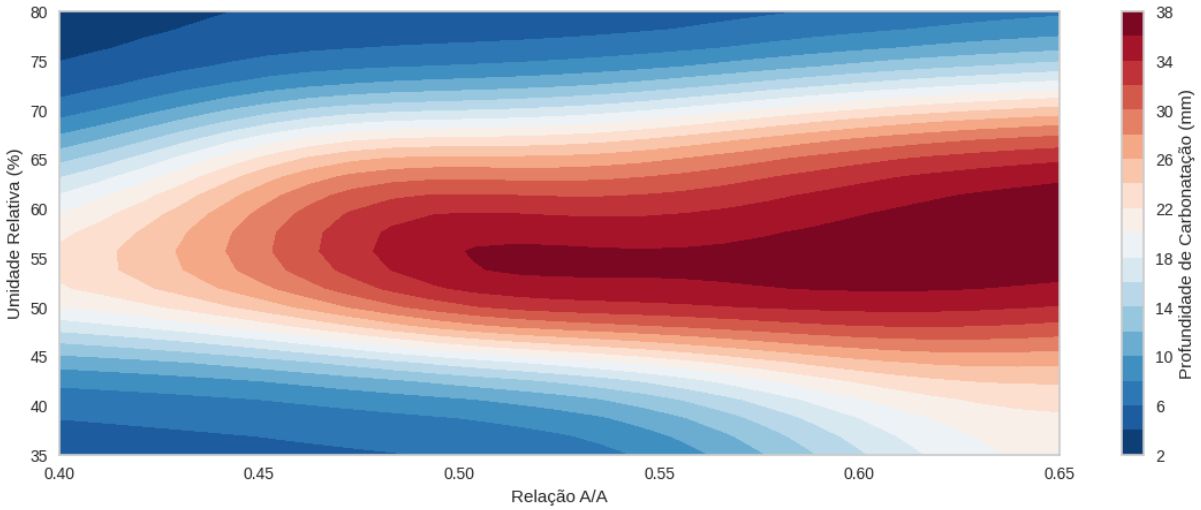
Figura 42 – Análise paramétrica da umidade relativa versus a temperatura.



Fonte: Autor.

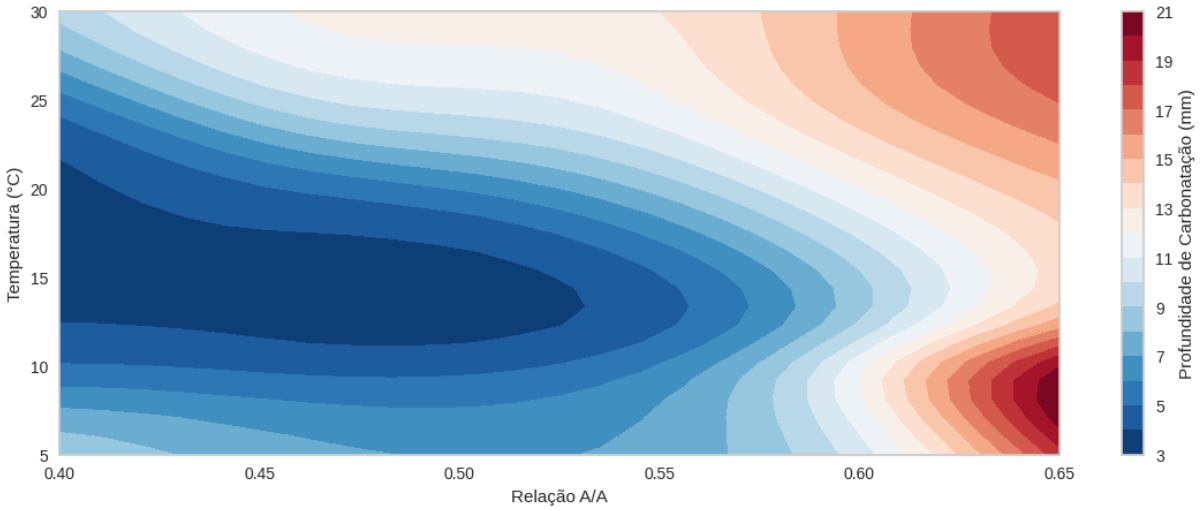
Observando a Figura 42 e Figura 43, é possível perceber que as maiores profundidades de carbonatação são próximas a 38 mm e se concentram entre 50% e 60% de umidade relativa. Isso consoa com o exposto por Verbeck (1958), que indica valores de umidade próximos a esses como aqueles onde há maior carbonatação, assim como com Hou *et al.* (2025), que sugerem que a maior carbonatação ocorrerá numa faixa intermediária de umidade, sem que os poros estejam muito secos nem muito saturados.

Figura 43 – Análise paramétrica da umidade relativa versus a relação A/A.



Fonte: Autor.

Figura 44 – Análise paramétrica da temperatura versus a relação A/A.



Fonte: Autor.

Esses resultados também estão de acordo com o relatado por Felix, Carrazedo e Possan (2017) e por Lavinicki *et al.* (2025), que indicam valores de umidade próximos de 60% como os mais favoráveis à carbonatação. No estudo de Liu, Yu e Chen (2020), entretanto, as maiores profundidades de carbonatação ocorreram para umidades entre 70% e 80%, que podem estar relacionadas com a influência de outras variáveis que diferem das premissas dos dados usados para a análise em questão, como o teor de CO_2 de 20% (carbonatação acelerada) e o ambiente interno de exposição.

É interessante observar, ainda, na Figura 42 o comportamento sutil da carbonatação, correlacionado à umidade relativa e à temperatura. Para temperaturas até 20 °C, a carbonatação atinge valores máximos de 30 mm em umidades relativas em torno de 60%, ao mesmo tempo em que essa profundidade aumenta conforme a temperatura aumenta, mas tem seu ponto de máximo deslocado para valores de umidade um pouco menores (em torno de 50%). Essa pequena variação pode estar associada à influência da temperatura na formação de vapor nos poros do concreto, conforme descrito por Majlesi *et al.* (2023). De acordo com os autores, espera-se que temperaturas mais altas reduzam a saturação dos poros e, por isso, intensifiquem a carbonatação.

Ainda interpretando a correlação entre a umidade relativa e a temperatura (Figura 42), a influência térmica no processo de carbonatação tem uma oscilação perceptível. Em condições de umidade acima de 70% ou abaixo de 45%, as maiores

profundidades de carbonatação concentram-se nos extremos térmicos, próximos de 5 °C e 30 °C. Já em umidades intermediárias (45% a 65%), observa-se uma correlação direta, com o processo sendo intensificado sob temperaturas mais elevadas.

Ao mesmo tempo, na Figura 44, verifica-se uma carbonatação mais dispersa em função da temperatura. Ao longo do gráfico, para os valores mais altos da relação água/aglomerante, percebe-se que há profundidades de carbonatação entre 18 e 21 mm, mas não há uma correlação muito clara entre a carbonatação e a temperatura.

Como pode ser conferido no trabalho de Xu *et al.* (2022), a temperatura tem um efeito ambíguo no processo de carbonatação. Valores mais elevados podem tanto inibir a carbonatação (pela diminuição da solubilidade de íons cálcio e CO_2) quanto acelerar o processo (pelo aumento do vapor d'água nos poros e aumento da taxa de difusão de dióxido de carbono).

No trabalho de Lavinicki *et al.* (2025), os autores expõem um comportamento crescente da carbonatação com um aumento da temperatura, enquanto temperaturas mais baixas provocam uma carbonatação mais lenta. Eles ressaltam a importância de se considerar a temperatura como um parâmetro de entrada em modelos de predição, correspondendo a mais de 20% de contribuição para o resultado final.

Nos estudos de Drouet *et al.* (2019), os autores avaliaram a carbonatação acelerada em concretos com e sem adições minerais sob temperaturas de 20, 50 e 80 °C. Os resultados indicaram comportamentos distintos, com a temperatura diretamente proporcional à profundidade de carbonatação na ausência de adições minerais, enquanto que, para as amostras com adições, a maior carbonatação se deu na temperatura intermediária de 50 °C. Sendo essa temperatura muito maior do que a usual para a maioria das estruturas de concreto armado, pode-se inferir com base nesses resultados que a tendência explicitada pelo estudo, na maior parte das vezes, é que temperaturas mais altas aceleram o processo de carbonatação.

Observando, por sua vez, a relação água/aglomerante, a influência dessa variável sobre a carbonatação torna-se mais explícita. Na Figura 43 e na Figura 44, nota-se claramente uma maior profundidade de carbonatação na região em que a relação água/aglomerante é maior.

Esse comportamento consoa com o visto na maior parte da literatura existente, como no estudo de Lavinicki *et al.* (2025), que ressaltam através de uma análise *SHAP* que, quanto mais alta a relação água aglomerante, maior será a profundidade de carbonatação graças à maior porosidade do concreto. Da mesma maneira, Kazemi (2024) aponta uma relação forte e diretamente proporcional entre a relação água/aglomerante e a profundidade de carbonatação.

Huo, Wang e Huang (2023), por sua vez, verificam o impacto da relação água-aglomerante no processo em questão utilizando um modelo ensemble de aprendizado de máquinas. Reforçando essa tese, Couto *et al.* (2026) realiza uma revisão de literatura e também indica essa variável como uma das principais com forte impacto na carbonatação.

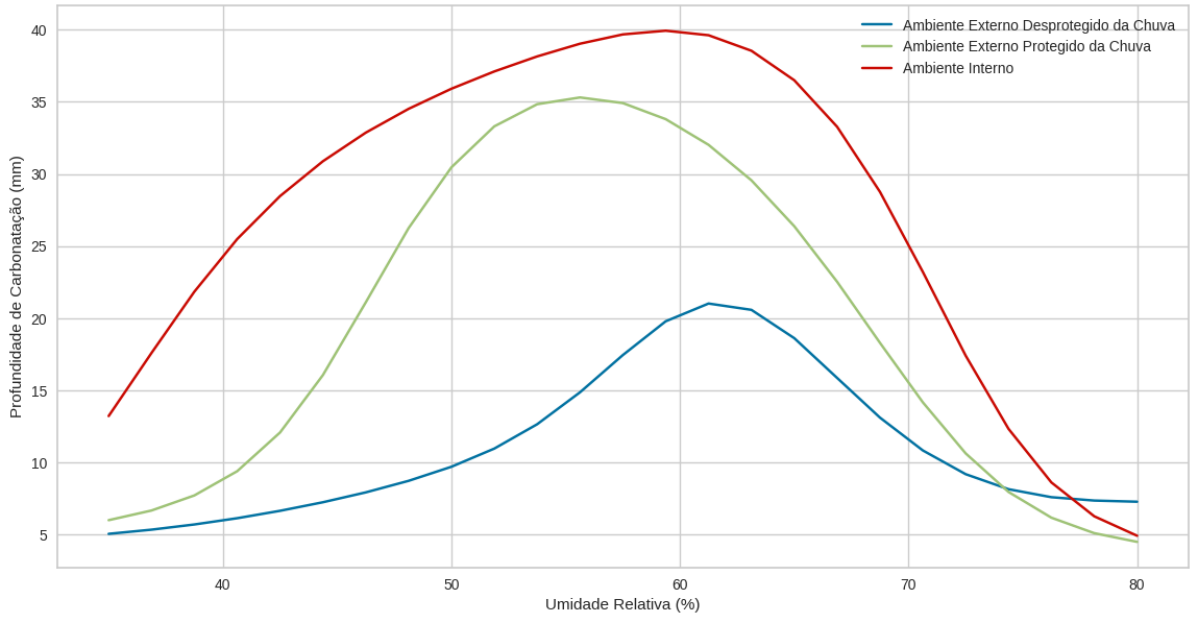
3.8.1 Efeitos do ambiente de exposição

Foram desenvolvidas, ainda, três análises para demonstrar a influência do ambiente de exposição sobre a carbonatação. Essa variável foi combinada com a umidade relativa (Figura 45), com a temperatura (Figura 46) e com a relação água-aglomerante (Figura 47).

Como é possível verificar nas figuras, em todos os casos, o ambiente interno é o que mais favorece um processo acelerado de carbonatação, de modo bastante explícito. Ao mesmo tempo, o comportamento no ambiente externo protegido e no externo desprotegido da chuva varia de tendência nos gráficos, com ora um, ora outro favorecendo mais o processo.

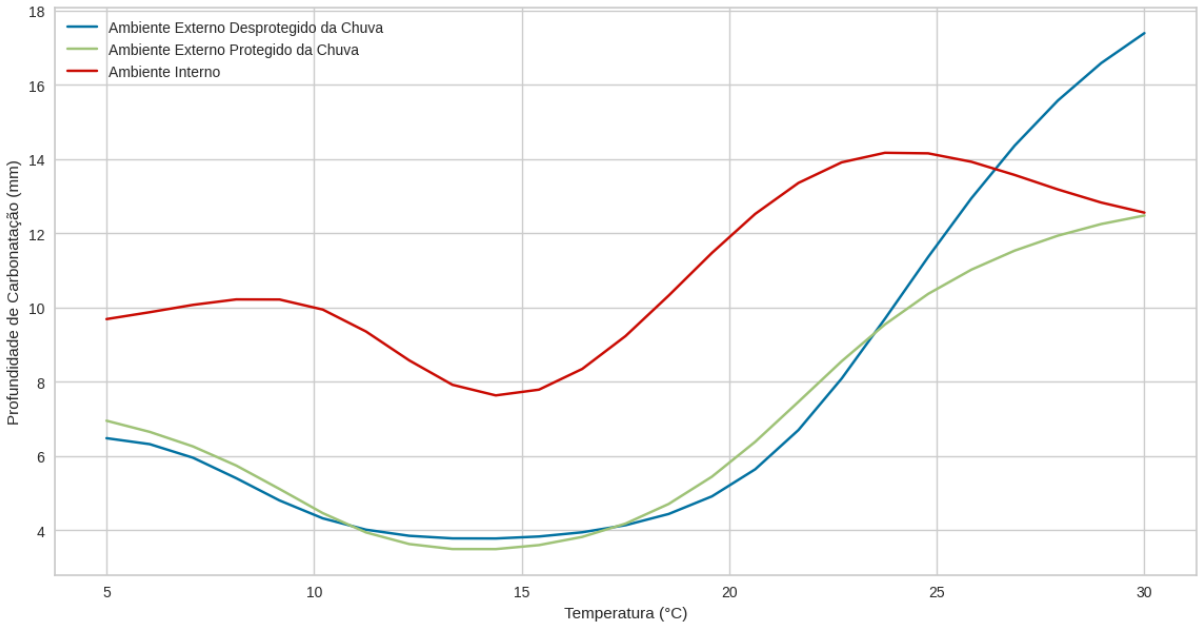
Esse comportamento está razoavelmente de acordo com a literatura, conforme explicado por Gopinath, Alexander e Beushausen (2025) e por Hou *et al.* (2025), que indicam que a saturação dos poros inibe a difusão de CO_2 na matriz cimentícia, assim como a umidade do ar equilibrada favorece a carbonatação. Desse modo, os autores reforçam a relevância da forma e da quantidade em que a água está presente nos poros do concreto podem acelerar ou desacelerar a carbonatação, aspecto definido em boa parte pelo ambiente de exposição.

Figura 45 – Carbonatação em função da umidade relativa e do ambiente de exposição.



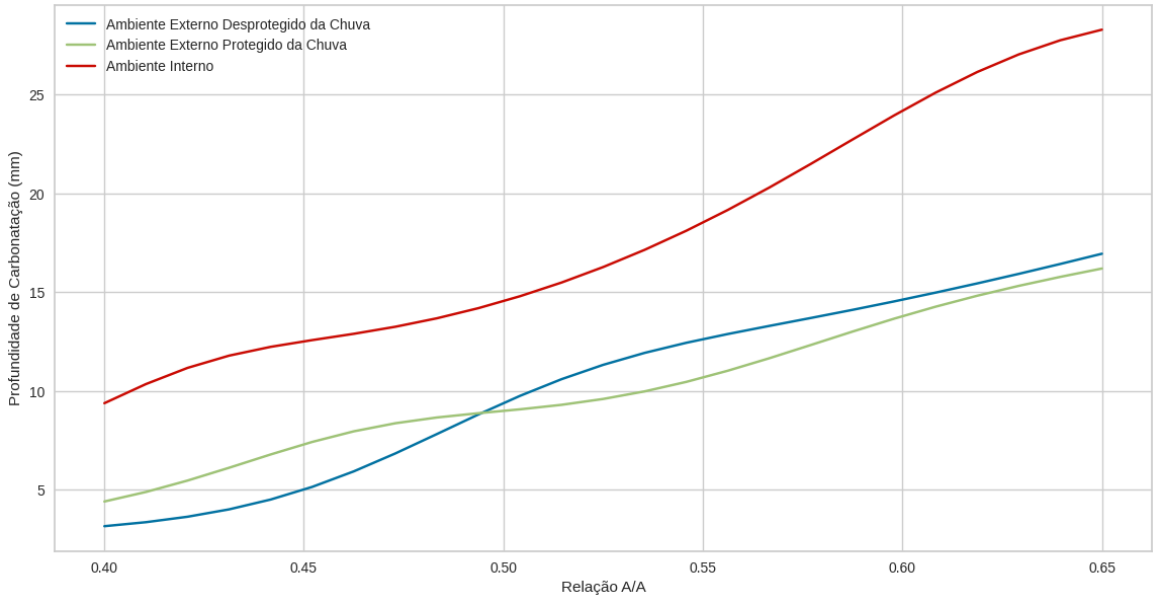
Fonte: Autor.

Figura 46 – Carbonatação em função da temperatura e do ambiente de exposição.



Fonte: Autor.

Figura 47 – Carbonatação em função da relação água/aglomerante e do ambiente de exposição.

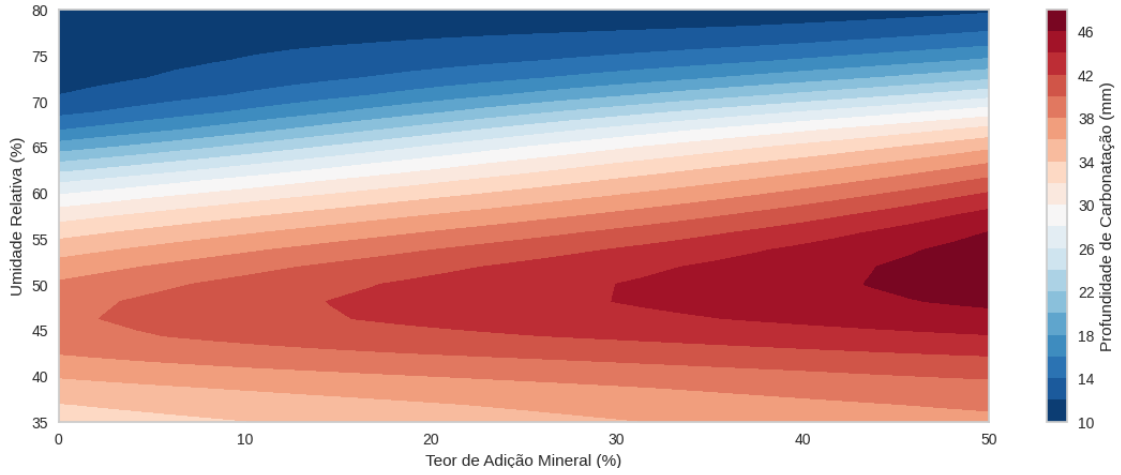


Fonte: Autor.

3.8.2 Efeitos da adição mineral

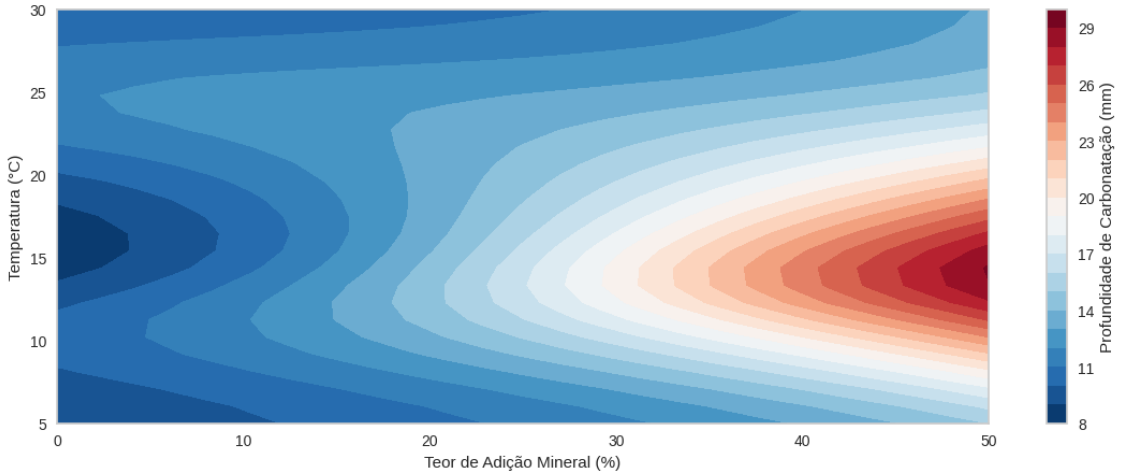
Considerando a tendência de descarbonização no setor da construção civil por meio da adição de componentes minerais ao material aglomerante do concreto (Couto *et al.*, 2026; Kellouche *et al.*, 2019), foram gerados também gráficos que correlacionam as três primeiras variáveis apresentadas no item 3.8 (umidade relativa, temperatura e relação água/aglomerante) com diferentes proporções de adição mineral (Figura 48, Figura 49 e Figura 50). As variáveis de entrada que não pertencem a cada um dos gráficos foram fixadas de acordo com o apresentado na Tabela 12 (com exceção do Tipo de Adição mineral), sendo eles: teor de clínquer e gesso = 97,5%; resistência à compressão aos 28 dias = 40,47 MPa; teor de adição mineral = 0; relação água/aglomerante = 0,49; umidade relativa = 73,71%; temperatura = 22,96 °C; teor de CO_2 = 0,04%; tipo de adição mineral = 2 (cinzas volantes); ambiente de exposição = 1,0 (externo abrigado da chuva).

Figura 48 – Análise paramétrica da umidade relativa versus o teor de adição mineral.



Fonte: Autor.

Figura 49 – Análise paramétrica da temperatura versus o teor de adição mineral.

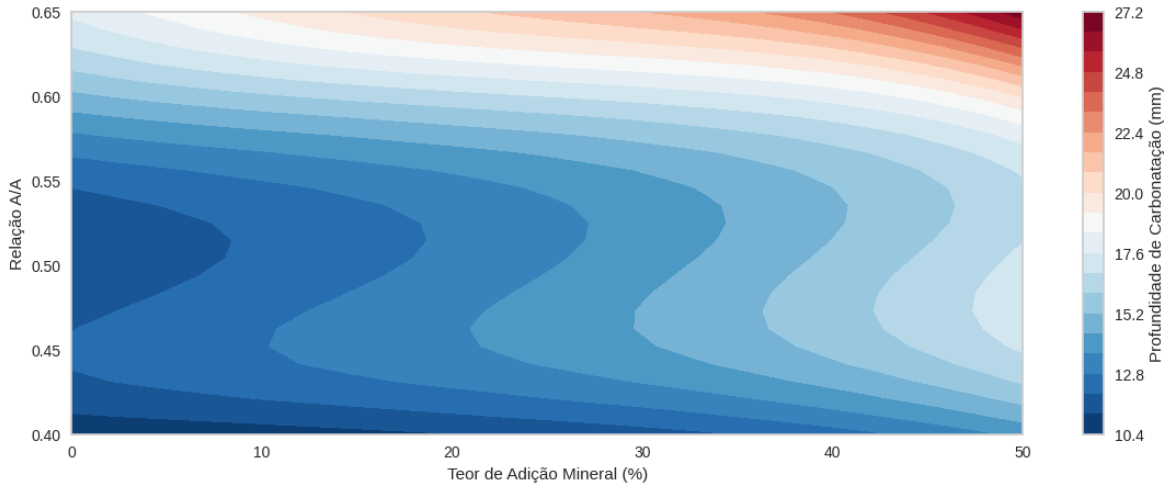


Fonte: Autor.

Como é possível verificar na Figura 48 em contraste com a Figura 42 e a Figura 43, o comportamento da umidade relativa com ou sem adições minerais não é alterado de maneira significativa. Em ambos os casos, a faixa de umidade relativa com maior profundidade de carbonatação situa-se entre 50 e 60%, o que constitui um comportamento bastante consistente nos diversos cenários analisados.

Na Figura 49, por sua vez, percebe-se que existe um pico localizado de carbonatação na temperatura de 15 °C. Esse pico, ao mesmo tempo em que consoa com o apresentado na Figura 44, ele destoa da Figura 46, o que demonstra uma tendência não muito clara sobre o modelo em questão no que diz respeito sobre a temperatura, demandando estudos mais aprofundados a esse respeito.

Figura 50 – Análise paramétrica da relação A/A versus o teor de adição mineral.



Fonte: Autor.

Já na Figura 50, é interessante observar que o comportamento da carbonatação está de acordo com o previsto na literatura. Ou seja, quanto maior a relação água-aglomerante e a adição mineral, maior será a carbonatação.

Por fim, observando a Figura 48, a Figura 49 e a Figura 50, percebe-se que a carbonatação é sempre diretamente proporcional ao teor de adição mineral, independentemente da outra variável com a qual o gráfico é correlacionado. Isso demonstra a relevância e o impacto do teor das adições sobre o fenômeno em estudo.

Esse comportamento está de acordo com o apresentado por Marani, Oyinkanola e Panesar (2024), que indicam que teores acima de 20% contribuem para acelerar a carbonatação. Do mesmo modo, Uwanuakwa (2021) ressalta a sensibilidade das predições realizadas pelo modelo desenvolvido no estudo com variações no conteúdo do aglomerante. Isso se deve principalmente ao fato de que, com menos cimento Portland na mistura, há redução no teor de clínquer, que contém compostos relevantes para a resistência à carbonatação, como o hidróxido de cálcio (CH) e o silicato de cálcio hidratado (CSH).

3.9 CONSIDERAÇÕES DO CAPÍTULO

Como pode ser observado, as redes ótimas encontradas na presente pesquisa apresentaram resultados satisfatórios, ainda que a precisão se situe numa faixa de valores um pouco inferior à observada em outros modelos baseados em aprendizado de máquina expostos na literatura. Essa diferença pode estar associada

às características do banco de dados utilizado e à configuração da rede em termos de arquitetura e hiperparâmetros. A combinação dos modelos com topologia ótima obteve um R^2 geral igual a 0,85, enquanto seu RMSE é de 0,847 mm/ano^{0,5}.

A limitação de amostras de longo prazo, a heterogeneidade das variáveis de entrada, e possíveis ruídos experimentais não capturados no pré-processamento dos dados, podem restringir a capacidade da rede neural de captar padrões mais complexos. Além disso, o espaço de busca considerado pode não ter sido suficientemente amplo para explorar arquiteturas mais próximas do ótimo global, ainda havendo margem para investigar diferentes hiperparâmetros, como algoritmos de otimização, funções de ativação e critérios de parada.

Em relação ao estudo de caso, no qual o modelo desenvolvido no presente estudo foi testado frente a outros dois modelos analíticos de predição e também frente a dados reais de carbonatação, percebeu-se que a predição resultante é estável e que, se considerada a margem de erro do modelo e a provável variabilidade presente nos parâmetros de entrada, os valores preditos se equiparam aos observados na prática.

Perante a análise paramétrica, ficou evidenciado que o modelo tem descrito o processo de carbonatação de modo razoavelmente coerente com a literatura, indicando que, de certo modo, o aprendizado gerado pelas RNAs sobre os dados é estável e pode representar o fenômeno da carbonatação em estruturas de concreto com idade avançada.

Ao mesmo tempo em que o modelo baseado em RNAs desenvolvido na presente pesquisa apresenta resultados satisfatórios para aplicação prática, é perceptível que ainda há espaço para evolução em sua acurácia. Nesse sentido, recomenda-se a realização de estudos complementares, com base de dados de maior amplitude, em especial com dados de carbonatação de longa duração, bem como a variação de diferentes hiperparâmetros, além das camadas e dos neurônios, e ainda a integração com outras técnicas de aprendizado de máquina.

4 DURAPASS-AI: SOFTWARE DE ANÁLISE PROBABILÍSTICA

Considerando o modelo proposto e validado no capítulo anterior e que, numa análise de vida útil, devem ser consideradas as incertezas das variáveis associadas aos materiais e ao ambiente de exposição, neste trabalho é proposto um software web que possibilita determinar a probabilidade de despassivação de armaduras metálicas imersas no concreto decorrente da carbonatação, por meio de simulações probabilísticas de Monte Carlo.

A seguir, apresenta-se a fundamentação teórica das simulações probabilísticas de Monte Carlo, bem como a metodologia de cálculo utilizada nas análises de probabilidade de despassivação, estudos de caso com a aplicação da ferramenta e a interface web desenvolvida e disponibilizada para uso público.

4.1 FUNDAMENTAÇÃO TEÓRICA DAS SIMULAÇÕES DE MONTE CARLO

A técnica de simulação de Monte Carlo é uma maneira sólida de analisar problemas que consideram múltiplos fatores aleatórios. Como primeiros estudos adotando essa metodologia, pode-se citar Metropolis e Ulam (1949) e Metropolis *et al.* (1953).

A técnica consiste em um método computacional de análise de confiabilidade, que gera amostras aleatórias de entrada para caracterizar a probabilidade de falha de um fenômeno. No presente estudo, a probabilidade de falha é definida como a despassivação das armaduras de uma estrutura de concreto armado ao longo de um determinado período de tempo. De modo geral a probabilidade de falha é descrita pela Equação (61).

$$P_f = \int_{G(x)\leq 0} f_x(x_1, x_2, \dots, x_n) dx_1, dx_2, \dots, dx_n \tag{61}$$

Em que:

- P_f: probabilidade de falha;
- $G(x)$: função de estado limite (critério de definição daquilo que é “falha”);
- f_x: função de densidade de probabilidade conjunta;

- x_n: variáveis de entrada.

Nessa formulação, realiza-se a integral sobre todas as combinações possíveis de variáveis, e o resultado final é de falha, isto é, G(x) ≤ 0. Essas combinações de variáveis são criadas com base na distribuição estatística associada à natureza de cada uma das respectivas variáveis aleatórias. Para a avaliação da despassivação do aço devido à carbonatação, como será visto mais adiante, essas variáveis aleatórias podem ser tanto climáticas quanto características do material.

A probabilidade de falha P_f é usualmente mapeada pelo índice de confiabilidade β, que é a métrica de segurança adotada pelas normas técnicas, consistindo na distância entre o ponto médio e o ponto de falha definido na função de estado limite (quando G(x) = 0) (ABNT, 2023; CEB-FIP, 2023). Esse mapeamento se dá através da função de distribuição normal padrão φ, conforme a Equação (62) (Zacchei; Nogueira, 2022).

$$P_f = \varphi(-\beta) \tag{62}$$

Em que:

- P_f: probabilidade de falha;
- φ: função de distribuição normal padrão;
- β: índice de confiabilidade.

Com isso, para obter o valor do índice de confiabilidade, é necessário, primeiro, determinar a probabilidade de falha, isto é, resolver a integral da Equação (61). No entanto, para a maioria dos problemas reais, a resolução analítica dessa integral é difícil, o que torna necessária a utilização da técnica de simulação de Monte Carlo.

Assim, a probabilidade de falha é definida pela integral da densidade de probabilidade conjunta no domínio de falha, que será a média populacional da função indicadora $I\,(x_i)$. Para a obtenção desse valor, na técnica de simulação de Monte Carlo, utiliza-se um estimador que avalia a função de estado limite, obtendo a média amostral das *N* simulações realizadas, conforme pode ser visto nas Equações (63), (64) e (65) (Zacchei; Nogueira, 2022).

$$P_f = \int_{-\infty}^{+\infty} I\,(x_i)\, f_x(x_i)\, dx_i = E\,[I\,(x_i)] \tag{63}$$

$$I\,(x_i) = \begin{cases} 1, G(X) \leq 0 \\ 0, G(X) > 0 \end{cases} \tag{64}$$

$$\widehat{P_f} = E\,[I\,(x_i)] = \frac{1}{N} \sum_{i=1}^{N} I\,(x_i) \tag{65}$$

Em que:

- N: número total de simulações;
- $I\,(x_i)$: função indicadora;
- $E[I\,(x_i)]$: valor esperado como resultado da integral;
- $\widehat{P_f}$: valor estimado da probabilidade de despassivação.

Com isso, a probabilidade de despassivação P_f tem seu valor obtido com precisão razoável, uma vez que esse valor converge para o E conforme o número de simulações aumenta.

4.2 ACOPLAMENTO DE MONTE CARLO AO MODELO DE CARBONATAÇÃO

Com o método para determinar a probabilidade de falha (no caso, a probabilidade de despassivação) estabelecido, define-se também a equação de estado limite. Para tal, utilizou-se o modelo gerado com as RNAs, apresentado no capítulo 3, que fornece a taxa de carbonatação (Equação (66)), multiplicada pela raiz do tempo de exposição ao CO_2, conforme a Equação (67). Em seguida, a profundidade é subtraída do cobrimento nominal da estrutura para obtenção do valor de G, equação de estado limite dada pela Equação (68).

$$k_{carb} = f_{RNA}(X) \tag{66}$$

$$y_{carb} = k_{carb} \,.\sqrt{t} \tag{67}$$

$$G(X) = C_{non} - y_{carb} \tag{68}$$

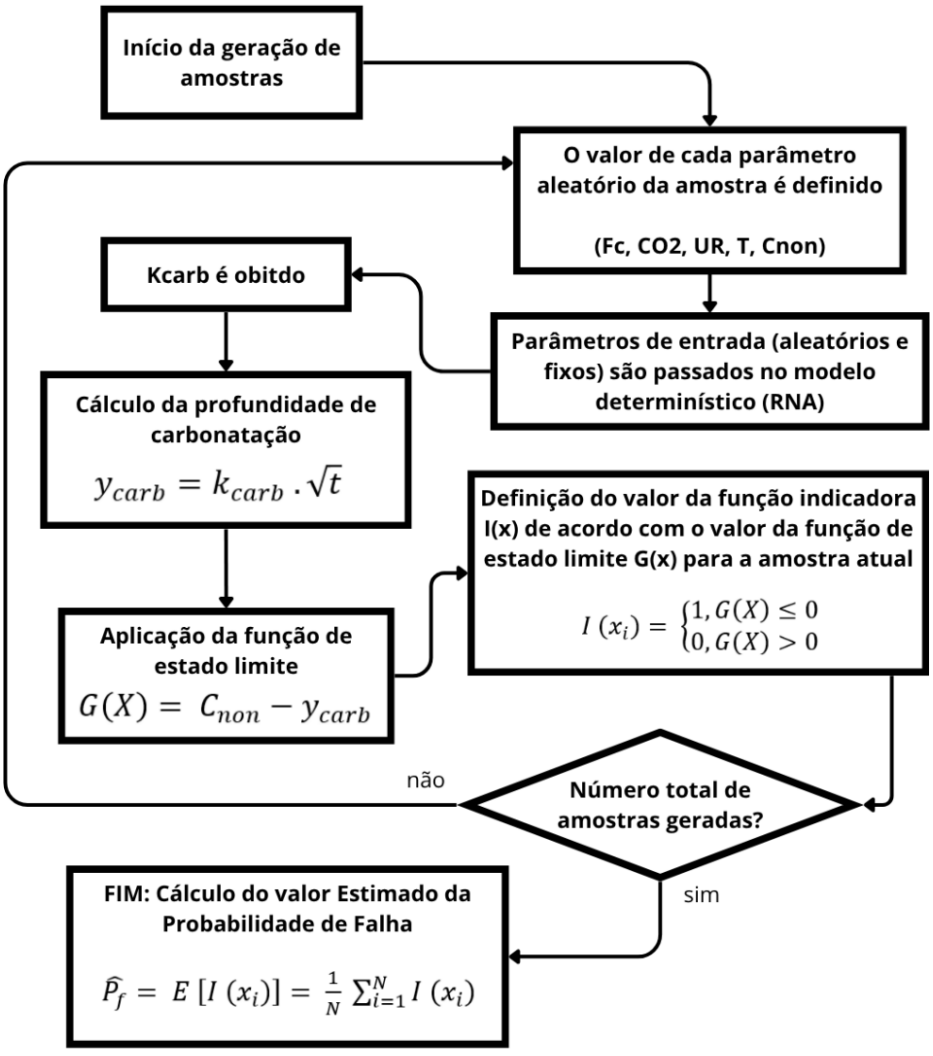
Em que:

- X: vetor de variáveis de entrada do modelo de RNA;

- f_{RNA}: saída do modelo de RNA definido anteriormente;
- k_{carb}: taxa de carbonatação (em milímetros/ano^{0,5});
- t: tempo de carbonatação (em anos);
- y_{carb}: profundidade de carbonatação (em milímetros);
- C_{non}: cobrimento nominal (em milímetros);
- $G(X)$: equação de estado limite.

O fluxo de processos, conduzido pela metodologia definida nesse trabalho para o cálculo da probabilidade de despassivação, obtida pelo acoplamento dos dois modelos (determinístico e probabilístico), pode ser conferido na Figura 51.

Figura 51 - Fluxograma ilustrativo do cálculo da probabilidade de despassivação.



Fonte: Autor.

Inicialmente, são fornecidos os parâmetros médios de entrada do modelo (conforme o item 3.4.1), bem como o cobrimento nominal da armadura. Também são fornecidos os coeficientes de variação e a função de distribuição das variáveis aleatórias consideradas no modelo em questão.

A cada amostra gerada, as variáveis aleatórias têm seus valores definidos de acordo com a respectiva média do vetor de entrada, a respectiva função de distribuição e o respectivo coeficiente de variação. Esses valores são passados, em conjunto com os das demais variáveis não aleatórias, como entrada do modelo determinístico, e a taxa de carbonatação daquela amostra é calculada.

A profundidade de carbonatação é calculada, por sua vez, em função da taxa de carbonatação e da vida útil (tempo de exposição). A profundidade é subtraída do cobrimento nominal daquela amostra, que também é uma variável aleatória, com um novo valor definido a cada nova amostra gerada em função de seu valor médio, de sua função de distribuição e de seu coeficiente de variação.

Por fim, o valor da função de estado limite é calculado para essa amostra, assim como para todas as demais. No final das *N* amostras, é possível obter um valor estimado da probabilidade de despassivação, possibilitando a obtenção do índice de confiabilidade β através da função de distribuição normal.

Nesse estudo, as variáveis aleatórias são as seguintes:

- Resistência à compressão aos 28 dias (*Fc*);
- Concentração média de CO_2 atmosférico (*CO2*);
- Umidade relativa do ar (*UR*);
- Temperatura (*T*);
- Cobrimento nominal (*Cnon*).

As variáveis *FC*, *CO2*, *UR*, *T* e *Cnon*, foram adotadas como aleatórias por conta de sua natureza de maior variabilidade e imprevisibilidade em relação às demais. Com isso, as variáveis teor de clínquer e de gesso, teor e tipo de adição mineral, ambiente de exposição e relação água-aglomerante ficaram fixadas ao longo dos cálculos de probabilidade, enquanto a resistência à compressão, o cobrimento nominal e as variáveis de cunho ambiental variavam, incorporando incertezas inerentes ao clima e ao processo produtivo do concreto.

4.2.1 Estudo para definição do tamanho da amostragem aleatória

Antes de prosseguir com o desenvolvimento da interface gráfica da ferramenta, foi necessário definir o tamanho da amostragem (*N*) a ser utilizada nas análises probabilísticas, de modo que um aumento desse valor não resultasse em variações significativas na probabilidade de despassivação. Isso deve ao fato de que *N* afeta diretamente o custo computacional das simulações e, ao mesmo, a estabilidade e precisão dos resultados do modelo, conforme descrito por Zacchei e Nogueira (2022).

Tomando os critérios descritos por Uliano (2018), o número de amostras pode ser estimado pela Equação (69).

$$N \geq 10^{p+2} \tag{69}$$

Em que:

- p: ordem de grandeza da probabilidade de falha;
- N: número de amostras.

Para definir o número total de simulações N do modelo em questão, foram realizadas explorações com N variando de 1.000 a 100.000, a fim de observar a partir de qual faixa de valores os resultados do modelo se estabilizariam. Para as explorações, os parâmetros médios de entrada do modelo foram os mesmos que os do teste de aplicabilidade (Tabela 12), os tempos de carbonatação foram de 50, 75 e 100 anos e as classes de agressividade para definição do cobrimento foram I, II e III, de acordo com a NBR 6118 (ABNT, 2023). A função de distribuição foi definida como a função normal para cada uma das amostras, enquanto o coeficiente de variação das variáveis aleatórias foi definido de acordo com os dados de Conte (2024):

- Resistência à compressão: 12,4%
- Concentração de CO_2: 20%
- Umidade relativa: 29,7%
- Temperatura: 10,4%
- Cobrimento nominal: 20%

O coeficiente de variação de cada uma das variáveis de entrada é dado pela Equação (70) .

$$COV = \frac{\sigma}{\mu} \tag{70}$$

Em que:

- COV: coeficiente de variação da variável de entrada;
- σ: desvio padrão da variável de entrada;
- μ: valor médio da variável de entrada.

Os resultados dessa exploração podem ser visualizados na Figura 52, com as respectivas curvas de probabilidade de despassivação em função do valor de *N*.

Na Figura 52.a, é possível observar as probabilidades de despassivação para a classe I de agressividade ambiental, com 25 mm de cobrimento, em que a estabilização do modelo ocorre para *N* próximo de 20.000 amostras. Do mesmo modo, na Figura 52.b e na Figura 52.c, que correspondem às classes de agressividade II e III respectivamente (30 e 40 mm de cobrimento), o valor de 20.000 também pode ser visto como um ponto de referência.

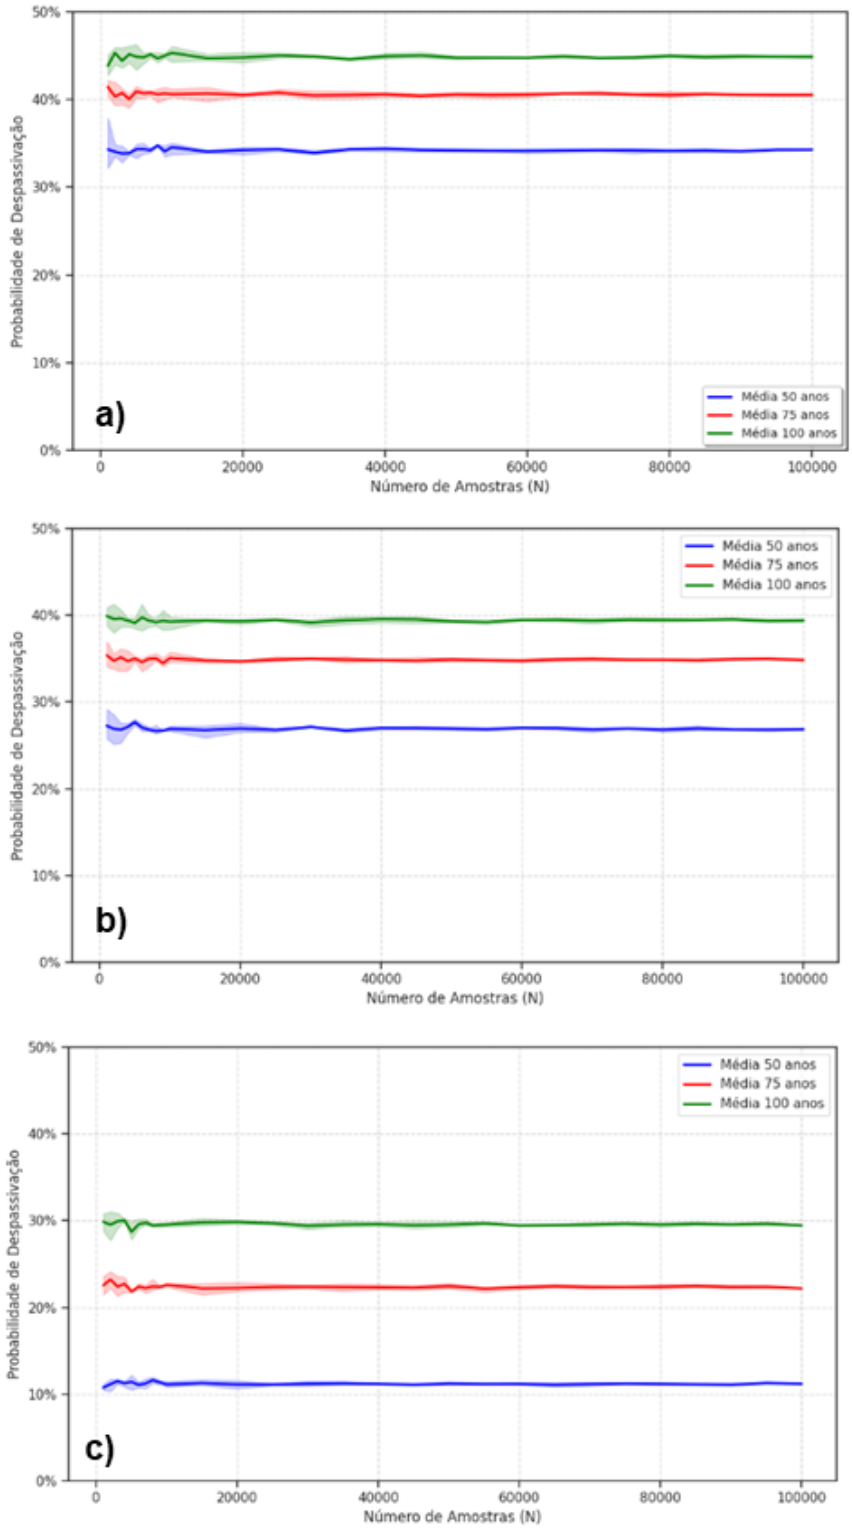
Além dos gráficos apresentados, utilizou-se como critério para definir o valor de *N* o coeficiente de variação da probabilidade de despassivação, isto é, do *output* do modelo probabilístico em questão. Esse coeficiente de variação é dado pela Equação (71) (Sorensen, 2004 apud Uliano, 2018) e seus valores podem ser conferidos na Figura 53.

$$COV_{P_f} = \sqrt{\frac{1 - P_f}{N \,.\, P_f}} \tag{71}$$

Em que:

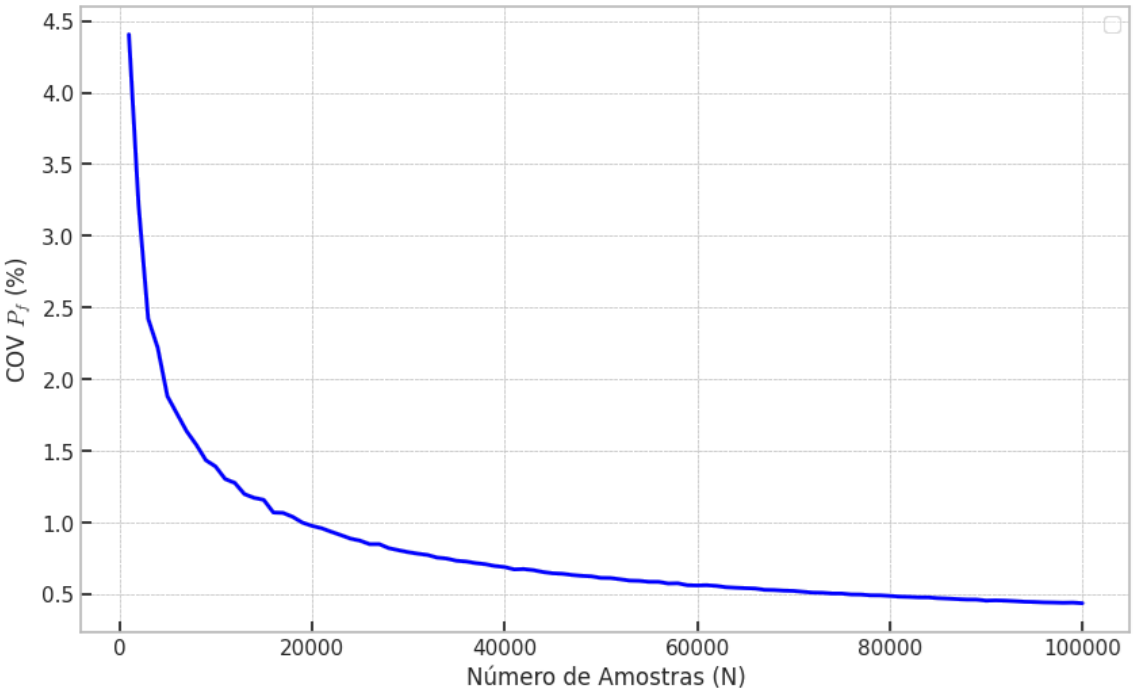
- COV_{P_f}: coeficiente de variação da probabilidade de despassivação;
- P_f: probabilidade de despassivação média para N amostras;
- N: número de amostras.

Figura 52 – Probabilidade de despassivação em função do valor de N.



Fonte: Autor.

Figura 53 – Coeficiente de variação da probabilidade de falha em função de N.



Fonte: Autor.

O valor do coeficiente de variação da probabilidade de despassivação para 20.000 resultou em 0,97% para classe I de agressividade, 1,16% para a classe II e 1,97% para a classe III. Observando tanto a Figura 52 quanto a Figura 53, verifica-se que a estabilização do modelo ocorre a partir de valores de *N* superiores a 30.000 (com COV < 1%). Assim, na ferramenta proposta, será empregado um número de amostras de 30.000.

A título de comparação, Uliano (2018) adotou o número de 3,1 x 10^7 amostras, muito superior ao da presente pesquisa, o qual foi necessário para a devida convergência do índice de confiabilidade β definido pelo autor, enquanto Teodoro e Carrazedo (2025) e Zacchei e Nogueira (2022) valores na ordem de 10^6. Com isso, pode-se dizer, dada a alta probabilidade de falha nos cenários aqui estudados, que o tamanho amostral pôde ser bastante reduzido, garantindo baixo tempo de computação sem perda significativa de precisão. Além disso, deve-se considerar que a aplicação final será executada em um servidor on-line, no qual um número maior de simulações elevará o tempo de execução do aplicativo web.

4.3 INTERFACE DO APP DURAPASS-AI

Para facilitar a aplicação prática do modelo probabilístico descrito, foi desenvolvida uma interface gráfica em Python, de fácil manipulação e de acesso público. A ferramenta denominada *DURAPASS-AI* (a hybrid neural network-Monte Carlo framework for probabilistic assessment of reinforcement depassivation) pode ser acessada em durapassai.dasmae.com. A interface foi pensada de modo a permitir que o usuário insira as condições específicas do projeto e obtenha, como saídas, a curva de profundidade de carbonatação, o tempo de despassivação com análise determinística e, a probabilidade de despassivação aos 50, 63 ou 75 anos de vida útil. Na Figura 54 é apresentada uma visão geral da interface web desenvolvida.

Os *inputs* a serem inseridos pelo usuário são divididos em dois grupos: os fixos, isto é, que não variam durante as simulações probabilísticas, e os variáveis. Para todos os parâmetros, é necessário informar o valor médio de cada um e, para as variáveis, é necessário ainda informar o respectivo coeficiente de variação e a respectiva função de distribuição.

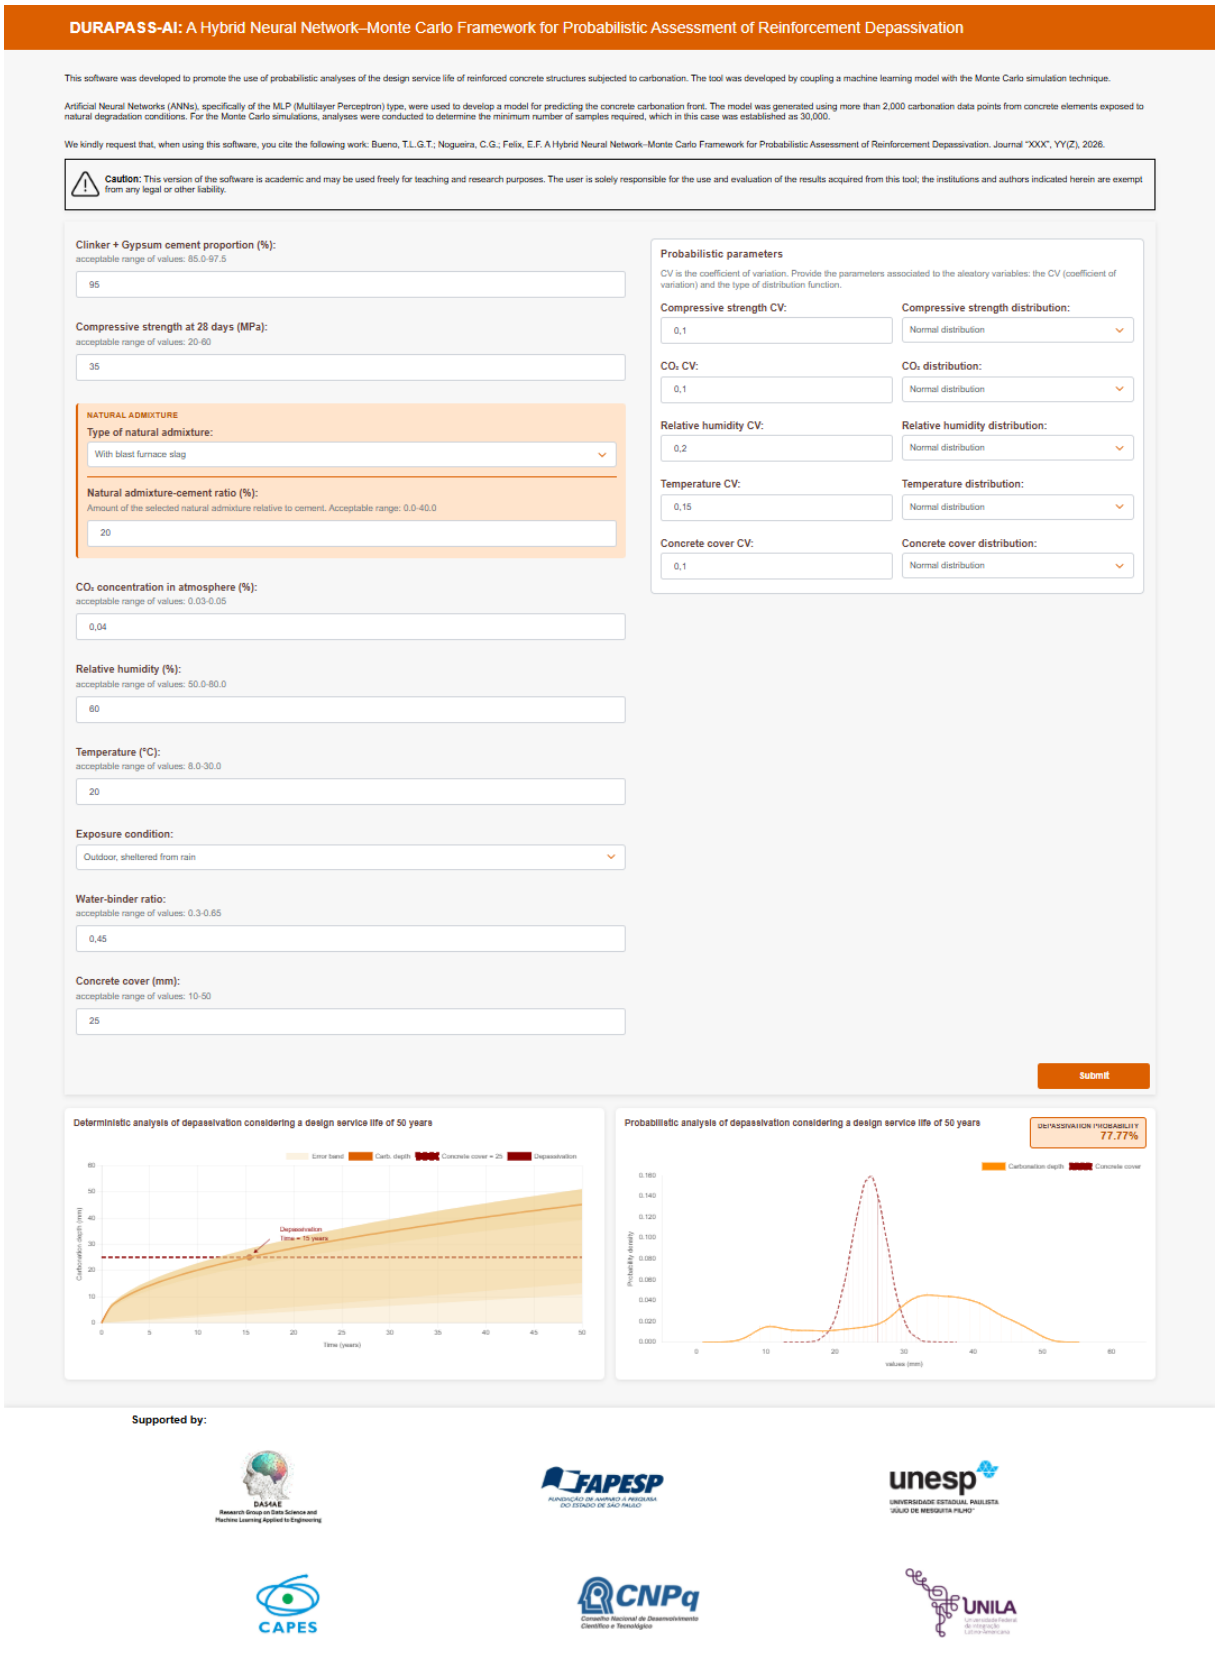
As entradas fixas são os seguintes:

- Teor de clínquer e gesso (%);
- Tipo de adição mineral;
- Teor de adição mineral (%);
- Ambiente de exposição (interno ou externo);
- Relação água/aglomerante;
- Tempo de exposição ao CO_2 da análise (50, 63 ou 75 anos).

As entradas variáveis, por sua vez, são:

- Concentração de CO2 (%);
- Umidade relativa (%);
- Temperatura média do ambiente (°C);
- Resistência à compressão (MPa);
- Cobrimento nominal das armaduras (mm).

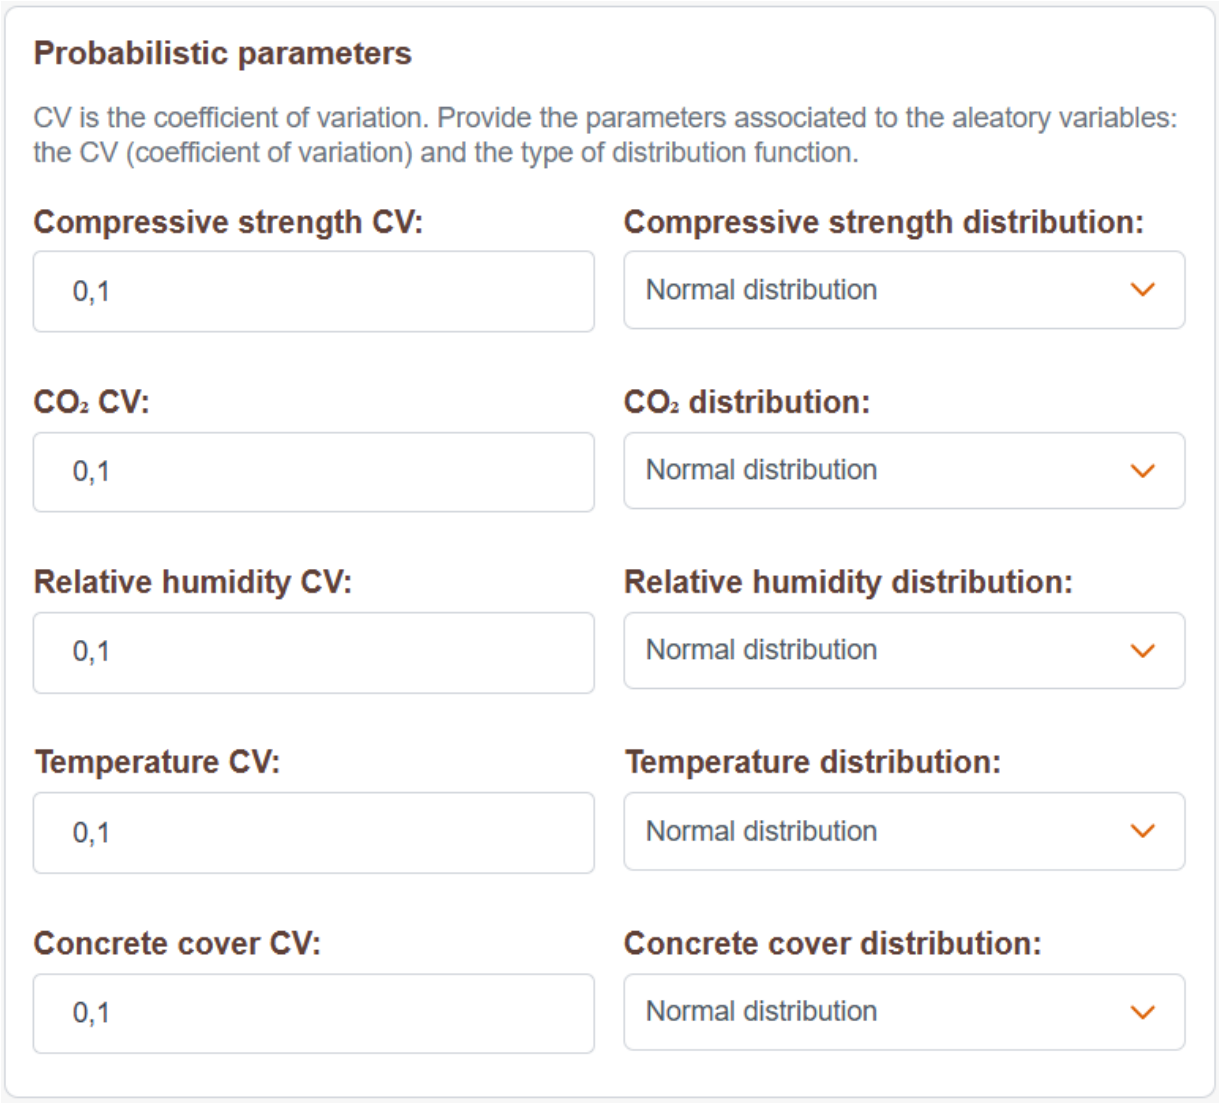
Figura 54 - Visão geral da interface web.



Fonte: Autor.

O coeficiente de variação de cada parâmetro deve ser calculado previamente pelo usuário ou obtido na literatura. A função de distribuição poderá ser normal ou log-normal, definida individualmente para cada variável. Para inserção desses parâmetros de cada variável aleatória, foi reservado um espaço à parte, conforme a Figura 55.

Figura 55 – Região para parâmetros de distribuição das variáveis aleatórias.

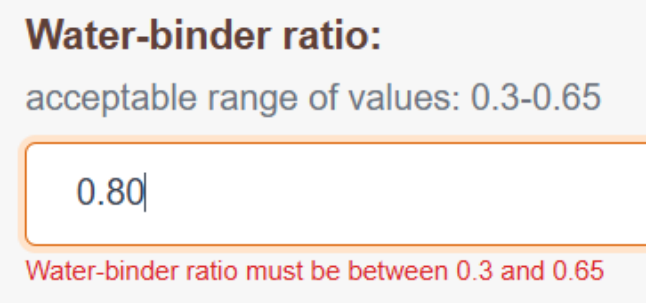


Fonte: Autor.

É importante salientar que os valores a serem inseridos como *input* devem respeitar os domínios de aplicabilidade do modelo. Nesse sentido, foram implementadas validações dos dados de entrada de acordo com o domínio de cada um, de modo que, na hipótese de um valor fora dos limites de aplicação ser inserido,

o campo é marcado em vermelho e o processamento é impedido, como pode ser conferido na Figura 56. Pontua-se que a interface foi desenvolvida em inglês.

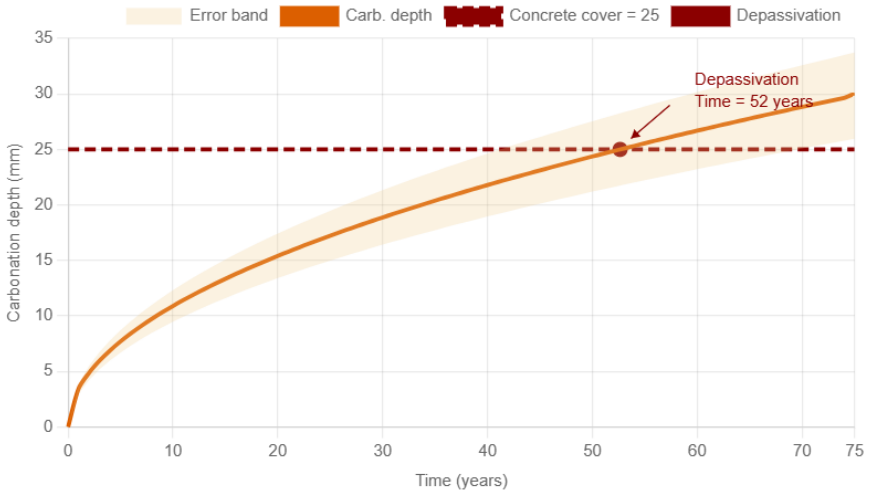
Figura 56 – Exemplo de validação de dados.



Fonte: Autor.

Com as entradas devidamente informadas pelo usuário, o botão “REALIZAR ANÁLISE” é habilitado e, ao clicar nele, dois gráficos são exibidos na tela como resultado. O primeiro gráfico exibe os resultados do modelo determinístico, como pode ser conferido em um exemplo na Figura 57, que descreve a profundidade de carbonatação em função do tempo.

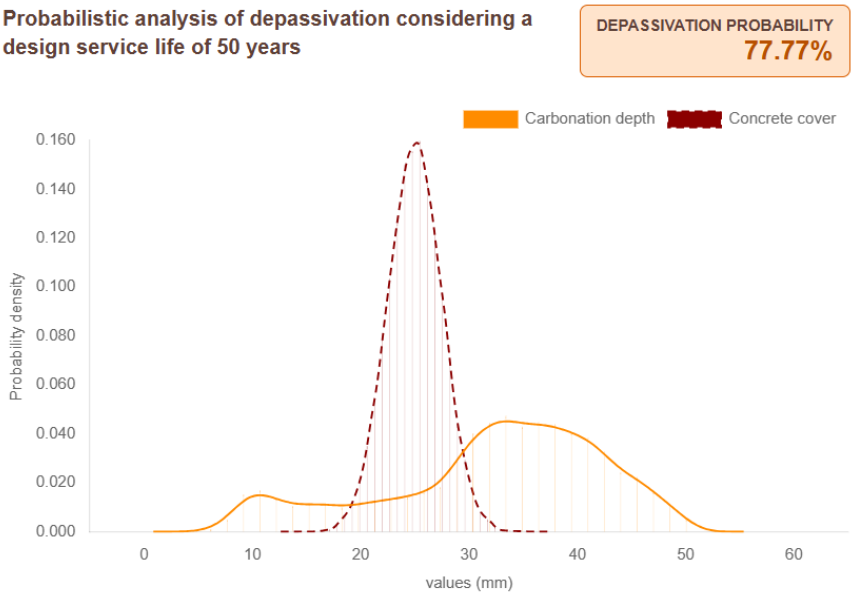
Figura 57 – Exemplo de saída da análise determinística da interface web.



Fonte: Autor.

O segundo exibe resultados do modelo probabilístico, como pode ser conferido em um exemplo na Figura 58, que descreve as frequências de profundidade de carbonatação e de cobrimento nominal, além da probabilidade de despassivação para o tempo escolhido.

Figura 58 – Exemplo de *output* probabilístico da interface *web*.



Fonte: Autor.

4.4 ANÁLISE DE APLICABILIDADE DO SOFTWARE

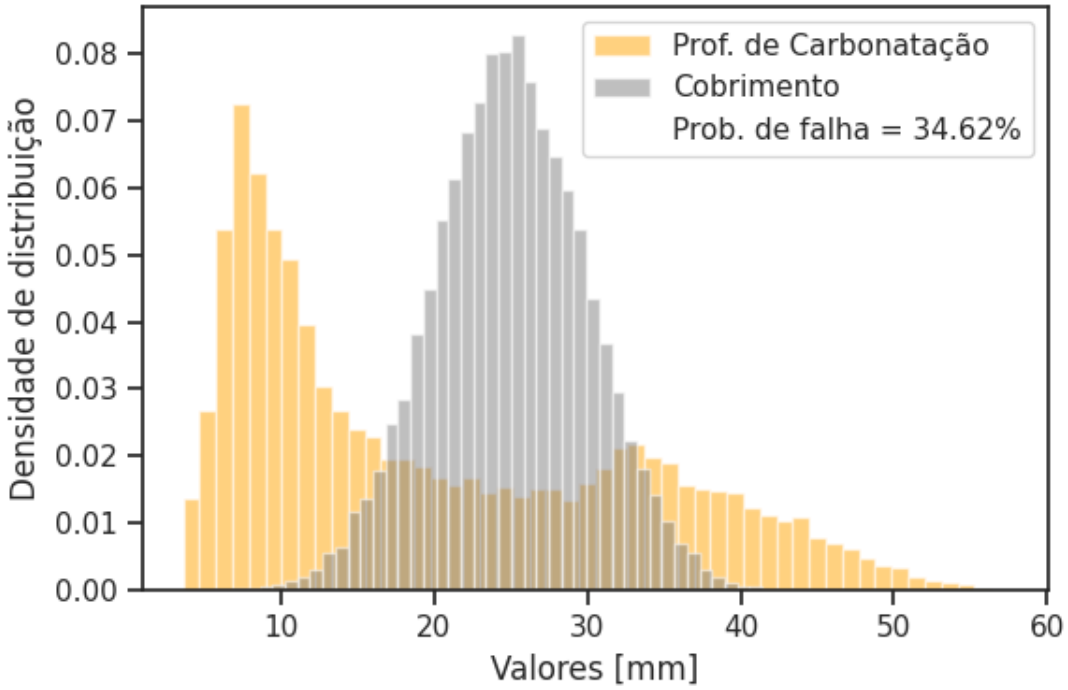
Para avaliar o comportamento da ferramenta desenvolvida, ela foi testada em diferentes cenários e submetida a uma análise paramétrica da probabilidade de despassivação, associada à Vida Útil de Projeto (VUP) de elementos de concreto armado. Durante essa análise, foi possível contrastar os resultados obtidos entre análises determinísticas (comparação entre a profundidade de carbonatação predita pelo modelo proposto e o cobrimento do concreto) e probabilísticas (considerando incertezas nas entradas do modelo por meio de simulações de Monte Carlo).

As análises foram realizadas com os dados fornecidos na Tabela 12, fazendo referência à viga da ponte com 41 anos da cidade de Bauru-SP, sendo eles: teor de clínquer e gesso = 97,5%; resistência à compressão aos 28 dias = 40,47 MPa; teor de adição mineral = 0; relação água/aglomerante = 0,49; umidade relativa = 73,71%; temperatura = 22,96 °C; teor de CO_2 = 0,04%; tipo de adição mineral = 0 (sem adições); ambiente de exposição = 1,0 (externo abrigado da chuva).

Como referência, foi plotado o gráfico de densidade da distribuição dos valores de profundidade de carbonatação e de cobrimento nominal do cenário de referência (Figura 59). Foram utilizados os valores fornecidos no parágrafo anterior,

bem como os coeficientes de variação e as funções de distribuição dos parâmetros indicados no item 4.2.1. O período de análise considerado foi de 50 anos.

Figura 59 – Distribuição da profundidade de carbonatação e do cobrimento no cenário padrão.



Fonte: Autor.

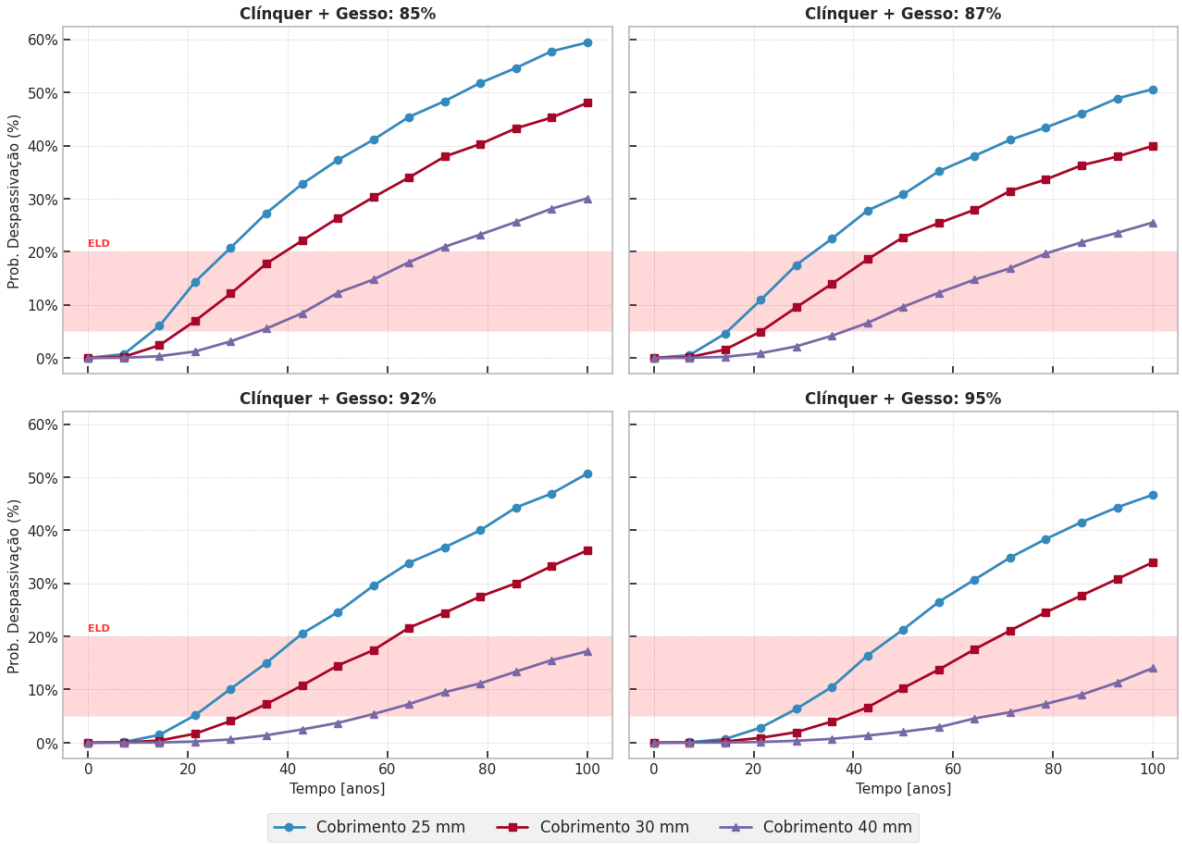
A norma ISO 13823:2008 (International Organization for Standardization, 2008) caracteriza a Vida Útil de Projeto (VUP) como a idade em que o Estado Limite de Durabilidade (ELD) é atingido, isto é, quando a probabilidade de despassivação da armadura se situa entre 5% e 20%. Com isso, nos gráficos a seguir, o ELD foi indicado por uma faixa vermelha transparente para facilitar a visualização da VUP em cada cenário de análise probabilística. Na Figura 59, por exemplo, observa-se que, aos 50 anos, a estrutura em questão terá ultrapassado sua VUP, pois a probabilidade de falha é de 34,62%.

4.4.1 Efeito do teor de clínquer e gesso do cimento

A primeira variável em análise é o teor de clínquer e de gesso do cimento. Os gráficos de probabilidade de despassivação em função do tempo, para diferentes valores dessa variável, podem ser consultados na Figura 60. É importante ressaltar

que, para a confecção desses gráficos, considerou-se que, ao reduzir o teor de clínquer e gesso, uma fração de adição é incorporada ao cimento, aqui considerado um acréscimo de escória de alto-forno.

Figura 60 - Análise probabilística: Clínquer + Gesso.

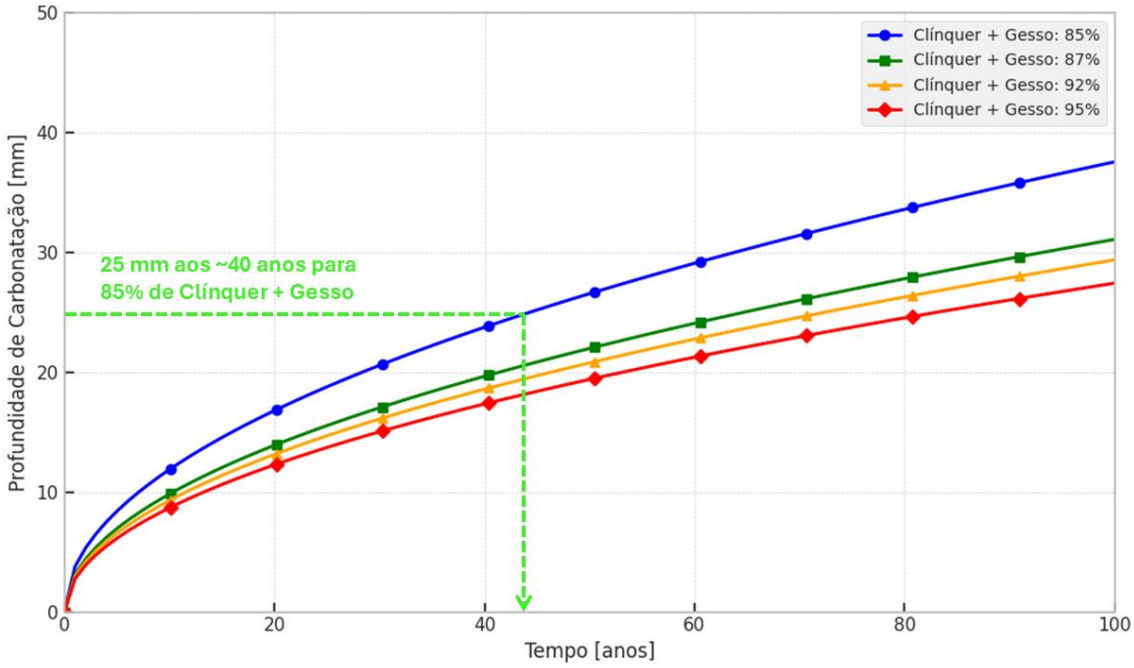


Fonte: Autor.

É possível contrastar os resultados obtidos na ferramenta probabilística, nos mesmos cenários, com os obtidos em uma análise determinística, apresentados na Figura 61, na qual constam as profundidades de carbonatação ao longo do tempo em função de diferentes teores de clínquer e de gesso.

Ao comparar os resultados das análises probabilísticas e determinísticas, é possível observar algumas diferenças, entre as quais o principal destaque é para as curvas referentes aos teores de 85% de clínquer e de gesso. Nas duas figuras, esse é o teor de caráter mais crítico para a estrutura, fornecendo tanto as maiores probabilidades de despassivação quanto as maiores profundidades de carbonatação.

Figura 61 - Análise determinística: Clínquer + Gesso.



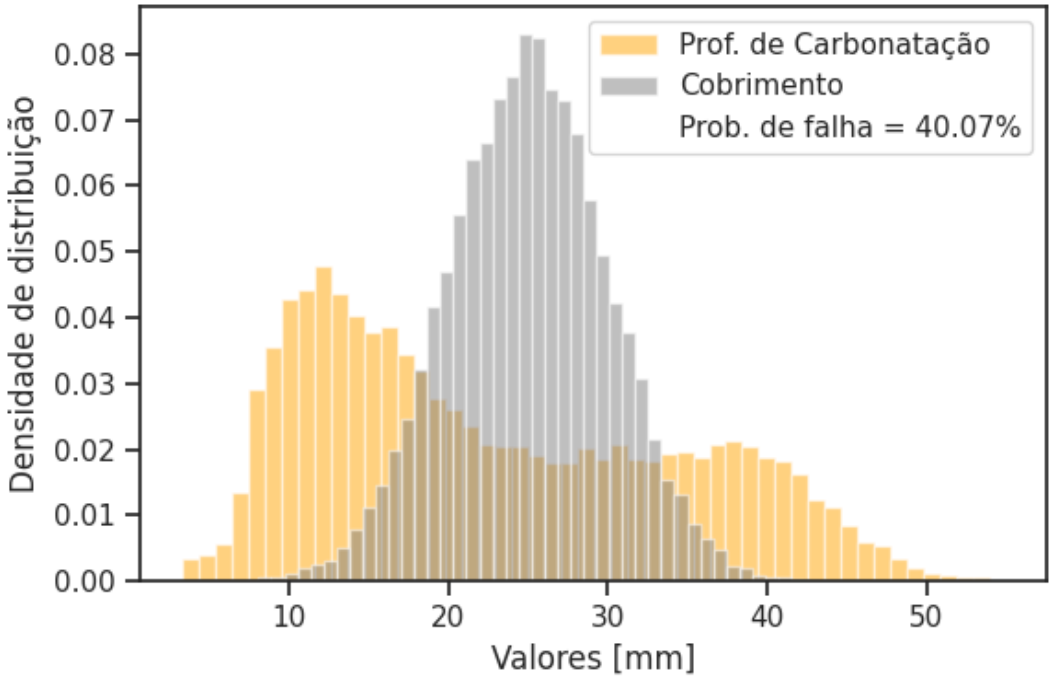
Fonte: Autor.

No entanto, adotando, de modo conservador, a probabilidade de despassivação de 5% como limite para o ELD, estruturas com teor de 85% de clínquer e gesso têm sua VUP inferior a 50 anos, de acordo com a análise probabilística, em torno de 20 anos, para um cobrimento médio de 25 mm. Em contrapartida, na análise determinística, observa-se que a profundidade de carbonatação da curva do teor de 85% alcança 25 mm apenas após 40 anos de idade da estrutura.

Além disso, observa-se que o cenário com maior teor de clínquer e gesso (95%) é aquele em que a VUP para cobrimentos de 25, 30 e 40 mm será de 25, 40 e 70 anos, respectivamente. Por outro lado, na análise determinística, nota-se que, para esse teor de clínquer e de gesso, a carbonatação leva mais de 80 anos para atingir o cobrimento de 25 mm.

Para avaliar o efeito das adições na estrutura da ponte, confrontaram-se os resultados probabilísticos da condição de referência da ponte (produzido com concreto sem adições) com os da construção na qual teriam sido utilizados 15% de adições no concreto (do tipo cinza volante). As distribuições dos cobrimentos e das profundidades de carbonatação das simulações são apresentadas na Figura 62, juntamente com a probabilidade de despassivação.

Figura 62 - Distribuição da profundidade de carbonatação e de cobrimento para a viga do viaduto, considerando um cimento com CG+ = 85%.



Fonte: Autor.

Seguindo a tendência esperada, a probabilidade de falha foi maior do que a observada no cenário de referência, uma vez que houve uma diminuição significativa nos teores de clínquer e de gesso. De acordo com a literatura, é esperado que, quanto maior o teor de clínquer, mais lenta será a carbonatação e, portanto, menos provável a despassivação durante a VUP (Bueno *et al.*, 2024; Elsalamawy; Mohamed; Kamal, 2019; Sisomphon; Franke, 2007).

Portanto, pode-se dizer que o modelo descreveu razoavelmente bem o comportamento do processo ao considerar essa variável isoladamente.

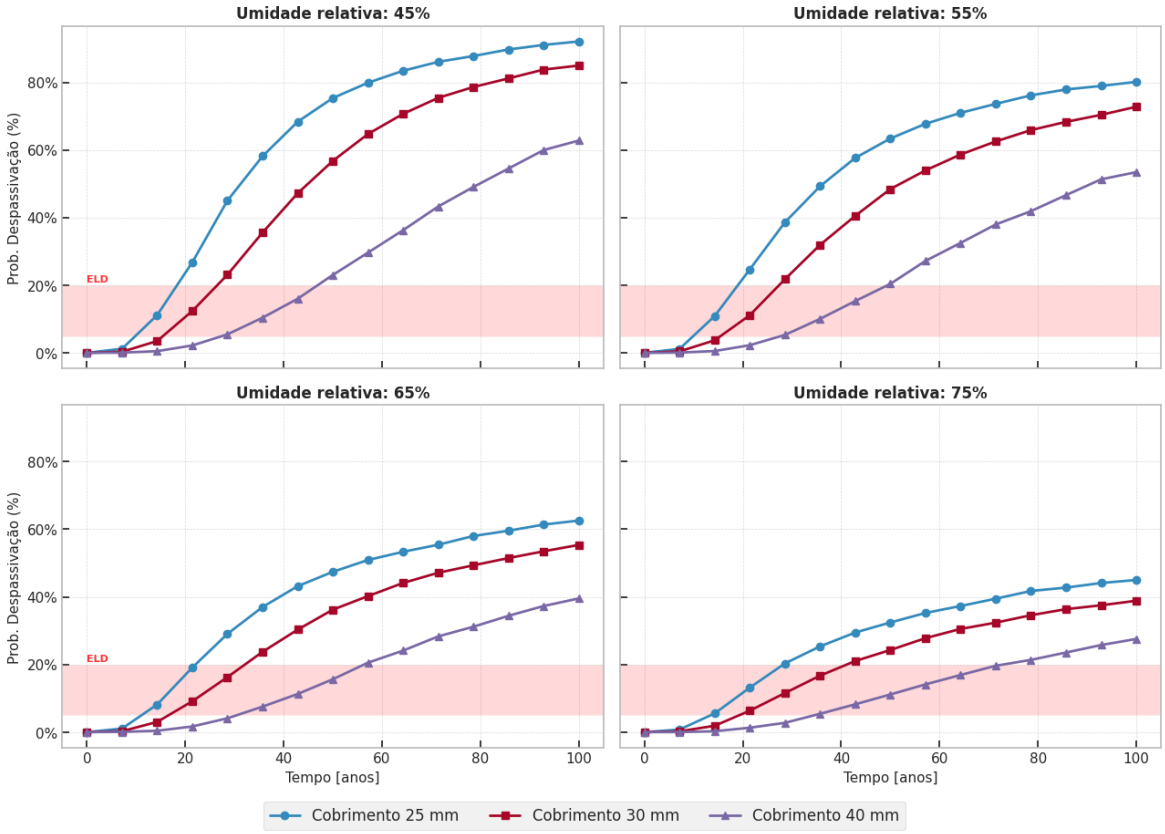
4.4.2 Efeito da umidade relativa

Na sequência, apresenta-se a análise do efeito da umidade relativa sobre a VUP, considerando a ferramenta desenvolvida neste estudo. De acordo com a literatura, as maiores profundidades de carbonatação acontecem para valores intermediários de umidade (50-70%), uma vez que os poros não podem estar completamente secos (para que haja transporte do CO_2 por meio do vapor d'água) e

nem completamente saturados (Elsalamawy; Mohamed; Kamal, 2019; Hou *et al.*, 2025).

Como pode ser observado na Figura 63, o cenário em que o ELD é alcançado mais cedo (antes dos 20 anos para 30 mm de cobrimento) é aquele com umidade relativa próxima de 45%, seguido pela umidade relativa de 55%, enquanto, para umidades mais elevadas, a curva de probabilidade em função do tempo é mais suave.

Figura 63 - Análise probabilística: Umidade relativa.



Fonte: Autor.

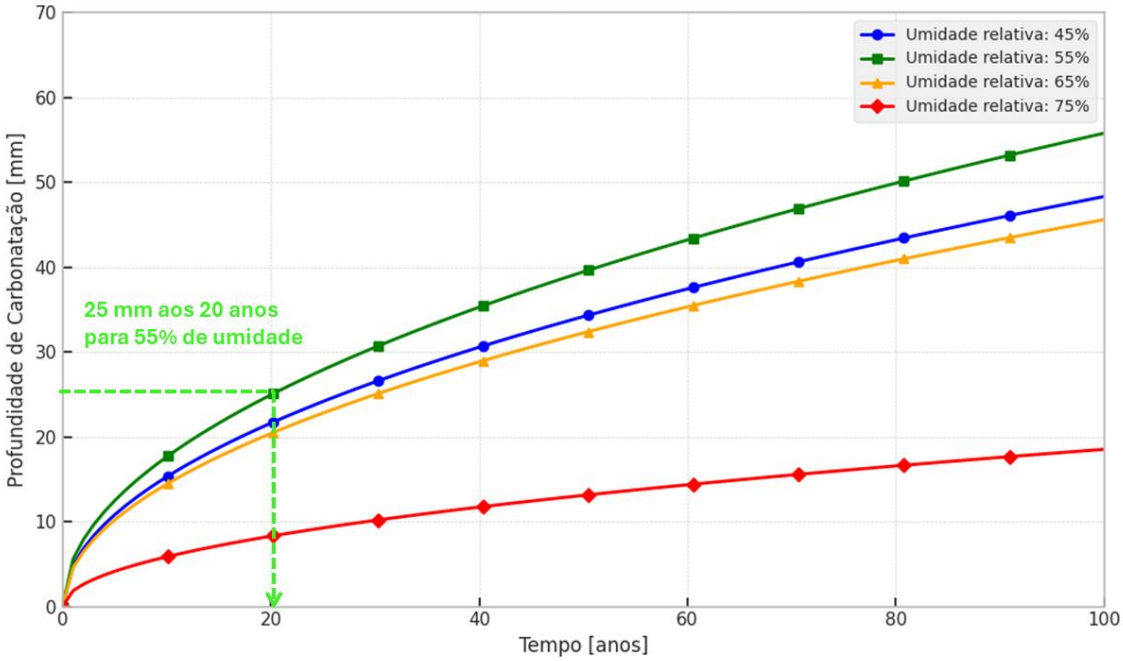
Em comparação com a análise determinística, cujos resultados estão dispostos na Figura 64, verifica-se que as maiores profundidades de carbonatação ocorrem em umidade relativa de 55%. Nesse valor, as profundidades de 25, 30 e 40 mm são alcançadas, respectivamente, aos 20, 30 e 50 anos.

É importante observar a discrepância entre as umidades relativas que geram os casos mais críticos nos cenários retratados por ambas as abordagens. Enquanto o modelo probabilístico retrata as curvas de 45% de umidade como as de

menor VUP (embora bastante semelhantes às de 55%), o modelo determinístico indica maiores profundidades de carbonatação para umidade de 55%.

Há algumas explicações possíveis para isso, que envolvem a variabilidade dos cenários nas amostras geradas aleatoriamente pela técnica de Monte Carlo. Primeiramente, é importante observar que a umidade relativa apresenta coeficiente de variação maior do que o dos demais parâmetros aleatórios do presente modelo, o que resulta em maior variabilidade dos valores em cada amostra e pode ter gerado condições mais críticas para a umidade de 55% do que para a de 45%, dada a aleatoriedade na definição da amostragem.

Figura 64 - Análise determinística: Umidade relativa.



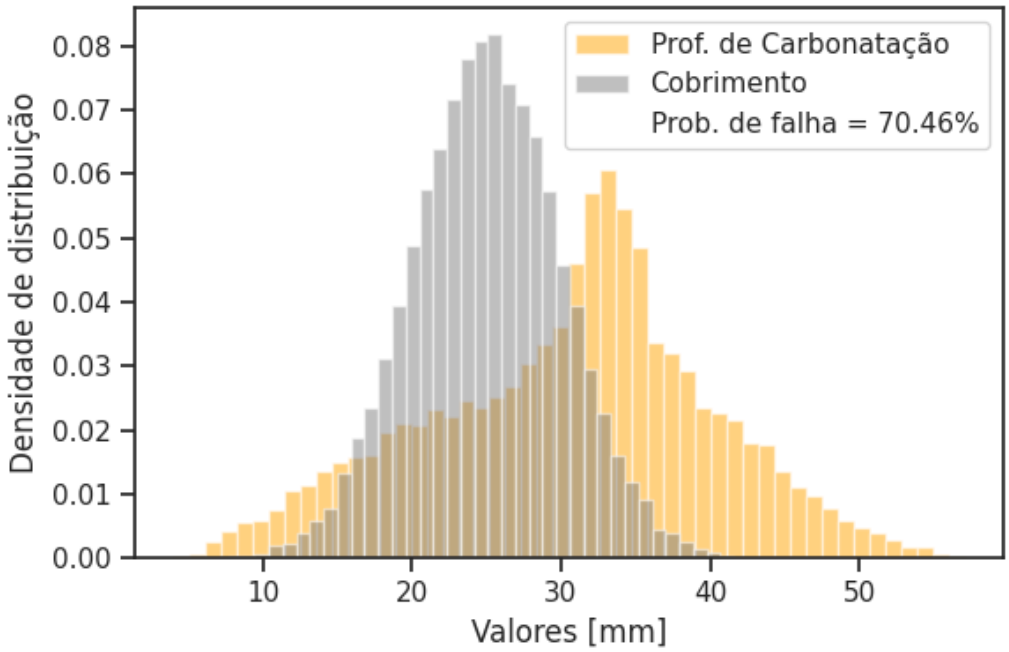
Fonte: Autor.

Unido a essa maior variabilidade, observa-se, na Figura 42, que o mapeamento da profundidade de carbonatação é apresentado em função da combinação entre a umidade e a temperatura. Nessa figura, é interessante notar que a umidade crítica será necessariamente afetada pela faixa de temperatura em que a predição é feita, uma variável também aleatória. Com isso, é possível inferir que a diferença entre os resultados obtidos pelas simulações probabilísticas e pelas determinísticas reflete a heterogeneidade de cenários decorrentes das incertezas e de diferentes cenários simulados com os parâmetros de entrada.

Nos cenários mais críticos expostos pela análise probabilística, as idades em que a probabilidade de despassivação de 5% é alcançada (caracterizando, de modo conservador, o ELD) são todas valores entre 10 e 30 anos. Na hipótese de considerarmos uma probabilidade de 20% para o ELD, a VUP pode ser ampliada, atingindo idades semelhantes às observadas na análise determinística.

Para contrastar com as densidades de distribuição do cenário de referência, os resultados da Figura 65 foram gerados considerando que a estrutura da ponte estaria localizada em um ambiente com umidade relativa média de 50%, valor muito inferior aos 73,7% indicados na Tabela 12.

Figura 65 - Distribuição da profundidade de carbonatação e do cobrimento da viga da ponte, considerando uma umidade relativa média de 50%.



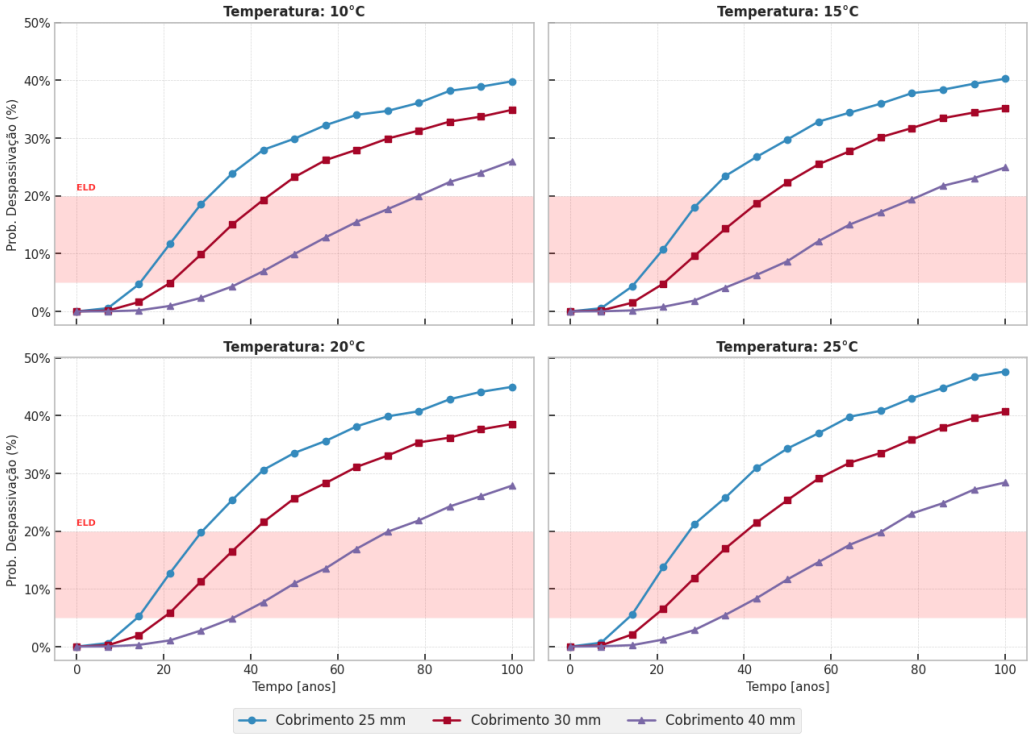
Fonte: Autor.

Percebe-se que a distribuição da profundidade de carbonatação apresenta média deslocada para valores entre 30 e 40 mm. Além disso, a probabilidade de despassivação aumentou consideravelmente em relação ao cenário padrão aos 50 anos de idade (de 35% para 70%). Esse comportamento está coerente com o observado na literatura e com os resultados anteriores obtidos no modelo, reforçando, portanto, a confiabilidade e a estabilidade dos resultados fornecidos pelo modelo.

4.4.3 Efeito da temperatura

Na sequência, na Figura 66, é apresentada a análise probabilística do efeito da temperatura, enquanto, na Figura 67, a análise determinística da mesma variável é apresentada para fins de comparação.

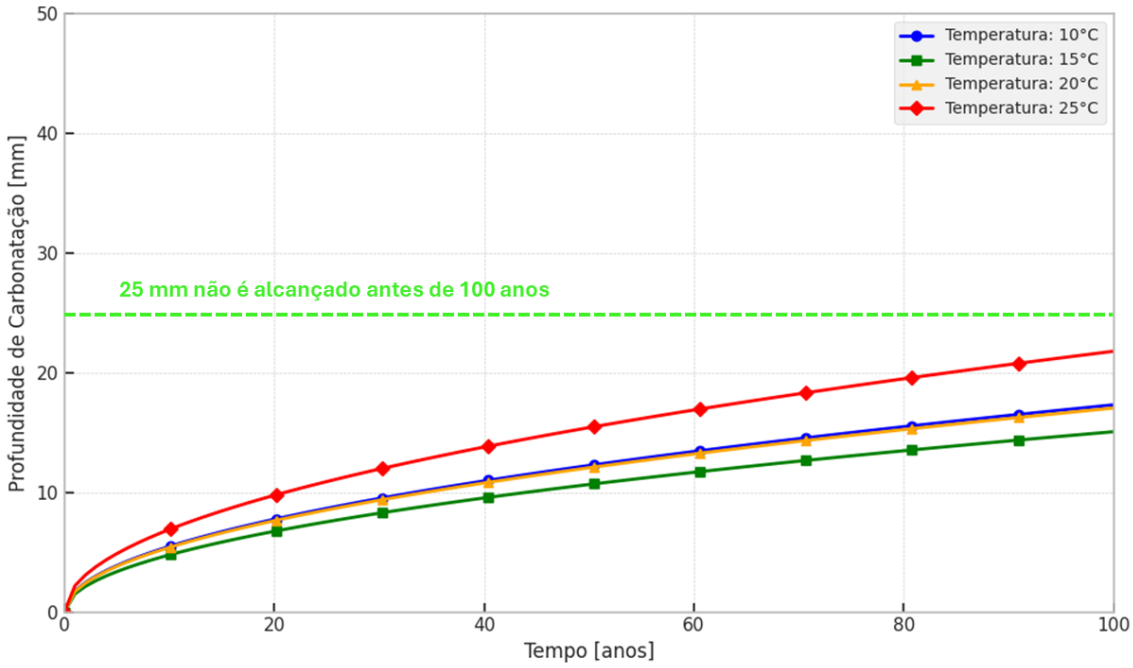
Figura 66 - Análise probabilística: Temperatura.



Fonte: Autor.

Como se pode observar, o patamar de temperatura associado à menor VUP, de acordo com a análise probabilística, é de 25 °C, com idades muito semelhantes às da curva de 20 °C. Tanto num caso quanto noutro, o ELD é alcançado para idades entre 10 e 15 anos quando a estrutura possui 25 mm de cobrimento, entre 20 e 30 anos para 30 mm e pouco mais de 30 anos para 40 mm. Em contraste, os resultados puramente determinísticos indicam que, mesmo após 100 anos de idade, a profundidade de carbonatação não alcançará nem 25 mm, independentemente da temperatura média.

Figura 67 - Análise determinística: Temperatura.



Fonte: Autor.

No estudo de Majlesi *et al.* (2023), é implementado um modelo de predição de carbonatação, com a temperatura como uma das variáveis de entrada. Nesse contexto, a intensidade da carbonatação apresentou-se diretamente proporcional à temperatura, sendo uma variável especialmente determinante para idades maiores, cujo efeito se combina com a precipitação acumulada nos poros.

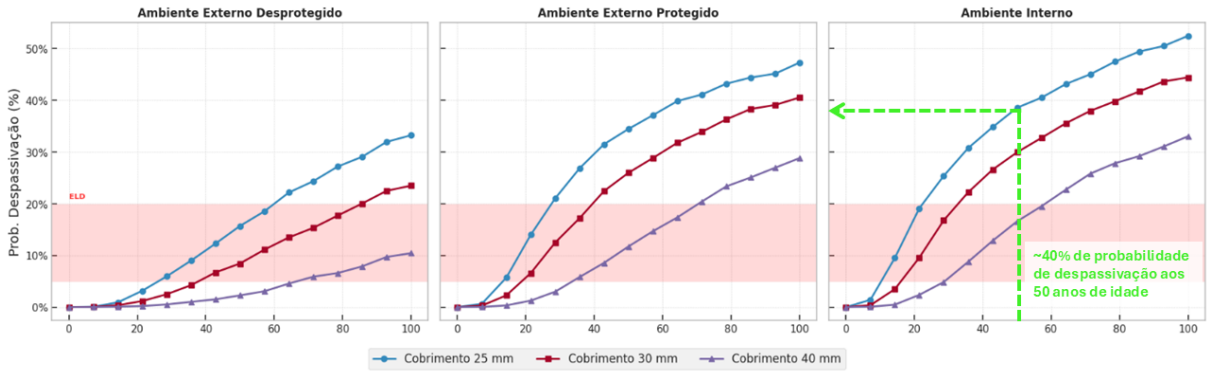
4.4.4 Efeito do ambiente de exposição

A condição de exposição à chuva, ou não, também foi avaliada quanto ao seu efeito sobre a VUP. Na Figura 68 é possível observar as probabilidades de despassivação em função do tempo para cada cenário de exposição, enquanto na Figura 69, as profundidades de carbonatação ao longo do tempo, também para cada ambiente.

De modo bastante consistente entre as duas figuras, o cenário de carbonatação mais branda é aquele em que elementos estruturais ficam expostos diretamente à chuva, sem qualquer proteção. Isso pode ser associado principalmente à possível saturação dos poros, o que desfavorece o transporte de CO_2 na matriz

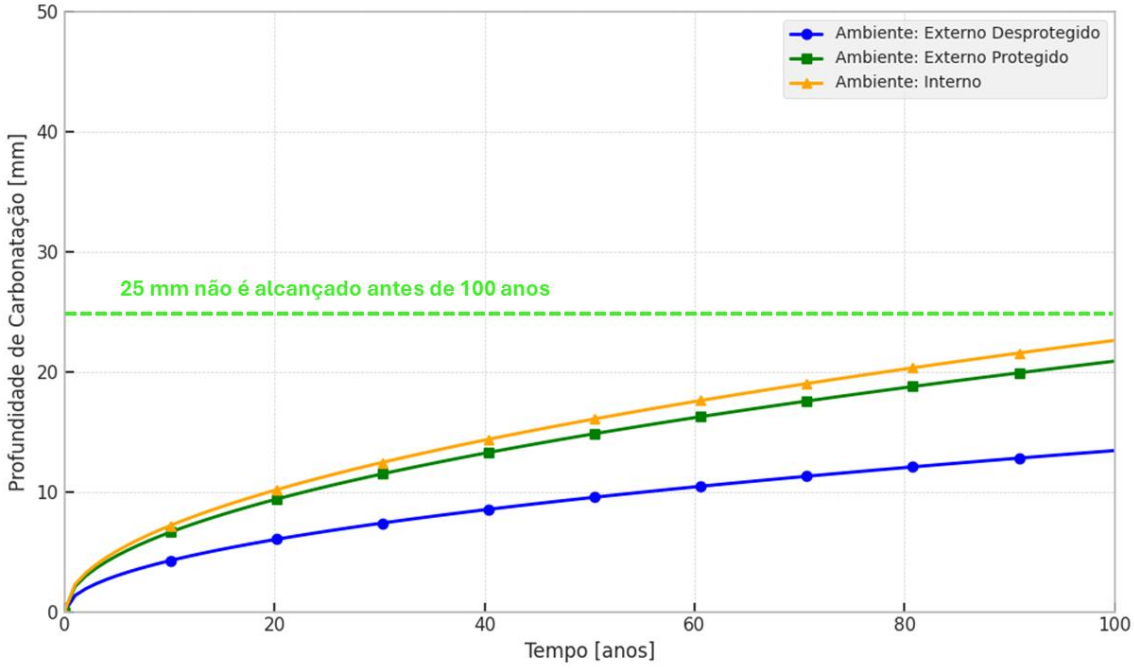
cimentícia, enquanto, em ambientes protegidos ou internos, quando há umidade adequada, o fenômeno em estudo é favorecido.

Figura 68 - Análise probabilística: Ambiente de exposição.



Fonte: Autor.

Figura 69 - Análise determinística: Ambiente de exposição.



Fonte: Autor.

Esse comportamento está de acordo com os resultados obtidos por Lavinicki *et al.* (2025). Nesse estudo, a exposição à chuva é avaliada como um dos fatores de influência da carbonatação, e o modelo proposto indica uma profundidade, em média, 50% maior no ambiente de exposição interna em comparação com o ambiente externo desabrigado da chuva, comportamento que se evidencia cada vez mais com o passar dos anos.

A carbonatação menos acentuada em ambientes externos também é destacada por Possan *et al.* (2020). Nesse estudo, os autores explicam que a carbonatação em ambientes internos pode ser até duas vezes maior do que em ambientes expostos à chuva, o que reforça o comportamento observado.

Observando especificamente os valores de profundidade de carbonatação nos resultados determinísticos (Figura 69), percebe-se que, após 100 anos, em nenhum dos cenários dos resultados determinísticos a profundidade de 25 mm é alcançada. De modo distinto, os resultados probabilísticos (Figura 68) sugerem que aos 50 anos de idade a VUP já teria sido ultrapassada, uma vez que a probabilidade de despassivação na situação mais crítica (isto é, ambiente interno de exposição) é próxima de 40%, maior do que o critério de ELD fornecido pela ISO 13823:2008.

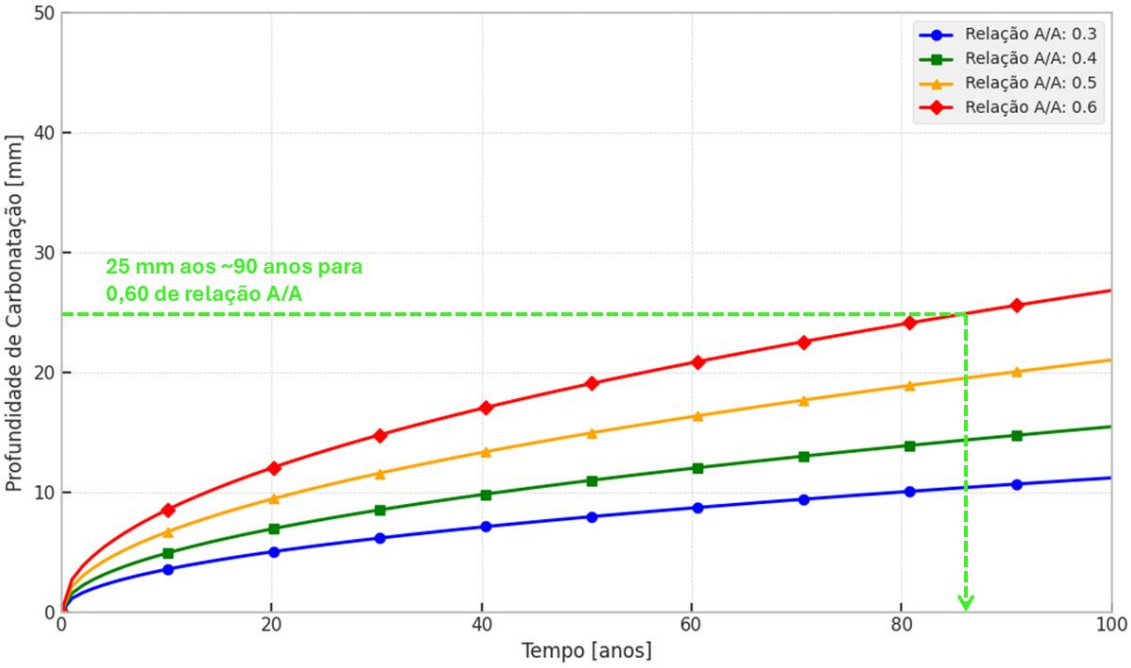
4.4.5 Efeito da relação água/aglomerante

Por fim, a última variável analisada foi a relação água/aglomerante, que teve influência significativa sobre os resultados das duas análises, determinísticas e probabilísticas, como pode ser conferido na Figura 71 e na Figura 70.

De acordo com a literatura, espera-se que, quanto maior for a relação água/aglomerante, mais intenso será o processo de carbonatação, o que foi observado nos resultados do modelo desenvolvido. Isso se deve ao fato de essa relação estar diretamente associada à porosidade do material, que, por sua vez, determina os caminhos percorridos pelo CO_2 no meio cimentício.

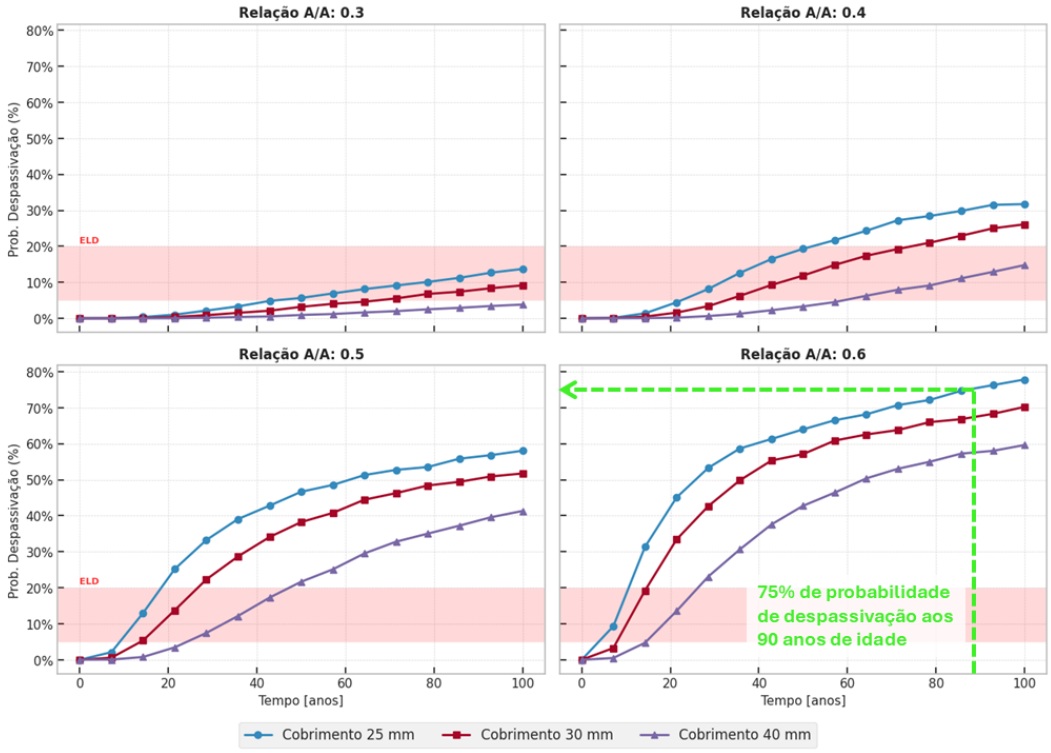
No estudo de Malysz *et al.* (2023), os autores realizaram um estudo de confiabilidade utilizando simulações de Monte Carlo para avaliar estruturas em processo de carbonatação natural. Ao variar a relação água/aglomerante entre 0,38 e 0,58, essa variável destaca-se por desempenhar um papel determinante na probabilidade de falha.

Figura 70 - Análise determinística: Relação água/aglomerante.



Fonte: Autor.

Figura 71 - Análise probabilística: Relação água/aglomerante.



Fonte: Autor.

Esses resultados também são coerentes com os obtidos na abordagem probabilística proposta por Nogueira, Yoshio e Zacchei (2023). Nesse estudo, com

horizonte de tempo de 50 anos e valores de relação água/cimento de 0,40 e 0,50, foi possível observar diferenças consideráveis na probabilidade de iniciação da corrosão. O impacto dessa variável foi comparável, inclusive, ao do tamanho do cobrimento nominal das armaduras.

Comparando as duas análises, é possível perceber, ainda, nos resultados determinísticos (Figura 70), que a profundidade de 25 mm é alcançada apenas pela curva de relação água/aglomerante de 0,60 e somente após 80 anos de idade. Por outro lado, nos resultados probabilísticos (Figura 71), nota-se que, para essa mesma relação água/aglomerante, na idade de 80 anos, a probabilidade de despassivação ultrapassa 70%, muito acima do critério de ELD definido pela ISO 13823:2008.

4.5 CONSIDERAÇÕES DO CAPÍTULO

No presente capítulo, foi descrito o processo de desenvolvimento da ferramenta probabilística para a predição da despassivação de estruturas de concreto armado. Além disso, foram analisados diferentes cenários de aplicação, identificando-se o efeito de determinados parâmetros sobre a VUP.

Foram realizados testes de aplicação do modelo, acompanhados de uma análise paramétrica, na qual foi possível contrastar os resultados probabilísticos com os do modelo determinístico obtidos anteriormente. Durante essas análises, considerando os critérios de durabilidade estabelecidos pela ISO 13823:2008, foi perceptível como o modelo probabilístico forneceu resultados mais conservadores com relação à vida útil de projetos das estruturas do que o modelo determinístico independentemente do contexto ambiental e de material, do mesmo modo que o relatado por Nogueira, Yoshio e Zacchei (2023). Os resultados indicam a importância de considerar a aleatoriedade dos parâmetros envolvidos em uma análise de vida útil de projeto, a fim de contemplar os diferentes cenários de degradação da estrutura.

A ferramenta, desenvolvida com base na técnica de simulação de Monte Carlo e em RNAs, permite, de forma simplificada, que usuários realizem análises probabilísticas da VUP de estruturas de concreto armado, considerando a propagação de incertezas por meio da geração de diversos cenários aleatórios, das variáveis climáticas e de variabilidade no processo produtivo de estruturas de concreto armado destacando-se: o cobrimento nominal das armaduras, a resistência à compressão do

concreto, a temperatura média, a umidade relativa média do ar e a concentração de CO_2. Além de sua utilidade como recurso de pesquisa ou de auxílio à tomada de decisão em um projeto, a ferramenta configura-se como um instrumento aplicável ao dimensionamento e à gestão da durabilidade de estruturas de concreto, podendo ser utilizada tanto em estudos acadêmicos quanto em práticas de engenharia.

5 CONCLUSÕES

Na presente pesquisa, a questão da durabilidade de estruturas de concreto armado foi contextualizada e problematizada, de modo a embasar a proposição de uma ferramenta numérica para a análise probabilística da vida útil de projeto de estruturas de concreto armado sujeitas à corrosão por carbonatação, acoplando técnicas de aprendizado de máquina ao método de simulação de Monte Carlo. Diante disso, na sequência são apresentados os principais resultados da pesquisa e suas contribuições, além das limitações e sugestões para trabalhos futuros.

Partindo de uma base originalmente composta por pouco mais de 1000 registros do grupo de pesquisa DASMAE, o presente trabalho ampliou essa base para 2335 registros de carbonatação exclusivamente natural. Com isso, foi possível ampliar a representatividade do modelo do grupo de pesquisa, bem como seu domínio de atuação, abrangendo concretos oriundos de diferentes regiões e condições ambientais.

A análise e o tratamento dos dados, realizados com base no método do IQR e em critérios técnicos próprios da construção civil, permitiram eliminar valores atípicos que poderiam comprometer a acurácia do modelo. Além disso, esse pré-processamento contribuiu para delimitar o domínio de atuação do modelo, restringindo os intervalos de variáveis-chave como taxa de carbonatação, resistência à compressão, relação água/aglomerante e teores de clínquer e gesso e de adições minerais.

A etapa de modelagem e busca pelas melhores arquiteturas, conduzida por meio do método Random Grid Search, representou o estágio mais exigente em termos de tempo e custo computacional, mas permitiu identificar arquiteturas de rede neural com desempenho satisfatório, considerando a complexidade do problema. Para a avaliação comparativa das redes, foram utilizadas as métricas do coeficiente de correlação (R^2) e da raiz do erro quadrático médio (RMSE), calculadas de forma ponderada para treino (40%) e teste (60%), de modo a priorizar a capacidade de generalização dos modelos.

Nos treinamentos com redes de camada única, observou-se que as arquiteturas com 10 a 20 neurônios forneceram resultados mais consistentes, sendo a rede com 13 neurônios a de melhor equilíbrio entre treino e teste, com R^2 de 0,805

e 0,826 e RMSE de 0,964 e 0,916 mm/ano^{0,5}, respectivamente. As redes com mais de 35 neurônios apresentaram instabilidade e queda de desempenho. Esses achados são coerentes com a literatura, que geralmente considera ótimo o intervalo de 10 a 15 neurônios em redes de uma única camada.

Nas redes de duas camadas ocultas, dentre as 400 arquiteturas testadas, a melhor topologia encontrada foi 9-15-9-1, alcançando R^2 de 0,827 em treino e 0,839 em teste, com RMSE de 0,908 e 0,882 mm/ano^{0,5}. Embora os valores sejam inferiores aos relatados em alguns estudos, os resultados demonstraram coerência metodológica e confirmaram o maior potencial das RNAs multicamadas para o mapeamento de fenômenos não lineares complexos.

Já no caso das redes de três camadas, a busca por arquiteturas ideais foi realizada em três fases sucessivas de Random Grid Search, restringindo gradualmente o espaço de busca. As melhores redes encontradas foram com topologia 9-19-18-1-1 e 9-20-12-6-1, que obtiveram R^2 médio de 0,835 em treino e 0,851 em teste, RMSE médio de 0,888 em treino e 0,847 mm/ano^{0,5} em teste e MAE médio de 0,625 mm/ano^{0,5} em treino e 0,617 mm/ano^{0,5} em teste.

Um padrão recorrente identificado foi a concentração de um número maior de neurônios nas primeiras camadas e de quantidades menores na terceira, tendência também destacada em estudos recentes. Embora os resultados fiquem abaixo dos de trabalhos que reportaram R^2 superiores a 0,95, ressalta-se que a presente pesquisa utilizou uma base de dados mais heterogênea e com informações de carbonatação natural em longas idades (acima de 10 anos), o que confere maior representatividade do fenômeno.

O modelo proposto, selecionado com a melhor performance, apresentou R^2 geral em torno de 0,85, RMSE de aproximadamente 0,84 mm/ano^{0,5} e MAE de 0,61 mm/ano^{0,5}.

Com o modelo validado, foi realizada uma análise paramétrica para explorar como o comportamento de uma série de variáveis de entrada foi mapeado. Durante essa análise, observou-se que a umidade relativa que provoca as carbonatações mais intensas concentra-se entre 50% e 60%, bem como a correlação direta entre a relação água/aglomerante e a carbonatação, decorrente da porosidade do concreto.

Além disso, o modelo preditivo descreveu a carbonatação em função da temperatura sem uma correlação direta clara, mas talvez de acordo com a combinação dessa com outras variáveis. Enquanto isso, o ambiente de exposição interno foi caracterizado como o mais propício à aceleração do processo. Por fim, as adições minerais também foram exploradas, com relação direta entre o teor de adição e a profundidade de carbonatação.

Os resultados obtidos com a incorporação do modelo determinístico ao método de simulação de Monte Carlo mostraram que este último fornece estimativas mais conservadoras de vida útil de projeto (VUP), sempre dentro do critério estabelecido pela ISO 13823:2008. Em diversos cenários, enquanto o modelo determinístico não indicava despassivação mesmo após longos períodos, o probabilístico apontava VUP entre 10 e 20 anos, evidenciando maior aderência às incertezas reais dos materiais, dos processos construtivos e dos ambientes de exposição.

Verificou-se que cimentos com maior teor de clínquer e gesso, como CP I e CP V, tendem a apresentar maior durabilidade, enquanto a redução desses componentes aumenta a probabilidade de despassivação. A análise da umidade relativa revelou diferenças entre os modelos: o determinístico indicou 55% como condição crítica, enquanto o probabilístico apontou 45%, resultado da interação entre umidade e temperatura, que gera diferentes cenários de carbonatação. A temperatura, por sua vez, não apresentou tendência direta isoladamente, sugerindo efeito indireto e dependente da combinação com outras variáveis.

As variáveis de teor de adições minerais, ambiente de exposição e relação água/aglomerante confirmaram tendências já descritas na literatura: maiores teores de adições minerais, ambientes internos e relações água/aglomerante elevadas resultaram em menores idades de VUP.

Por fim, consolidando os achados e o comportamento das variáveis, foi desenvolvida uma interface web pública que permite a inserção intuitiva dos dados de entrada e a visualização clara dos resultados determinísticos e probabilísticos. Essa ferramenta viabiliza a aplicação prática do modelo em estudos de confiabilidade de estruturas e amplia seu uso em pesquisas científicas e em aplicações tecnológicas.

5.1 LIMITAÇÕES E FUTUROS DESENVOLVIMENTOS

Como esperado, com os avanços alcançados na presente pesquisa, surgem novas frentes de estudo, bem como oportunidades de preencher lacunas e de aprimorar a ferramenta e os modelos aqui desenvolvidos.

Ao discutir as limitações das ferramentas desenvolvidas, é importante explicitar o domínio de validade do modelo de predição da frente de carbonatação, ou seja, o intervalo de valores das variáveis para os quais os resultados obtidos podem ser considerados confiáveis. O modelo foi criado e validado nas seguintes faixas: clínquer + gesso entre 85,00% e 97,50%; resistência à compressão média entre 13,90 MPa e 60,00 MPa; teor de adição mineral entre 0,00% e 100,00%; relação água/aglomerante entre 0,29 e 0,65; umidade relativa do ar entre 32,60% e 80,00%; temperatura entre 5,90 °C e 29,50 °C; e concentração de CO_2 atmosférico entre 0,01% e 0,05%.

Assim, a primeira melhoria a ser implementada no modelo desenvolvido é a ampliação do banco de dados de carbonatação em condições naturais de degradação. A acurácia e o domínio de aplicabilidade do modelo de predição baseado em redes neurais dependem, em grande parte, da abrangência e, sobretudo, da qualidade dos dados de treinamento; portanto, quanto mais dados confiáveis e completos forem inseridos, mais preciso se tornará o modelo e maior será a possibilidade de aplicação em diferentes cenários.

Variáveis cujas influências também podem ser melhor investigadas são a temperatura e a concentração de CO_2. Uma vez que variáveis ambientais muitas vezes não são incorporadas em estudos de campo ou laboratoriais, foi preciso imputar valores a esses parâmetros a partir de bases públicas, o que pode comprometer a qualidade de algumas amostras. Nesse sentido, é relevante a obtenção de amostras que considerem com maior precisão os valores dessas variáveis ambientais.

Além disso, também é interessante avaliar a maneira como as variáveis ambientais são utilizadas pelo modelo de redes neurais. Isto é, atualmente a entrada desses valores é dado exclusivamente pelo seu valor médio ao longo de toda a idade da estrutura, idade essa que pode chegar a décadas. Para uma análise mais refinada e possivelmente mais precisa, pode-se levar em consideração espectros

macroclimáticos de temperatura, umidade e teor de CO_2, abrangendo valores máximos e mínimos ou, ainda, variações mensais ou anuais dos mesmos para cada parâmetro.

A presente ferramenta limita-se ainda à predição da Vida Útil de Projeto, momento em que a estrutura tem sua armadura despassivada. O próximo passo de evolução dessa linha de pesquisa envolve estender a predição às Vidas Úteis de Serviço e Total, de modo a abranger todo o ciclo de vida de uma estrutura.

Para isso, recomenda-se a implementação de um modelo de elementos finitos para descrever o comportamento mecânico global de um elemento de concreto armado durante o processo de corrosão do aço. Com isso seria possível avaliar a falha mecânica da estrutura e sua vida útil total.

REFERÊNCIAS

AARON, G. H.; MYDIN, M. A. O.; TOBBALA, D. E.; JAGADESH, P.; ÖZKILIÇ, Y. O.; DATTA, S. D.; AL BAKRI ABDULLAH, M. Experimental and machine learning approaches to investigate the properties of foamed concrete made with surkhi and dolomitic limestone as cement replacements. **Multiscale and Multidisciplinary Modeling, Experiments and Design**, Cham, v. 8, n. 2, p. 151, 2025.

ABAMBRES, M.; LANTSOGHT, E. O. L. ANN-Based Shear Capacity of Steel Fiber-Reinforced Concrete Beams without Stirrups. **Fibers**, Basel, v. 7, n. 10, p. 88, 2019.

ACOSTA, A. A. T.; BORGES, P. C.; RINCÓN, O. T.; PÉREZ, B. M.; MOLINA, W. M.; GUZMÁN, E. A.; REYES, C. B.; LÓPEZ, T. P.; PERRUSQUÍA, C. A.; SÁNCHEZ, S. E. C.; QUIROZ, J. T. P.; MIGUEL, A. L.; VAZQUEZ, E. L.; CRUZ, C. E. J.; RODRÍGUEZ, J. A.; GÓMEZ, F. J. R.; ZAMORA, M. A. B.; RUIZ, L. L.; BANDALA, E. M.; MENDOZA, D. N.; HERRERA, J. A. M. Concrete carbonation in tropical urban and urban/marine environments after 20 years of natural exposure. **Construction and Building Materials**, Oxford, v. 450, p. 138511, 2024.

AFNOR. **NF EN 206/CN**: Béton - spécification, performance, production et conformité. Paris: AFNOR, 2014.

AKPINAR, P.; UWANUAKWA, I. D. Intelligent prediction of concrete carbonation depth using neural networks. **Bulletin of the Transilvania University of Brasov**, Brasov, v. 9, n. 2, p. 99-108, 2016.

AKPINAR, P.; UWANUAKWA, I. D. Investigation of the parameters influencing progress of concrete carbonation depth by using artificial neural networks. **Materiales de Construcción**, Madrid, v. 70, n. 337, p. e209, 2020.

ALHASSAN, Y. A. **The effects of materials and micro-climate variations on predictions of carbonation rate in reinforced concrete in the inland environment**. 2014. Dissertation (Master of Science in Engineering) – Faculty of Engineering and the Built Environment, University of the Witwatersrand, Johannesburg, 2014.

ALMEIDA, T. A. C.; FELIX, E. F.; DE SOUSA, C. M. A.; PEDROSO, G. O. M.; MOTTA, M. F. B.; PRADO, L. P. Influence of the ANN Hyperparameters on the Forecast Accuracy of RAC's Compressive Strength. **Materials**, Basel, v. 16, n. 24, p. 7683, 2023.

ANGST, U. M.; GEIKER, M. R.; MICHEL, A.; GEHLEN, C.; WONG, H.; ISGOR, O. B.; ELSENER, B.; HANSSON, C. M.; FRANÇOIS, R.; HORNBOSTEL, K.; POLDER, R.; ALONSO, M. C.; SANCHEZ, M.; CORREIA, M. J.; CRIADO, M.; SAGÜÉS, A.; BUENFELD, N. The steel–concrete interface. **Materials and Structures**, Dordrecht, v. 50, n. 2, p. 143, 2017.

ANN, K. Y.; PACK, S.-W.; HWANG, J.-P.; SONG, H.-W.; KIM, S.-H. Service life prediction of a concrete bridge structure subjected to carbonation. **Construction and Building Materials**, Oxford, v. 24, n. 8, p. 1494-1501, 2010.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 15575-1**: edificações habitacionais – desempenho - parte 1: requisitos gerais. Rio de Janeiro: ABNT, 2013.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 16697**: cimento portland – requisitos. Rio de Janeiro: ABNT, 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 6118**: projeto de estruturas de concreto. Rio de Janeiro: ABNT, 2026.

ATKINS, P.; PAULA, J.; KEELER, J. **Atkins' Physical Chemistry**. 11. ed. Oxford: Oxford University Press, 2018. v. 1

AUTOMERIS LLC. **WebPlotDigitizer 5.2**: extract data from charts. Pacifica: Automeris LLC, 2024. Disponível em: https://automeris.io/wpd/?v=5_2. Acesso em: 3 set. 2024.

BAKKER, R. F. M. Initiation Period. *In*: SCHIESSL, Peter (org.). **Corrosion of steel in concrete**: report of the Technical Committee 60-CSC RILEM. New York: Chapman and Hall, 1988. v. 1, p. 22-55.

BARY, B.; SELLIER, A. Coupled moisture—carbon dioxide–calcium transfer model for carbonation of concrete. **Cement and Concrete Research**, Oxford, v. 34, n. 10, p. 1859-1872, 2004.

BAUER, L. A. F. **Materiais de Construção**. 6. ed. Rio de Janeiro: LTC, 2019. v. 2.

BERGSTRA, J.; BENGIO, Y. Random Search for Hyper-Parameter Optimization. **Journal of Machine Learning Research**, Cambridge, v. 13, p. 281-305, 2012.

BERKELEY EARTH. **August 2024 Temperature Update**. Berkeley: Berkeley Earth, 2024. Disponível em: https://berkeleyearth.org/august-2024-temperature-update/. Acesso em: 29 ago. 2024.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. New York: Springer, 2006.

BISWAS, R.; LI, E.; ZHANG, N.; KUMAR, S.; RAI, B.; ZHOU, J. Development of hybrid models using metaheuristic optimization techniques to predict the carbonation depth of fly ash concrete. **Construction and Building Materials**, Oxford, v. 346, p. 128483, 2022.

BOB, C.; AFANA, E. On-site assessment of concrete carbonation. *In*: INTERNATIONAL CONFERENCE ON FAILURE OF CONCRETE STRUCTURES, RILEM, 1993, Bratislava. **Proceedings** [...]. Bratislava: Expertcentrum, 1993. p. 84-89.

BOGUE, R. H. **The Chemistry of Portland Cement**. New York: Reinhold Publishing Corp., 1947.

BOLINA, F. L.; TUTIKIAN, B. F.; HELENE, P. **Patologia de estruturas**. São Paulo: Oficina de Textos, 2019.

BONI, R.; HELENE, P. Evolução da resistência à compressão do concreto segundo a ABNT NBR 6118:2023; fib Model Code 2020 e Eurocode 2: 2023. *In*: CONGRESSO BRASILEIRO DO CONCRETO, 65., 2024, Maceió. **Anais** [...]. São Paulo: IBRACON, 2024.

BOUZOUBAÂ, N.; BILODEAU, A.; TAMTSIA, B.; FOO, S. Carbonation of fly ash concrete: laboratory and field data. **Canadian Journal of Civil Engineering**, Ottawa, v. 37, n. 12, p. 1535-1549, 2010.

BORGES, R. R.; IAROSZ, K. C.; BATISTA, A. M.; CALDAS, I. L.; BORGES, F. S.; LAMEU, E. L. Sincronização de disparos em redes neuronais com plasticidade sináptica. **Revista Brasileira de Ensino de Física**, São Paulo, v. 37, n. 2, 2310, 2015.

BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. L. F. **Redes neurais artificiais**: teoria e aplicações. Rio de Janeiro: LTC, 2000.

BUENO, T. L. G. T.; CANDIDO, R. A.; FELIX, E. F.; PRADO, L. P. Avaliação do Impacto das Mudanças Climáticas na Vida Útil de Projeto de Estruturas de Concreto sob Corrosão por Carbonatação. *In*: CONGRESSO BRASILEIRO DO CONCRETO, 65., 2024, Maceió. **Anais** [...]. São Paulo: IBRACON, 2024.

BUENO, T. L. G. T.; CONTE, W.; NOGUEIRA, C.; FELIX, E. F. Data-Driven Prediction of Carbonation Depth in Concrete Using Deep Learning. *In*: SIMPÓSIO BRASILEIRO DE TECNOLOGIA DA INFORMAÇÃO E COMUNICAÇÃO NA CONSTRUÇÃO, 5., 2025, Brasília. **Anais** [...]. Brasília: LaSUS FAU UnB, 2025.

CABRERA, J. G. Deterioration of concrete due to reinforcement steel corrosion. **Cement and Concrete Composites**, Barking, v. 18, n. 1, p. 47-59, 1996.

CAREVIĆ, V.; IGNJATOVIĆ, I.; DRAGAŠ, J. Model for practical carbonation depth prediction for high volume fly ash concrete and recycled aggregate concrete. **Construction and Building Materials**, Oxford, v. 213, p. 194-208, 2019.

CARPENTER, G. A.; GROSSBERG, S. Associative Learning, Adaptive Pattern Recognition, And Cooperative-Competitive Decision Making By Neural Networks. *In*: SZU, Harold H. (org.). **Optical and Hybrid Computing**. Bellingham: SPIE, 1986. p. 218-247.

CASCUDO, O. **O controle da corrosão de armaduras em concreto**: inspeção e técnicas eletroquímicas. São Paulo: Pini, 1999.

CEB-FIP. **fib Model Code for Concrete Structures 2020**. Lausanne: Fédération Internationale du Béton, 2023.

COLLEPARDI, M.; COLLEPARDI, S.; OLAGOT, J. J. O.; SIMONELLI, F. The influence of slag and fly ash on the carbonation of concrete. *In*: INTERNATIONAL CONFERENCE ON FLY ASH, SILICA FUME, SLAG, AND NATURAL POZZOLANS IN CONCRETE, 8., 2004, Las Vegas. **Proceedings** [...]. Farmington Hills: American Concrete Institute, 2004. p. 483-496. (ACI SP-221).

CONCHA, N. C. A robust carbonation depth model in recycled aggregate concrete (RAC) using neural network. **Expert Systems with Applications**, Oxford, v. 237, p. 121650, 2024.

CONTE, W. **Previsão da vida útil de estruturas de concreto armado frente à corrosão das armaduras por carbonatação**. 2024. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Faculdade de Engenharia, Universidade Estadual Paulista "Júlio de Mesquita Filho", Bauru, 2024.

CORDOBA, G.; SPOSITO, R.; KÖBERL, M.; ZITO, S.; BEUNTNER, N.; TIRONI, A.; THIENEL, K.-C.; IRASSAR, E. F. Chloride migration and long-term natural carbonation on concretes with calcined clays: A study of calcined clays in Argentina. **Case Studies in Construction Materials**, Amsterdam, v. 17, p. e01190, 2022.

COUTO, R. A.; REIS, E. D.; CAMPOS, I. A. G.; DALIP, D. H.; POGGIALI, F. S. J.; LUDVIG, P. A systematic review of machine learning applications in carbonation depth prediction for reinforced concrete structures. **Journal of Building Pathology and Rehabilitation**, Cham, v. 11, n. 1, art. 28, 2026.

CUN, Y. L. **A theoretical framework for back-propagation**. Pittsburgh: Carnegie Mellon University, 1988. (Technical Report CMU-CS-88-148).

CUNHA, M.; HELENE, P.; LOURENÇO, M.; RIBEIRO, D.; ALMEIDA, F.; SALES, A.; SOUSA, C. **Corrosão em estruturas de concreto armado**: teoria, controle e métodos de análise. Rio de Janeiro: Elsevier, 2013.

CZARNECKI, L.; WOYCIECHOWSKI, P. Concrete carbonation as a limited process and its relevance to concrete cover thickness. **ACI Materials Journal**, Farmington Hills, v. 109, n. 3, p. 275-282, 2012.

DADOS MUNDIAIS. **Dados sobre temperatura e umidade relativa**. [S. l.], 2024. Disponível em: https://www.dadosmundiais.com/. Acesso em: 25 ago. 2024.

DAL MOLIN, D. C. C.; MASUERO, A. B.; ANDRADE, J. J. O.; POSSAN, E.; MASUERO, J. R.; MENNUCCI, M. M. Contribuição à previsão da vida útil de estruturas de concreto. *In*: SATTERTHWAIT, M.; AKASAKI, J. L. (org.). **Avaliação de desempenho de tecnologias construtivas inovadoras**: materiais e sustentabilidade. São Carlos: Scienza, 2016. p. 223-270.

DE DOMENICO, D.; MESSINA, D.; RECUPERO, A. Quality control and safety assessment of prestressed concrete bridge decks through combined field tests and numerical simulation. **Structures**, Oxford, v. 39, p. 1135-1157, 2022.

DROUET, E.; POYET, S.; LE BESCOP, P.; TORRENTI, J.-M.; BOURBON, X. Carbonation of hardened cement pastes: Influence of temperature. **Cement and Concrete Research**, Oxford, v. 115, p. 445-459, 2019.

EKOLU, S. O. Model for practical prediction of natural carbonation in reinforced concrete: Part 1-formulation. **Cement and Concrete Composites**, Oxford, v. 86, p. 40-56, 2018.

ELSALAMAWY, M.; MOHAMED, A. R.; KAMAL, E. M. The role of relative humidity and cement type on carbonation resistance of concrete. **Alexandria Engineering Journal**, Alexandria, v. 58, n. 4, p. 1257-1264, 2019.

ESPANHA. Ministerio de Fomento. **EHE-08**: Instrucción de Hormigón Estructural. Madrid: Centro de Publicaciones, Secretaría General Técnica, Ministerio de Fomento, 2010.

FAUSETT, L. **Fundamentals Of Neural Networks**. Bangalore: Pearson India, 1993.

FELIX, E. F.; BALABUCH, T. J. R.; CARRAZEDO, R.; POSSAN, E. Análise da vida útil de serviço de estruturas de concreto armado sujeitas à corrosão: uma abordagem mecânico-probabilística. *In*: CONGRESSO CONGRESO LATINOAMERICANO DE PATOLOGÍA DE LA CONSTRUCCIÓN, 15.; CONGRESO DE CONTROL DE LA CALIDAD EN LA CONSTRUCCIÓN, 17., 2019, Tuxtla Gutiérrez. **Anais** [...]. Tuxtla Gutiérrez: ALCONPAT Internacional, 2019. p. 1-14.

FELIX, E. F.; POSSAN, E. Modeling the carbonation front of concrete structures in the marine environment through ANN. **IEEE Latin America Transactions**, Piscataway, v. 16, n. 6, p. 1772-1779, 2018.

FELIX, E. F.; LAVINICKI, B. M.; BUENO, T. L. G. T.; CASTRO, T. C. C. de; CÂNDIDO, R. A. Integrating machine learning and Monte Carlo Simulation for probabilistic assessment of durability in RC structures affected by carbonation-induced corrosion. **Journal of Building Pathology and Rehabilitation**, Cham, v. 9, n. 2, art. 132, p. 1-17, 2024.

FELIX, 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**, Oxford, v. 266, p. 121050, 2021.

FELIX, E. F. **Modelagem da deformação do concreto armado devido à formação dos produtos de corrosão**. 2018. Dissertação (Mestrado em Engenharia Estrutural) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2018.

FELIX, E. F.; FALCÃO, I. S.; SANTOS, L. G. dos; CARRAZEDO, R.; POSSAN, E. A Monte Carlo-based approach to assess the reinforcement depassivation probability

of RC structures: simulation and analysis. **Buildings**, Basel, v. 13, n. 4, art. 993, p. 1-21, 2023.

FELIX, E. F.; CARRAZEDO, R. Análise probabilística da vida útil de lajes de concreto armado sujeitas à corrosão por carbonatação via simulação de Monte Carlo. **Matéria**, Rio de Janeiro, v. 26, n. 3, e13043, 2021.

FELIX, E. F.; CARRAZEDO, R.; POSSAN, E. Análise paramétrica da carbonatação em estruturas de concreto armado via Redes Neurais Artificiais. **Revista ALCONPAT**, Mérida, v. 7, n. 3, p. 302-316, 2017.

FELIX, E. F.; POSSAN, E.; CARRAZEDO, R. Analysis of training parameters in the ANN learning process to mapping the concrete carbonation depth. **Journal of Building Pathology and Rehabilitation**, Cham, v. 4, n. 1, art. 16, p. 1-13, 2019.

FERREIRA, M. B. **Estudo da carbonatação natural de concretos com diferentes adições minerais após 10 anos de exposição**. 2013. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia Civil, Universidade Federal de Goiás, Goiânia, 2013.

FERREIRA, M. F. C.; PORTELLA, P. D.; SOUZA, J. F.; DIAS, B. C.; ASSUNÇÃO, L. R. S.; OLIVEIRA, L. F. Avaliação do uso redes neurais convolucionais para identificação de lesões cariosas dentárias. *In*: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE (SBCAS), 23. , 2023, Evento On-line. **Anais** [...]. Porto Alegre: Sociedade Brasileira de Computação, 2023. p. 473-478.

FURTADO, M. I. V. **Redes Neurais Artificiais:** Uma Abordagem Para Sala de Aula. Ponta Grossa: Atena Editora, 2019.

GARCES-VARGAS, J. F.; DÍAZ-CÁRDENAS, Y.; MARTIRENA HERNANDEZ, J. F. Evaluation of the durability of concrete with the use of calcined clays and limestone in Salinas, Ecuador. **Minerals**, Basel, v. 14, n. 5, art. 460, p. 1-17, 2024.

GÉRON, A. **Mãos à obra**: aprendizado de máquina com Scikit-Learn, Keras & TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes. 2. ed. Rio de Janeiro: Alta Books, 2021.

GHANOONI-BAGHA, M.; YEKEFALLAH, M. R.; SHAYANFAR, M. A. Durability of RC structures against carbonation-induced corrosion under the impact of climate change. **KSCE Journal of Civil Engineering**, Seul, v. 24, n. 1, p. 131-142, 2020

GIULIETTI, N.; CHIARIOTTI, P.; COSOLI, G.; MOBILI, A.; PANDARESE, G.; TITTARELLI, F.; REVEL, G. M. Automated measurement system for detecting carbonation depth: Image-processing based technique applied to concrete sprayed with phenolphthalein. **Measurement**, Amsterdam, v. 175, art. 109142, p. 1-13, 2021.

GLOBAL MONITORING LABORATORY. **Trends in globally-averaged CO2 determined from NOAA Global Monitoring Laboratory measurements**. [S. l.]: NOAA, 2024. Disponível em:

https://gml.noaa.gov/ccgg/trends/global.html?doi=10.15138/9n0h-zh07. Acesso em: 29 ago. 2024.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

GOPINATH, R.; ALEXANDER, M.; BEUSHAUSEN, H. Single-parameter concrete carbonation model for varying environmental exposure conditions. **Materials and Structures**, Dordrecht, v. 58, n. 1, art. 21, p. 1-17, 2025.

HAMZEHIE, M. E.; MAZINANI, S.; DAVARDOOST, F.; MOKHTARE, A.; NAJIBI, H.; VAN DER BRUGGEN, B.; DARVISHMANESH, S. Developing a feed forward multilayer neural network model for prediction of CO2 solubility in blended aqueous amine solutions. **Journal of Natural Gas Science and Engineering**, Amsterdam, v. 21, p. 19-25, 2014.

HASSANI NIAKI, M.; PASHAIAN, M.; GHORBANZADEH AHANGARI, M. Experimental assessment of the efficiency of deep learning method in predicting the mechanical properties of polymer concretes and composites. **Journal of Building Engineering**, Oxford, v. 76, art. 107107, p. 1-15, 2023.

HAYKIN, S. **Redes Neurais: princípios e prática**. 2. ed. Hamilton, Ontário, Canadá: McMaster University, 1999.

HELENE, P. Vida útil das estruturas de concreto. *In*: CONGRESSO IBEROAMERICANO DE PATOLOGIA DAS CONSTRUÇÕES, 4.; CONGRESSO DE CONTROLE DE QUALIDADE, 6., 1997, Porto Alegre. **Anais** [...]. Porto Alegre: LEME/CPGEC/UFRGS, 1997. p. 1-30.

HELENE, P. R. L. **Contribuição ao Estudo da Corrosão em Armaduras de Concreto Armado**. São Paulo: Universidade de São Paulo, 1993.

HELENE, P. R. L.; FIGUEIREDO, A. D. de. Corrosão de armaduras para concreto armado. **Revista Engenharia Mackenzie**, São Paulo, v. 71, n. 180, p. 7-10, 1986.

HENRIQUES, G. F.; TAVARES, J. C.; TERCEIRO NETO, A. D. de L. Carbonatação natural e modelos de previsão para concretos de cimento Portland: uma revisão. **Revista Principia**, João Pessoa, v. 60, n. 1, p. 102-119, 2023.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences**, Washington, DC, v. 79, n. 8, p. 2554-2558, 1982.

HOU, Y.; MAHIEUX, P.-Y.; TURCRY, P.; LUX, J.; JOURDAIN, X.; AÏT-MOKHTAR, A. Stockpile of recycled aggregates: A carbon sink? **Construction and Building Materials**, Oxford, v. 473, art. 140979, p. 1-13, 2025.

HUANG, S.; LI, C.; ZHOU, J. Toward durability loss in buildings: Probabilistic prediction of concrete carbonation depth using machine learning and kernel density

estimation. **Journal of Building Engineering**, Oxford, v. 124, art. 115983, p. 1-16, 2026.

HUO, Z.; WANG, L.; HUANG, Y. Predicting carbonation depth of concrete using a hybrid ensemble model. **Journal of Building Engineering**, Oxford, v. 76, art. 107320, p. 1-14, 2023.

HUY VU, Q.; PHAM, G.; CHONIER, A.; BROUARD, E.; RATHNARAJAN, S.; PILLAI, R.; GETTU, R.; SANTHANAM, M.; AGUAYO, F.; FOLLIARD, K. J.; THOMAS, M. D.; MOFFAT, T.; SHI, C.; SARNOT, A. Impact of different climates on the resistance of concrete to natural carbonation. **Construction and Building Materials**, Oxford, v. 216, p. 450-467, ago. 2019.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 13823**: general principles on the design of structures for durability. Geneva: 2008.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 15686-1**: buildings and constructed assets — service life planning — part 1: general principles and framework. Geneva: 2011.

ISHIDA, T.; MAEKAWA, K. Modeling of pH profile in pore water based on mass transport and chemical equilibrium theory. **Doboku Gakkai Ronbunshu**, Tóquio, v. 2000, n. 648, p. 203–215, 2000.

JIANG, J.; WANG, D.; CHU, H.; MA, H.; LIU, Y.; GAO, Y.; SHI, J.; SUN, W. The passive film growth mechanism of new corrosion-resistant steel rebar in simulated concrete pore solution: nanometer structure and electrochemical study. **Materials**, Basel, v. 10, n. 4, art. 412, p. 1–13, 2017.

JUNG, D.; LEE, H. An analytical study on the prediction of carbonation velocity coefficient using deep learning algorithm. **International Journal of Sustainable Building Technology and Urban Development**, Seoul, v. 10, n. 4, p. 205-215, 2019.

KAZEMI, R. A hybrid artificial intelligence approach for modeling the carbonation depth of sustainable concrete containing fly ash. **Scientific Reports**, London, v. 14, n. 1, art. 13247, p. 1-21, 2024.

KELLOUCHE, Y.; BOUKHATEM, B.; GHRICI, M.; TAGNIT-HAMOU, A. Exploring the major factors affecting fly-ash concrete carbonation using artificial neural network. **Neural Computing and Applications**, London, v. 31, n. 2, p. 969-988, 2019.

KHAN, M. S. H.; NGUYEN, Q. D.; CASTEL, A. Performance of limestone calcined clay blended cement-based concrete against carbonation. **Advances in Cement Research**, London, v. 32, n. 11, p. 481-491, 2020.

KOBAYASHI, K.; UNO, Y. Influence of alkali on carbonation of concrete, part 2 - Influence of alkali in cement on rate of carbonation of concrete. **Cement and Concrete Research**, New York, v. 20, n. 4, p. 619-622, 1990.

KUMAR, M.; SINGH, S.; KIM, S.; ANAND, A.; PANDEY, S.; HASNAIN, S. M. M.; RAGAB, A. E.; DEIFALLA, A. F. A hybrid model based on convolution neural network and long short-term memory for qualitative assessment of permeable and porous concrete. **Case Studies in Construction Materials**, Amsterdam, v. 19, art. e02254, p. 1-19, 2023.

KWON, S.-J.; SONG, H.-W. Analysis of carbonation behavior in concrete using neural network algorithm and carbonation modeling. **Cement and Concrete Research**, New York, v. 40, n. 1, p. 119-127, 2010.

LAVINICKI, B. M. **Proposta de modelo ensemble de aprendizagem de máquina para a predição da profundidade de carbonatação de concretos expostos a condições naturais de degradação**. 2024. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal da Integração Latino-Americana, Foz do Iguaçu, 2024.

LAVINICKI, B. M.; CÂNDIDO, R. A.; CARRAZEDO, R.; POSSAN, E.; FELIX, E. F. Stacking-ensemble ANN model to predict the carbonation depth of concrete structures exposed to natural degradation environments. **Construction and Building Materials**, Oxford, v. 495, art. 143522, p. 1-16, 2025.

LAZAREVSKA, M.; MILANOVIC, M.; KNEZEVIC, M.; CVETKOVSKA, M.; TROMBEVA-GAVRILOVSKA, A.; SAMARDZIOSKA, T. An artificial neural network prediction model for fire resistance of composite columns. **Istraživanja i projektovanja za privredu**, Belgrado, v. 12, n. 1, p. 63-68, 2014.

LIANG, M. T.; HUANG, R.; FANG, S. A. Carbonation service life prediction of existing concrete viaduct/bridge using time-dependent reliability analysis. **Journal of Marine Science and Technology**, Taipei, v. 21, n. 1, art. 13, p. 94-104, 2013.

LIISMA, E.; SEIN, S.; JÄRVPÕLD, M. The influence of carbonation process on concrete bridges and durability in Estonian practice. **IOP Conference Series: Materials Science and Engineering**, Bristol, v. 251, art. 012072, p. 1-8, 2017.

LIU, K.; ALAM, M. S.; ZHU, J.; ZHENG, J.; CHI, L. Prediction of carbonation depth for recycled aggregate concrete using ANN hybridized with swarm intelligence algorithms. **Construction and Building Materials**, Oxford, v. 301, art. 124382, p. 1-17, 2021.

LIU, M.; CHENG, X.; ZHAO, G.; LI, X.; PAN, Y. Corrosion resistances of passive films on low-Cr steel and carbon steel in simulated concrete pore solution. **Surface and Interface Analysis**, Chichester, v. 48, n. 9, p. 981-989, 2016.

LIU, P.; CHEN, Y.; YU, Z. Effects of temperature, relative humidity and carbon dioxide concentration on concrete carbonation. **Magazine of Concrete Research**, London, v. 72, n. 18, p. 936-947, 2020.

LIU, P.; YU, Z.; CHEN, Y. Carbonation depth model and carbonated acceleration rate of concrete under different environment. **Cement and Concrete Composites**, Oxford, v. 114, art. 103736, p. 1-13, 2020.

LOLLINI, F.; REDAELLI, E. Carbonation of blended cement concretes after 12 years of natural exposure. **Construction and Building Materials**, Oxford, v. 276, art. 122122, p. 1-13, 2021.

LONDHE, S. N.; KULKARNI, P. S.; DIXIT, P. R.; SILVA, A.; NEVES, R.; DE BRITO, J. Predicting carbonation coefficient using artificial neural networks and genetic programming. **Journal of Building Engineering**, Amsterdam, v. 39, art. 102258, p. 1-13, 2021.

LU, C.; WANG, W.; LI, Q.; HAO, M.; XU, Y. Effects of micro-environmental climate on the carbonation depth and the pH value in fly ash concrete. **Journal of Cleaner Production**, Amsterdam, v. 181, p. 309-317, 2018.

LU, C.; LIU, R. Predicting carbonation depth of prestressed concrete under different stress states using artificial neural network. **Advances in Artificial Neural Systems**, New York, v. 2009, art. 308985, p. 1-7, 2009.

LUO, D.; NIU, D.; DONG, Z. Application of neural network for concrete carbonation depth prediction. *In*: INTERNATIONAL CONFERENCE ON DURABILITY OF CONCRETE STRUCTURES, 4., 2014, West Lafayette. **Proceedings** [...]. West Lafayette: Purdue University Libraries Scholarly Publishing Services, 2014. p. 288–293.

MAEKAWA, K.; ISHIDA, T.; KISHI, T. Multi-scale modeling of concrete performance. **Journal of Advanced Concrete Technology**, Tokyo, v. 1, n. 2, p. 91–126, 2003.

MAJLESI, A.; KHODADADI K., H.; DE RINCÓN, O. T.; MONTOYA, A.; MILLANO, V.; TORRES-ACOSTA, A. A.; TROCONIS DE RINCÓN, B. C. Artificial neural network model to estimate the long-term carbonation depth of concrete exposed to natural environments. **Journal of Building Engineering**, Amsterdam, v. 74, art. 106545, p. 1-17, 2023.

MALAMI, S. I.; ANWAR, F. H.; ABDULRAHMAN, S.; HARUNA, S. I.; ALI, S. I. A.; ABBA, S. I. Implementation of hybrid neuro-fuzzy and self-turning predictive model for the prediction of concrete carbonation depth: a soft computing technique. **Results in Engineering**, Amsterdam, v. 10, art. 100228, p. 1-12, 2021.

MALAMI, S. I.; VAL, D. V.; SURYANTO, B.; SALMAN, H. A.; WANG, X. H. Probabilistic approach to the sustainability assessment of reinforced concrete structures in conditions of climate change. **Structural Safety**, Amsterdam, v. 107, art. 102428, p. 1-16, 2024.

MALYSZ, G. N.; BOSSE, R. M.; DE MIRANDA, G. S. G.; SILVESTRO, L.; DAL MOLIN, D. C. C.; MASUERO, A. B. Service-life prediction of recycled coarse aggregate concrete under natural carbonation: a time-dependent reliability analysis. **Construction and Building Materials**, Oxford, v. 387, art. 131632, p. 1-11, 2023.

MARANI, A.; OYINKANOLA, T.; PANESAR, D. K. Probabilistic deep learning prediction of natural carbonation of low-carbon concrete incorporating SCMs. **Cement and Concrete Composites**, Oxford, v. 152, art. 105635, p. 1-13, 2024.

MARUYA, T.; HSU, K.; TAKEDA, H.; TANGTERMSIRIKUL, S. Numerical modeling of steel corrosion in concrete structures due to chloride ion, oxygen and water movement. **Journal of Advanced Concrete Technology**, Tokyo, v. 1, n. 2, p. 147-160, 2003.

MATLAKHOV, A. N.; MATLAKHOVA, L. A. **Corrosão e proteção dos materiais**. Jundiaí: Paco Editorial, 2021.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, Chicago, v. 5, n. 4, p. 115-133, 1943.

MEDEIROS, M. H. F.; ANDRADE, J. J. O.; HELENE, P. R. L. Durabilidade e vida útil das estruturas de concreto. *In*: ISAIA, Geraldo Cechella (org.). **Concreto**: ciência e tecnologia. 1. ed. São Paulo: IBRACON, 2011. v. 1, cap. 22, p. 773-808.

MEHTA, P. K.; MONTEIRO, P. J. M. **Concreto**: microestrutura, propriedades e materiais. 2. ed. São Paulo: IBRACON, 2014.

MEIRA, G. R.; PADARATZ, I. J.; BORBA JÚNIOR, J. C. Natural concrete carbonation: results of four years of monitoring. *In*: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 11., 2006, Florianópolis. **Anais** [...]. Porto Alegre: ANTAC, 2006. p. 3089-3098.

MELO, S. K. de. **Carbonatação natural de concretos com adições minerais ao longo de 20 anos**: retenção de água livre e o avanço da frente de carbonatação. 2022. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia Civil e Ambiental, Universidade Federal de Goiás, Goiânia, 2022.

MENNUCCI, M. M. **Influência de inibidores no comportamento de corrosão de aço CA-50 para armadura de estruturas de concreto**. 2006. Dissertação (Mestrado em Tecnologia Nuclear) – Instituto de Pesquisas Energéticas e Nucleares, Universidade de São Paulo, São Paulo, 2006.

METROPOLIS, N.; ULAM, S. The Monte Carlo method. **Journal of the American Statistical Association**, Washington, DC, v. 44, n. 247, p. 335-341, 1949.

METROPOLIS, N.; ROSENBLUTH, A. W.; ROSENBLUTH, M. N.; TELLER, A. H.; TELLER, E. Equation of state calculations by fast computing machines. **The Journal of Chemical Physics**, Melville, v. 21, n. 6, p. 1087-1092, 1953.

MINSKY, M.; PAPERT, S. **Perceptrons**: an introduction to computational geometry. Cambridge: MIT Press, 1969.

MOURA, F. A. **O uso de redes neurais artificiais na previsão de tendências no mercado de ações**. 2006. Dissertação (Mestrado em Gestão Empresarial) – Faculdade de Ciências da Administração de Pernambuco, Universidade de Pernambuco, Recife, 2006.

MSIGWA, O. J. Data Science and ML (Part 27): Convolutional Neural Networks (CNNs) in MetaTrader 5 Trading Bots — Are They Worth It? **MQL5 Articles**, [S. l.], 19 July 2024. Disponível em: https://www.mql5.com/en/articles/15259. Acesso em: 27 ago. 2025.

NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. *In*: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 27., 2010, Haifa. **Proceedings** [...]. Madison: Omnipress, 2010. p. 807-814.

NGO, V. D.; NGUYEN, N. T.; DUPRAT, F.; VU, N. T.; NGUYEN, V. P. Climatic issue in an advanced numerical modeling of concrete carbonation. **Sustainability**, Basel, v. 13, n. 11, art. 5994, p. 1-25, 2021.

NOGUEIRA, C. G.; YOSHIO, L.; ZACCHEI, E. Deterministic and probabilistic approaches for corrosion in RC structures: A direct proposed model to total service life predictions. **Case Studies in Construction Materials**, Amsterdam, v. 18, art. e01913, p. 1-19, 2023.

NUÑEZ, I.; NEHDI, M. L. Machine learning prediction of carbonation depth in recycled aggregate concrete incorporating SCMs. **Construction and Building Materials**, Amsterdam, v. 287, art. 123027, p. 1-15, 2021.

OPENAI. **ChatGPT** (versão GPT-4o). [São Francisco, CA]: OpenAI, 2025. 1 resposta gerada por IA. Prompt: “Crie uma figura da seção transversal de uma viga em concreto armado, com a região de concreto inteiro em cinza claro, com barras de aço em cinza mais escuro, sem nada escrito nem cotas indicando cobrimento. Deve haver os produtos de corrosão, na cor amarela próximo a caramelo, ferrugem ou dourado, representando o aço corroído ao redor das armaduras”. Disponível em: https://chat.openai.com. Acesso em: 11 set. 2025.

PAPADAKIS, V. G.; VAYENAS, C. G.; FARDIS, M. N. Fundamental modeling and experimental investigation of concrete carbonation. **ACI Materials Journal**, Farmington Hills, v. 88, n. 4, p. 363-373, 1991.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COUR NAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, Cambridge, v. 12, p. 2825-2830, 2011.

POSSAN, E.; ANDRADE, J. J. O.; DAL MOLIN, D. C. C.; RIBEIRO, J. L. D. Model to estimate concrete carbonation depth and service life prediction. *In*: DELGADO, J. M. P. Q. (ed.). **Hygrothermal behaviour and building pathologies**. Cham: Springer International Publishing, 2020. p. 119-153. (Building Pathology and Rehabilitation, v. 11).

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

POSSAN, E.; ANDRADE, J. J. O. Markov chains and reliability analysis for reinforced concrete structure service life. **Materials Research**, São Carlos, v. 17, n. 3, p. 593-602, 2014.

POURBAIX, M. **Atlas of electrochemical equilibria in aqueous solutions**. 2. ed. Houston: National Association of Corrosion Engineers, 1974. 644 p.

PUKL, R.; NOVÁK, D.; SAJDLOVÁ, T.; LEHKÝ, D.; ČERVENKA, J.; ČERVENKA, V. Probabilistic design of fibre concrete structures. **IOP Conference Series: Materials Science and Engineering**, Bristol, v. 246, n. 1, art. 012004, p. 1-8, 2017.

QIN, H.; WANG, J. Probabilistic prediction model of concrete carbonation depth considering the influence of multiple factors. **Structural Concrete**, Hoboken, v. 24, n. 5, p. 6209-6238, 2023.

RADOVIĆ, A.; CAREVIĆ, V.; MARINKOVIĆ, S.; PLAVŠIĆ, J.; TEŠIĆ, K. Prediction model for calculation of the limestone powder concrete carbonation depth. **Journal of Building Engineering**, Amsterdam, v. 86, art. 108776, p. 1-16, 2024.

RATHNARAJAN, S.; DHANYA, B. S.; PILLAI, R. G.; GETTU, R.; SANTHANAM, M. Carbonation model for concretes with fly ash, slag, and limestone calcined clay - using accelerated and five - year natural exposure data. **Cement and Concrete Composites**, Amsterdam, v. 126, art. 104329, p. 1-17, 2022.

REDDY, K. C.; MELAKU, N. S.; PARK, S. Thermodynamic modeling study of carbonation of Portland cement. **Materials**, Basel, v. 15, n. 14, art. 5060, p. 1-18, 2022.

RÊGO, A. S. **Predição de parâmetros de qualidade do biodiesel utilizando redes neurais artificiais**. 2013. Dissertação (Mestrado em Engenharia de Eletricidade) – Centro de Ciências Exatas e Tecnologia, Universidade Federal do Maranhão, São Luís, 2013.

RIBEIRO, A. B.; SANTOS, T.; GONÇALVES, A. Performance of concrete exposed to natural carbonation: Use of the k-value concept. **Construction and Building Materials**, Amsterdam, v. 175, p. 360-370, 2018.

RICH, E.; KNIGHT, K. **Inteligência Artificial**. 2. ed. São Paulo: Makron Books, 1993.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, DC, v. 65, n. 6, p. 386-408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, London, v. 323, n. 6088, p. 533-536, 1986.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence**: A Modern Approach. 4. ed. London: Pearson, 2020. 1166 p.

SAILLIO, M.; BAROGHEL-BOUNY, V.; PRADELLE, S.; BERTIN, M.; VINCENT, J.; D'ESPINOSE DE LACAILLERIE, J. Effect of supplementary cementitious materials on carbonation of cement pastes. **Cement and Concrete Research**, Amsterdam, v. 142, art. 106358, p. 1–16, 2021.

SCIKIT-LEARN. **MLPClassifier**. Scikit-learn developers, [2025?]. Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPClassifier.html. Acesso em: 15 dez. 2025.

SHAFABAKHSH, G.; TALEBSAFA, M.; MOTAMEDI, M.; BADROODI, S. K. Analytical evaluation of load movement on flexible pavement and selection of optimum neural network algorithm. **KSCE Journal of Civil Engineering**, Seoul, v. 19, n. 6, p. 1738-1746, 2015.

SHAH, V.; BISHNOI, S. Carbonation resistance of cements containing supplementary cementitious materials and its relation to various parameters of concrete. **Construction and Building Materials**, Amsterdam, v. 178, p. 219-232, 2018.

SHODJA, H. M.; KIANI, K.; HASHEMIAN, A. A model for the evolution of concrete deterioration due to reinforcement corrosion. **Mathematical and Computer Modelling**, Oxford, v. 52, n. 9-10, p. 1403-1422, 2010.

SISOMPHON, K.; FRANKE, L. Carbonation rates of concretes containing high volume of pozzolanic materials. **Cement and Concrete Research**, Amsterdam, v. 37, n. 12, p. 1647-1653, 2007.

SMOLCZYK, H. G. Physical and chemical phenomena of carbonation. *In*: RILEM INTERNATIONAL SYMPOSIUM ON CARBONATION OF CONCRETE, 1976, Fulmer Grange. **Proceedings** [...]. Slough: Cement and Concrete Association, 1976. p. 1-10. (Theme 1, Paper 1.1).

SOMODÍKOVÁ, M.; SLOWIK, O.; LEHKÝ, D.; DOLEŽEL, J. Deterioration-based probabilistic assessment of design resistance of railway bridge. **Bridge Safety, Maintenance, Management, Life-Cycle, Resilience and Sustainability**: proceedings [...]. London: CRC Press/Balkema, 2023. p. 339-347.

ŠOMODÍKOVÁ, M.; LEHKÝ, D.; DOLEŽEL, J.; NOVÁK, D. Modeling of degradation processes in concrete: Probabilistic lifetime and load-bearing capacity assessment of existing reinforced concrete bridges. **Engineering Structures**, Oxford, v. 119, p. 49-60, 2016.

SORENSEN, J. D. **Notes in structural reliability theory and risk analysis**. Aalborg: Aalborg University, 2004. 201 p. (Lecture Notes in Structural Reliability Theory and Risk Analysis).

SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: A simple way to prevent neural networks from

overfitting. **Journal of Machine Learning Research**, Cambridge, MA, v. 15, n. 56, p. 1929-1958, 2014.

STEWART, M. G.; ROSOWSKY, D. V. Time-dependent reliability of deteriorating reinforced concrete bridge decks. **Structural Safety**, Amsterdam, v. 20, n. 1, p. 91-109, 1998.

STREHBLOW, H.; MARCUS, P. Fundamentals of Corrosion. *In*: MARCUS, Philippe (ed.). **Corrosion Mechanisms in Theory and Practice**. 3. ed. Boca Raton: CRC Press, 2011. cap. 1, p. 1-98.

SUN, B.; XIAO, R. C.; RUAN, W. D.; WANG, P. Bo. Corrosion-induced cracking fragility of RC bridge with improved concrete carbonation and steel reinforcement corrosion models. **Engineering Structures**, Oxford, v. 208, art. 110313, p. 1-15, 2020.

TA, V.; BONNET, S.; SENGA K., T.; VENTURA, A. A new meta-model to calculate carbonation front depth within concrete structures. **Construction and Building Materials**, Amsterdam, v. 129, p. 172-181, 2016.

TAFFESE, W. Z.; SISTONEN, E. Service life prediction of repaired structures using concrete recasting method: state-of-the-art. **Procedia Engineering**, Amsterdam, v. 57, p. 1138-1144, 2013.

TAFFESE, W. Z.; SISTONEN, E.; PUTTONEN, J. CaPrM: carbonation prediction model for reinforced concrete using machine learning methods. **Construction and Building Materials**, Amsterdam, v. 100, p. 70-82, 2015.

TEODORO, C. P.; CARRAZEDO, R. Nonlinear numerical analysis of corroded reinforced concrete structures using laminated frame elements. **Materials and Structures**, Dordrecht, v. 57, n. 5, art. 109, p. 1-17, 2024.

TEODORO, C. P.; CARRAZEDO, R. Impact of carbonation on reinforced concrete structures, considering the increase of CO2 due to climate change in Brazil. **Revista IBRACON de Estruturas e Materiais**, São Paulo, v. 18, n. 1, e18106, 2025.

THIERY, M.; CREMONA, C.; BAROGHEL-BOUNY, V. Application of the reliability theory to the assessment of carbonation-induced corrosion risk of rebars. **European Journal of Environmental and Civil Engineering**, Paris, v. 16, n. 3-4, p. 273-287, 2012.

THOMAS, G. T.; WEIR, M.; HASS, J. **Cálculo**. 12. ed. Londres: Pearson, 2012. v. 1

THOMAS, M. D. A.; MATTHEWS, J. D. Carbonation of fly ash concrete. **Magazine of Concrete Research**, London, v. 44, n. 160, p. 217-228, 1992.

TONG, L.; CAI, Y.; LIU, Q. Carbonation modelling of hardened cementitious materials considering pore structure characteristics: A review. **Journal of Building Engineering**, Amsterdam, v. 96, art. 110547, p. 1–21, 2024.

TORRES-ACOSTA, A. A.; BORGES, P. C.; RINCÓN, O. T.; PÉREZ, B. M.; MOLINA, W. M.; GUZMÁN, E. A.; REYES, C. B.; LÓPEZ, T. P.; PERRUSQUÍA, C. A.; SÁNCHEZ, S. E. C.; QUIROZ, J. T. P.; MIGUEL, A. L.; VAZQUEZ, E. L.; CRUZ, C. E. J.; RODRÍGUEZ, J. A.; GÓMEZ, F. J. R.; ZAMORA, M. A. B.; RUIZ, L. L.; BANDALA, E. M.; MENDOZA, D. N.; HERRERA, J. A. M. Concrete carbonation in tropical urban and urban/marine environments after 20 years of natural exposure. **Construction and Building Materials**, Amsterdam, v. 450, art. 138511, p. 1-17, 2024.

TUKEY, J. **Exploratory Data Analysis**. London: Addison-Wesley, 1977.

TUUTTI, K. **Corrosion of steel in concrete**. Stockholm: Swedish Cement and Concrete Research Institute, 1982.

ULIANO, V. G. **Confiabilidade estrutural de vigas de concreto armado submetidas à corrosão das armaduras induzida por íons cloreto**. 2018. Dissertação (Mestrado em Engenharia Civil) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2018.

UWANUAKWA, I. D. Deep learning modelling and generalisation of carbonation depth in fly ash blended concrete. **Arabian Journal for Science and Engineering**, Heidelberg, v. 46, n. 5, p. 4731-4746, 2021.

VERBECK, G. Carbonation of hydrated Portland cement. *In*: **CEMENT AND CONCRETE**. West Conshohocken: ASTM International, 1958. p. 17–36. (Special Technical Publication, 205).

VESIKARI, E. **Service life of concrete structures with regard to corrosion of reinforcement**. Espoo: Technical Research Centre of Finland, 1988. (VTT Research Notes, 830).

VICARI, R. M. **Tendências em inteligência artificial na educação no período de 2017 a 2030**. Brasília, DF: UNESCO, 2018.

VIEIRA, R. M.; MEIRA, G. R.; MARQUES, V. M.; PADILHA, J. M. Natural e accelerated concrete carbonation. *In*: CONGRESSO BRASILEIRO DO CONCRETO, 51., 2009, Curitiba. **Anais** [...]. Curitiba: IBRACON, 2009. p. 1-15.

VON GREVE-DIERFELD, S.; LOTHENBACH, B.; VOLLPRACHT, A.; WU, B.; HUET, B.; ANDRADE, C.; MEDINA, C.; THIEL, C.; GRUYAERT, E.; VANOUTRIVE, H.; SAÉZ DEL BOSQUE, I. F.; IGNJATOVIC, I.; ELSEN, J.; PROVIS, J. L.; SCRIVENER, K.; THIENEL, K.; SIDERIS, K.; ZAJAC, M.; ALDERETE, N.; CIZER, Ö.; VAN DEN HEEDE, P.; HOOTON, R. D.; KAMALI-BERNARD, S.; BERNAL, S. A.; ZHAO, Z.; SHI, Z.; DE BELIE, N. Understanding the carbonation of concrete with supplementary cementitious materials: a critical review by RILEM TC 281-CCC. **Materials and Structures**, Cham, v. 53, n. 6, art. 136, p. 1-34, 2020.

WANG, J.; ZHENG, W.; ZHAO, Y.; ZHANG, X. Time-varying reliability evaluation of concrete based on carbonation depth. **Applied Sciences**, Basel, v. 9, n. 23, art. 5116, p. 1-17, 2019.

WANG, M.; DU, M.; ZHUANG, X.; LV, H.; WANG, C.; ZHOU, S. Multi-objective optimization of ultra-high performance concrete based on life-cycle assessment and machine learning methods. **Frontiers of Structural and Civil Engineering**, Heidelberg, v. 19, n. 1, p. 143-161, 2025.

WANG, Q.; YANG, J.; CHEN, H. Long-term properties of concrete containing limestone powder. **Materials and Structures**, Cham, v. 50, n. 3, art. 168, p. 1-11, 2017.

WANG, X.; YANG, Q.; PENG, X.; QIN, F. A review of concrete carbonation depth evaluation models. **Coatings**, Basel, v. 14, n. 4, art. 386, p. 1-28, 2024.

WEI, Y.; CHEN, P.; CAO, S.; WANG, H.; LIU, Y.; WANG, Z.; ZHAO, W. Prediction of carbonation depth for concrete containing mineral admixtures based on machine learning. **Arabian Journal for Science and Engineering**, Heidelberg, v. 48, n. 10, p. 13211-13225, 2023.

WITKOWSKI, H.; KONIORCZYK, M. The influence of pozzolanic additives on the carbonation rate and Life Cycle Inventory of concrete. **Construction and Building Materials**, Amsterdam, v. 254, art. 119301, p. 1-11, 2020.

WU, D.; LIU, Y.; YIN, Y.; DENG, Z.; LIU, Z. Neural network method based on concrete carbonation depth prediction. **IOP Conference Series: Earth and Environmental Science**, Bristol, v. 825, n. 1, art. 012020, p. 1-8, 2021.

XI-ZHAO, W.; QING-YAN, S.; QING, M.; JUN-HAI, Z. Architecture selection for networks trained with extreme learning machine using localized generalization error model. **Neurocomputing**, Amsterdam, v. 102, p. 3-9, 2013.

XU, Z.; ZHANG, Z.; HUANG, J.; YU, K.; ZHONG, G.; CHEN, F.; CHEN, X.; YANG, W. Effects of temperature, humidity and CO2 concentration on carbonation of cement-based materials: A review. **Construction and Building Materials**, Amsterdam, v. 346, art. 128399, p. 1-17, 2022.

YOUNSI, A.; TURCRY, P.; AÏT-MOKHTAR, A. Quantification of CO2 uptake of concretes with mineral additions after 10-year natural carbonation. **Journal of Cleaner Production**, Amsterdam, v. 349, art. 131362, p. 1-11, 2022.

YU, B.; FANG, Z.; GAO, Y.; YANG, W.; WANG, C.; ZHOU, S. Carbonation of supersulfated cement concrete after 8 years of natural exposure. **Cement and Concrete Composites**, Amsterdam, v. 142, art. 105165, p. 1-13, 2023.

YU, M.; BAO, H.; YE, J.; CHI, Y. The effect of random porosity field on supercritical carbonation of cement-based materials. **Construction and Building Materials**, Amsterdam, v. 146, p. 144-155, 2017.

ZACCHEI, E.; NOGUEIRA, C. G. Numerical solutions for chloride diffusion fluctuation in RC elements from corrosion probability assessments. **Buildings**, Basel, v. 12, n. 8, art. 1211, p. 1-25, 2022.

ZHANG, B.; SENOUCI, A.; MEDVEDEV, V.; PUSTOVGAR, A. A review of concrete carbonation and approaches to its research under irradiation. **Buildings**, Basel, v. 13, n. 8, art. 1998, p. 1-25, 2023.

ZHANG, Z.; WANG, Q.; CHEN, H. Properties of high-volume limestone powder concrete under standard curing and steam-curing conditions. **Powder Technology**, Lausanne, v. 301, p. 16-25, 2016.

ZUCCA, M.; LANDI, F.; PUPPIO, M. L.; MISTRETTA, F.; FORMICHI, P.; CROCE, P. Climate change impact on corrosion of reinforced concrete bridges and their seismic performance. **Applied Sciences**, Basel, v. 14, n. 1, art. 60, p. 1-21, 2023.

DADOS CURRICULARES

IDENTIFICAÇÃO	
	TOBIAS LOMBARDI GARCIA TIBURCIO BUENO 01/07/2001
Nacionalidade	Brasileira
Nome em citações bibliográficas:	Bueno, Tobias Lombardi Garcia Tiburcio Bueno, T. L. G. T.
Currículo Lattes	http://lattes.cnpq.br/3608994855424715
ORCID	https://orcid.org/0000-0002-5885-0994
FORMAÇÃO ACADÊMICA	
02/2024	Bacharel em Engenharia Civil pela Faculdade de Engenharia e Ciências de Guaratinguetá (FEG / UNESP)
PRODUÇÃO BIBLIOGRÁFICA	
FELIX, E. F.; LAVINICKI, B. M.; BUENO, T. L. G. T.; DE CASTRO, T. C.C.; CÂNDIDO, R. A. Integrating machine learning and Monte Carlo Simulation for probabilistic assessment of durability in RC structures affected by carbonation-induced corrosion. **Journal of Building Pathology and Rehabilitation**, v. 9, n. 2, p. 1–17, 2024.	
PARTICIPAÇÃO EM EVENTOS CIENTÍFICOS	
65° Congresso Brasileiro do Concreto, 2024 (Maceió). Avaliação do Impacto das Mudanças Climáticas da Vida Útil de Projeto de Estruturas de Concreto sob Corrosão por Carbonatação. 2024. XXI International Conference on Building Pathology and Constructions Repair, 2025 (Brasília). Data-Driven Prediction of Carbonation Depth in Concrete Using Deep Learning. 2025.	