



Ministério da Educação
Universidade Federal da Integração Latino-Americana
Instituto de Tecnologia, Infraestrutura e Território
Centro Interdisciplinar de Tecnologia e Infraestrutura

**DESENVOLVIMENTO DE SOFTWARE PARA A ESTIMATIVA DA
PROFUNDIDADE DE CARBONATAÇÃO, VIDA ÚTIL E CAPTURA DE
CO₂ DE ESTRUTURAS DE CONCRETO EMPREGANDO RNA'S**

EMERSON FELIPE FELIX

Foz do Iguaçu, PR
Novembro de 2015



Ministério da Educação
Universidade Federal da Integração Latino-Americana
Instituto de Tecnologia, Infraestrutura e Território
Centro Interdisciplinar de Tecnologia e Infraestrutura

**DESENVOLVIMENTO DE SOFTWARE PARA A ESTIMATIVA DA
PROFUNDIDADE DE CARBONATAÇÃO, VIDA ÚTIL E CAPTURA DE
CO₂ DE ESTRUTURAS DE CONCRETO EMPREGANDO RNA'S**

EMERSON FELIPE FELIX

Trabalho de Conclusão de Curso apresentado a Banca Examinadora do Curso de Engenharia Civil de Infraestrutura da UNILA, como parte dos requisitos para obtenção do Grau de Bacharel em Engenharia Civil.

Orientadora: Prof^a. Dr^a. Edna Possan

Coorientadora: Prof^a. Dr^a. Gláucia Maria Dalfré

Foz do Iguaçu, PR

Novembro de 2015

DEDICATÓRIA

Mãezinha, não existem maneiras de lhe agradecer
Graças a ti, o mundo me viu nascer
E graças a você, me tornei quem sou
E sem saber o que dizer
Afirmo que te amo
Neste e em qualquer outro plano

AGRADECIMENTOS

A minha mãe, meu talismã, pelo amor, amizade, pelos puxões de orelha, orações e dedicação interminável.

A minha avó, pelo amor, amizade, dedicação e zelo.

Aos familiares próximos, pelo constante incentivo.

A Rosemary Lopes, irmã de outras vidas, em quem me espelho e na qual sempre encontrarei inspiração.

Ao Luciano, meu porto seguro, meu suporte e minha fonte de alegrias.

A Daniely, minha estrela guia, pela sua constante amizade e carinho.

Ao Luís Fernando, pelo carinho, conforto e imensurável alegria.

A Camila de Paula, pelo carinho, pela confiança a mim depositada e pelos intermináveis momentos de felicidades.

A Amanda, pelo carinho, pelas risadas, pelas palavras de conforto, pelas nossas aventuras de crianças e pela sua coragem de viver a vida.

A Rubia, pela amizade e carinho, além das palavras de incentivo.

A Dra. Edna Possan, pela amizade, carinho, aprendizado, atenção, confiança, alegrias, e pela constante fonte de inspiração.

A Dra. Glaucia, pela amizade, carinho, ensino, incentivo e confiança a mim depositada.

Ao Dr. Pedro Konzen, pela amizade, ensino e pelas oportunidades à mim oferecidas.

Aos Drs. Rodrigo Bloot e Juan, pelo aprendizado e as constantes palavras de incentivo.

Aos queridos professores, Rodrigo Lameiras, Helenice Sacht, Cesar Winter, Jiam Frigo, Herlander Mata-Lima, Ulises Bobadilla, Makerli Galvan, Helena Graf, Mara Rubia, Ricardo Souza e Aref Kzam, pela amizade, carinho, dedicação e por todo o aprendizado transmitido, sem o qual a realização do presente trabalho não seria possível.

As companheiras de pesquisa, Thays Feliciano, Bianca Dezen e Isabela Oliveira, pelo carinho, atenção, força, por me aguentarem diariamente e acreditarem em mim.

Ao Pablo Flores, pela amizade e suporte na criação do CARBEM.

A equipe do Laboratório de Tecnologia do Concreto de Itaipu (LTCl), em especial ao Nilo, Mauricio e Fabio, pela atenção e constante suporte.

Ao CEASB, FPTI, UNILA e CAPES, pelo fomento às pesquisas que deram origem ao presente trabalho.

A CAPES, pela bolsa do CsF possibilitando aprofundar meus conhecimentos na Universidade Politecnico di Torino na Itália.

Por fim, a DEUS, minha força e meu guia, sem o qual nada existiria.

LISTA DE FIGURAS

Figura 2.1: Avanço da carbonatação no concreto ao longo do tempo	18
Figura 2.2: Fatores que influenciam na carbonatação do concreto	19
Figura 2.3: Variação da velocidade de carbonatação com a umidade	20
Figura 2.4: Representação esquemática da carbonatação, levando em conta poros secos, parcialmente preenchidos com água e saturados (a, b, e c)	21
Figura 2.5: Carbonatação do concreto x captura de CO ₂	24
Figura 2.6: Conceituação de vida útil das estruturas de concreto com relação à corrosão das armaduras	26
Figura 3.1: Modelo de um neurônio artificial	33
Figura 3.2: Representação do modelo simplificado de um neurônio biológico	34
Figura 3.3: Função linear.....	35
Figura 3.4: Função Degrau	35
Figura 3.5: Função sigmoide tangente hiperbólica	35
Figura 3.6: Função sigmoide logística	35
Figura 3.7: Arquitetura de redes com uma (a) ou mais (b e c) camadas	37
Figura 3.8: Rede com alimentação <i>Feedforward</i>	37
Figura 3.9: Rede com alimentação <i>Feedback</i>	37
Figura 3.10: Processo de modelagem com RNA's	38
Figura 3.11: Aprendizado supervisionado.....	39
Figura 3.12: Aprendizado não supervisionado.....	39
Figura 3.13: Algoritmo de treinamento do <i>Perceptron</i>	41
Figura 3.14: Modelo de uma rede <i>MLP</i>	42
Figura 3.15: Algoritmo de treinamento <i>Backpropagation</i>	42
Figura 4.1: Fluxograma das fases de trabalho.....	44
Figura 4.2: Proporção dos dados utilizados em cada fase da modelagem	46
Figura 4.3: Topologias básicas das RNA's implementadas	46
Figura 4.4: Captura de tela de treinamento usando o <i>PROJECT-YAPY</i>	47

Figura 4.5: <i>Brainstorming</i> para a criação da interface gráfica do CARBEM	50
Figura 5.1: Rede [4-7-5-1]	51
Figura 5.2: Rede [5-4-3-1]	51
Figura 5.3 c: Rede [7-4-1]	51
Figura 5.4: Correlação no treinamento	52
Figura 5.5: Correlação na validação	52
Figura 5.6: Correlação no treinamento	52
Figura 5.7: Correlação na validação	52
Figura 5.8: Correlação no treinamento	53
Figura 5.9: Correlação na validação	53
Figura 5.10: Resíduos da diferença entre a profundidade real e a calculada pelo modelo .	54
Figura 5.11: Estimativa da profundidade de carbonatação do concreto – estrutura I.....	55
Figura 5.12: Estimativa da profundidade de carbonatação do concreto – estrutura II.....	55
Figura 5.13: Estimativa da profundidade de carbonatação do concreto – estrutura III.....	55
Figura 5.14: Estimativa da profundidade de carbonatação do concreto – estrutura IV	56
Figura 5.15: Estimativa da profundidade de carbonatação do concreto – estrutura V	56
Figura 5.16: Estimativa da profundidade de carbonatação do concreto – estrutura VI	56
Figura 5.17: Superfície de profundidade de concreto com CP II E	57
Figura 5.18: Superfície de profundidade de concreto com CP II F.....	57
Figura 5.19: Superfície de profundidade de concreto com CP II Z	57
Figura 5.20: Superfície de profundidade de concreto com CP III.....	57
Figura 5.21: Superfície de profundidade de concreto com CP IV	57
Figura 5.22: Superfície de profundidade de concreto com CP V	57
Figura 6.1: Fluxograma da metodologia para obtenção dos outros modelos	58
Figura 6.2: Desenvolvimento da tela referente a estimativa da profundidade em linguagem JAVA.....	59
Figura 6.3: Desenvolvimento da tela referente a estimativa da profundidade (interface)	59
Figura 6.4: Tela principal do CARBEM	60
Figura 6.5: Tela da estimativa da profundidade de carbonatação.....	60

Figura 6.6: Características da viga de concreto.....	61
Figura 6.7: Resultados do CARBEM para a profundidade de carbonatação.....	61
Figura 6.8: Tela da estimativa da VUP	62
Figura 6.9: Resultados do CARBEM para a vida útil de projeto.....	62
Figura 6.10: Tela da estimativa do cobrimento mínimo	63
Figura 6.11: Resultados do CARBEM para determinação do cobrimento da armadura.....	63
Figura 6.12: Tela da estimativa da captura de CO ₂	64
Figura 6.13: Resultados do CARBEM para determinação da captura de CO ₂	64
Figura 6.13: Determinação da quantidade de CO ₂ capturado	65

LISTA DE TABELAS

Tabela 2.1: Classificação dos ambientes em função da concentração de CO ₂	22
Tabela 2.2: Coeficientes do modelo, (a) coeficiente dependente da umidade, (b) coeficiente da taxa de CO ₂ presente no ar e (c) parâmetros dependentes do tipo de aglomerante	29
Tabela 2.3: Coeficientes do modelo, (a) coeficiente do ar incorporado, (b) coeficiente de ambiente e (c) parâmetros dependentes do tipo de aglomerante.	29
Tabela 2.4: Coeficientes do modelo em função, (a) das características do concreto e das condições ambientais (b) das condições ambientais	31
Tabela 4.1: Domínio das variáveis do conjunto de dados	45
Tabela 5.1: Melhores RNA's em função do E _{max} e da sua tipologia	51
Tabela 5.2: Resultados da validação com os melhores modelos	54

LISTA DE QUADROS

Quadro 5.1: Estrutura I	55
Quadro 5.2: Estrutura II	55
Quadro 5.3: Estrutura III	55
Quadro 5.4: Estrutura IV.....	56
Quadro 5.5: Estrutura V.....	56
Quadro 5.6: Estrutura VI.....	56
Quadro 6.1: Características da viga de concreto	61
Quadro 6.2: Profundidade	61

LISTA DE EQUAÇÕES

Equação 1	19
Equação 2	19
Equação 3	19
Equação 4	24
Equação 5	27
Equação 6	27
Equação 7	28
Equação 8	28
Equação 9	29
Equação 10	30
Equação 11	34
Equação 12	34
Equação 13	47
Equação 14	48
Equação 15	48
Equação 16	48

RESUMO

É crescente a busca por modelos matemáticos capazes de estimar e prever a frente de carbonatação do concreto, uma vez que a profundidade carbonatada está diretamente relacionada à vida útil das estruturas. Porém, devido a complexidade, ao número de variáveis envolvidas e a não-linearidade do problema, a determinação destes modelos torna-se uma tarefa árdua. Para contornar estas dificuldades, utilizam-se atualmente ferramentas computacionais que possibilitam a modelagem de problemas de forma otimizada, como é o caso das Redes Neurais Artificiais (RNA's). Estas redes apresentam características semelhantes às biológicas, possibilitando o reconhecimento de padrões e comportamentos de forma eficiente, impulsionando sua utilização para modelar a profundidade carbonatada. Neste trabalho, visando criar um software para estudos de durabilidade e vida útil das estruturas de concreto sujeitas à carbonatação, modelou-se a degradação do concreto empregando RNA's do tipo *MultiLayer Perceptron* implementadas em linguagem orientada à objetos C++. Ao todo foram implementadas 1200 redes com características distintas, das quais selecionou-se a que apresentava o melhor comportamento, obtendo correlação de 0,98, erro máximo de 3,8 mm e erro médio abaixo de 1,0 mm. Por meio de comparações com modelos da literatura, verificou-se a potencialidade da rede criada, possibilitando utilizá-la na geração de modelos secundários, para estimativa da vida útil de projeto, cobertura mínima da armadura e captura de CO₂ devido à carbonatação do concreto, acoplados em um software denominado CARBEM. Concebido em linguagem JAVA, o software possui interface gráfica agradável facilitando a interação máquina-usuário. Os resultados encontrados apontam a grande aplicabilidade das RNA's para modelar a frente de carbonatação do concreto, e que o CARBEM se apresenta como uma ferramenta potencial para a determinação da profundidade de carbonatação, vida útil de projeto, cobertura da armadura e captura de CO₂, contribuindo para o estudo da durabilidade, sustentabilidade e vida útil das estruturas de concreto.

Palavras-chave: Captura de CO₂; Modelagem; Redes Neurais Artificiais; Vida Útil de Projeto; Software.

ABSTRACT

The seek for mathematical models capable of estimating and predicting the front of concrete carbonation has been increased due to the carbonation deepness, which is directly linked to the life cycle of the structures. However, some factors, such as the complexity, the number of involved variables, and the lack of linearity of the problem are contributors to make the determination of these models difficult. In order to soften these difficulties, computational tools have been developed, enabling the optimization of problems modeling. One of these tools are the Artificial Neural Networks (ANN's) that have similar characteristics to biological neural networks, efficiently helping in the recognition of patterns and behaviors, making these networks ideal for the modeling of the carbonatation deepness. Thinking about developing a software to study the durability and the life cycle of the concrete structures that are subjected to the carbonatation process, the degradation of the concrete was modeled utilizing *Multilayer Perceptron* ANN's, implemented in C++ object-oriented language. Altogether, 1200 neural networks with distinct characteristics were implemented, which was selected the one with best behavior. The chosen network presented a correlation of 0.98, maximum error of 3.8 mm, and medium error below 1.0 mm. Comparisons with literature models show the potential of the developed network, that is ready to be used to generate secondary models, estimate the life cycle of projects, predict the minimum covering of the reinforcement, and estimate the CO₂ capture due to concrete carbonation. These functions are all found in a coupled software called CARBEM. Besides this, the software has a neat graphic interface that facilitate its utilization, being totally developed in JAVA language. It is worth noting that the results show the great applicability of the RNAs in the modeling of the front of concrete carbonation, and also the utilization to determine the carbonation deepness, the project life cycle, and the CO₂ capture. Therefore, the CARBEM software contributes to the study of the durability of concrete structures, as well as the sustainability of the projects.

Keywords: CO₂ Uptake; Modeling; Artificial Neural Networks; Project Life Cycle; Software.

SUMÁRIO

LISTA DE FIGURAS.....	v
LISTA DE TABELAS	viii
LISTA DE QUADROS	ix
LISTA DE EQUAÇÕES	x
RESUMO	xi
ABSTRACT	xii
1.0 Introdução	15
1.1 Motivação e Justificativa do Trabalho.....	15
1.2 Objetivos	16
1.2.1 Objetivo Geral	16
1.2.2 Objetivos Específicos	16
1.3 Estrutura do Trabalho	17
2.0 Carbonatação do Concreto, Vida Útil de Projeto e Captura de CO ₂	18
2.1 Fatores que Influenciam na Carbonatação	19
2.1.1 Umidade Relativa do ar	20
2.1.2 Incidências de Chuvas.....	21
2.1.3 Concentração de CO ₂	22
2.1.4 Outros Fatores Externos	22
2.1.5 Composição do Concreto	22
2.1.6 Condições de Execução	23
2.1.7 Resistência à Compressão e Relação Água/Cimento (a/c)	23
2.2 Captura de CO ₂	24
2.3 Vida Útil	25
2.4 Modelos de Estimativa da Profundidade de Carbonatação	27
2.4.1 Modelo de SMOLCZYK	27
2.4.2 Modelo de VESIKARI	28

2.4.3 Modelo de BOB e AFFANA	28
2.4.4 Modelo de EHE	29
2.4.5 Modelo de POSSAN.....	30
3.0 Redes Neurais Artificiais	32
3.1 Notas Históricas	32
3.2 Modelo das Redes Artificiais	32
3.2.1 Função de Ativação	34
3.2.2 Arquitetura das Redes Artificiais	36
3.3 Métodos de Aprendizagem	38
3.3.1 Aprendizado Supervisionado	38
3.3.2 Aprendizado Não-Supervisionada	39
3.4 Modelos e Algoritmos de Treinamento	40
3.4.1 Redes Perceptron e o Algoritmo de Treinamento	40
3.4.2 Redes MultiLayer Perceptron (MLP) e o Algoritmo de Treinamento	41
3.5 Aplicações na Engenharia e nas Ciências Exatas	43
4.0 Metodologia	44
4.1 Banco de Dados – Etapa (i).....	45
4.2 Implementação e Treinamento das RNA's – Etapa (ii)	46
4.3 Análises Estatísticas e Seleção do Melhor Modelo – Etapa (iii).....	48
4.4 Teste do Modelo – Etapa (iv).....	48
4.5 Determinação da VUP e da Captura de CO ₂ – Etapa (v).....	49
4.6 Implementação Final – Etapa (vi)	49
5.0 Análise dos Modelos	51
6.0 Software CARBEM	58
6.1 Implementação.....	58
6.2 Tutorial do CARBEM	60
7.0 Conclusões e Sugestões Para Trabalhos Futuros	66
Referências Bibliográficas	69

1 INTRODUÇÃO

1.1 Motivação e Justificativa do Trabalho

O concreto armado, apesar de ser uma associação inteligente entre diferentes materiais (rocha, aglomerante, agregados e aço), devido à ação de diferentes mecanismos de degradação está sujeito à deterioração, principalmente à corrosão das armaduras, que além de prejuízos estéticos, pode levar a estrutura ao colapso. No Brasil, Carmona & Marega (1988), Dal Molin (1988), Andrade (1992) e Aranha (1994), verificaram a existência de um índice que varia entre 14 e 64% da ocorrência de corrosão, sendo esta a deterioração mais frequente do concreto armado.

Neste sentido, a durabilidade das estruturas de concreto (armado ou não) é uma de suas principais propriedades, pois a capacidade de suportar as ações para as quais foram projetadas durante a vida útil de projeto (VUP) é dependente da durabilidade. O ingresso de CO₂ através do concreto é um dos principais causadores da corrosão das armaduras, uma vez que a penetração do dióxido de carbono reduz o pH do concreto (de 12,5 a 9) destruindo a camada passivadora que envolve a armadura a deixando suscetível à degradação com o tempo. Segundo Possan (2010), com o crescente desenvolvimento das cidades, a tendência mundial de aumento das emissões de CO₂ na atmosfera, traz consequências diretas às estruturas de concreto em ambiente urbano. Isso porque a profundidade de carbonatação aumenta com a elevação do CO₂ no meio ambiente, afetando o ciclo de vida das estruturas e reduzindo a durabilidade das mesmas.

Existem hoje na literatura diversos trabalhos que visam determinar e explicar os fatores relacionados à carbonatação e também obter modelos matemáticos para a previsão da frente de carbonatação (HAMADA, 1968; SMOLCZIK, 1969; HELENE, 1981; TUUTTI, 1982; PAPADAKIS, 1991; ANDRADE, 1992; HYVERT, 2009; POSSAN, 2010). Porém, muitos dos modelos destinados à determinação da profundidade carbonatada são baseados em equações simplificadas limitando o seu domínio de aplicação, enquanto que os modelos mais sofisticados, com maiores domínios de aplicabilidade, apresentam dificuldades quanto a obtenção das variáveis de entrada. Por este motivo, modelos matemáticos que possuem dados de entrada de fácil obtenção (baixo custo de aquisição) e que contemplem um amplo domínio de aplicação apresentam uma grande procura por pesquisadores, além de contribuir significativamente para a difusão da modelagem da degradação do concreto por carbonatação.

O interesse na área levou vários pesquisadores a desenvolverem modelos do comportamento ou de previsão de vida útil, que em geral, apresentam duas abordagens,

uma determinística e a outra probabilística (POSSAN, 2010). A primeira oferece uma estimativa máxima ou média da degradação, já a segunda considera a existência da probabilidade da ocorrência dos principais fatores que interferem na vida útil. Grande parte destes modelos representam a penetração dos agentes agressivos no interior do concreto, principalmente da penetração do dióxido de carbono (CO_2) e de íons cloreto (Cl^-).

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

É por tais motivos que a utilização de RNA's para a solução de alguns problemas é altamente recomendada, já que a forma como são representados internamente pela rede e pelo processamento natural em paralelo inerente à arquitetura dessas RNA's desenvolve a possibilidade de obter um desempenho superior ao dos modelos não convencionais.

Frente ao exposto, a utilização de RNA's para modelar a profundidade de carbonatação do concreto pode agregar resultados positivos nos estudos referentes à degradação das estruturas de concreto, e conseqüentemente da determinação da vida útil destas estruturas, sendo objeto deste estudo.

1.2 Objetivos

1.2.1 Objetivo Geral

Desenvolver um software para a determinação da profundidade de carbonatação, da vida útil de projeto e da captura de CO_2 de estruturas de concreto.

1.2.1 Objetivos Específicos

- Construir, treinar e validar modelos com RNA's, para determinar a profundidade de carbonatação do concreto ao longo do tempo;
- Estudar a relação e a importância de cada variável de entrada (tipo de cimento, umidade, ambiente de exposição, resistência à compressão, exposição ao CO_2 , teor de adições e relação água/cimento) na obtenção da profundidade de carbonatação do concreto ao longo do tempo;
- Analisar e identificar, dentre os modelos determinados o que apresenta a maior capacidade de prever a frente de carbonatação do concreto;

- A partir do modelo de carbonatação, propor modelos para a previsão da vida útil de projeto (VUP) e para a estimativa da captura de CO₂ durante o ciclo de vida de estruturas de concreto sujeitas à ação de CO₂;
- Implementar um sistema computacional para a previsão da profundidade de carbonatação, da VUP e da captura de CO₂;

1.3 Estrutura do Trabalho

O trabalho inicia com uma breve motivação do estudo, um resumo do cenário geral do tema no Brasil e no exterior e os objetivos a serem alcançados.

O segundo capítulo apresenta os principais conceitos teóricos inerentes à pesquisa, de forma a garantir o bom entendimento do trabalho, além de fornecer subsídios para as definições metodologias e análise dos resultados.

No terceiro capítulo é realizada uma breve revisão sobre as Redes Neurais Artificiais, de modo a identificar todos os aspectos funcionais e matemáticos, apresentando os algoritmos de treinamento e suas formulações.

No quarto capítulo são apresentadas as etapas necessárias para o desenvolvimento do presente trabalho, especificamente da elaboração da modelagem, alternando características operacionais das redes e suas arquiteturas, possibilitando dessa forma a determinação de um modelo que abranja o maior domínio possível.

No quinto capítulo são apresentados os resultados referentes ao processo de modelagem das Redes Neurais Artificiais, além da realização de testes e comparação do modelo proposto com outros da literatura.

Já no sexto capítulo, apresenta-se o software gerado, indicando suas características e funcionalidades.

Por fim, no último capítulo são apresentadas as considerações finais referentes ao trabalho desenvolvido e aos resultados obtidos durante toda a pesquisa.

2 CARBONATAÇÃO, CAPTURA DE CO₂ E VIDA ÚTIL

A carbonatação do concreto é estudada há mais de seis décadas, sendo um processo físico-químico ocasionado pela penetração do dióxido de carbono (CO₂) na estrutura porosa do substrato. Em estruturas armadas, a carbonatação é tida como um mecanismo de deterioração, pois causa a diminuição do pH do concreto deixando a armadura suscetível à corrosão.

Segundo Parrot (1987), com aumento das emissões de CO₂ na atmosfera, a carbonatação é um tema importante nas pesquisas passando a ser considerada uma das principais manifestações patológicas das estruturas de concreto armado, afetando a durabilidade das mesmas.

De acordo com a NBR 6118 (ABNT, 2014), norma referente aos projetos de estruturas de concreto, a durabilidade “consiste na capacidade da estrutura resistir às influências ambientais previstas e definidas em conjunto pelo autor do projeto e o contratante, no início dos trabalhos de elaboração do projeto”.

Entretanto, em concretos não armados e/ou não estruturais a carbonatação atua como um processo que captura CO₂ da atmosfera, compensando parcialmente o CO₂ gerado na produção do cimento (PADE; GUIMARAES, 2007; GALAN *et al.*, 2010; POSSAN; FOGAÇA; PAZUCH, 2012), a qual pode ser considerada no balanço das emissões dos gases causadores do efeito estufa associados às estruturas de concreto.

A carbonatação é um fenômeno físico-químico resultante das reações de gases ácidos (principal CO₂) do ambiente com os produtos alcalinos do concreto, essa alcalinidade é conferida principalmente pela presença do hidróxido de cálcio (Ca(OH)₂), dissolvidos ou precipitados no concreto endurecido. O CO₂ (dióxido de carbono) ao penetrar no concreto, reage com os hidróxidos, especialmente com o Ca(OH)₂, que se apresenta em maior quantidade (POSSAN, 2010). Com início a partir da superfície, a carbonatação avança progressivamente para o interior da estrutura de concreto, formando uma camada carbonatada (Figura 2.1). O avanço dessa camada está diretamente relacionado com a facilidade que o CO₂ encontra para difundir-se no interior do concreto.







Figura 2.1: Avanço da carbonatação no concreto ao longo do tempo

Segundo Possan (2010) a carbonatação do concreto ocorre inicialmente com a difusão do CO₂ através da matriz cimentícia. Na sequência há dissolução de CO₂ na solução dos poros para a formação do ácido carbônico e reação com hidróxido de cálcio, conforme reação apresentada na Equação 1. Então, ocorrem as reações com os silicatos e os aluminatos, conforme as equações 2 e 3.



O principal composto carbonatado pelo dióxido de carbono é o hidróxido de cálcio (Ca(OH)₂), porém também são carbonatáveis o hidróxido de potássio (KOH), o hidróxido de sódio (NaOH) e os silicatos alcalinos.

Um dos resultados desta reação é a redução do pH do concreto para um valor igual ou inferior a 9, que normalmente apresenta valor igual ou superior a 12,5 (BAKKER, 1988). Outro resultado dessa reação é a captura do CO₂ da atmosfera gerando o carbonato de cálcio (CaCO₃) que aprisiona o dióxido de carbono na estrutura de concreto.

2.1 Fatores que Influenciam na Carbonatação

Alguns pesquisadores (PARROT, 1988; HELENE, 1993; HOUST; WITTMANN, 2002), dividem os fatores que influenciam na carbonatação do concreto em duas categorias, internos e externos, as quais são apresentadas na Figura 2.2.



Figura 2.2: Fatores que influenciam na carbonatação do concreto¹

¹ Créditos à Helenice Sacht, que auxiliou e deu inspiração à criação da Figura.

Os principais fatores externos são, por exemplo, a concentração de CO_2 presente na atmosfera, a incidência de chuvas, a umidade relativa do ar, o clima e outros. Quanto aos internos cita-se a relação (a/c), a resistência à compressão, as condições de execução ao qual é submetido e a composição do concreto, esta última refere-se, por exemplo, ao tipo de cimento, ao teor de adições, ao tipo de adição e outros. Todos estes fatores que afetam a carbonatação do concreto serão discutidos na sequência.

2.1.1 Umidade Relativa do Ar

A carbonatação possui relação com a umidade relativa do ar, uma vez que o ingresso de CO_2 no interior da matriz cimentante ocorre principalmente graças a difusão deste gás. Na difusão, a quantidade de água funciona como veículo para o transporte de CO_2 através da porosidade do concreto, portanto, quando na presença de poros saturados ou secos o processo de difusão encontra-se impedido, não havendo ingresso do dióxido de carbono.

Verbeck (1958) relata que a carbonatação está relacionada com a umidade relativa do ar conforme se observa na Figura 2.3, a qual mostra que a carbonatação alcança valores máximos quando a umidade relativa do ambiente se situa dentro do intervalo de 50 a 70%. Assim em ambientes com baixa umidade relativa a perda d'água será maior, minimizando a água livre disponível para reagir com o dióxido de carbono, dificultando o processo de carbonatação.

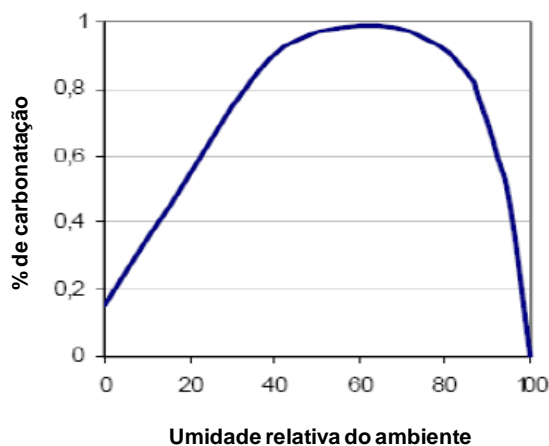



Figura 2.3: Variação da velocidade de carbonatação com a umidade

Fonte: Verbeck, 1958

Na realidade, determinar uma relação entre a umidade relativa do ar e a carbonatação do concreto em função do tempo é muito difícil e complexa, devido aos randômicos ciclos de

umedecimento e secagem a que às estruturas de concretos estão submetidas ao longo de sua vida (ANDRADE, 1992; PARROT, 1992; HELENE, 1993).

Verifica-se, portanto, que existe uma relação da difusão do CO₂ no concreto e a incidência de chuvas, devido à saturação dos poros, já que em concretos parcialmente saturados a frente de carbonatação é maior que em concretos totalmente saturados (ver Figura 2.4). Isso demonstra a complexidade no estudo desta patologia.



Fonte: Adaptado (ANDRADE, 1992)

2.1.2 Incidência de Chuvas

A exposição à incidência de chuvas faz com que parte da água livre seja absorvida pela atmosfera e outra penetre no concreto por capilaridade. Desta forma, a umidade das estruturas de concreto é dependente do período e do volume de precipitação higrométrica, a qual faz com que o concreto permaneça saturado por um tempo razoável. Neste período, a penetração de CO₂ é dificultada, resultando em uma menor frente de carbonatação (STEFFENS; DINKLER; AHRENS, 2002).

Já no período de estiagem, parte da água livre é evaporada, facilitando as condições para que a umidade fique dentro do intervalo definido por Verbeck (1958) (Figura 2.3), acarretando na máxima carbonatação.

Assim, pode-se dizer que a profundidade carbonatada com o tempo é consequência dos efeitos de molhagem e secagem da superfície do concreto. A profundidade de carbonatação é menor nos ambientes sujeitos à molhagem e secagem, do que em ambientes protegidos de chuva sejam internos ou externos (STEFFENS; DINKLER; AHRENS, 2002).

2.1.3 Concentração de CO₂

Devido às baixas concentrações de CO₂ na atmosfera, tem-se uma baixa difusão do gás no concreto, fazendo com que o mesmo necessite de um longo tempo de exposição para atingir pequenas profundidades de carbonatação (PAPADAKIS *et al.*, 1992; HELENE, 1993).

Na Tabela 2.1 são apresentadas as taxas de CO₂ às quais as estruturas estão submetidas de acordo com o ambiente onde estão inseridas.

Tabela 2.1: Classificação dos ambientes em função da concentração de CO₂

Ambiente	Concentração de CO ₂ (% em volume)	
	(NEVILLE, 1997)	(SAETTA; VITTALINE, 2004)
Ambiente rural	0,03	0,015
Cidade	0,3 a 1	0,036
Ambiente de laboratório não ventilado	> 0,1	-
Ambiente industrial	-	0,045

Em locais onde a concentração de CO₂ é mais elevada, como em regiões urbanas, ou zonas industriais o processo da carbonatação pode ou não ocorrer em maior intensidade, dependendo de outros fatores que propiciam as condições necessárias à carbonatação (VERBECK, 1958; HELENE, 1993). Richardson (1988) classifica os ambientes em ordem crescente em função da taxa de carbonatação: ambientes costeiros, rurais, suburbanos e urbanos.

Segundo Martins (2011) o ambiente onde estão inseridas as estruturas de concreto devem ser levados em consideração na descrição do fenômeno da carbonatação, os ambientes mais nocivos são, por exemplo, locais urbanos com grande tráfego de veículos, ambientes internos de garagens e ambientes industriais nos quais ocorrem à queima de combustíveis fósseis.

2.1.4 Outros Fatores Externos

Além de todas as variáveis descritas nos tópicos anteriores, a carbonatação do concreto sofre ainda influências de outras variáveis ambientais, como a temperatura, o microclima, a manutenção das estruturas ao longo do ano, o modo de utilização, entre outros.

2.1.5 Composição do Concreto

A utilização de elevados teores de adições pozolânicas densifica a matriz de concreto, reduzindo a porosidade capilar do mesmo. Porém, as adições podem vir a consumir o hidróxido de cálcio Ca(OH)₂, reduzindo o pH da solução dos poros e propiciando

a difusão do gás no concreto de forma acelerada. Para concretos com resistências à compressão inferiores a 40 MPa, as adições possuem efeitos negativos na carbonatação já que aumenta a velocidade da mesma, isso porque, o efeito da reserva alcalina se prepondera sobre a densificação da porosidade.

Isaia (1999) relata que em cimentos sem adições, o gás carbônico necessita reduzir o pH para reagir com o Ca(OH)₂ presente no substrato, para que possa prosseguir penetrando e precipitando CaCO₃ (carbonato de cálcio).

2.1.6 Condições de Execução

As condições de execução a qual foi submetido o concreto, por exemplo, a mistura, o transporte, o lançamento, o adensamento e a cura, podem ou não minimizar a sua permeabilidade, evitando desta forma problemas relacionados à segregação, exsudação excessiva e formação de fissuras.

Para Martins et al. (2001), a cura garante diversos benefícios ao concreto, não evitando apenas a perda de resistência à compressão, mas também garante que não haja retrações plásticas excessivas e aumento da permeabilidade (inclusive do gás carbono pelos poros).

Ainda de acordo com Martins et al. (2001), os benefícios da cura no concreto armado são importantes porque garantem a durabilidade da estrutura, pois a região onde se encontra a armadura está sujeita à intempéries, à carbonatação, à abrasão e outros agentes de degradação.

2.1.7 Resistência à Compressão e Relação Água/Cimento (a/c)

A relação a/c influi diretamente sobre a carbonatação, isso porque ela é responsável, pela porosidade total, aumentando ou diminuindo a facilidade com que o CO₂ penetra no concreto com o tempo.

A relação a/c e a resistência à compressão do concreto possuem o mesmo grau de influência na determinação do comportamento da carbonatação, isso porque (menores ou maiores) valores de a/c, produzem concretos (mais ou menos) resistentes, possuindo (menos ou mais poros) em sua estrutura.

A produção de concretos com reduzidos valores para a relação a/c permite que as partículas de cimento fiquem mais próximas umas das outras na pasta fresca. Durante o processo de cura, a estrutura do concreto se fecha de forma acelerada produzindo cristais menores e, conseqüentemente, reduzindo a porosidade do mesmo, como a porosidade está relacionada com a facilidade do gás carbônico adentrar no concreto, se terá ao final um concreto com menores profundidades de carbonatação com o tempo (AİTCIN, 2000). Para

Venquiarutto *et al.* (2001) a relação a/c é um dos principais fatores para a determinação do comportamento e do grau de carbonatação do concreto com tempo.

Papadakis *et al.* (1991), analisou três diferentes relações a/c (0,8, 0,65 e 0,5) na produção de concretos com cimento Portland comum e sua influência sobre a profundidade de carbonatação. Foi verificado que a relação a/c de 0,8 apresentou concretos com maiores taxas de difusão do CO_2 .

2.2 Captura de CO_2

Atualmente, tem-se discutido que o concreto tem a potencialidade de capturar CO_2 da atmosfera por um processo denominado carbonatação (GAJDA; MILLER, 2000; PADE; GUIMARÃES, 2007; POSSAN, et al., 2012). De modo geral, o processo de captura de CO_2 devido à carbonatação do concreto pode ser esquematizado conforme a Figura 2.5. A Equação 4 apresenta a quantidade (kg/m^3) de CO_2 que é capturado pelo concreto.

$$CO_2 = y \cdot c \cdot CaO \cdot r \cdot A \cdot M \quad (\text{Equação 4})$$

Onde: y é a profundidade de carbonatação do concreto (em metros), c é a quantidade de cimento empregada para produzir um m^3 de concreto (sem considerar as adições), CaO é a quantidade de óxido de cálcio contido no cimento, r é a proporção de CaO totalmente carbonatada, ou seja, transformada em CaCO_3 , A é a área superficial do concreto exposta à ação do CO_2 (em m^2) e M é a fração molar do CO_2/CaO .



Figura 2.5: Carbonatação do concreto x captura de CO_2

Fonte: Possan, et al (2012)

Existem divergências na literatura em relação à potencialidade do sequestro/captura de CO₂ devido à carbonatação do concreto. Em estudo desenvolvido na Noruega, Jacobsen e Jahren (2002) estimaram que 16% do CO₂ emitido na produção do cimento são reabsorvidos pelo concreto devido à carbonatação durante sua vida útil. Gajda (2001) relata que podem ser absorvidos 7,6% do CO₂ emitido. Por outro lado Pade e Guimarães (2007), em estudo realizado na Dinamarca, estimam, para uma perspectiva de 100 anos, considerando a demolição da estrutura, que o concreto devido à carbonatação pode absorver até 57% do CO₂ emitido na produção do cimento.

Desta forma, a carbonatação passa a ser um processo benéfico aos elementos de concreto não armados (não há corrosão), já que a estrutura passa a armazenar o CO₂ livre na atmosfera, minimizando danos causados pelo setor construtivo ao meio ambiente.

2.3. Vida útil

O conceito de vida útil foi apresentado à primeira vez por Tuutti (1982), onde o mesmo refere-se ao caso particular da corrosão de armaduras presentes no concreto armado, definindo o período de iniciação e de propagação da corrosão.

A norma inglesa BS 7543 (1992), apresenta diversos conceitos e critérios para que na fase de projeto seja possível determinar e, conseqüentemente, levar em conta a durabilidade das estruturas de concreto. Esses critérios foram coletados no capítulo IX do "Code of Practice 3" com data de publicação de 1950. Desta forma percebe-se que há um longo tempo já existia a preocupação com o desempenho das edificações.

No Brasil, Helene (1997) apresentou várias considerações acerca da vida útil das estruturas de concreto, levando em consideração o histórico dos estudos já realizados e do futuro das pesquisas nessa área.

A primeira versão da norma ISO 15.686 (2000), contemplava o planejamento da vida útil a ser seguida pelo projetista. A norma seguia os mesmos preceitos da ACI 365, publicada no ano de 2000, a qual faz um detalhamento do estado da arte e dos aspectos econômicos no ciclo de vida de uma estrutura.

De acordo com a norma de brasileira de desempenho das edificações, NBR 15575 (ABNT, 2013), a vida útil (VU) refere-se ao período de tempo em que o edifício e seus sistemas construtivos se prestam às atividades para as quais foram projetados, caso exista uma periodicidade de manutenção da edificação ao longo dos anos.

A VU é representada pela junção de diversos períodos para o qual as edificações são projetadas, sendo elas a vida útil de projeto (VUP), a vida útil de serviço, a vida útil de utilização e a vida útil última. Todos estes períodos podem ser analisados na Figura 2.6.




Figura 2.6: Conceituação de vida útil das estruturas de concreto com relação à corrosão das armaduras

Fonte: (HELENE, 1993)

De acordo com HELENE (1993), a VUP refere-se à vida útil mínima definida em projeto à qual a estrutura estará submetida e remete ao período de tempo ao qual ocorre a carbonatação da camada de concreto de cobrimento da armadura, dando início ao processo de corrosão da mesma.

Para a definição da vida útil de uma estrutura devem ser considerados os seguintes critérios:

- Agressividade ao qual a estrutura está submetida;
- Mecanismos de deterioração;
- Quantificação do grau de aceitabilidade de degradação;

A determinação da captura de CO₂ devido à carbonatação do concreto, assim como da estimativa da vida útil de projeto de uma estrutura, é dependente da existência de um modelo (matemático, estatístico, etc.) capaz de determinar a profundidade de carbonatação do concreto ao longo de tempo, tendo em consideração as principais variáveis que afetam o fenômeno. Na sequência, são apresentados cinco modelos da literatura que serão comparados, no capítulo de resultados, com o modelo proposto neste estudo.

2.4 Modelos de Estimativa da Profundidade de Carbonatação

Nas últimas décadas, diversos pesquisadores buscaram determinar modelos que fossem capazes de prever a profundidade de carbonatação do concreto, e conseqüentemente da vida útil das estruturas. Grande parte dos modelos desenvolvidos foram pressupostos da formulação feita por Tuutti (1982), onde o mesmo diz que a penetração do dióxido de carbono no concreto pode ser representada através do processo de difusão de um gás em um determinado meio de acordo com a Equação 5.

$$y = k\sqrt{t} \quad (\text{Equação 5})$$

Onde:

k = coeficiente de carbonatação (mm/ano^{0.5});

t = tempo (anos);

Várias críticas são feitas ao modelo de Tuutti (1998), especialmente à dificuldade de se determinar o coeficiente de carbonatação “k” para novas estruturas, o que levou a comunidade científica ao desenvolvimento de diferentes modelos de carbonatação (PAPADAKIS; VAYENAS; FARDIS, 1991; CEB, 1997; POSSAN, 2004; THIÉRY, 2005; HYVERT, 2009), sejam eles empíricos² ou complexos³. Alguns dos modelos desenvolvidos nas últimas décadas são apresentados a seguir em ordem cronológica quanto a sua determinação. Os modelos se diferenciam quanto a sua concepção, quanto as variáveis (número e tipo) e quanto ao domínio de abrangência.

Sanjuán (1992), Pauletti (2009) e Possan (2010) compilaram estas e outras formulações para a determinação da profundidade de carbonatação do concreto, apresentando suas características, variáveis e observações referentes às suas aplicações.

2.4.1 Modelo de SMOLCZYK

Smolczyk (1976) definiu através da Equação 6 a profundidade de carbonatação (em cm), que uma estrutura de concreto está submetida ao logo do tempo.

$$y = a \cdot \left(\frac{1}{\sqrt{f_c}} - \frac{1}{\sqrt{f_{clim}}} \right) \cdot \sqrt{t} \quad (\text{Equação 6})$$

Onde:

y = profundidade carbonatada (cm);

² Definem-se como modelos empíricos aqueles que são determinados através de dados advindos de experiências anteriores do fenômeno. Em geral possuem dificuldades de extrapolação dos resultados.

³ Modelos Complexos podem ser definidos como modelos que buscam extrapolar os resultados buscando explicações sobre as causas ou mecanismos naturais que determinam o fenômeno estudado.

a = velocidade de carbonatação;

f_c = 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);

Analisado o modelo, a profundidade carbonatada com o tempo é função apenas da resistência à compressão do concreto. Porém, a grande dificuldade na utilização deste modelo consiste em determinada o valor da velocidade de carbonatação “ a ”.

2.4.2 Modelo de VESIKARI

Vesikari (1988) baseando-se no modelo de difusão do CO₂ no concreto (Equação 4) proposto por (TUTTI, 1982), buscou determinar o valor da constante “ k ” (coeficiente de carbonatação (mm/ano^{0,5})), os resultados levaram a Equação 7.

$$k = [26. (ac - 0,3)^2 + 1,6] \quad (\text{Equação 7})$$

Onde:

ac = relação água/cimento (com limites $0,45 < ac < 0,75$);

Após o cálculo do coeficiente de carbonatação “ k ”, pode-se utilizar a Equação (5), para então determinar a profundidade de carbonatação. Vesikari (1988) impõe a condição que em ambientes externos desprotegidos de chuvas, o coeficiente “ k ” calculado deve ser multiplicado por 4, isso porque o autor considera o ambiente com maior velocidade de carbonatação.

2.4.3 Modelo de BOB e AFFANA

O modelo determinado por Bob e Affana (1993), foi definido baseando-se na (Equação 5), porém os autores perceberam que a profundidade de carbonatação dependia da quantidade de CO₂ que o concreto estava submetido, da umidade relativa do ar, do tipo de cimento (composição) e também da resistência à compressão do concreto. O modelo determinado é apresentado na Equação 8.

$$y = 150. \left(\frac{c.k.d}{f_c} \right) . \sqrt{t} \quad (\text{Equação 8})$$

Onde:

c = coeficiente do tipo de cimento;

k = coeficiente dependente da umidade relativa do ar;

f_c = Resistência à compressão do concreto (MPa);

d = coeficiente referente a quantidade de CO₂

Tabela 2.2: Coeficientes do modelo, (a) coeficiente dependente da umidade, (b) coeficiente da taxa de CO₂ presente no ar e (c) parâmetros dependentes do tipo de aglomerante.

a)		b)	
Umidade Relativa	k	Quantidade de CO ₂	d
UR ≤ 60	1,0	CO ₂ ≤ 0,03%	1,0
70 ≤ UR ≤ 75	0,7	0,03% < CO ₂ ≤ 0,1%	2,0
80 ≤ UR ≤ 85	0,5		
UR > 90	0,3		

c)	
Tipo de Cimento	c
Cimento Portland (CP40 e CP 45)	0,8
Cimento Portland (CP50 e CP 55)	1,0
Cimento Portland + 15% de adições	1,2
Cimento Portland + 30% de adições	1,4
Cimento Portland + 50% de adições	2,0

2.4.4 Modelo de EHE

O modelo (Equação 9) determinado por EHE (2008) foi baseado no modelo proposto por Håkkinen (1993). Na formulação os autores não levaram em consideração alguns dos principais fatores influentes no processo de carbonatação, como por exemplo, a relação (a/c). A maioria dos parâmetros são encontrados em Tabelas determinadas pelo autor.

$$y = C_{amb} \cdot C_{ar} \cdot a \cdot f_{cm}^b \cdot \sqrt{t} \quad (\text{Equação 9})$$

Onde:

k = coeficiente dependente da umidade relativa do ar;

C_{amb} = Coeficiente de ambiente (Tabelado) (Tabela 2.3 “a”);

C_{ar} = Coeficiente do ar incorporado (Tabelado) (Tabela 2.3 “b”);

f_{cm} = Resistência média à compressão (MPa);

a, b = parâmetros dependentes do tipo de aglomerante (Tabelados) (Tabela 2.3 “c”);

Tabela 2.3: Coeficientes do modelo, (a) coeficiente do ar incorporado, (b) coeficiente de ambiente e (c) parâmetros dependentes do tipo de aglomerante.

a)		b)	
Ar Incorporado	C_{ar}	Ambiente	C_{amb}
< 4,5%	1,0	Protegido de Chuva	1,0
≥ 4,5%	0,7	Desprotegido da Chuva	0,7

c)

Tipo de Cimento	a	b
Cimento Portland	1800,00	-1,70
Cimento Portland + 28% de CV	360,00	-1,20
Cimento Portland + 9% de SA	400,00	-1,20
Cimento Portland + 65% de Escória	360,00	-1,20

2.4.5 Modelo de POSSAN

Possan (2010) propôs uma formulação para a profundidade de carbonatação conforme a Equação 10, analisando um grande número de fatores que influenciam o processo de carbonatação, como a resistência à compressão, a composição do cimento (tipo de cimento e adições) e outros fatores ambientais.

$$y = k_c \cdot \left(\frac{20}{f_c}\right)^{k_{fc}} \cdot \left(\frac{t}{20}\right)^{\frac{1}{2}} \cdot \exp\left[\left(\frac{k_{ad} \cdot ad^{\frac{3}{2}}}{40+f_c}\right) + \left(\frac{k_{CO_2} \cdot CO_2^{\frac{1}{2}}}{60+f_c}\right) - \left(\frac{k_{RU} \cdot (UR-0,58)^2}{100+f_c}\right)\right] \cdot k_{ce} \quad (\text{Equação 10})$$

Onde:

y = profundidade de carbonatação (mm);

f_c = Resistência média à compressão (MPa);

k_c = fator dependente do tipo de cimento (Tabela 2.4 “a”);

k_{fc} = fator dependente da resistência à compressão do concreto, em função do tipo de cimento (Tabela 2.4 “a”);

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 (Tabela 2.4 “a”);

UR = Umidade relativa do ar (%*0,01);

k_{UR} = fator dependente da umidade relativa do ar, em função do cimento (Tabela 2.4 “a”);

CO_2 = teor de dióxido de carbono no ambiente (%);

k_{CO_2} = fator dependente do teor de dióxido de carbono no ambiente, em função do cimento (Tabela 2.4 “a”);

k_{ce} = fator dependente do ambiente de exposição (protegido ou desprotegido), em função das condições de exposição do concreto (Tabela 2.4 “b”);

Tabela 2.4: Coeficientes do modelo em função (a) das características do concreto e das condições ambientais (b) das condições de exposição (POSSAN, 2010)

Tipo de Cimento	a)					b)	
	Características do concreto			Condições Ambientais		Condições de exposição da estrutura	
	Cimento	f _c	Adição	CO ₂	UR	Proteção à chuva	k _{ce}
	k _c	k _{fc}	k _{ad}	k _{co2}	k _{UR}		
CP I	19,80	1,70	0,24	18,00	1300		
CP II E	22,48	1,50	0,32	15,50	1300	Ambiente interno Protegido da chuva	1,30
CP II F	21,68	1,50	0,24	18,00	1100		
CP II Z	23,66	1,50	0,32	15,50	1300	Ambiente externo Protegido da chuva	1,00
CP III	30,50	1,70	0,32	15,50	1300		
CP IV	33,27	1,70	0,32	15,50	1000		
CP V ARI	19,80	1,70	0,24	18,00	1300	Ambiente externo Desprotegido da chuva	0,65

O modelo de Possan (2010) foi obtido a partir do conhecimento de especialistas, o qual na validação representou 85% dos casos reais testados.

3 REDES NEURAIS ARTIFICIAIS

3.1 Notas Históricas

A busca pelo domínio das redes neurais artificiais (RNA's) iniciou-se em meados do ano de 1943, quando os pesquisadores Warren McCulloch e Walter Pitts apresentaram o primeiro modelo. A partir deste momento novos modelos foram desenvolvidos ao longo dos anos (MARTINS, 2011).

Em 1958, quinze anos após a descoberta de McCulloch e Pitts, Frank Rosenblatt criou a rede Perceptron, e com ela foi possível realizar o reconhecimento de caracteres. Desta forma, as redes possuíam um método inovador com uma metodologia de aprendizado supervisionado (método que necessita de um supervisor para garantir o aprendizado).

Durante toda a década de 60, as redes propostas por Rosenblatt tiveram grande aceitação no meio científico, perdendo em seguida credibilidade devido às árduas críticas feitas por Mavin Minsky e Seymour Papert em 1969. Os dois pesquisadores publicaram um trabalho denominado "Perceptron" onde argumentavam que as RNA's apresentavam limitações e não possuíam grande capacidade de aprendizado mesmo em problemas simples, não apresentando também uma sustentação matemática. Devido a essas críticas, as redes passaram por um período de descrédito e desuso durante toda a década de 70.

As pesquisas com as RNA's voltaram fortemente depois do trabalho realizado pelo físico e biólogo John Hopfield em 1982, quebrando os argumentos feitos por Minsky e Papert em 1969. Hopfield demonstrou a potencialidade das redes na resolução de diversos problemas, e fez com que uma avalanche de trabalhos fossem publicados sequencialmente trazendo ao mundo diversos modelos e contribuições (FAUSETT, 1993).

Em 1985 Parker e LeCun desenvolveram finalmente o primeiro algoritmo de treinamento para redes com múltiplas camadas, intitulado Backpropagation. Tal descoberta possibilitou às redes a resolução de problemas complexos e não lineares, aumentando o domínio de aplicabilidade das RNA's (MARTINS, 2011).

3.2 Modelo das Redes Artificiais

As RNA's são estruturas inspiradas no cérebro humano. São definidas como sistemas paralelos e distribuídos compostos por unidades de processamento (neurônios artificiais). Os neurônios possuem a propriedade de mapear funções matemáticas, em geral, não lineares, sendo dispostos em uma ou mais camadas, interligadas através de conexões as quais estão associadas a pesos sinápticos que possuem a propriedade de armazenar o conhecimento.

As RNA's demonstram uma capacidade que supera a função de mapear relações entre entradas e saídas. Elas são capazes também de extrair informações não encontradas e/ou não apresentadas a rede, fazendo extrapolação dos resultados. O funcionamento destas redes tem como inspiração o cérebro humano (BRAGA; LURDEMIR; CARVALHO, 2000).

Haykin (2001) destaca que as RNA's apresentam cinco elementos básicos (Figura 3.1), que se assemelham as redes biológicas (Figura 3.2), a saber:

- I. Um conjunto de entradas e saídas, onde cada um carrega o seu respectivo peso sináptico (dendritos no neurônio biológico);
- II. Um somador, para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio (corpo celular no neurônio biológico);
- III. Uma função de ativação, para restringir a amplitude da saída;
- IV. Um bias, responsável por aumentar ou diminuir a entrada líquida da função de ativação;
- V. Uma saída gerada pela rede (representa um axônio no neurônio biológico);

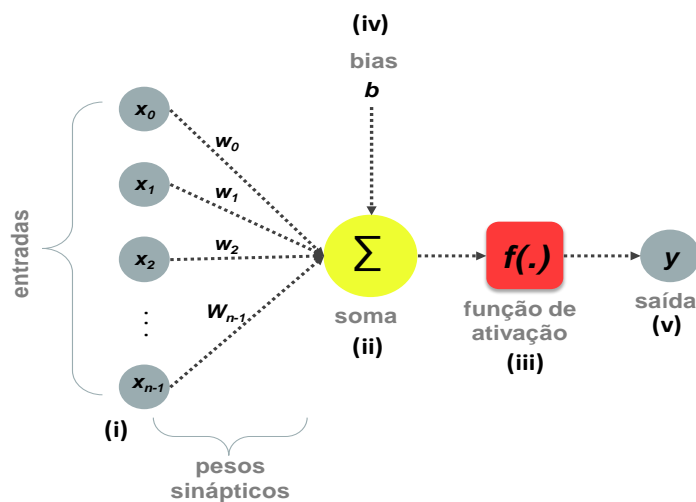


Figura 3.1: Modelo de um neurônio artificial

Para Martins (2011), as RNA's são sistemas paralelos e distribuídos, compostos por unidades de processamento simples (neurônios), capazes de mapear funções matemáticas não lineares. Os neurônios podem estar arranjados em uma ou mais camadas, sendo interligados através de conexões. Em muitos dos modelos existentes, as conexões entre os neurônios associam-se aos pesos sinápticos, sendo responsáveis por armazenar todo o conhecimento representado no modelo.

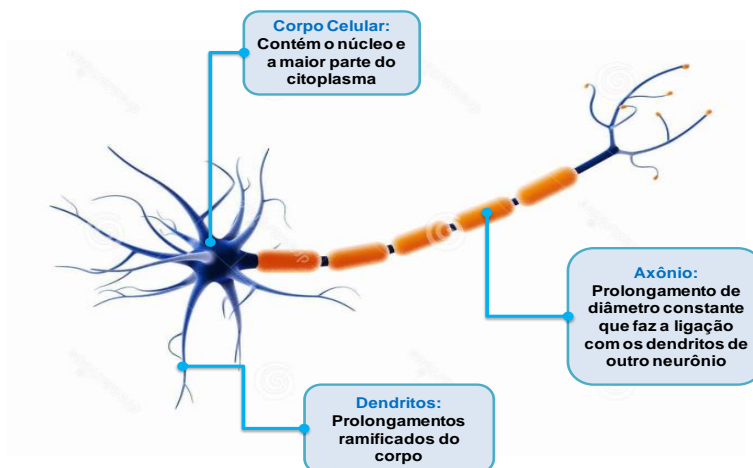


Figura 3.2: Representação do modelo simplificado de um neurônio biológico

Fonte: Adaptado de Braga, Lurdemir e Carvalho (2000)

Assim, de modo geral, pode-se representar matematicamente um neurônio com n entradas (Figura 3.1) por meio da Equação 11.

$$z = b + \sum_{i=0}^{n-1} x_i w_i \quad (\text{Equação 11})$$

Cada entrada $x_i \in \mathbb{R}$, $i = 0, 1, \dots, n-1$, é pesada (ponderada) por meio de um correspondente $w_i \in \mathbb{R}$ formando o vetor de pesos $w = (w_0, w_1, \dots, w_{n-1})^T$. O neurônio possui ainda um bias $b \in \mathbb{R}$ que é somado a cada entrada multiplicada com seu respectivo peso, que forma a entrada a ser informada à rede ($z \in \mathbb{R}$). Desta forma a função de ativação $f: \mathbb{R} \rightarrow \mathbb{R}$ é aplicada para a entrada z , obtendo a saída $y \in \mathbb{R}$.

$$y = f(z) \quad (\text{Equação 12})$$

3.2.1 Função de Ativação

A função de ativação tem por finalidade converter o somatório das entradas ponderadas pelos pesos em um sinal de ativação de entrada para o neurônio. Em seguida, a função de ativação tem por objetivo converter a somatória das ativações das entradas em ativação de saída e diferenciar a decisão neural se influenciando no potencial interno do neurônio, determinando os valores a serem enviados aos demais neurônios (MARTINS, 2001).

As RNA's possuem unidades de processamentos (neurônio) que estão associadas a um estado de ativação, este estado é caracterizado através das funções de ativações, que podem ser discretas ou contínuas, de acordo com o problema que se quer modelar.

As funções de ativações são conhecidas também por serem limiares lógicos. Em geral, cada função possui características específicas como descrevem (SILVA et al., 2004):

- **Função linear:** é uma função que não limita a saída da rede, em geral é usada para armazenar dados de entrada e saída (Figura 3.3);
- **Função degrau:** é uma função binária, ela é muito utilizada como função classificadora já que limita a saída da rede somente a dois valores (Figura 3.4);
- **Função sigmoide tangente hiperbólica:** é uma função assim como a sigmoide logística limitada superiormente e inferiormente tendo como intervalo (-1, 1) (Figura 3.5);
- **Função sigmoide logística:** é uma função limitada, que assume valores entre dois extremos, sendo um o limitante superior e o outro o limitante inferior, compreendida assim no intervalo (0,1) (Figura 3.6);




Figura 3.3: Função linear




Figura 3.4: Função Degrau




Figura 3.5: Função sigmoide tangente hiperbólica




Figura 3.6: Função sigmoide logística

Para muitos pesquisadores (HAYKIN, 2001; OLIVEIRA, 2005; MARTINS, 2011), as funções sigmóides são as mais utilizadas como função de ativação na construção de RNA's, por serem funções de caráter crescente mostrando propriedades homogêneas e assintóticas. Estas funções são ainda semi-lineares, contínuas, simétricas, monotonicamente crescente, limitadas e com derivadas fáceis de serem obtidas.

3.2.2 Arquitetura das Redes Artificiais

Braga, Lurdemir e Carvalho (2000) relatam que a arquitetura de uma RNA tem grande importância sobre o comportamento e funcionamento da mesma, uma vez que é a arquitetura que limita o tipo de problema que pode ser solucionado. Redes contendo apenas uma camada de processamento podem resolver apenas problemas linearmente separáveis, enquanto que as redes recorrentes podem resolver problemas de processamento temporal.

Existem diversas estruturas diferenciadas pelo número de camadas de processamento e pela forma como os neurônios de uma camada interagem com os das outras camadas.

A arquitetura é então, o modo como os neurônios são estruturados. Na literatura existem diversos trabalhos que relatam como devem ser estruturados os neurônios devido à complexidade e tipo de problema a ser modelado. Porém, não existe uma regra lógica para a decisão da melhor forma a estruturar uma rede. As regras existentes adquiridas de experiências realizadas podem servir como balizamento, mas a definição de certos parâmetros, como por exemplo, os algoritmos de treinamento, o número de camadas de processamento, o número de neurônios em cada camada e o tipo de conexão, não possuem uma regra pré-determinada. Assim, a estrutura deve ser montada analisando o problema e sendo ajustada a cada treinamento (FAUSETT, 1993).

A determinação de como os neurônios são conectados (topologia da rede), é feita por sucessivos refinamentos do modelo, mas é necessário que o número de neurônios esteja dentro de um intervalo aceitável, sendo que não deve haver poucos nem demasiados, já que em excesso ou em falta de neurônios na rede tende a apresentar perda de sensibilidade no aprendizado e reconhecimento de padrões, ou memorização dos dados, fazendo com que a rede deixe de aprender e tenha a sua potencialidade de generalizar os dados prejudicada.

Na Figura 3.7, são apresentados alguns exemplos de arquiteturas desenvolvidas ao longo dos anos, onde as variáveis x_1, x_2, \dots, x_n representam as entradas e as variáveis y_1, y_2, \dots, y_n a(s) saída(s). As linhas pontilhadas representam conectores entre os neurônios de uma camada e outra, e é através dessas conexões que as informações entre duas

camadas são processadas. Os retângulos representam as camadas ocultas, aquelas que possuem a capacidade de processar informações através de funções de ativação.

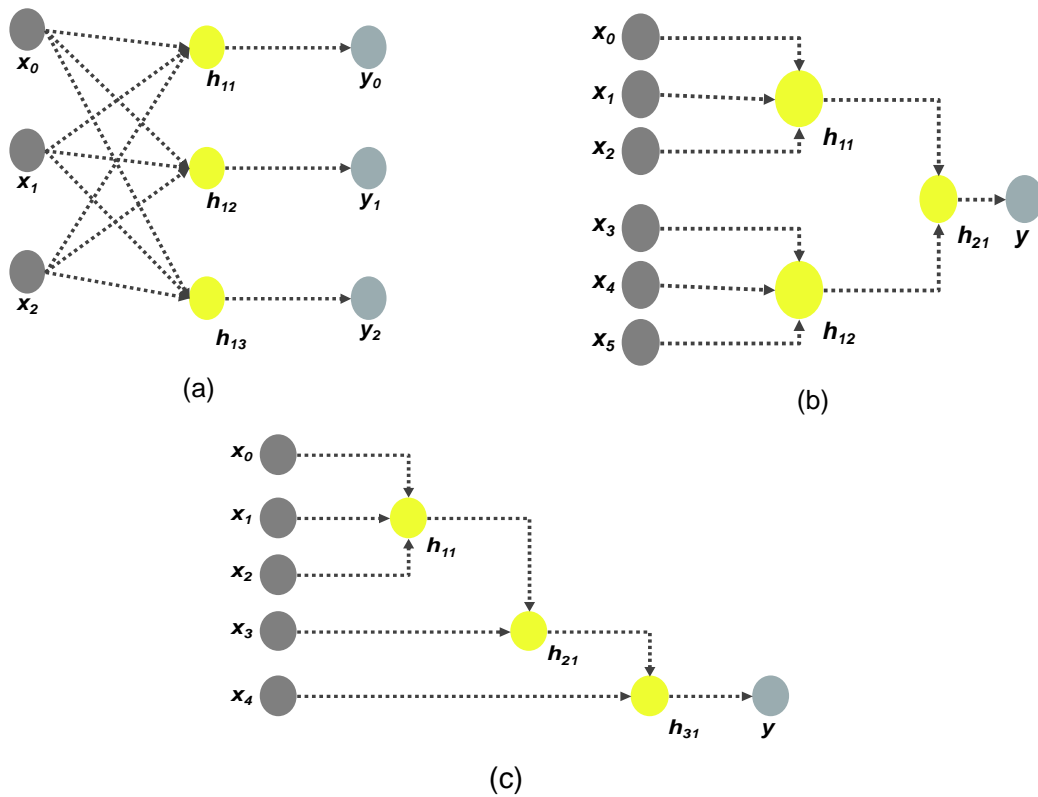


Figura 3.7: Arquitetura de redes com uma (a) ou mais (b e c) camadas

Quanto a ligação das unidades de processamento, existem diversos modos de realizar a interação entre elas, podendo haver conexões do tipo *Feedforward* ou *Feedback*. No primeiro caso, as conexões são feitas de forma subsequente, ou seja, a saída de um neurônio da *i-ésima* camada não pode servir de entrada para um neurônio de camada menor ou igual a *i* (ver Figura 3.8). Já no tipo *Feedback*, isto pode ocorrer (Figura 3.9).




Figura 3.8: Rede com alimentação *Feedforward*

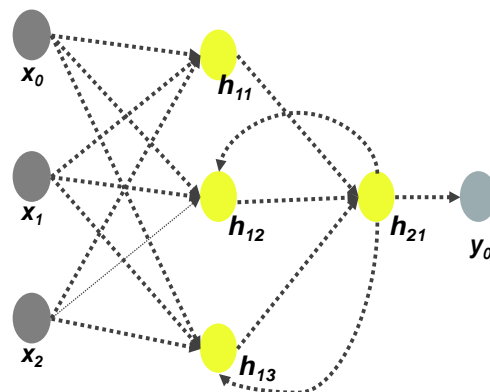


Figura 3.9: Rede com alimentação *Feedback*

3.3 Métodos de Aprendizagem

A capacidade de aprender é uma das características mais importantes das RNA's. Esta capacidade de aprendizado está associada à habilidade em adaptar-se, de acordo com as regras pré-existentes em seu ambiente, modificando-as com o tempo.

Para as RNA's, o aprendizado é definido como um processo no qual os parâmetros livres de uma rede são alterados devido à uma estimulação provocada pelo ambiente ao qual está inserida (VON ZUBEN, 2013). Assim, o objetivo geral de uma rede é a determinação de um modelo implícito do problema através de ajustes dos parâmetros da sua estrutura. A Figura 3.10 sintetiza de forma esquemática o processo para chegar a este objetivo.

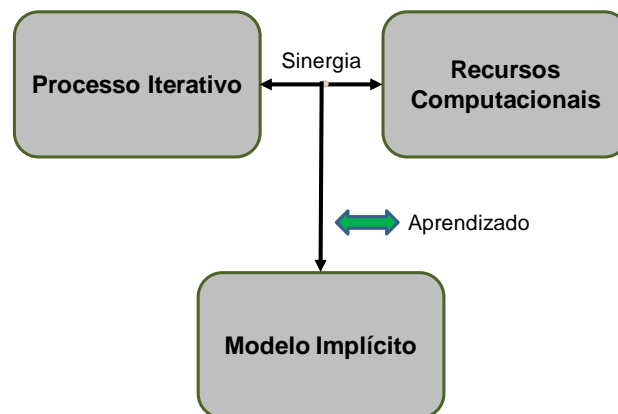


Figura 3.10: Processo de modelagem com RNA's

O tipo de aprendizado é caracterizado pela técnica responsável pelo ajuste dos parâmetros da rede, mais precisamente na maneira como são ajustados o vetor dos pesos sinápticos (pesos que ponderam as entradas de uma camada). Porém, o ambiente também influencia a rede em seu aprendizado definindo assim os paradigmas de aprendizagem. A seguir serão apresentados os dois aprendizados mais utilizados na literatura: o supervisionado e o não supervisionado.

3.3.1 Aprendizado Supervisionado

Para que a rede venha a mapear uma relação, a mesma deve passar por um processo de aprendizado (Figura 3.11). O processo mais utilizado é o aprendizado supervisionado. Sua denominação vem do fato que a rede é controlada inicialmente por um supervisor, onde este apresenta os dados à rede, passando a esta o objetivo de encontrar uma relação entre os pares de entradas e saídas fornecidos. Ao encontrar tal relação, a rede calcula todas as saídas e faz uma comparação com as apresentadas pelo supervisor.

No caso destas saídas divergirem, a rede ajusta os pesos das conexões de modo a minimizar as diferenças (erros).




Figura 3.11: Aprendizado supervisionado

Segundo Martins (2011), a minimização da diferença é incremental já que pequenos ajustes são feitos a rede a cada treinamento, fazendo com que estes encaminhem a RNA para a solução do problema. Martins relata ainda que uma desvantagem do método é que, com a ausência de um supervisor, a rede não consegue solucionar o problema, não sendo capaz de criar estratégias para cobrir situações não aprendidas no treinamento.

3.3.2 Aprendizado Não supervisionado

Muitos dos sistemas biológicos possuem como paradigma de aprendizagem o aprendizado não supervisionado, por exemplo, os estágios iniciais dos sistemas de audição e visão.

Embora exista uma grande semelhança com o aprendizado supervisionado, no aprendizado não supervisionado não há um professor (supervisor) para acompanhar o processo (Figura 3.12), desta forma, não há exemplos a serem aprendidos e identificados pela rede. Para este tipo de aprendizado apenas os padrões de entradas são apresentados às redes, sem haver a formação de um par de dados com os padrões de saídas (BRAGA; LURDEMIR; CARVALHO, 2000).




Figura 3.12: Aprendizado não supervisionado

A partir do momento em que se estabelece uma harmonia entre as regularidades estatísticas da entrada de dados, a rede passa a desenvolver a habilidade de formar representações para que haja a codificação das características da entrada, criando novas classes ou grupos (MARTINS, 2011).

O aprendizado só ocorrerá quando houver redundância nos dados de entrada, pois caso não exista será impossível obter quaisquer padrões ou características dos mesmos.

3.4 Modelos e Algoritmos de Treinamento

Existem hoje diversos modelos de redes neurais artificiais, diferenciados quanto as estruturas (arquiteturas), quanto ao método de aprendizagem e pela forma em que se alcança o objetivo principal da rede; objetivo este de fornecer uma relação implícita para um determinado problema. Serão citados a seguir dois modelos, escolhidos pelo fato de serem os mais utilizados na literatura e por serem objetivos de estudo neste trabalho.

3.4.1 Redes Perceptron e o Algoritmo de Treinamento

O perceptron é o modelo mais básico encontrado na literatura das RNA's, sendo uma rede classificadora de padrões que podem ser separados por hiperplanos, ou seja, podem resolver apenas problemas linearmente separáveis. Este tipo de rede ficou conhecido pela capacidade de distinguir caracteres e por conseguir resolver problemas lógicos (com respostas binárias). O perceptron é baseado no primeiro modelo criado por McCulloch e Pitts em 1958, e possui a mesma estrutura apresentada na Figura 3.1.

A rede quando possui somente um neurônio pode apenas classificar padrões em duas classes, sendo necessário aumentar o número de neurônios para que venha a classificar padrões em mais de duas classes, desde que estas sejam divididas por hiperplanos. O algoritmo de treinamento utilizado é conhecido como algoritmo de retropropagação ou também Backpropagation.

O algoritmo geral criado por Rosenblatt é apresentado em forma de fluxograma (Figura 3.13). O processo de treinamento consiste em um combinador linear (somador), seguido de uma função de ativação limiar, caracterizando-se como uma modelagem de neurônio não linear.

Na Figura 3.13, W é o vetor de pesos sinápticos; X é o vetor de entrada; Y é o vetor de saída; e é o erro associado a cada saída; α é o coeficiente de aprendizado; e δ é o gradiente dos erros.

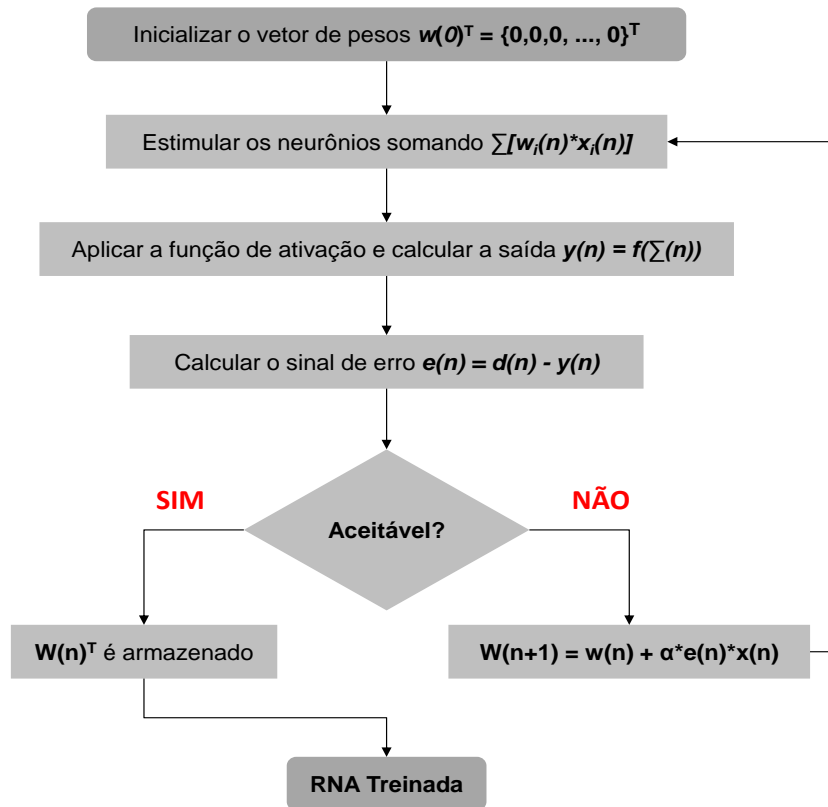


Figura 3.13: Algoritmo de treinamento do Perceptron

3.4.2 Redes MultiLayer Perceptron (MLP) e Algoritmo de Treinamento

As redes MultiLayer Perceptron (em português Perceptron de múltiplas camadas), diferenciam-se das redes Perceptron por apresentarem mais de uma camada de processamento (Figura 3.14), possibilitando ao modelo resolver problemas com dados não linearmente separáveis.

De acordo com Oliveira (2005), as MLP's apresentam três tipos fundamentais de camadas, a saber: camada de entrada, camadas ocultas e a camada de saída. A primeira e a última não apresentam potencial computacional, já que apresentam apenas função de armazenar valores e construir padrões (camada de saída). Já as camadas ocultas, apresentam capacidades computacionais, uma vez que é nestas camadas que ocorrem o processamento de informação necessário para que seja gerado o modelo implícito que leve à solução de um determinado problema.

No que se refere ao número de camadas ocultas (camadas com potencial de processamento), sabe-se que uma rede com duas camadas ocultas possui a capacidade de mapear uma função contínua, e acima de duas camadas, faz com que a rede seja capaz de modelar qualquer função matemática (CYBENKO, 1989).

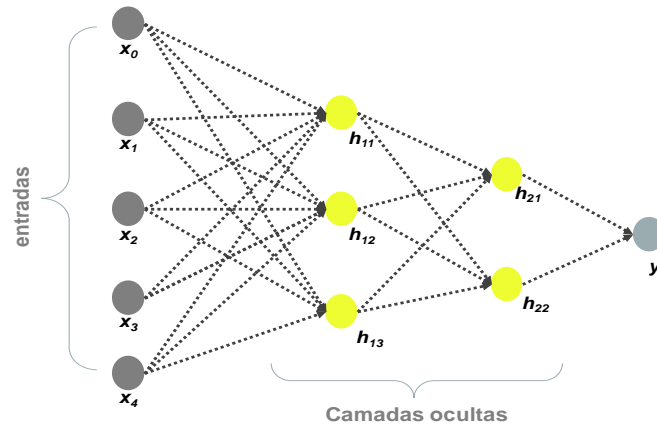
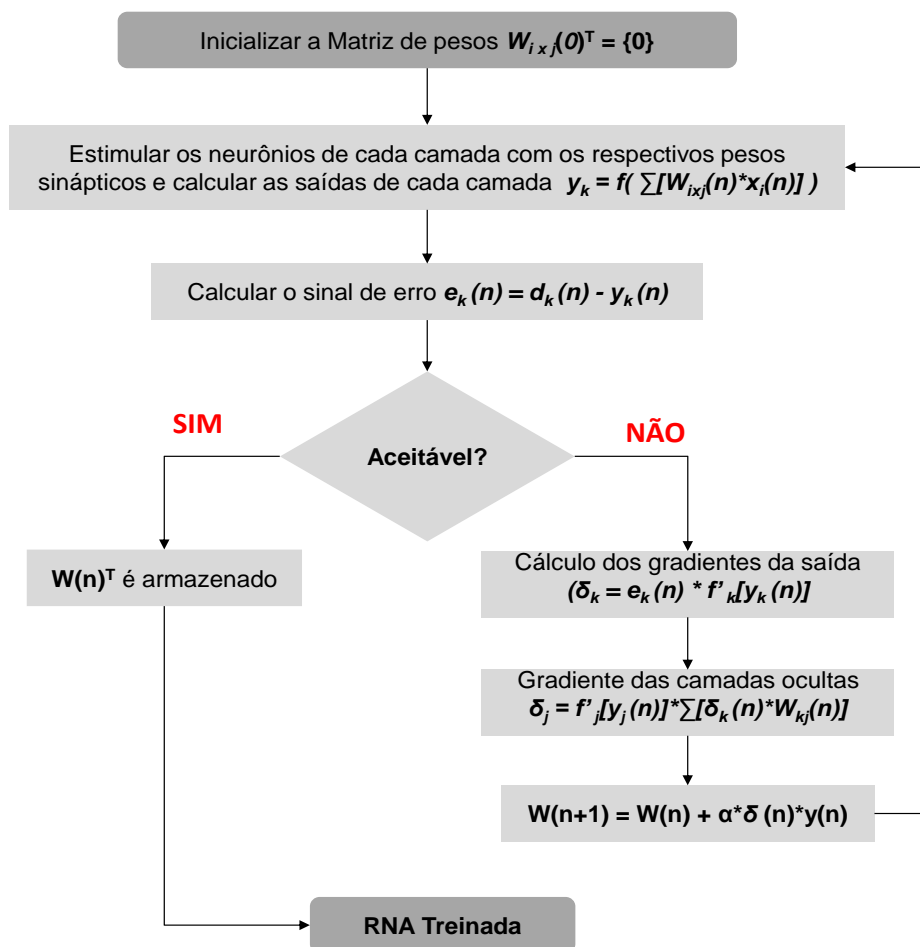


Figura 3.14: Modelo de uma rede MLP

Quanto ao treinamento das redes MLP's, generalizou-se o algoritmo de treinamento do Perceptron, aumentando a complexidade de aplicação. O algoritmo foi desenvolvido tendo como base a regra de aprendizagem por correção de erro.

O algoritmo é apresentado na Figura 3.15 em forma de fluxograma apresentando as interações que são feitas para que ao final seja gerado o modelo.


 Figura 3.15: Algoritmo de treinamento *Backpropagation*

Onde:

W é o vetor de pesos sinápticos; X é o vetor de entrada; Y é o vetor de saída; e é o erro associado a cada saída; α é o coeficiente de aprendizado; δ é o gradiente dos erros; e f' é a derivada da função de ativação.

3.5 Aplicações na Engenharia e nas Ciências Exatas

Ao longo dos anos, as redes passaram a ganhar espaço e foram sendo desenvolvidas e aprimoradas para serem usadas nas mais distintas áreas, como na matemática, nas engenharias e nas ciências exatas, nas ciências biológicas, na medicina, nas ciências econômicas, entre outras.

Na engenharia, as RNA's veem sendo aplicadas nas áreas de geociência (GALO, 2000; ANDRADE; CENTENO, 2003, ESPINHOSA, 2004; GALVÃO; MENEZES, 2005), geologia (FLECK; PEDREIRA, 2003), análise sísmica (SANTOS, 2008), estruturas (ZANETTI, 2008; CASTRO, 2009), engenharia elétrica (MELO, 2008), em estudos com concreto (MARTINS, 2011; FELIX; POSSAN; KONZEN, 2013), em estudos com pavimentos (KASEKO; RITCHIE, 1993; FWA; CHAN, 1993; HUA; FAGHRI, 1993; BREGA, 1996; FAXINA, 2005), e em hidrologia (SANTOS; PEREIRA, 2003; MACHADO, 2005).

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

4 METODOLOGIA

A metodologia utilizada no presente estudo envolveu seis etapas: i) levantamento e montagem de um banco de dados da profundidade de carbonatação para diferentes concretos; ii) modelagem com redes neurais artificiais; iii) análises estatísticas para seleção do melhor modelo; iv) testes com o modelo; v) determinação de modelos para a VUP, cobertura mínima de armaduras e captura de CO₂; vi) implementação de um software com interface gráfica (ver Figura 4.1). Na sequência são descritas de forma sucinta cada uma destas etapas, detalhando o processo metodológico adotado no trabalho.

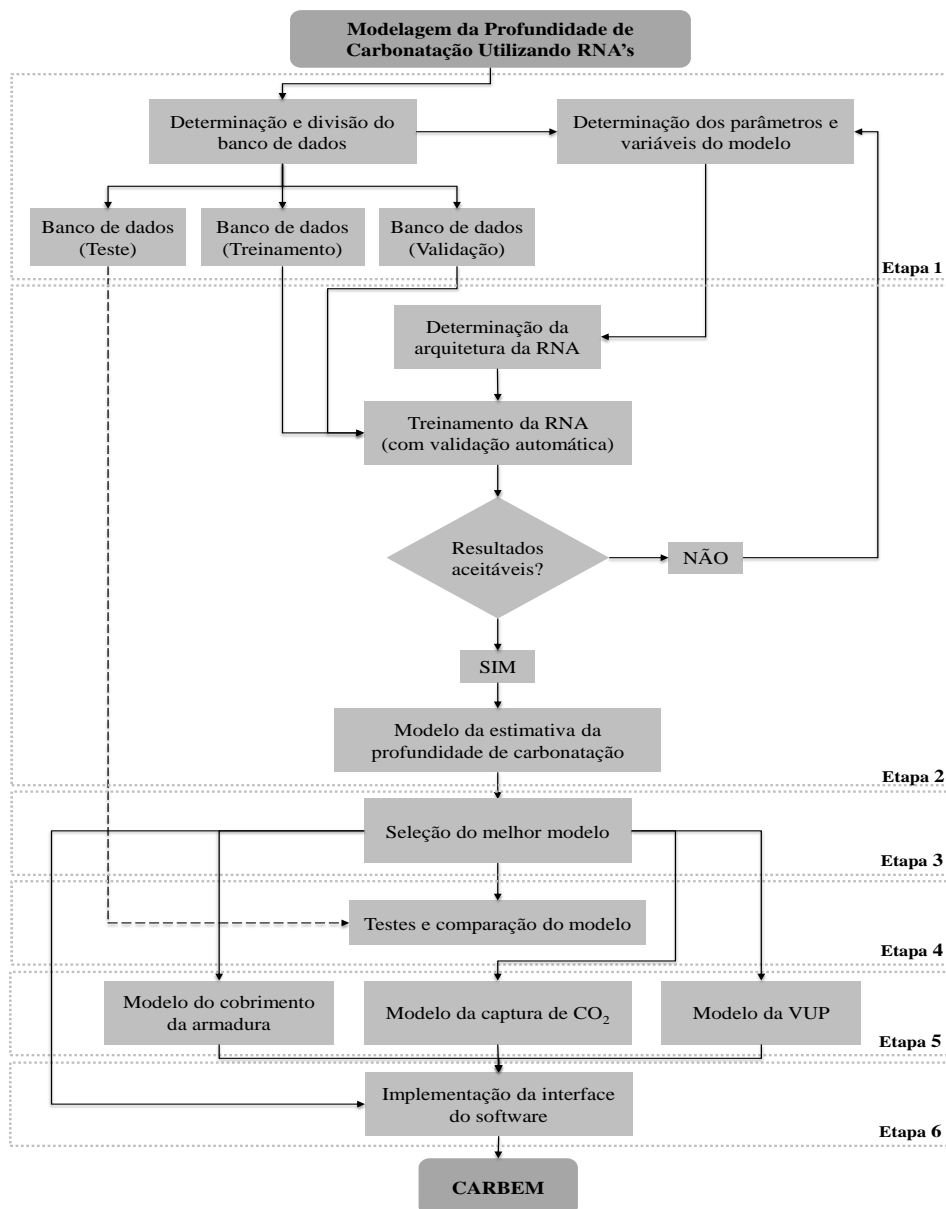


Figura 4.1: Fluxograma das etapas do trabalho

4.1 Banco de Dados - Etapa (i)

Para a determinação da profundidade de carbonatação do concreto foi realizado primeiramente o levantamento de um banco de dados, o qual é composto por informações advindas de ensaios já realizados por outras instituições, grupos de pesquisa e pesquisadores (ISAIA, 1999; MEIRA et al., 2006; VIEIRA et al., 2009;) (178 dados), e por outros meios, como grupo focal (POSSAN, 2010) (100 dados). Para tal, fez-se necessário estudar a carbonatação do concreto e as variáveis que influenciam o fenômeno físico-químico da reação, para uma melhor montagem do banco de dados, dado o número e complexidade das variáveis de influência.

Para a determinação das informações a serem inseridas no banco de dados foram realizadas correlações entre as variáveis de influência e a profundidade de carbonatação, possibilitando determinar quais delas possuíam maiores relações com a carbonatação.

Para que fosse possível realizar a modelagem utilizando as RNA's foi necessário fazer a conversão ou representação das variáveis discretas em algarismos, como é o caso das variáveis de entradas referentes ao tipo de cimento e às condições de exposição da estrutura. O tipo de cimento, CP II-E, CP II-F, CP II-Z, CP III, CP IV e CP V ARI, foi enumerado em ordem crescente de 1 a 6. A condição de exposição da estrutura, subdividida em ambiente interno protegido da chuva, externo protegido da chuva e externo desprotegido da chuva, foi representada, respectivamente, por 1,30, 1,00 e 0,65, conforme determinado por Possan (2010). Este processo além de garantir a utilização das variáveis discretas na modelagem com as RNA's possibilitou também a definição do domínio de aplicabilidade do modelo para cada variável (ver Tabela 4.1).

Tabela 4.1: Domínio das variáveis do conjunto de dados

Variável	Domínio
Tipo de cimento	[1; 2; 3; 4; 5; 6]
Umidade Relativa do ar (%)	[30 a 90]
Fator de exposição da estrutura	[1,30; 1,00; 0,65]
Teor de adições (%)	[0 a 30]
Teor de CO ₂ no ambiente (%)	[0,01 a 3,0]
Resistência à compressão (MPa)	[20 a 90]
Tempo (anos)	[0 a 60]

Para a definição dos domínios, além da consideração das variáveis influentes no fenômeno da carbonatação, verificou-se também a extensão dos dados disponíveis na literatura, já que estes seriam usados para validar o domínio de aplicabilidade do modelo.

4.2 Implementação e Treinamento das RNA's - Etapa (ii)

Após a montagem do banco de dados, deu-se início aos estudos referentes às redes neurais artificiais (RNAs), iniciando com a implementação da rede, passando pelo treinamento e terminando na validação. Para tal, o banco de dados foi dividido em três partes (dados de treinamento, dados de validação e dados de teste), conforme a Figura 4.2, assegurando que os dados utilizados na geração da rede fossem distintos dos que seriam utilizados na validação e nos testes com o modelo selecionado.




Figura 4.2: Proporção dos dados utilizados em cada fase da modelagem

Após a separação dos dados, passou-se ao treinamento das redes, no qual foram implementadas 1200 RNA's, sendo estas diferenciadas pela taxa de aprendizado (0,1, 0,2, 0,3 e 0,4), pelo número de entradas (4, 5 e 7) (ver Figura 4.3), pela arquitetura interna da rede (uma ou duas camadas de neurônios) e pelo número de neurônios contido em cada camada (de 0 a 9 neurônios). Desta forma, foi feita a combinação de todas as possibilidades de configuração das redes ($4 \times 3 \times 10 \times 10$), totalizando 1200 RNA's.

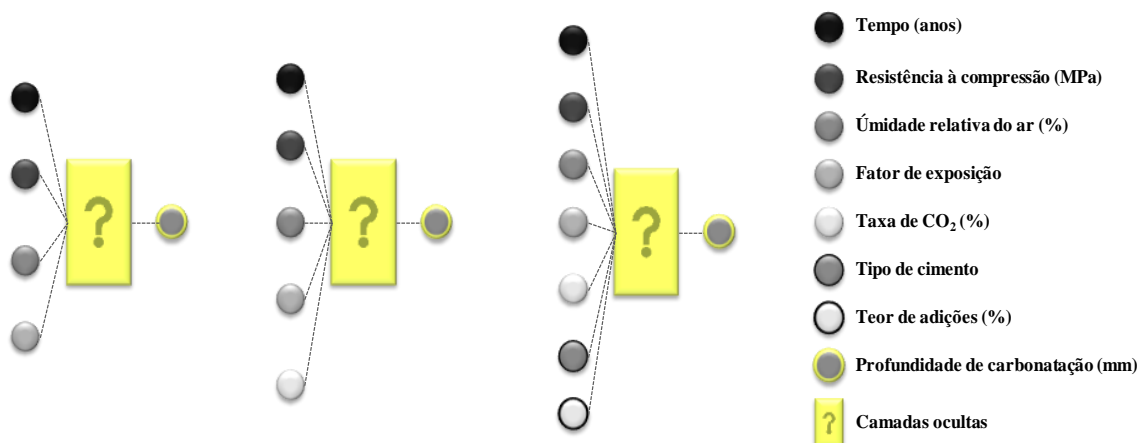


Figura 4.3: Topologias básicas das RNA's implementadas

Para o treinamento das redes, utilizou-se o treinamento supervisionado, adotando os algoritmos de otimização *Back Propagation Classic*, *Delta-Bar-Delta* e *Momentum*, os quais diferenciam-se pelo processo de ajuste dos pesos sinápticos da rede.

Para a criação das redes fez-se uso do pacote computacional PROJECT-YAPY (2011), desenvolvido em conjunto em um projeto de pesquisa de iniciação científica na Universidade Federal da Integração Latino-Americana (UNILA), orientado pelo professor e pesquisador matemático Pedro Konzen. A partir da inserção dos dados, inicia-se o treinamento das redes neurais para a estimativa da profundidade de carbonatação do concreto. Na Figura 4.4 é apresentado uma imagem do processo de treinamento.

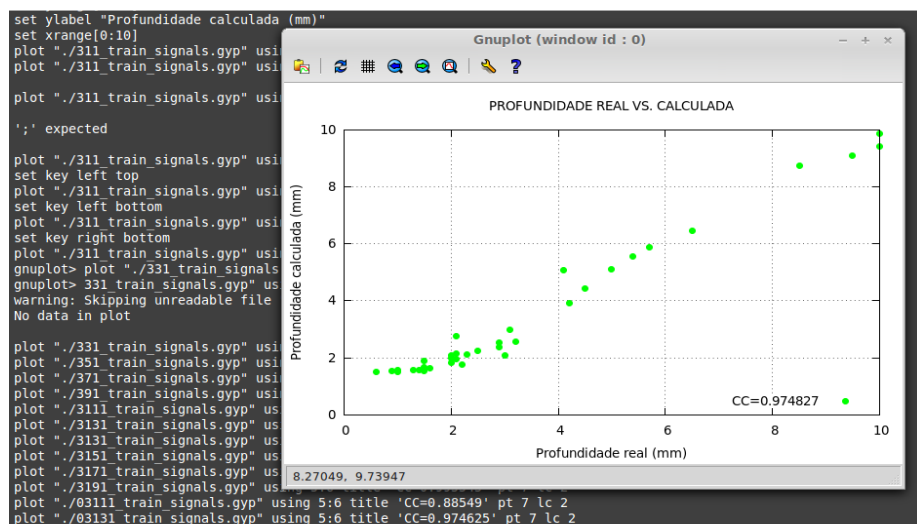


Figura 4.4: Captura de tela de treinamento usando o PROJECT-YAPY

Para o treinamento das RNA's, utilizou-se como critério de convergência a Raiz do Erro Médio Quadrático (*RMSE – Root Mean Square Error*) (Equação 13) entre as saídas reais e as calculadas, além do número máximo de interações permitidas (10^6), uma vez que um grande número de interações pode levar ao “*overfitting*” (treinamento demais da rede).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad \text{Equação 13}$$

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

4.3 Análises Estatísticas e Seleção do Melhor Modelo - Etapa (iii)

Após o treinamento das 1200 redes, os modelos criados passaram por análises estatística (análise da raiz do erro médio quadrático (Equação 13), do coeficiente de determinação (Equação 14), do erro máximo (Equação 15) e do erro mínimo (Equação 16)) quanto às profundidades estimadas e as reais (obtidas da literatura), usando para isto os dados do subconjunto de treinamento e validação (ver Figura 4.2).

$$R^2 = \left(\frac{\sum_{i=0}^{l-1} (t_i - \bar{t})(y_i - \bar{y})}{\sqrt{\sum_{i=0}^{l-1} (t_i - \bar{t})^2 (y_i - \bar{y})^2}} \right)^2 \quad \text{Equação 14}$$

$$E_{max} = \max_i \{|t_i - y_i|\} \quad \text{Equação 15}$$

$$E_{min} = \min_i \{|t_i - y_i|\} \quad \text{Equação 16}$$

Onde, t representa o valor real da profundidade carbonatada, y o valor obtido pela rede e \bar{t} e \bar{y} os valores médios de ambas as variáveis.

Para a seleção do melhor modelo, primeiramente, todas as redes foram separadas quanto ao número de variáveis de entrada (separação das três arquiteturas básicas, conforme indicado na Figura 4.3), realizando em seguida de forma crescente a ordenação do E_{max} obtido na fase de validação.

Na primeira seleção foram escolhidos os cinco modelos que obtiveram os menores valores de E_{max} e E_{min} , utilizando para isto o gráfico de resíduos. Em seguida, para cada uma das tipologias (Figura 4.3) fez-se novamente uma ordenação das redes, porém desta vez em ordem decrescente, ordem essa, em função do coeficiente de determinação entre as saídas desejadas e as obtidas com o modelo na fase de validação, possibilitando assim, a seleção do melhor modelo para cada uma das três tipologias.

Desta forma a seleção do modelo que melhor representa a profundidade de carbonatação foi realizada analisando de forma integrada o coeficiente de determinação e os erros, análise feita tanto para o treinamento quanto para a validação.

4.4 Teste do Modelo - Etapa (iv)

Após determinar o melhor modelo, foram realizadas simulações com dados (não usados no treinamento e na validação) do subconjunto de teste, de modo a verificar se a rede conseguiria representar de forma satisfatória a profundidade de carbonatação do concreto durante o ciclo de vida da estrutura. Neste conjunto de testes analisou-se o comportamento do modelo frente a determinação da profundidade de carbonatação para

diferentes concretos e em diferentes ambientes de exposição. Essas análises foram necessárias para verificar se o modelo era capaz de generalizar os resultados, atendendo o domínio de aplicabilidade imposto no início da modelagem.

Para verificar o grau de confiabilidade do modelo, decidiu-se por realizar uma comparação do mesmo com outros modelos da literatura (Equações 6 – 10 detalhadas no tópico 2.3 do presente trabalho), analisando concretos produzidos com diferentes tipos de cimentos Portland (CP II E, CP II F, CP II Z, CP III, CP IV e CP V).

4.5 Determinação da VUP e da Captura de CO₂ - Etapa (v)

Em posse do modelo para a estimativa da profundidade de carbonatação, foi possível determinar a vida útil de projeto (VUP) de estruturas de concreto armado e a captura de CO₂ devido à carbonatação do concreto ao longo do tempo.

Para a determinação da VUP é feito primeiramente a determinação da curva (profundidade de carbonatação vs. tempo) através do modelo desenvolvido, sendo conhecidas as características do ambiente onde a estrutura está ou será inserida e o cobrimento utilizado na fase de projeto. Tendo como base os preceitos da norma de desempenho NBR 15575 (ABNT, 2013), é possível determinar a VUP do elemento de concreto armado, levando em conta o tempo de desp passivação da armadura.

Ao mesmo tempo que pode-se determinar a VUP, o presente modelo proporciona também a estimativa do cobrimento mínimo da armadura (d) em estruturas de concreto, afim de garantir os 60 anos previsto pela NBR 15575 (ABNT, 2013), limite superior. Para esta determinação, é necessário recorrer ao gráfico obtido pelo modelo para a estrutura em que deseja-se conhecer o cobrimento mínimo e analisar qual a profundidade de carbonatação alcançada ao longo dos 60 anos, impondo uma medida para o cobrimento superior àquela obtida na curva do modelo ($y < d$).

Quanto à captura de CO₂ a mesma é determinada utilizando a Equação 4 definida no capítulo 2, na qual a variável “ y ” (profundidade de carbonatação) é obtida com o modelo desenvolvido, sendo necessário apenas ter o conhecimento das demais variáveis (área superficial, características químicas e consumo de cimento).

4.6 Implementação Final - Etapa (vi)

Com o modelo da profundidade de carbonatação do concreto (y) advindo das RNA's e os derivados deste (VUP, cobrimento mínimo da armadura e Captura de CO₂) passou-se a implementação do software, o qual é o principal objetivo do presente trabalho. O software denominado CARBEM foi desenvolvido primeiramente em linguagem orientada à objetos

5 ANÁLISE DOS MODELOS

Com o propósito de determinar qual dentre as 1200 RNA's apresentava o melhor comportamento para modelar a frente de carbonatação de concreto, selecionou-se as quinze redes com menores E_{max} (erro máximo da rede na validação), sendo cinco redes de cada tipologia básica (com 4, 5 ou 7 neurônios na camada de entrada). Na Tabela 5.1 apresentam-se em ordem sequencial as redes e seus respectivos E_{max} , além da taxa de aprendizado (α) utilizada no processo de treinamento da RNA.

Tabela 5.1: Melhores RNA's em função do E_{max} e da sua tipologia

RNA's com 4 entradas			RNA's com 5 entradas			RNA's com 7 entradas		
Arquitetura	α	E_{max} (mm)	Arquitetura	α	E_{max} (mm)	Arquitetura	α	E_{max} (mm)
[4-7-5-1]	0,4	5,944	[5-4-3-1]	0,4	4,564	[7-4-1]	0,4	3,381
[4-5-2-1]	0,4	5,983	[5-2-1-1]	0,2	4,581	[7-5-3-1]	0,3	3,396
[4-4-2-1]	0,2	6,017	[5-4-1]	0,4	4,679	[7-5-1]	0,3	3,411
[4-3-1]	0,1	6,138	[5-2-1]	0,4	4,685	[7-3-1]	0,2	3,413
[4-5-2-1]	0,1	6,211	[5-3-2-1]	0,3	4,692	[7-3-1]	0,4	3,422

Obs.: A simbologia utilizada para caracterizar uma arquitetura como $[a-b-c-d]$ refere-se "a" uma rede com a neurônios na camada de entrada, "b" neurônios na segunda camada, "c" neurônios na terceira e "d" na saída.

Observa-se na Tabela 5.1 que todas as redes apresentam resultados satisfatórios, já que em média o E_{max} é de 4,70 mm. Ainda de acordo com a Tabela 5.1, na primeira linha encontram-se os melhores modelos para cada tipologia (analisando apenas o erro máximo).

Afim de determinar qual dos três modelos apresentava o melhor comportamento foram feitas análises da correlação (R^2) para cada uma das três arquiteturas (Figuras de 5.1 a 5.3).




Figura 5.1: Rede [4-7-5-1]




Figura 5.2: Rede [5-4-3-1]




Figura 5.3 c: Rede [7-4-1]

Nas Figuras 5.4 e 5.5 são apresentadas respectivamente as correlações do treinamento e da validação da rede com arquitetura [4-7-5-1] que se baseia na seguinte estrutura: quatro entradas, sete neurônios na primeira camada oculta, cinco neurônios na segunda camada oculta e uma saída.




Figura 5.4: Correlação no treinamento

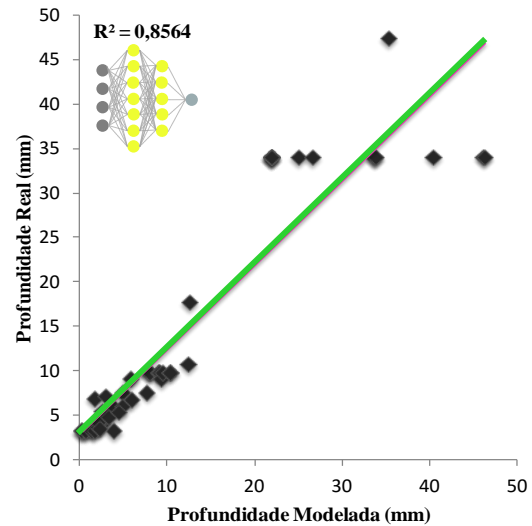


Figura 5.5: Correlação na validação

Nas Figuras 5.6 e 5.7 são apresentadas, respectivamente, as correlações do treinamento e da validação da rede com arquitetura [5-4-3-1], que se baseia na seguinte estrutura: cinco entradas, quatro neurônios na primeira camada oculta, três neurônios na segunda camada oculta e uma saída.




Figura 5.6: Correlação no treinamento

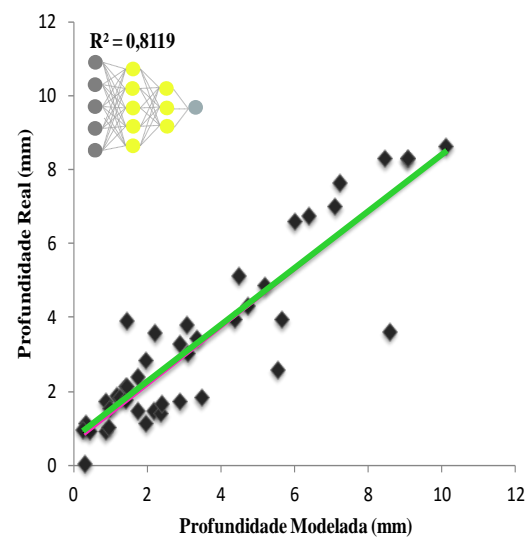


Figura 5.7: Correlação na validação

Nas Figuras 5.8 e 5.9 são apresentadas, respectivamente, as correlações do treinamento e da validação da rede com arquitetura [7-4-1], que se baseia na seguinte estrutura: sete entradas, quatro neurônios na camada oculta e uma saída.




Figura 5.8: Correlação no treinamento




Figura 5.9: Correlação na validação

Os três modelos apresentaram resultados satisfatórios, tanto no treinamento quanto na validação. Porém, à medida que o número de variáveis de entrada é aumentado, a correlação entre a profundidade de carbonatação real e a profundidade calculada pelo modelo também aumenta. Tal fato demonstra que quanto maior e mais significativo for o conjunto de variáveis de entrada, maior será a capacidade das RNA's em aprender o comportamento da carbonatação do concreto.

Percebe-se ainda que com a utilização do maior número de variáveis de entrada significativas para o estudo da carbonatação, a rede conseguiu associar de forma mais fácil a relação entre as variáveis de entrada e a saída desejada, gerando um modelo melhor (menor erro), garantindo correlações semelhantes na fase de treinamento e de validação. Outro aspecto relevante é que a medida que foi aumentado o número de entradas diminuiu-se o número de neurônios necessários nas camadas de processamento, demonstrando a otimização do aprendizado pela rede.

A Tabela 5.2 apresenta os resultados referentes às análises realizadas durante a fase de validação com cada um dos três modelos selecionados.

Tabela 5.2: Resultados da validação com os melhores modelos

Arquitetura	RMSE	R ²	E _{max}	E _{min}
[4-7-5-1]	1,199	0,856	5,944	0,054
[5-4-3-1]	1,053	0,811	4,564	0,012
[7-4-1]	0,812	0,981	3,381	0,004

Analisando a Tabela 5.2, nota-se que a rede de arquitetura [7-4-1] apresenta a melhor correlação frente à fase de teste, assim como nas fases de treinamento e validação (Figuras 5.8 e 5.9). É possível verificar ainda que esta rede apresenta os menores erros (RMSE, E_{max} e E_{min}), sendo escolhida como o melhor modelo dentre todas as 1200 redes projetadas neste trabalho.

Como objetivo de confirmar os resultados obtidos com a rede [7-4-1], eleita como a melhor dentre todas as implementadas, apresenta-se na Figura 5.10 o gráfico de resíduos do modelo durante fase de testes, comprovando a capacidade do modelo estimar a profundidade de carbonatação de dados diferentes dos conjuntos de treinamento e validação, simulando assim, a situações de uso real.





Figura 5.10: Resíduos da diferença entre a profundidade real e a calculada pelo modelo

O modelo [7-4-1] apresentou resultados excelentes, sendo que o mesmo obteve uma correlação na fase de testes de 0,994 e RMSE de 0,840 mm. Desta forma, o erro médio apresentado pelo modelo para a estimativa da profundidade de carbonatação dentro do domínio de aplicabilidade é inferior a 1 mm, o que corresponde a medida de erro de um paquímetro digital (instrumento de medida da profundidade carbonatada), enquanto que o erro máximo ao qual o modelo está submetido é de 3,40 mm. Estes resultados comprovam o poder de interpolação e aprendizado das RNA's frente a problemas complexos.


Afim de comparar o modelo [7-4-1] com outros da literatura (Equações 2.6-2.10), os quais foram detalhados no tópico 2.3 do presente trabalho, apresentam-se nas Figuras 5.11-5.16 simulações para o avanço da profundidade de carbonatação de concretos com diferentes ambientes de exposição (Tabelas 5.3 – 5.8) e com os diferentes tipos de cimentos Portland (CP II E, CP II F, CP II Z, CP III, CP IV e CP V) comercializados no Brasil.



Quadro 5.1: Estrutura I

Resistência à compressão (Mpa)	30
Taxa de CO ₂ (%)	0,04
Teor de adições (%)	0
UR (%)	70
Fator de exposição	1,3
Tipo de cimento	CP II - E

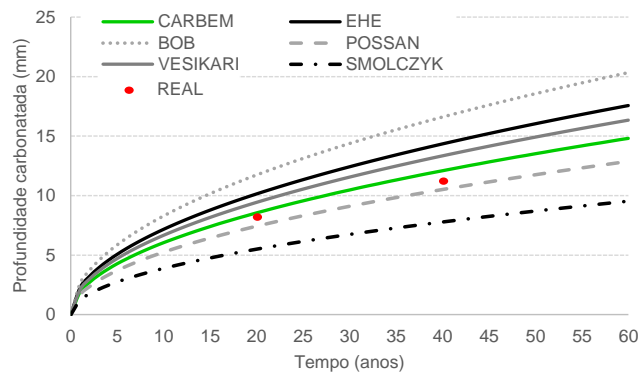
Figura 5.11: Estimativa da profundidade de carbonatação do concreto – estrutura I



Quadro 5.2: Estrutura II

Resistência à compressão (Mpa)	40
Taxa de CO ₂ (%)	0,01
Teor de adições (%)	0
UR (%)	70
Fator de exposição	1,0
Tipo de cimento	CP II - F


Figura 5.12: Estimativa da profundidade de carbonatação do concreto – estrutura II




Quadro 5.3: Estrutura III

Resistência à compressão (Mpa)	40
Taxa de CO ₂ (%)	0,01
Teor de adições (%)	0
UR (%)	70
Fator de exposição	1,0
Tipo de cimento	CP II - Z


Figura 5.13: Estimativa da profundidade de carbonatação do concreto – estrutura III


Quadro 5.4: Estrutura IV

Resistência à compressão (Mpa)	40
Taxa de CO ₂ (%)	0,01
Teor de adições (%)	0
UR (%)	70
Fator de exposição	1,0
Tipo de cimento	CP III

Figura 5.14: Estimativa da profundidade de carbonatação do concreto – estrutura IV

Quadro 5.5: Estrutura V

Resistência à compressão (Mpa)	40
Taxa de CO ₂ (%)	0,01
Teor de adições (%)	0
UR (%)	70
Fator de exposição	0,65
Tipo de cimento	CP IV

Figura 5.15: Estimativa da profundidade de carbonatação do concreto – estrutura V

Quadro 5.6: Estrutura VI

Resistência à compressão (Mpa)	40
Taxa de CO ₂ (%)	0,01
Teor de adições (%)	0
UR (%)	70
Fator de exposição	0,65
Tipo de cimento	CP V

Figura 5.16: Estimativa da profundidade de carbonatação do concreto – estrutura IV

De forma a verificar a generalização do modelo dentro do domínio de aplicação (interpolação da rede), são apresentadas as Figuras de 5.17 até 5.22, as quais são superfícies que representam a profundidade carbonatada ao longo da VUP das estruturas de concreto variando a resistência à compressão aos 28 dias (MPa). Pode-se ainda notar que todas as superfícies possuem comportamento exponencial característico do avanço da profundidade com o tempo, e que a medida que é aumentada a resistência à compressão do concreto, diminui-se a profundidade, devido a diminuição da porosidade da matriz cimentante, dificultando a difusão do dióxido de carbono no concreto.




Figura 5.17: Superfície de profundidade de concreto com CP II E




Figura 5.18: Superfície de profundidade de concreto com CP II F




Figura 5.19: Superfície de profundidade de concreto com CP II Z




Figura 5.20: Superfície de profundidade de concreto com CP III




Figura 5.21: Superfície de profundidade de concreto com CP IV




Figura 5.22: Superfície de profundidade de concreto com CP V

OBS.: Para todos os cálculos os concretos estavam inseridos sobre o seguinte cenário: (I) teor de CO₂ de 0,04 %; (II) concretos sem adições; (III) UR de 70 %; (IV) ambiente interno protegido da chuva;

Pela análise das superfícies (Figuras 5.17- 5.22) verifica-se que o banco de dados utilizado na modelagem é representativo, devido a inexistência de picos nos gráficos, demonstrando a adequação do mesmo ao estudo.

O somatório das análises estatísticas (correlação e erro residual) e a suavização das superfícies permitiram comprovar que as RNA's possibilitaram de forma eficaz reconhecer e mapear o comportamento do fenômeno físico-químico da carbonatação, indicando que a rede treinada pode ser utilizada na representação da carbonatação do concreto.

6 SOFTWARE CARBEM

6.1 Implementação

Conforme discutido nos resultados o modelo [7-4-1] apresentou o melhor mapeamento da profundidade carbonatada, obtendo bons resultados quanto a suas estimativas, o qual foi escolhido para a implementação de um software para a determinação da profundidade de carbonatação do concreto. E em função dessa medida (y), foi possível implementar modelos para a determinação da vida útil de projeto (t_{VUP}), do cobrimento mínimo da armadura (d) e da captura de CO_2 pelo concreto (C_{CO_2}). O software tem como propósito ser uma ferramenta computacional de fácil utilização para auxílio aos profissionais da área de construção civil, agregando o conhecimento científico e tecnológico à área de patologia de estruturas de concreto.

Assim, o software CARBEM⁴ além de estimar a profundidade de carbonatação do concreto, possibilita a determinação de três outras estimativas, sendo elas: (I) VUP, (II) cobrimento mínimo da armadura e (III) captura de CO_2 , obtidas de acordo com o fluxograma da Figura 6.1.

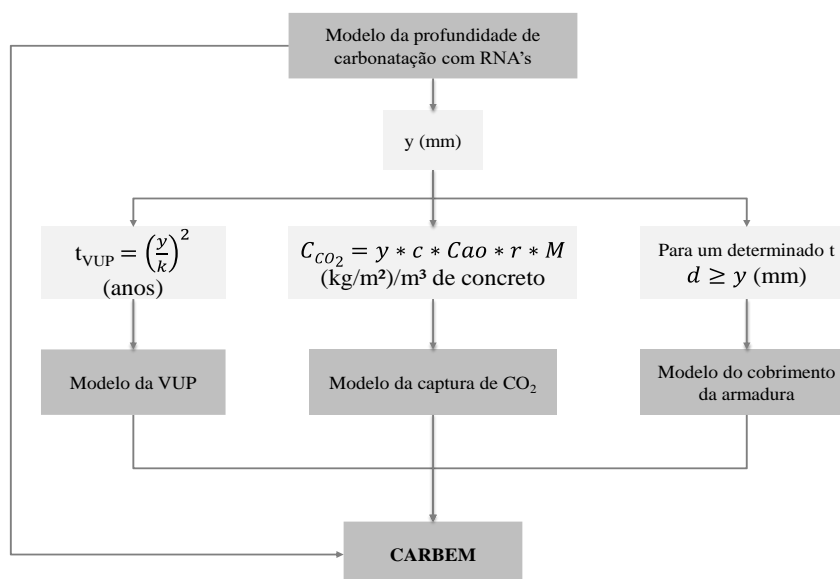


Figura 6.1: Fluxograma da metodologia para obtenção dos outros modelos

Onde, k representa a velocidade do avanço da frente de carbonatação do concreto, y é a profundidade (mm), t_{VUP} é o tempo de vida útil da estrutura (anos), C_{CO_2} representa a quantidade de CO_2 capturado pelo concreto ($kg/m^2/m^3$ de concreto), c é a quantidade de cimento para a produção de $1 m^3$ de concreto (kg), CaO é a quantidade de óxido de cálcio contido no cimento, r é a proporção de CaO totalmente carbonatada, ou seja, transformada em $CaCO_3$, M é a fração molar do CO_2/CaO e d é o cobrimento mínimo da armadura (mm).

⁴ O nome CARBEM originou-se da junção das palavras carbonatação (CARB) e emissão (EM), ambas correlacionadas ao dióxido de carbono (CO_2), o qual é objetivo de estudo no presente trabalho.

O desenvolvimento do software foi realizado primeiramente em linguagem orientada à objetos C++, e posteriormente transferido para linguagem JAVA no ambiente de desenvolvimento NetBeans IDE 8.1® compatível com o sistema operacional Windows® da empresa Microsoft®. Nas Figuras 6.2 e 6.3 são apresentados respectivamente imagens referentes a um dos códigos implementados em linguagem JAVA e a tela (interface) gerada pelo programa NetBeans.

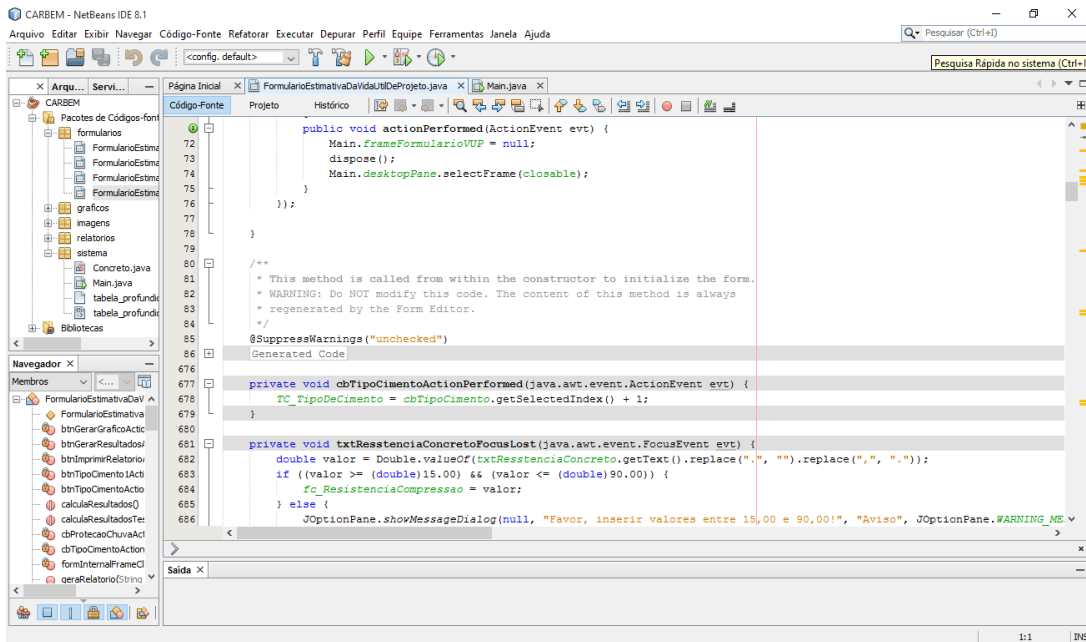


Figura 6.2: Desenvolvimento da tela referente a estimativa da profundidade em linguagem JAVA

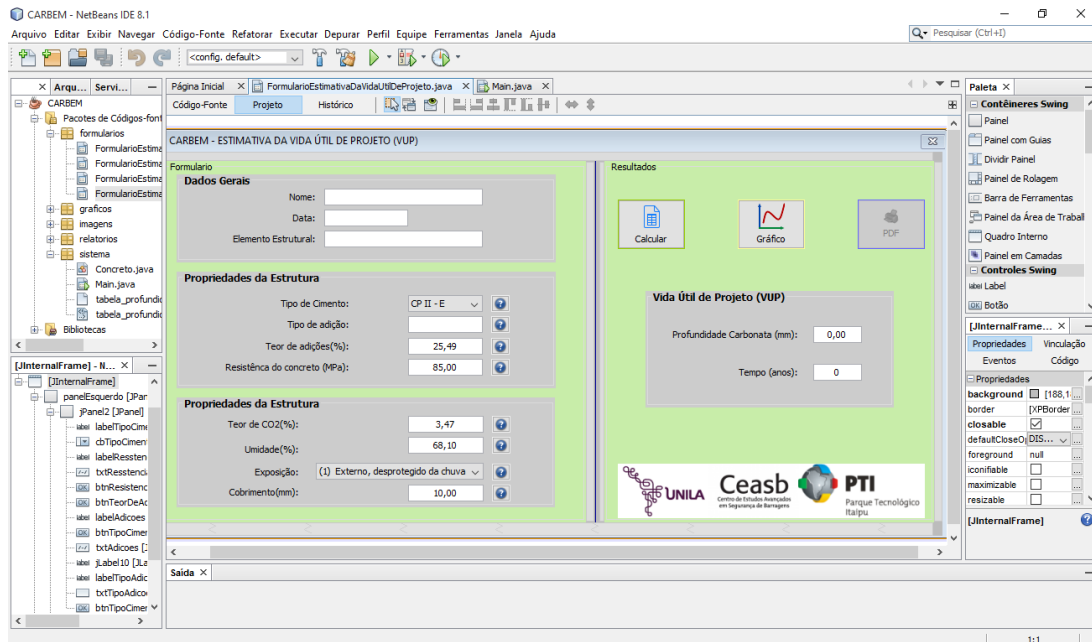


Figura 6.3: Desenvolvimento da tela referente a estimativa da profundidade (interface)

6.2 Tutorial do CARBEM

Ao ser aberto, o CARBEM irá exibir a sua tela de boas-vindas (tela principal do software), a qual apresenta um breve resumo das ferramentas disponíveis e considerações tomadas no desenvolvimento do modelo (Figura 6.4).



Figura 6.4: Tela principal do CARBEM

Na Figura 6.5 apresentam-se as funções da tela de estimativa da profundidade de carbonatação. Como observa-se nesta tela o usuário deve inserir informações para que seja feito o cálculo da profundidade ao longo do tempo, e o mesmo pode ainda obter um relatório do avanço da profundidade com o tempo em distintas formas, gráfico ou Tabela.

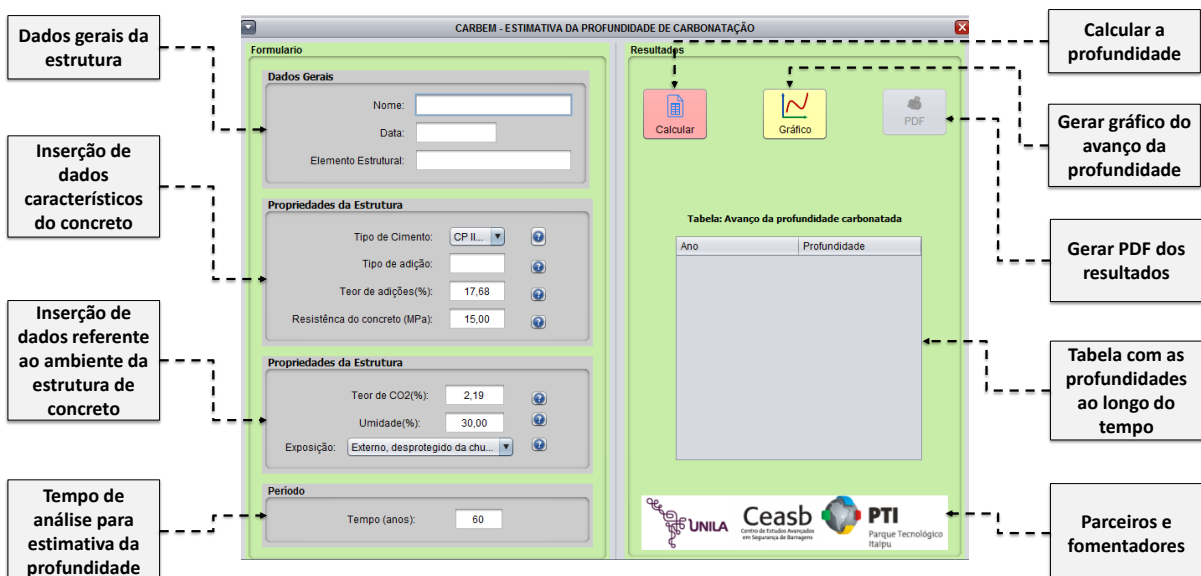


Figura 6.5: Tela da estimativa da profundidade de carbonatação (y)

Como exemplo, a seguir serão descrito os passos para obter a estimativa da profundidade carbonatada com o tempo. Sendo a estrutura de concreto uma viga com as características segundo a Figura 6.6, o usuário deve digitar todas as informações necessárias na tela do programa e em seguida selecionar a opção “Calcular”, nesse momento o algoritmo será chamado e realizará todos os cálculos, informando na tela os resultados através de uma Tabela, caso o usuário queira analisar o avanço da profundidade em forma gráfica o mesmo deve selecionar a opção “Gráfico”, e caso necessite salvar ou imprimir os resultados pode-se ainda gerar um arquivo selecionando para tal a opção “PDF”. Na Figura 6.7 apresenta-se os resultados que são obtidos para os dados da Figura 6.6 utilizando o CARBEM.




Figura 6.6: Características da viga




Figura 6.7: Resultados obtidos através do CARBEM para a profundidade de carbonatação

Para a determinação da VUP de estruturas de concreto armado, primeiramente deve ser selecionada a opção correspondente, na tela principal, e em seguida será aberta uma nova tela conforme vê-se na Figura 6.8. Para obter uma estimativa da VUP deve-se inserir todos os dados solicitados na tela selecionando depois a opção “Calcular”, nesse momento o algoritmo será chamado e realizará todos os cálculos, informando na tela a VUP (anos), caso o usuário queira analisar o avanço da profundidade em forma gráfica o mesmo deve selecionar a opção “Gráfico”, e caso necessite salvar ou imprimir os resultados pode-se ainda gerar um arquivo selecionando para tal a opção “PDF”. Na Figura 6.9 apresentam-se os resultados que são obtidos para os dados da Figura 6.6 utilizando o CARBEM.

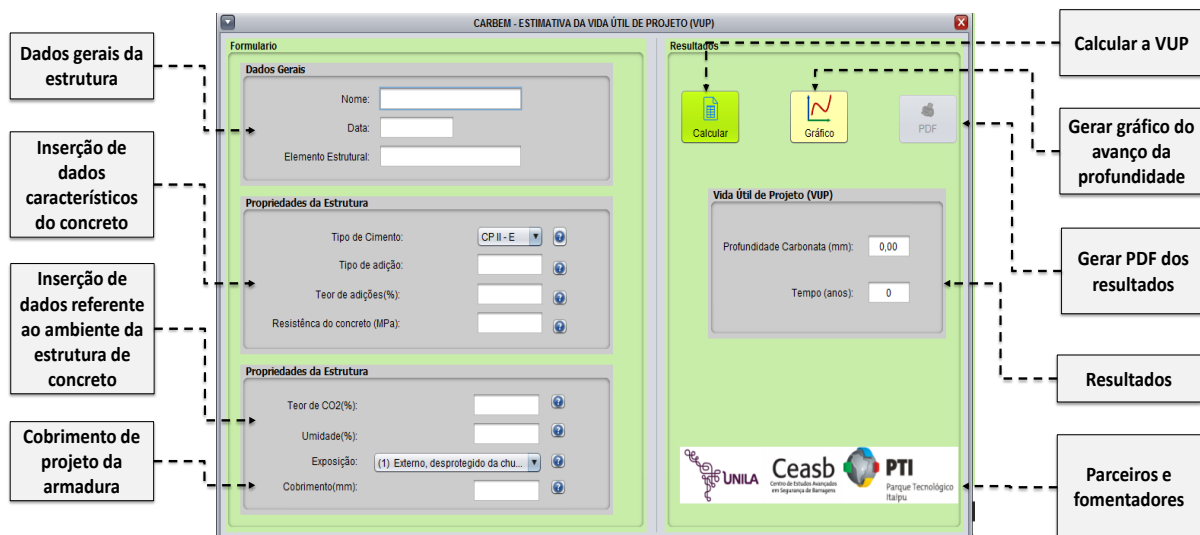


Figura 6.8: Tela da estimativa da VUP (t_{vup})




Figura 6.9: Resultados obtidos através do CARBEM para a vida útil de projeto

Para a determinação do cobrimento mínimo da armadura de estruturas de concreto armado, primeiramente deve ser selecionada a opção correspondente, na tela principal, e em seguida será aberta uma nova tela conforme vê-se na Figura 6.10. Para a obtenção do cobrimento é necessário inserir todos os dados solicitados na tela, selecionando depois a

opção “Calcular”, nesse momento o algoritmo será chamado e realizará todos os cálculos, informando na tela valor do cobrimento mínimo (mm) (sobre este valor já está acrescentado o erro do modelo de predição da profundidade carbonatada), caso o usuário queira analisar o avanço da profundidade em forma gráfica o mesmo deve selecionar a opção “Gráfico”, e caso necessite salvar ou imprimir os resultados pode-se ainda gerar um arquivo selecionando para tal a opção “PDF”. Na Figura 6.11 apresentam-se os resultados que são obtidos para os dados da Figura 6.6 utilizando o CARBEM.

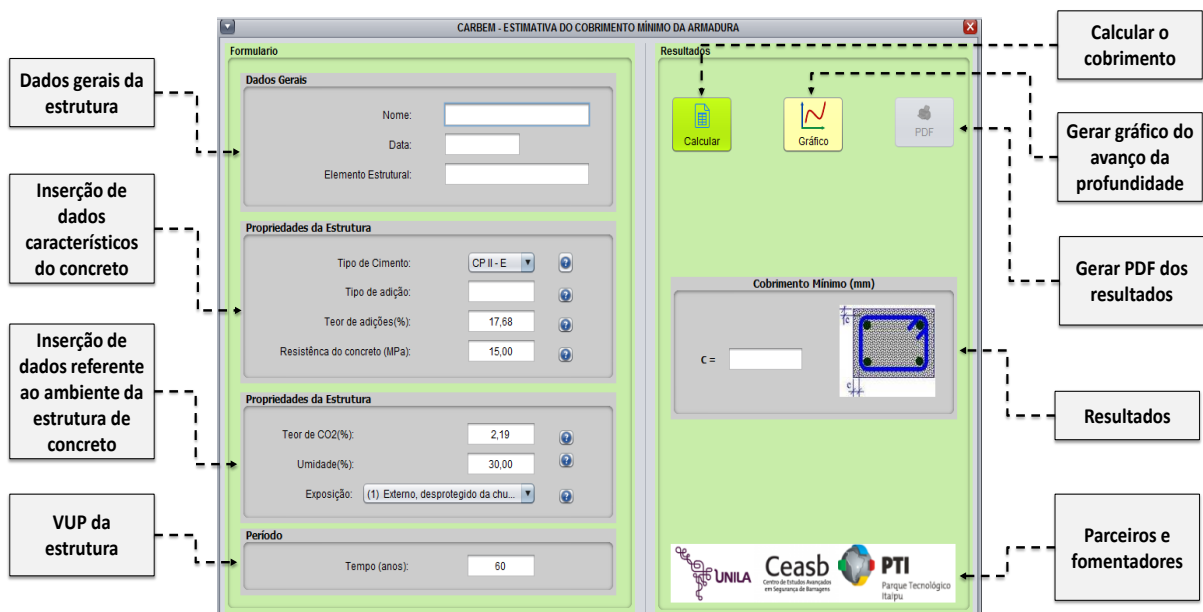


Figura 6.10: Tela da estimativa do cobrimento mínimo (d)




Figura 6.11: Resultados obtidos através do CARBEM para determinação do cobrimento da armadura

Por fim, se o usuário estiver interessado em determinar qual a captura de CO₂ pelo concreto o mesmo deve primeiramente selecionar a opção correspondente na tela principal, e em seguida será aberta uma nova tela conforme vê-se na Figura 6.12. Para a obtenção do cobrimento é necessário inserir todos os dados solicitados na tela, selecionando depois a opção “Calcular”, nesse momento o algoritmo será chamado e realizará todos os cálculos, informando na tela valor do cobrimento mínimo (mm) (sobre este valor já está acrescentado

o erro do modelo de predição da profundidade carbonatada), caso o usuário queira analisar o avanço da profundidade em forma gráfica o mesmo deve selecionar a opção “Gráfico”, e caso necessite salvar ou imprimir os resultados pode-se ainda gerar um arquivo selecionando para tal a opção “PDF”. Na Figura 6.13 apresentam-se os resultados que são obtidos para os dados da Figura 6.6 utilizando o CARBEM. Em seguida na Figura 6.14 apresenta-se o método de cálculo para determinar a quantidade de CO₂ absorvida por vigas de diferentes seções transversais, dado o resultado obtido pelo CARBEM para a taxa de absorção do concreto (ver Figura 6.14).

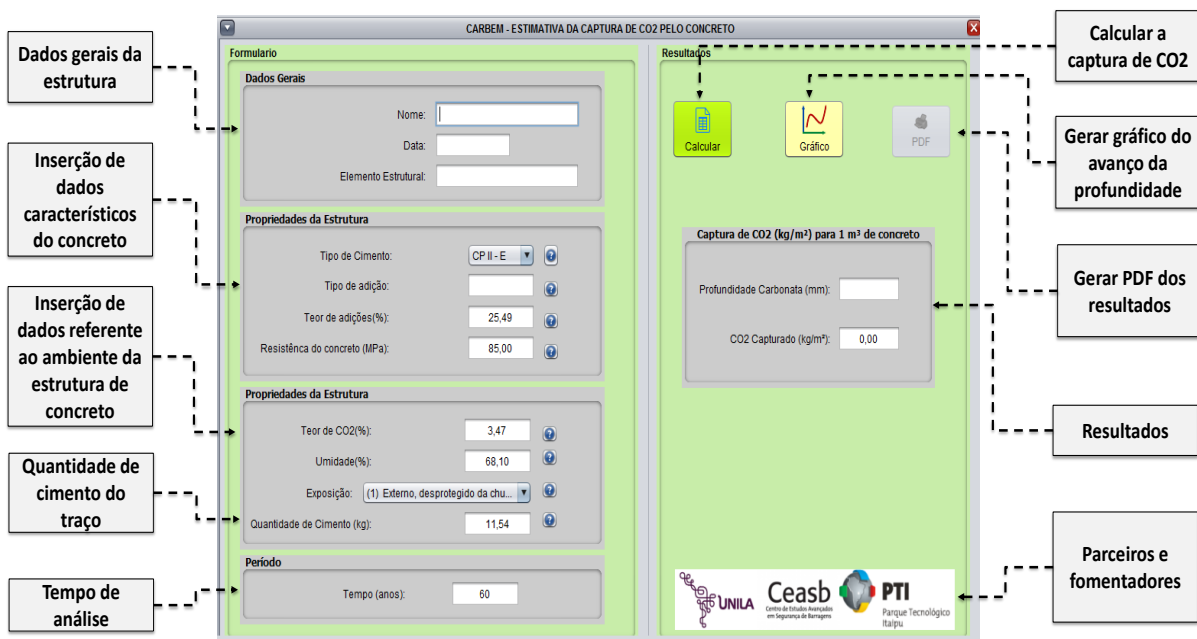


Figura 6.12: Tela da estimativa da captura de CO₂ (C_{CO_2})





Figura 6.13: Resultados obtidos através do CARBEM para determinação da captura de CO₂

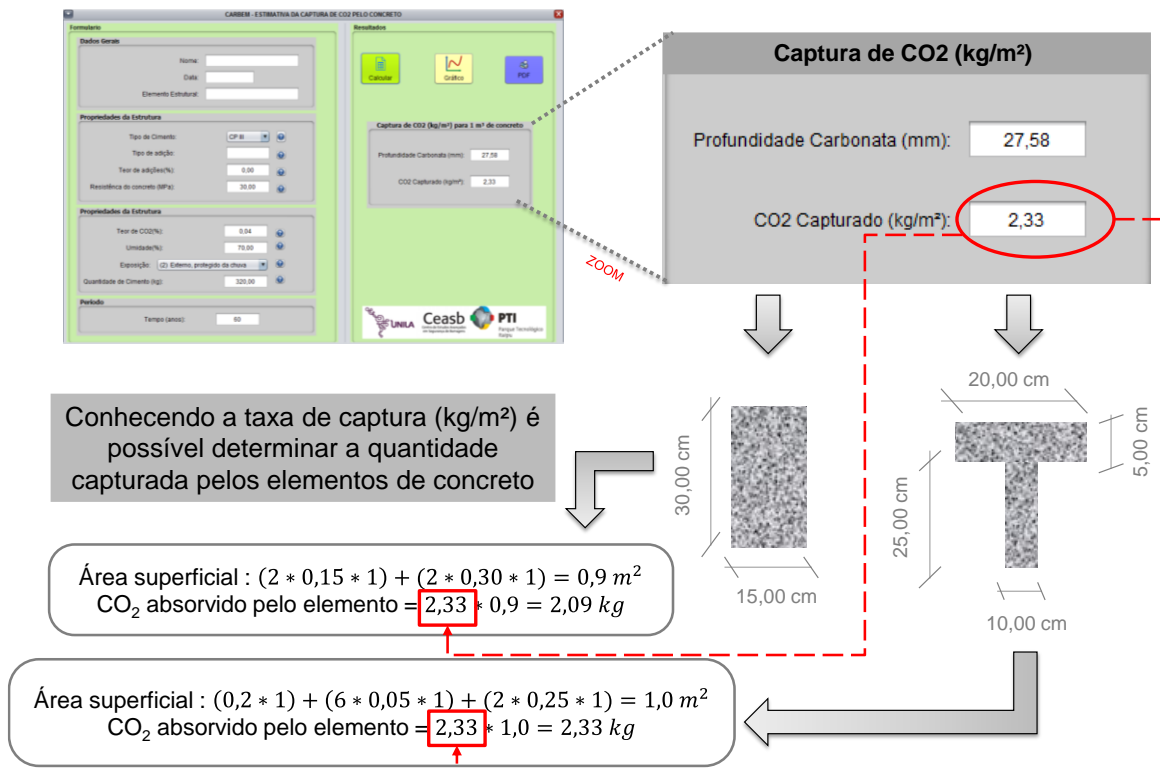


Figura 6.14: Determinação da quantidade de CO₂ capturado

7 CONCLUSÕES E SUJESTÕES PARA TRABALHOS FUTUROS

De forma geral, com presente trabalho pode-se fazer as seguintes conclusões:

a) Quanto à modelagem:

- A determinação de um banco de dados robusto e confiável torna-se necessário e indispensável quando necessita-se realizar a modelagem de problemas via RNA's, e que o mesmo deve ser dividido entre os subconjuntos de treinamento, validação e teste de forma permaneça a representatividade, evitando possíveis erros na criação e nas análises dos resultados do modelo;
- O treinamento das diferentes tipologias permitiu analisar que o número de camadas ocultas (camadas de processamento da rede) não necessita ser extenso (duas são suficientes), e na medida em que aumenta-se o número de entradas (que tenham correlação com a saída) o número de camadas e de seus neurônios podem ser reduzidos significativamente;
- Devido ao número de variáveis utilizadas no modelo e da representatividade dos conjuntos de treinamento e validação, verificou-se que a melhor rede apresentou ótima interpolação (aprendizado dentro do domínio de aplicabilidade), devido à suavização verificada nos gráficos das superfícies para os diferentes tipos de concretos;
- Diante das 1200 redes, com distintas arquiteturas, foi possível analisar que a medida que agrega-se informações (variáveis) a modelagem, o processo de treinamento das RNA's torna-se otimizado, minimizando o tempo de iterações e o erro médio do modelo;
- Os resultados apresentados pela rede de arquitetura [7-4-1] durante as fases de treinamento, validação e teste, confirmaram a hipótese de que as redes neurais artificiais (RNA's) resultam em uma robusta e eficiente ferramenta computacional para a modelagem de problemas complexos e não-lineares, como é o caso da difusão do CO₂ no concreto (carbonatação);
- Verificou-se que o modelo gerado representa uma alternativa viável e confiável para a estimativa da profundidade de carbonatação, e que o mesmo quando comparado com outros modelos da literatura, apresenta um comportamento adequado e eficiente para o tipo de função mapeada;

b) Quanto aos modelos gerados:

- Ao somar-se as análises estatísticas (correlação e erro residual) e a suavização das superfícies, comprovou-se que as RNA's possibilitaram de forma eficaz reconhecer e mapear o comportamento do fenômeno físico-químico da carbonatação, indicando que a rede treinada pode ser utilizada na representação da carbonatação do concreto.
- O modelo com arquitetura [7-4-1] apresentou ótimos resultados e o melhor comportamento frente a estimativa da carbonatação do concreto (erro máximo de 3,8 mm e correlação de 0,98), o qual possibilitou a implementação de uma ferramenta computacional que determinasse a profundidade para diferentes concretos;
- O modelo determinado com as RNA's possibilitou determinar outras estimativas que possuem como variável principal a profundidade de carbonatação, sendo estas, a estimativa da vida útil de projeto (período de despassivação da armadura de estruturas de concreto armado), a estimativa do cobrimento mínimo para garantir a VUP de um elemento de concreto armado e a estimativa da taxa de CO₂ que é absorvido pelo substrato ao longo da vida da estrutura em função da sua área superficial;

c) Quanto ao software desenvolvido:

- O CARBEM se caracteriza como uma ferramenta computacional robusta em termos de algoritmo, e simplificada quanto a sua interação máquina-usuário;
- O software é um sistema que acopla quatro modelos distintos, ao qual otimiza tempo e esforço do usuário;
- O CARBEM é uma ferramenta que difunde a utilização de modelos gerados via RNA's;
- O software auxiliará profissionais do setor construtivo, por exemplo, técnicos, engenheiro, arquitetos e projetistas, além de agregar conhecimento ao meio científico correlacionado a área de patologias de estruturas de concreto;

Visando contribuir com o desenvolvimento de pesquisas na área de durabilidade e vida útil de estruturas de concreto, a seguir estão descritas algumas sugestões para futuros trabalhos:

- Modificar o algoritmo de treinamento do gradiente da função erro utilizado neste trabalho (*BackPropagation*) para verificar se o treinamento pode ser otimizado;

- Estudar e modelar o período de pós-despassivação da armadura (corrosão) utilizando as RNA's;
- Desenvolver um software para a determinação da vida útil de estruturas de concretos, levando em consideração tanto o período de despassivação quanto de corrosão;
- Modelar por intermédio das RNA's o comportamento das estruturas de concreto frente à outros processos de degradação, por exemplo, reação álcalis agregado (RAA), difusão de sulfatos e cloretos;
- Criar um software capaz de realizar o balanço das emissões de CO₂ em elementos à base de concreto, considerando às emissões e a carbonatação ao longo da vida útil.

REFERÊNCIAS BIBLIOGRÁFICAS

- AÏCTIN, P. C. **Concreto de alto desempenho**. 1. ed. São Paulo: Pini, 2000. 667p.
- AMERICAN CONCRETE INSTITUTE. **Service Life Prediction – State-of-the-Art Report**: reported by ACI comitee 365. 2000.
- ANDRADE, A. F.; FARIA, M. B.; CENTENO, J. A. S. **Classificação de Imagens de Alta Resolução Integrando Variáveis Espectrais e Forma Utilizando Redes Neurais Artificial**. In: XI Simpósio Brasileiro de Sensoriamento Remoto, 2003, Belo Horizonte. Anais do XI Simpósio Brasileiro de Sensoriamento Remoto. 2003.
- ANDRADE, C. **Manual para diagnóstico de obras deterioradas por corrosão de armaduras**. Trad. De Antonio Carmona e Paulo Helene. São Paulo, Pini, 1992.
- ARANHA, P. M. **Contribuição ao estudo das manifestações patológicas em estruturas de concreto armado na região Amazônica**. 1994, 161f. Dissertação (Mestrado em Engenharia) – Curso de Pós-Graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre, 1994.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15575-2**: Edifícios Habitacionais – Desempenho – Parte 2: Requisitos para os sistemas estruturais, Rio de Janeiro, 2013. 32p.
- _____. **NBR 6118**: projeto de estruturas de concreto – procedimento. Rio de Janeiro, 1968, rev. maio, 2014
- BAKKER, R.F.M. **Initiation period**: Corrosion of steel in concrete. London: Chapman and Hall, 1988.
- BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. C. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora, 2000. 262p.
- BOB, C.; AFANA, E. On-site assessment of concrete carbonation. **Proceedings of the International Conference Failure of Concrete Structures, RILEM**, Bratislava, Rep. Eslovaca, 1993, p. 84–87.
- BREGA, J. R. F. **A utilização de redes neurais artificiais em um sistema de gerência de pavimentos**. São Carlos. Tese (Doutorado). Escola de Engenharia de São Carlos. Universidade de São Paulo, 1996.

BRITISH STANDARDS INSTITUTION. **Durability of Building Elements, Products and Components**. BS 7543. Londres, 1992.

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

COMIÇÃO PERMANENTE DEL HORMIGÓN. **EHE: Instrucción de Hormigón Estructural**. Ministério de obras públicas e urbanismo. Madri, Espanha, 2008.

COMITE EURO-INTERNATIONAL DU BETON. **CEB 238: new approach to durability design: an example for carbonation induced corrosion**. Bulletin d' Information, Suecis, n. 238, may 1997, 138p.

CYBENKO, G. Approximation by Superpositions of a Sigmoid Function In: **Mathematics of Control, Signals and Sstems**, pp.303-314, 1989.

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

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

FAUSETT, L. **Fundamentals of Neural Networks: Architectures, Algorithms, and Applications**, Ed. Prentice Hall, 1993, ISBN 9780133341867.

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

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

- FLECK, E. M.; PEDREIRA, C. E.; SANTOS, R. **Agrupamento de dados sísmicos através do algoritmo de Kohonen**. In: Congresso Brasileiro de Redes Neurais, 6., São Paulo. Anais. São Paulo, 2003.
- FWA, T. F.; CHAN, W. T. Priority rating of highway maintenance needs by neural networks. **Journal of Transportation Engineering of the ASCE**, v. 119 n° 3 p. 419-432, 1993.
- GAJDA, J.; MILLER, F. M. Concrete as a Sink for Atmospheric Carbon Dioxide: A Literature Review and estimation of CO₂ Absorption by Portland Cement Concrete. **PCA, Chicago, R&D** Serial no. 2255, 2000.
- GALAN, I. et al. Sequestration of CO₂ by concrete carbonation. **Environmental Science & Technology**, p.3181–3186, 2010.
- GALO, M. L. B. T. **Aplicações de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo**. 2005. Tese (Doutorado), Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, 2005.
- GALVÃO, W. S.; MENESES, P. R. **Geração de mapa de potencial à alocação de estações na bacia do rio São Francisco como um produto estratégico de apoio às ações de planejamento de redes fluviométricas, através do uso e do classificador neural supervisionado**. Simpósio Brasileiro de Sensoriamento remoto, 12 Goiânia. Anais. Goiânia: INPE, 2005.
- Häkkinen, T., **Influence of high slag contents on the basic mechanical properties and carbonation of concrete**. VTT publications N° 141, Espoo, Finland, 1993.
- HAMADA, M. Neutralization (carbonation) of concrete and corrosion of reinforcing steel. In: International Symposium on the Chemistry of Cement, 5, 1969. Tokyo. **Proceedings...** Tokyo, 1969, Part III, v. II/4, p.343-369.
- HAYKIN, S. **Redes Neurais: Princípios e Práticas**. Porto Alegre: Editora Bookman, 2001. 900p.
- HELENE, P., R. L. **Corrosão das Armaduras em Concreto Armado**. In: Simpósio de Aplicação da Tecnologia do Concreto, 4, Campinas, 1981. SIMPATCON: QDLV-Campinas, Concrelix, 1981.
- HELENE, P. R. L. **Contribuição ao estudo da corrosão em armaduras de concreto armado**. 1993, 231f. Tese (Livre Docência) – Departamento de Engenharia Civil, Escola Politécnica da Universidade de São Paulo, São Paulo, 1993.

HOUST, Y. F.; WITTMANN, F. H. Depth profiles of carbonates formed during natural carbonation. **Cement and Concrete Research**, v. 32, n. 12, p. 1923-1930, 2002.

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

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

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **Buildings and Constructed Assets – Service Life Planning**. ISO 15.686. Genebra, 2000.

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

JACOBSEN, S.; JAHREN, P. **Binding of CO₂ by Carbonation of Norwegian OPC Concrete**. CANMET/ACI International Conference on Sustainability and Concrete Technology, Lyon, 2002.

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

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

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

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

MARTINS, A. R.; MONTICELLI, I.; CAMARINI, G. Carbonatação em concretos submetidos a diferentes procedimentos de cura. In: Congresso Brasileiro do Cimento, 43º, Foz do Iguaçu, 2001. **Anais...** São Paulo: Instituto Brasileiro do Concreto, 2001 (CD-ROM).

MINISTERIO DE FOMENTO. Instrucción de Hormigón Estructural – **EHE**. Madrid, 1993.

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

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

OLIVEIRA, A. R. **Redes Neurais Artificiais Aplicadas na Detecção, Classificação e Localização de Defeitos em Linhas de Transmissão**. 2005. Dissertação (Mestrado em Engenharia) - Escola de Engenharia, Programa de Pós-Graduação em Engenharia Elétrica, UFJF, Juiz de Fora.

OLIVEIRA, C. T. A. **Água dos poros de pastas de cimento de escória**. Tese (Doutorado). Escola Politécnica da Universidade de São Paulo. São Paulo, 2000.

PADE, C.; GUIMARÃES, M. The CO₂ uptake of concrete in a 100 year perspective. **Cement and Concrete Research**, v 37, p. 1348–1356, 2007.

PAPADAKIS, V. G.; VAYENAS, C. G.; FARDIS, M. N. **Fundamental Modeling and Experimental Investigation of Concrete Carbonation**. **ACI Journal**, v.88, n.4, July-Auguste, 1991.

PARROT, L. J. **A review of carbonation in reinforced concrete**. Cement and concrete Association report, 1987.

PARROT, L. J. Variations of water absorption rate and porosity with depth from an exposed concrete surface: effects of exposure conditions and cement type. **Cement and Concrete Research**, v.22, p. 1077-1088, 1992.

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

POSSAN, E. **Contribuição ao estudo da carbonatação do concreto com adição de sílica ativa em ambiente natural e acelerado**. 2004. Dissertação (Mestrado em Engenharia) – Curso de Pós-graduação em Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre, 146p.

POSSAN, E. **Modelagem da carbonatação e previsão de vida útil de estruturas de**

concreto em ambiente urbano. 2010. Tese (Doutorado em Engenharia) - Escola de Engenharia, Programa de Pós-Graduação em Engenharia Civil, UFRGS, Porto Alegre.

POSSAN, E.; FOGAÇA, J. C.; PAZUCH, C.M. Sequestro de CO₂ devido à carbonatação do concreto: potencialidades da barragem de Itaipu. **Revista de estudos ambientais.** 2012.

RICHARDSON, Mark G. **Carbonation on Reinforced Concrete**, CITTIS LTD, Dublin, 1988.

SAETTA, A.V.; VITALIANI, R. V. Experimental investigation and numerical modeling of carbonation process in reinforced concrete structures. Part I: Theoretical formulation. **Cement and Concrete Research**, v. 34, p.571-579, 2004.

SANJUAN, M. A. **Cálculo del período de iniciación de la corrosión de la armadura del hormigón.** Madrid, 1992. Tese (Doutorado), Universidad Complutense de Madrid.

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

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

SILVA, A.; RAMOS, R.; ZOUZA, L.; RODRIGUES, D.; MENDES, J. **Uma plataforma para introdução de técnicas emergentes no planejamento urbano regional e de transportes: uma ferramenta 3D para análise ambiental urbana, avaliação multicritério e redes neurais artificiais.** São Carlos: Editora dos Autores, 2004. 221p.

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

SMOLCZYK, G. H. **Physical and chemical phenomena of carbonation.** RILEM Symposium on Carbonation of Concrete, 1976, p. 10.

STEFFENS, A.; DINKLER, D. AHRENS, H. Modeling carbonation for corrosion risk prediction of concrete structures. **Cement and Concrete Research**, v. 32, p. 935 – 941, 2002.

THIÉRY, M. **Modélisation de la carbonatation atmosphérique des bétons:** Prise en compte des effets cinétiques et de l'état hydrique. Thèse de doctorat, Ecole Nationale des Ponts et Chaussées, Paris, 2005.

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

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

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

VENQUIARUTO, S. D.; ISAIA, G. C.; GASTALDINI, A. L. G. A influência do teor e da quantidade de adições minerais na carbonatação do concreto. In: Congresso Brasileiro do Cimento, 43º, Foz do Iguaçu, 2001. **Anais...** São Paulo: Instituto Brasileiro do Concreto, 2001 (CD-ROM).

VERBECK, G. **Carbonatation of Hydrated Portland Cement**. American Society Testing Material. Special Technical Publication, 1958.

VESIKARI, E. Service life prediction of concrete structures with regard to corrosion of reinforcement. In: **TECHNICAL RESEARCH CENTRE OF FINLAND**, report n 553 (Espoo), Finland, 1988, 53 p.

VON ZUBEN, F; **Aprendizado em redes neurais artificiais**. Notas de aula. Departamento de Engenharia da Computação. UNICAMP, Campinas, 2013.