



UNIVERSIDADE CATÓLICA DE PERNAMBUCO
PRÓ-REITORIA ACADÊMICA - PRAC
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

ESTIMATIVA DA PROFUNDIDADE DE CARBONATAÇÃO DO
CONCRETO COM O USO DE REDES NEURAIAS

CARLOS ALBERTO CAVALCANTI MARTINS

ORIENTADORES: Profa. Dra. ELIANA CRISTINA BARRETO MONTEIRO

Prof. Dr. ROMILDE ALMEIDA DE OLIVEIRA

RECIFE
2011

ESTIMATIVA DA PROFUNDIDADE DE CARBONATAÇÃO DO CONCRETO COM O USO DE REDES NEURAIIS

Dissertação apresentada a Universidade Católica de Pernambuco como requisito parcial, exigida pelo Programa de Pós-Graduação em Engenharia Civil para obtenção do Título de Mestre em Engenharia Civil, na área de concentração em Engenharia das Construções, orientada pelos professores: Eliana Cristina Barreto Monteiro e Romilde Almeida de Oliveira.

RECIFE
2011

M386e Martins, Carlos Alberto Cavalcanti
Estimativa da profundidade de carbonatação do concreto com o uso de redes neurais / Carlos Alberto Cavalcanti Martins ; orientador Eliana Cristina Barreto Monteiro ; co-orientador Romilde Almeida de Oliveira, 2011.
90 f. : il.

Dissertação (Mestrado) - Universidade Católica de Pernambuco. Pró-reitoria Acadêmica. Coordenação de Pós-graduação. Mestrado em Engenharia Civil, 2011.

1. Carbonatação. 2. Concreto armado - Corrosão. 3. Redes neurais (Computação). I. Título.

CDU 620.193

ESTIMATIVA DA PROFUNDIDADE DE CARBONATAÇÃO DO CONCRETO
COM O USO DE REDES NEURAIIS

Carlos Alberto Cavalcanti Martins

Dissertação de Mestrado submetida ao Programa de Pós -
Graduação em Engenharia Civil da Universidade Católica
de Pernambuco, como parte dos requisitos necessários
para a obtenção do Título de Mestre em Engenharia Civil,
na área de Concentração em Engenharia das Construções.

Aprovada por:

Profa. Dra. Eliana Cristina Barreto Monteiro
(Orientadora- Engenharia Civil - Unicap)

Prof. Dr. Fernando Arthur Nogueira Silva
(Examinador Interno – Engenharia Civil - Unicap)

Prof. Dr. Cesar Augusto Cerqueira
(Examinador Externo – Engenharia Civil -UPE)

Data: 31 / 03 / 2011

Recife
2011

DEDICATÓRIA

*A meus pais (em memória), pela preocupação
com a educação e a todos que colaboraram
para o sucesso desse trabalho.*

*A minha esposa Izabel, e os meus filhos;
que sempre estiveram ao meu lado,
durante a realização deste trabalho.*

AGRADECIMENTOS

A Deus, que sem a sua ajuda nada poderia ser feito.

A professora Eliana Cristina Barreto Monteiro, minha orientadora, meus sinceros agradecimentos pela orientação sempre esclarecedora, incentivo pelo trabalho, durante todo o período de dissertação.

Ao meu orientador Romilde Almeida de Oliveira, pela orientação esclarecedora, incentivo pelo trabalho e amizade.

À Universidade Católica de Pernambuco, pelo suporte financeiro através da bolsa de mestrado e suporte dos laboratórios, que foram imprescindíveis para a realização desse trabalho.

Aos meus colegas de turma do mestrado: Paulo, Jesus, Carlos, Eugênio, Adelmo, Rosely, Thiago, pela amizade e união sempre objetivando o desenvolvimento de todos e especialmente para Clério e Célio Souto Maior meus amigos e companheiros de labuta.

Aos funcionários e colegas da Universidade Católica Washington Silva Espósito e André Miranda dos Santos pela dedicação nos experimentos e durante as aulas.

A todos os professores do mestrado Antonio Oscar Cavalcanti da Fonte, Romilde Almeida de Oliveira, Maria da Graça Ferreira, Paulo Roberto do Lago Helene, Eliana Cristina Barreto Monteiro, Fernando Arthur, José Orlando Vieira Filho.

Ao professor Francisco Madeiro Bernardino Junior, pela amizade e disposição de ouvir as minhas dificuldades.

A professora Clarissa Daisy C. Albuquerque, por sua cooperação, dedicação e disposição nas horas mais inconvenientes, mas que foram fundamentais no aprendizado do software qnet2000.

Aos meus irmãos Fernando, Cristina e Oswaldo minhas desculpas pelos momentos que precisaram de mim e não pude estar inteiramente disponível.

“Tudo tem seu tempo e até certas manifestações mais vigorosas e originais entram em voga ou saem de moda. mas a sabedoria tem uma vantagem: é eterna”

Baltasar Gracián (1601 – 1658)

LISTA DE NOMENCLATURAS E SÍMBOLOS

ABNT	Associação Brasileira de Normas Técnicas
ACI	American Concrete Institute
A/C	Água/cimento
ADALINE	Adaptative Linear Element
EDVAC	Eletronic Discrete Variable Automatic computer
ENIAC	Eletronic Numerical Integrator and Computer
MADALE	Many Adaptative Linear Element
MLP	Redes de Múltiplas Camadas – Multilayer Perceptron
MPa	Resistência ao esforço de compressão (Mega pascal)
MSE	Erro Médio Quadrático - Mean Square Error
LMS	Least Mean Square
RNA	Rede Neural Artificial
UR	Umidade Relativa
[H]	Matriz Hessiana
[J]	Matriz Jacobiana
u_k	Sinal de saída do somador do neurônio k
w_{kj}	Peso que conecta o terminal de entrada j ao neurônio k
y_k	Sinal de saída do neurônio k

LISTA DE COMPOSTOS E ELEMENTOS QUÍMICOS

CaCO_3	Carbonato de Cálcio
Ca(OH)_2	Hidróxido de Cálcio
C_3A	Aluminato tricálcio
CO_2	Dióxido de Carbono
Fe(OH)_2	Hidróxido Ferroso
Fe^{++}	Ferro
Fe_2O_3	Óxido férrico
H_2O	Água
H_2S	Gás sulfídrico
H_2SO_4	Ácido Sulfúrico
KOH	Hidróxido de potássio
NaOH	Hidróxido de sódio
O_2	Oxigênio
OH^-	Hidroxila
SO_2	Dióxido de enxofre
SO_4^{--}	Sulfato

LISTAS DE FIGURAS

	página
FIGURA 2.1-Representação esquemática de carbonatação, levando em conta poros secos, saturados com água e parcialmente preenchidos com água (ANDRADE, 1992).	08
FIGURA 2.2 – Representação do avanço da frente de carbonatação (TULA, 2000).	09
FIGURA 2.3– Representação esquemática do mecanismo da carbonatação (adaptado de RICHARDSON, 1988; BAKKER apud CASCUDO, 1997).	10
FIGURA 2.4 – Variação da velocidade de carbonatação com a umidade (Verbeck , 1958).	16
FIGURA 3.1 – Componentes do circuito neuronal disponível em: (http://www.Incc.bt/laboinfo/tutorialRN acessado em 11 de agosto de 2009).	30
FIGURA 3.2– Modelo simplificado de neurônio biológico típico (disponível em: (http://www.Incc.bt/~laboinfo/tutorialRN acessado em 11 agosto 2009).	31
FIGURA 3.3- Modelo de um neurônio artificial (HAYKIN, 2001).	32
FIGURA 3.4: Transformação afim produzida pela presença de um bias.	34
FIGURA 3.5 – (a) Função linear (b) Função Degrau (c) Função Rampa (d) Função Tangente Hiperbólica (e) Função Sigmóide.	35
FIGURA 3.6 – Arquiteturas de redes neurais	38
FIGURA 3.7- Rede alimentada adiante ou acíclica com uma única camada de neurônios	40
FIGURA 3.8 – Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída.	41
FIGURA 3.9– Rede recorrente sem laços de auto-realimentação e sem neurônios ocultos	42
FIGURA 3.10 – Aprendizado Supervisionado.	44

FIGURA 3.11 – Aprendizado não-supervisionado.	45
FIGURA 3.12 – Etapas de propagação e retropropagação do algoritmo <i>backpropagation</i> .	54
FIGURA 5.1 – Arquitetura da rede [3-3-1]	66
FIGURA 5.2 – Arquitetura da rede [3-4-1].	67
FIGURA 5.3 – Arquitetura da rede[3-8-1]	67
FIGURA 5.4 – Arquitetura da rede [3-12-1].	67
FIGURA 5.5 – Arquitetura da rede [3-16-1].	68
FIGURA 5.6 – Arquitetura da rede [3-20-1].	68
FIGURA 5.7 – Determinação da quantidade ótima de neurônios nas camadas ocultas	69
FIGURA 5.8 - Evolução do erro com número de iterações na fase de treinamento do modelo de estimação da profundidade de carbonatação.	70
FIGURA 5.9 – Evolução do erro com o número de iterações na fase de teste do treinamento do modelo de estimação da profundidade de carbonatação.	70
FIGURA 6.0 - Evolução do coeficiente de determinação (R^2) com o número de iterações na fase de treinamento do modelo de estimação da profundidade de carbonatação do concreto armado.	71
FIGURA 6.1 – Evolução do coeficiente de determinação (R^2) com o número de iterações na fase de teste do modelo de estimação da profundidade de carbonatação do concreto armado.	71
FIGURA 6.2- Arquitetura do modelo de estimação da carbonatação do concreto	73
FIGURA 6.3 – Resultada de erro e correlação extraídos do programa qnet para a rede [3-12-1] na fase de treinamento do modelo.	74

FIGURA 6.4 – Correlação entre os valores calculados pela rede e os valores fornecidos de profundidade de carbonatação do concreto na fase de treinamento	74
FIGURA 6.5 – Erro entre os valores calculados pela rede e os valores fornecidos da profundidade de carbonatação na fase de treinamento	75
FIGURA 6.6 – Resultado do erro e correlação extraído do programa qnet para a rede [3-12-1] na fase de validação.	76
FIGURA 6.7 - Correlação entre os valores calculados pela rede e os valores fornecidos da profundidade de carbonatação do concreto na fase de validação.	76
FIGURA 6.8 – Erro entre os valores calculados pela rede e os valores fornecidos da profundidade de carbonatação do concreto na fase de validação.	77

LISTA DE TABELAS

	Página
Tabela 2.1- Classificação dos ambientes de acordo com diversos autores em função do CO ₂	19
Tabela 2.2 – Recomendações de relação água/cimento do concreto em função da agressividade ambiental segundo a NBR 6116, 2007	22
Tabela 2.3 – Classes de agressividade do meio em função das condições de exposição segundo a NBR 6118, 2007	22
Tabela 2.4 – Recomendações de classe de resistência do concreto em função da agressividade ambiental e do cobrimento nominal segundo a NBR 6118, 2007	23
Tabela 4.1 - Valores máximos e mínimos das variáveis de entrada e saída da rede	63
Tabela 4.2 - Características por corpos de provas utilizados no estudo da profundidade de carbonatação	86
Tabela 4.3 – Normalização das variáveis – 0,15 a 0,85	89

ESTIMATIVA DA PROFUNDIDADE DE CARBONATAÇÃO DO CONCRETO COM O USO DE REDES NEURAIIS

RESUMO

O fenômeno da carbonatação, como agente desencadeador do processo de corrosão de armaduras, assume especial importância quando as estruturas de concreto armado estão expostas a ambientes urbanos e à atmosfera poluída de gases como o CO₂.

O controle da profundidade de carbonatação do concreto exige o uso de ferramentas (modelos matemáticos) que representem o comportamento das variáveis que interagem no processo da carbonatação do concreto de forma clara e objetiva no sentido de auxiliar a compreensão do fenômeno. Nessa perspectiva, desenvolveram-se modelos computacionais que conjugam problemas complexos de modo simples. Entre esses modelos, citam-se as redes neurais artificiais, que têm inspiração no cérebro humano e que possuem a habilidade de aprender e generalizar possibilitando a resolução de problemas complexos. Neste trabalho é estudada a aplicação de redes neurais artificiais do tipo *Perceptron multicamadas*, com base no algoritmo de aprendizado supervisionado *backpropagation*, com o objetivo de obter um mapeamento entre as variáveis de entrada do problema – relação água/cimento, distância do corpo de prova do mar e idade do corpo de prova – e a variável de saída de interesse – profundidade de carbonatação do concreto. Os resultados obtidos validam que os modelos de redes neurais artificiais se constituem numa importante ferramenta de avaliação da profundidade de carbonatação do concreto armado.

Palavras-Chave: Redes Neurais Artificiais, Profundidade de Carbonatação do Concreto Armado

ESTIMATE OF DEPTH CONCRETE CARBONATION WITH THE USE OF NEURAL NETWORKS

□

ABSTRACT

The phenomenon of carbonation as the triggering agent in the process of reinforcement corrosion is particularly important when concrete structures are exposed to urban environments and the atmosphere contamination with gases such as CO₂.

The concrete carbonation depth control requires the use of tools (mathematical models) that represent the behavior of the variables that interact in the process of concrete carbonation in a clear and objective way to help understand the phenomenon. In this perspective, computer models have been developed to combine complex problems in a simple way. Among those models are the artificial neural networks, which have been inspired on human nervous system and have the ability to learn and generalize, making it possible to solve complex problems. This work studied the application of artificial neural networks like multilayer perceptron, based on backpropagation, supervised learning algorithm in order to obtain a mapping between the input variables of the problem — the water/cement (w/c) ratio, body of proof distance from the sea and age of the body of proof — and the output variable of interest — the depth of concrete carbonation. The results validate that the use of artificial neural networks is an important tool to evaluate concrete carbonation.

Keywords: Artificial Neural Networks, Depth of Carbonation of Concrete Armed

SUMÁRIO

página

CAPÍTULO 1

1	INTRODUÇÃO	
1.1	Motivação e Justificativa do Trabalho	1
1.2	Objetivos	2
1.2.1	Objetivo Geral	2
1.2.2	Objetivos Específicos	3
1.3	Conteúdo	3

CAPÍTULO 2

2	REVISÃO BIBLIOGRÁFICA	
2.1	Durabilidade do concreto	4
2.2	Considerações sobre Vida Útil	5
2.3	O mecanismo da Carbonatação do Concreto	7
2.3.1	A difusão do CO ₂ nos poros do concreto	8
2.3.2	Carbonatação dos Compostos Hidratado do Cimento	13
2.4	Fatores que influenciam a Carbonatação	15
2.4.1	Fatores Ambientais	15
2.4.1.1	Umidade Relativa	15
2.4.1.2	Incidência de Chuvas	16
2.4.1.3	Temperatura Ambiental	17
2.4.1.4	Concentração de CO ₂	18
2.4.1.5	Outros Aspectos Ambientais	19
2.4.2	Fatores Internos ao Concreto	19
2.4.2.1	Idade e Grau de Hidratação do Concreto	20
2.4.2.2	Agregado	20
2.4.2.3	Qualidade do concreto	21
2.5	Ensaio de Carbonatação	23
2.5.1	Ensaio Naturais	24
2.5.2	Ensaio Acelerados	24
2.5.3	Medidas de Carbonatação	24

CAPÍTULO 3

3	REDES NEURAIS ARTIFICIAIS	
3.1	Introdução	26
3.1.1	Notas Históricas	27
3.1.2	Inspirações Biológicas	30
3.2	Neurônios Artificiais	32
3.2.1	Função de ativação	34
3.3	Principais Arquiteturas de Redes Neurais	37
3.3.1	Conexões entre as Unidades de Processamento	39

3.3.2	Redes Alimentadas Adiante com Camada Única	40
3.3.3	Redes Alimentadas Diretamente com múltiplas Camadas	42
3.3.4	Redes Recorrentes	42
3.4	Processo de Aprendizado	44
3.4.1	Aprendizado Supervisionado	45
3.4.2	Aprendizado não- supervisionado	46
3.5	Algoritmo de Otimização e Treinamento	47
3.5.1	Algoritmo de Otimização	49
3.5.1.1	Gradiente Descendente	51
3.5.1.2	Gradiente Conjugado	52
3.5.1.3	Gradiente Conjugado Escalado	53
3.5.2	Algoritmo de Treinamento	56
3.6	Modelos de Redes Neurais	56
3.6.1	Redes Perceptron	57
3.6.2	Redes MLP (Multi Layer Perceptron)	57
3.6.3	Redes Adaline	58
3.7	Aplicações de Redes Neurais Artificiais	

CAPÍTULO 4

4	MATERIAIS E MÉTODO	60
4.1	Obtenção dos dados da profundidade de carbonatação	60
4.2	Medidas de Carbonatação	61
4.3	Escolhas das Variáveis de Entrada	62
4.4	Determinação das Arquiteturas de Rede Neural	62
4.4.1	Tratamento e Separação dos Dados	64
4.4.2	Processo de Treinamento e Escolha da Melhor Arquitetura	

CAPÍTULO 5

5	SIMULAÇÃO COMPUTACIONAL	66
5.1	Análise e Discursão do Treinamento	66
5.2	Resultados das Simulações com Redes Neurais	69

CAPÍTULO 6

6	Conclusões e Sugestões para Trabalhos Futuros	77
6.1	Conclusões	77
6.2	Sugestões para Trabalhos Futuros	78

	REFERÊNCIAS BIBLIOGRÁFICAS	79
		85

APÊNDICE 1

CAPÍTULO 1

1 Introdução

1.1 Motivação e Justificativa do trabalho

As estruturas de concreto armado são susceptíveis de deterioração principalmente quando estão localizadas nos centros de maior ocupação. Embora os produtos de hidratação do cimento protejam as armaduras do concreto num ambiente de elevada alcalinidade, com pH acima de 12,6, não isentam à corrosão as estruturas de concreto armado quando expostas a ambientes urbanos e à atmosfera poluída de gases como o CO₂, na presença de umidade. Com o crescimento da industrialização e da urbanização acelerada torna o ambiente mais agressivo, favorecendo assim, o crescimento da corrosão mais precocemente.

As Edificações antigas eram consideradas com vida útil quase que infinita, no entanto, apresentam-se com uma deterioração cada vez mais precoce, sobretudo, quando se refere à degradação das estruturas do concreto pela corrosão. Esse fenômeno, afeta a construção civil em todo o mundo, com repercussões em função do volume de casos registrados, da precocidade, bem como do montante de recursos envolvidos para a recuperação.

Nesse contexto, verifica-se que os trabalhos realizados neste âmbito se baseiam, em sua maioria, em ensaios laboratoriais acelerados, como os obtidos por Coelho (2002), os quais nem sempre retratam bem a realidade, onde uma multiplicidade de agentes atua de modo simultâneo e com dinâmica distinta.

Segundo CARMONA (2005), atualmente dentre as patologias encontradas no concreto armado, a corrosão de armadura e a que se mostra como uma das mais frequentes ou a que envolve maiores risco a segurança. A corrosão das armaduras é um processo de degradação da fase metálica existente, que implica em crescente perda de seção de barras e a formação de produtos expansivos que invariavelmente fissuram o concreto.

A presente dissertação pretende, portanto, contribuir para oferecer informações sobre as potencialidades das técnicas de redes neurais artificiais, na estimação da profundidade de

carbonatação do concreto, onde se vislumbra um método alternativo a metodologia convencional (ensaios laboratoriais acelerados).

A motivação para o uso de redes neurais foi devida ao elevado número de fatores que influenciam a carbonatação, pois seria difícil e complexo utilizar um modelo matemático que levasse em consideração todos os elementos envolvidos. De acordo com Carmona (2005), muito embora os modelos matemáticos existentes contribuam muito para o entendimento do fenômeno da carbonatação, muitos deles são incompletos, pois não apresentam as equações para as estimativas de todos os parâmetros.

É por estes motivos que a solução de problemas através de redes neurais artificiais pode ser bastante interessante, já que a forma como tais problemas são representados internamente pela rede e o paralelismo natural inerente à arquitetura dessas redes cria a possibilidade de um desempenho superior à dos modelos convencionais.

Segundo Smolczyk (1968), o modelo mais conhecido é o da raiz quadrada do tempo $X_{\text{carb}} = K_{\text{carb}} \sqrt{t}$, em que X_{carb} representa a profundidade de carbonatação, t e o tempo de exposição e K_{carb} é uma constante que representa a velocidade de avanço da frente de carbonatação e depende das características do concreto e do ambiente. Essa equação oferece pouca divergência entre dados experimentais e as estimativas teóricas, no espaço de 5 a 30 anos. Entretanto, essa relação pode não oferecer bons resultados em situações onde fatores mutáveis com o tempo assumem maior importância como, por exemplo, a variação da porosidade em relação ao grau de hidratação e ao conteúdo de umidade do concreto. Não obstante, as inúmeras variações propostas, essa relação continua sendo até hoje, a mais utilizada para previsão da profundidade de carbonatação em que se depende das características do concreto e do ambiente.

1.2 Objetivos

1.2.1 Objetivo Geral

Estimar a profundidade de carbonatação do concreto armado utilizando redes neurais artificiais.

1.2.2 Objetivos Específicos

- Construir, treinar, testar e validar modelos de redes neurais artificiais para a inferência da profundidade de carbonatação do concreto usando a relação a/c, distância em relação ao mar e idade do corpo de prova como variáveis dos padrões de entrada das redes;
- Identificar, dentre um conjunto de arquiteturas de redes neurais, a que tem maior capacidade preditiva para aplicações práticas de reconhecimento de padrões e mapeamentos não lineares.
- Avaliar a eficiência do uso da simulação com redes neurais para estimar a profundidade de carbonatação do concreto

1.3 Conteúdo

Esta dissertação está subdividida em 6 (seis) capítulos. No Capítulo 1, aborda-se a motivação e a justificativa do trabalho.

No Capítulo 2, com o objetivo de fundamentar o problema a ser resolvido, é apresentada uma revisão da literatura relativa ao tema da carbonatação os fatores que o influenciam, os ensaios e métodos utilizados para avaliar esse mecanismo e a relação com a durabilidade do concreto.

No Capítulo 3, detalha-se o funcionamento das redes neurais artificiais, suas características e os principais parâmetros envolvidos na concepção de um projeto de redes neurais, bem como a apresentação dos parâmetros, simulações realizadas e a análise dos mesmos.

No Capítulo 4, é apresentada a descrição do método, a escolha das variáveis de entrada, determinação da arquitetura, tratamento e separação dos dados e o processo de treinamento e escolha da melhor arquitetura.

No Capítulo 5 apresenta a análise e discussão do treinamento e os resultados obtidos com a pesquisa.

No Capítulo 6 são apresentadas as conclusões que puderam ser extraídas da pesquisa bem como as sugestões para trabalhos futuros.

CAPÍTULO 2

A CARBONATAÇÃO DO CONCRETO

2 REVISÃO BIBLIOGRÁFICA

2.1 Durabilidade do Concreto

Durante muitos anos pensou-se que a durabilidade das estruturas de concreto armado era ilimitada, existia uma impressão geral (tanto do meio técnico quanto do usuário), que o concreto armado tinha durabilidade tão extrema que esse não era um tema a se preocupar. Infelizmente, com o uso crescente do concreto, esse entendimento mudou, pois muitas estruturas começaram a apresentar degradações com pouco tempo de uso, e há alguns anos a durabilidade do concreto tem sido um dos assuntos mais estudados na área de materiais de construção civil. Fazendo-se uma regressão no tempo, observa-se que, ao longo do tempo, a forma de produzir concreto sofreu várias modificações (MEHTA, P. K.; MONTEIRO, P. J. M, 2008).

É de fácil constatação, que os concretos executados há mais tempo, em geral, tem durabilidade bem superior aos executados recentemente. No entanto, com avanço rápido das atividades da construção civil e o desenvolvimento da indústria do concreto, verificou-se então uma melhoria nos traços, de modo a alcançar concretos mais resistentes com proporção mínima de cimento (FERREIRA, 2000).

De acordo com Lapa (2008) embora o concreto armado seja o material de construção mais consumido no mundo, a informação e a exposição das práticas construtivas adequadas não atendeu o crescimento das atividades de construção, ocasionando seguidos descuidos na execução das obras, como consequência, a durabilidade dessas estruturas foi afetada.

2.2 Considerações sobre Vida Útil

A durabilidade de uma estrutura é função de vários parâmetros; como as características das diversas etapas construtivas (projeto, especificações, materiais, manutenção), da agressividade do meio ambiente em que a estrutura está inserida, da forma de utilização da estrutura e do tempo, ou seja, da vida útil requerida (MEHTA, 1997).

De acordo com o Comitê Euro-international Du Betón (CEB, 238) (1997), como conceito de durabilidade entende-se que as estruturas de concreto devem ser projetadas, construídas e operadas de forma que mantenham sua segurança, utilidade e aparência aceitável, sob as influências ambientais esperadas, durante o período de tempo, sem a necessidade de altos custos de manutenção e reparo.

Considerando que a durabilidade do concreto tem vida útil limitada, uma estrutura de concreto deve ser projetada de forma a permitir que sob condições ambientais esperadas, conserve sua segurança, funcionalidade e aparência aceitável para determinada vida útil. De acordo com a (CEB, 1989) define-se como vida útil, o período que a estrutura se sustenta dentro de um limite aceitável para a qual foi projetada, sem elevados custos de manutenção e reparações elevados.

O American Concrete Institute (ACI) (2001), no Comitê 201, define a durabilidade do concreto de cimento Portland como a sua capacidade de resistir à ação das intempéries, ataques químicos, abrasão ou qualquer outro processo de deterioração, mantendo sua forma original, qualidade e vida útil quando exposto ao meio.

A Associação Brasileira de Normas Técnicas (NBR 6118, 2007) na norma de projeto de estrutura de concreto, descreve que 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”.

Nakamura (2004, p.24) apresenta às principais mudanças ocorridas na norma que passaram a ser válidas a partir de 30 de março de 2004. Anteriormente a sua revisão, a norma envolvia projeto e execução de obras de concreto armado, passando atualmente a considerar apenas os aspectos referentes ao projeto de estrutura de concreto armado.

Dentre as principais mudanças está o aumento dos cobrimentos mínimos de armadura, em função do grau de agressividade do ambiente, e o controle mais rigoroso de fissuras.

Alguns pesquisadores, (Tuutti, 1982; Andrade, 1988; Helene, 1993), têm realizado um esforço grande no sentido de estabelecer uma modelagem adequada para representar a curva desempenho *versus* tempo das estruturas. Neste sentido, os estudos realizados pelos pesquisadores estão direcionados para o estudo de corrosão das armaduras, pois, além de ser o fenômeno que apresenta um maior índice de ocorrência nas estruturas de concreto, tal tipo de degradação pode reduzir significativamente a vida útil das mesmas.

Em nível internacional, diversos trabalhos de levantamento de danos em estruturas de concreto armado foram realizados (Mehta, 1993; Stewart et al., 1998), e no Brasil (Carmona; Marega, 1988; Dal Molin, 1998; Andrade, 1997) mostraram que as obras de engenharia vêm apresentando uma degradação precoce, onde a corrosão de armaduras é o fenômeno responsável por grande parte dos danos nas estruturas, com um índice de ocorrência variando entre 27% e 64%. Segundo Helene (1997), o estudo da durabilidade cresceu, notadamente pelo conhecimento maior dos mecanismos de transporte dos fluidos no meio poroso, permitindo assim associar o tempo em número de anos aos modelos matemáticos que expressam quantitativamente esses mecanismos.

O concreto envolve a armadura que se encontra no seu interior criando um obstáculo físico, por meio do cobrimento, e uma proteção química, gerada pela elevação da alcalinidade, formando-se assim uma película passivadora em torno da armadura. Uma das maneiras de romper essa película passivadora é pela diminuição da alcalinidade do concreto, por reações físico-químicas entre o dióxido de carbono (CO_2) da atmosfera com os produtos da hidratação do cimento, provocando a carbonatação (ANDRADE, 2001).

Segundo Mehta (1994), o desempenho insatisfatório de estruturas relativamente novas exigiu que se aprofundasse o conhecimento sobre o comportamento do material para o qual era dada a ênfase apenas para a resistência adotada em projeto. A durabilidade do concreto passa então, da condição de característica secundária, à condição de critério de recebimento e aceitação da obra.

2.3 O Mecanismo da Carbonatação do Concreto

O concreto é o material mais utilizado no mundo não só pela sua resistência a compressão como também por ser facilmente moldado, permitindo a construção de obra de efeitos visuais peculiares, entretanto, o concreto é um material heterogêneo, poroso e bastante complexo, usado nas obras de engenharia civil (MEHTA; MONTEIRO, 2008).

O concreto quando examinado através da microscopia eletrônica, permite observar três fases: os agregados de formas e tamanhos variados, a pasta endurecida e uma zona de transição (MEHTA; MONTEIRO, 1994).

A pasta de cimento endurecida é composta de vazios e água. Quando a pasta endurecida estiver em contato com o cimento, produtos estáveis são gerados em ambiente alcalino, proveniente da dissolução dos álcalis; hidróxido de sódio (NaOH), hidróxido de potássio (KOH) e da precipitação do hidróxido de cálcio ($Ca(OH)_2$) (RICHARDSON, 1988; AL-KADHIMI et al., 1996).

Silva (1995) relata que os diversos tipos de poros são definidos como poros na pasta e os poros de ar. Os poros nas pastas podem ser de gel e capilares, enquanto que os poros de ar, em sua maioria, são volumosos e desenvolvidos pelos defeitos de execução do concreto.

Cascudo (1997) diz que é por meio dos poros que o CO_2 adentra no concreto, no entanto existe uma diferença entre poros secos e poros preenchidos com água. Quando os poros estão secos o CO_2 se difunde em seu interior até as regiões mais internas sem dificuldades, entretanto a carbonatação não ocorrerá devido à falta da água, conforme mostra a Figura 2.1(A). Quando os poros estão secos o CO_2 se dissemina em seu interior até as regiões mais internas sem dificuldades, porém a carbonatação não ocorrerá devido à falta da água, conforme Figura 2.1(C). E no caso dos poros que estejam parcialmente preenchidos com água, a frente de carbonatação avança lentamente devido à coexistência de dois fatores: água e probabilidade de difusão do CO_2 , como indicado na Figura 2.1(B).




FIGURA 2.1 - Representação esquemática de carbonatação, levando em conta poros secos, saturados com água e parcialmente preenchidos com água (ANDRADE, 1992).

2.3.1 A Difusão do CO₂ nos poros do Concreto

O CO₂ presente na atmosfera pode caminhar para os poros do concreto pelo mecanismo de difusão devido à diferença de concentração desse gás no ambiente e no interior do concreto. Ao adentrar, o CO₂ reage com o hidrato de pasta de cimento formando carbonatos e outros compostos, provocando, assim, algumas alterações físico-químicas tal como o aumento da resistência a compressão, redução da permeabilidade, aumento do módulo de deformação e da dureza (NEVILLE, 1997).

De acordo com Silva (1995), o CO₂, que se encontram na atmosfera, facilmente se combina as bases do cimento hidratado, resultando em compostos com um pH mais baixo. A atuação do CO₂ em cima dos constituintes do cimento hidratado é complexa, e não se limita unicamente ao hidróxido de cálcio, mas avança contra todos os produtos da hidratação do cimento.

Essa interação entre os elementos resulta na formação de CaCO₃ (carbonato de cálcio) e H₂O (água), de acordo com a reação expressa na equação 1.



O concreto em temperatura ambiente tem um pH de cerca de 12,5, em virtude da presença do $\text{Ca}(\text{OH})_2$. A ausência do hidróxido de cálcio do interior dos poros da pasta de cimento hidratado e posteriormente sua transformação em carbonato de cálcio fazem baixar o pH da solução balanceada de 12,5 para 9, dando início à corrosão das armaduras (SILVA, 1995).

Segundo (Silva, 1995), o processo da carbonatação tem início na região superficial do concreto e adentra para seu interior gradualmente, fazendo com que ao longo do tempo exista uma camada carbonatada que cresce em espessura, camada essa, que aumenta de espessura ao longo do tempo. Isso fica visível com a Figura 2.2.




FIGURA 2.2 – Representação do avanço da frente de carbonatação (TULA, 2000).

Durante o período que o CO_2 vai adentrando no concreto, três zonas com pH diferentes formam-se: uma zona com $\text{pH} \leq 9$, chamada de zona carbonatada, próxima a superfície; uma zona com pH próxima de 12,5, denominada região não carbonatada; e, entre as duas, uma zona de transição, chamada de zona parcialmente carbonatada. A evolução das reações do CO_2 com os componentes do cimento, e em particular com o $\text{Ca}(\text{OH})_2$, é chamada de frente de carbonatação, que progride para o interior do concreto de forma lenta e, quando o pH que está junto à armadura é reduzido para menos de 9, origina-se a corrosão da armadura (HELENE; MITIDIERI FILHO; THOMAS, (1995).

Na Figura 2.3 observa-se uma representação esquemática do mecanismo de carbonatação.




FIGURA 2.3 – Representação esquemática do mecanismo da carbonatação (adaptado de RICHARDSON, 1988; BAKKER apud CASCUDO, 1997).

A penetração do gás carbônico no interior do concreto dar-se por meio da diversidade de concentrações entre o ambiente atmosférico e a estrutura porosa do concreto, pelo mecanismo da difusão. A difusão é um processo de transporte dos íons que acontece pela colisão das moléculas, que se movem na direção da menor concentração desses íons. Essa difusão dar-se através dos poros capilares, microfissuras e vazios de ar formando uma rede de interconectividade no concreto (RICHARDSON, 1988; HELENE, 1993).

A influência da relação água/cimento na profundidade de carbonatação está diretamente ligada com a quantidade, dimensão e continuidade dos poros do concreto. Assim, quanto maior for a relação água/cimento no concreto maior será a permeabilidade e a porosidade. Portanto, o ingresso do CO_2 no concreto está vinculado à porosidade da pasta endurecida, que possuem dimensões e quantidades que são responsáveis pela taxa de carbonatação em concretos e argamassa (MEHTA; MONTEIRO, 1994; WEE; SURYAVANSHI; LOGENDRAN, 1999).

Para esses pesquisadores, Wee; Suryavanshi; Logendran (1999) acreditavam que apenas a quantidade de poros do concreto eram os principais responsáveis pela difusão da carbonatação. Entretanto, ao pesquisarem a influência das dimensões e do volume total dos poros na carbonatação concluíram que os poros de dimensão maior do que 450 \AA eram os principais responsáveis pela taxa de carbonatação, não podendo, entretanto, excluir a influência dos poros de dimensões menores que 450 \AA .

A difusão é o mecanismo preponderante no ingresso de íons através do concreto, porque, os gradientes de pressão não justificam os seus ingressos pelo mecanismo da permeabilidade. Entretanto, para alguns pesquisadores, a penetração de CO₂ no concreto pode ocorrer pelo mecanismo de permeabilidade, quando são utilizados teores de CO₂ maiores que os encontrados na atmosfera, como, por exemplo, em testes acelerados (RICHARDSON, 1988; HELENE, 1993).

Conforme Tuutti (1982), a equação clássica para calcular matematicamente o processo de carbonatação é descrita pela 2ª Lei de Fick, na forma simplificada, representando a difusão de um gás em função do tempo, através de um material,

$$x = k \cdot \sqrt{t} \quad [\text{Eq. 2}]$$

em que

x - profundidade de carbonatação

t - tempo de exposição ao CO₂ (anos)

k - coeficiente que depende da difusão do CO₂, do gradiente de concentração do CO₂ e da quantidade retida ou fixa de CO₂ na pasta em mm/ano^{1/2}, que, por sua vez, depende do material e das condições do ambiente.

Muitos modelos têm sido apresentados com o intuito de equacionar a velocidade de carbonatação. Sanjuán (1992) relaciona vários modelos buscando subsídios para uma modelação específica. O que se tem observado é um grande número de fatores e coeficientes que são específicos de certos materiais, certas condições climáticas, dentre outros, de difícil obtenção para condições gerais.

Diversos modelos enfatizam determinadas variáveis obviamente, em função da significância de cada uma para cada estudo realizado, o que dificulta o consenso. Assim, constata-se que o fenômeno da carbonatação é influenciado por um grande número de variáveis, o que leva a simplificações quando do tratamento matemático para modelações.

Bakker (1988) enfatiza tal aspecto ao propor que a espessura carbonatada é função da relação:

$$X = f(A, B, C.D, E1, E2, C.E1, C.E2, F1, F2, C.F1, C.F2, T1, T2),$$

[Eq.3]

em que

A – composição do cimento

B – teor de cimento

C – proporcionamento do concreto

D – grau de compactação do concreto

C.D – interação entre compactação e proporcionamento

E1 – umidade relativa durante a cura

E2 – temperatura durante a cura

F1 – umidade relativa durante o tempo de exposição

F2 – temperatura durante o tempo de exposição

C.E1 – interação entre umidade relativa e proporcionamento

C.E2 – interação entre temperatura durante a cura e proporcionamento

C.F1 – interação entre umidade relativa durante o tempo de exposição e proporcionamento.

C.F2 – interação entre temperatura durante o tempo de exposição e proporcionamento

T1 – tempo de cura

T2 – tempo de exposição

Além das variáveis mencionadas por BAKKER (1988), devem-se mencionar mais duas variáveis relevantes que atuam diretamente na porosidade e na reserva alcalina. Estas variáveis são: a relação água/cimento, que influencia no volume total de poros e distribuição de tamanhos de poros, e o grau de hidratação, que nos dá uma avaliação do grau de evolução das reações de hidratação.

Uma maneira de aferir a velocidade de difusão do CO₂ no concreto, pastas ou argamassas, é empregar gases inertes, como o oxigênio ou o nitrogênio, porque são gases que não reagem com os produtos hidratados do cimento, conseqüentemente, têm menor grau de interferência com as paredes dos poros do concreto. O teste de permeabilidade a oxigênio no concreto é um dos mais utilizados pela similaridade com a difusão do CO₂.

Assim como o CO₂, também o dióxido de enxofre atmosférico (SO₂) e o gás sulfídrico H₂S, são gases que penetram no concreto, e em contato o hidróxido de cálcio, reagem produzindo uma redução do pH da água dos poros.

Entretanto, o SO₂ é encontrado na atmosfera em teores muitas vezes menor do que o CO₂ (RICHARDSON, 1988; HELENE, 1993).

2.3.2 Carbonatação dos Compostos Hidratados do Cimento

A carbonatação de materiais cimentícios se realiza através de uma reação química entre o dióxido de carbono (CO₂) presente na atmosfera, e os produtos dos compostos hidratados do cimento: o hidróxido de cálcio (Ca (OH)₂), o silicato de cálcio hidratado (C-S-H), aluminatos e ferroaluminatos (HELENE, 1993; HOUST; WITTMANN, 2002).



Essa reação abrange vários mecanismos físico-químicos, sendo que, existe a necessidade de dissolução do CO₂, na solução aquosa, para que se inicie a carbonatação dos compostos hidratados segundo a equação 4.



No início da hidratação, os compostos anidros do cimento solubilizam-se e geram compostos pouco solúveis, tais como; íons potássio (K⁺), sódio (Na⁺) e íons hidroxila. Esses íons dissolvidos na água dos poros dos materiais cimentícios não são incorporados aos compostos hidratados, acumulam-se na água dos poros dos materiais cimentícios e, além dos cristais de Ca (OH)₂ originados da hidratação do C₃S e C₂S, que são os responsáveis pela elevação do pH da água dos poros (HELENE, 2002).

Como o hidróxido de cálcio é menos solúvel do que os hidróxidos de sódio (NaOH) e o do potássio (KOH), que estão presentes nos materiais cimentícios na forma de cristais ou em pequenas quantidades de íons dissolvidos tem sua solubilidade determinada pela quantidade de íons hidroxila presentes na solução (HELENE, 1993).

Para que ocorra a reação de carbonatação é necessária a dissolução e difusão do hidróxido de cálcio na água dos poros, reagindo com CO₂ dissolvido.



De acordo com Richardson (1988) as reações de transformação do hidróxido de cálcio e do silicato de cálcio hidratado em carbonatos de cálcio produzem o efeito da colmatação dos poros do concreto pela precipitação dos carbonatos nas suas diversas fases mineralógica. Esta precipitação dificulta a difusão posterior do CO₂ nos poros do concreto.

Durante a carbonatação do hidróxido de cálcio, a quantidade de C₃S do cimento é aumentada, gerando uma maior quantidade de hidróxido de cálcio, como consequência, menor é a carbonatação, uma vez que a precipitação desse composto dificulta a difusão do CO₂ pela maior afinidade do hidróxido de cálcio em reagir com o dióxido de carbono atmosférico, daí conclui-se que os cimentos produzidos essencialmente de clínquer ou com maiores teores de C₃S, são mais resistentes à ação da carbonatação (HELENE; MITIDIERI FILHO, TOMAZ, (1995), STEFFENS; DINKLER; AHRENS, 2002).

Segundo (Parrot, 1987) os compostos do cimento, silicato tri-cálcico (C₃S) e o silicato di-cálcico (C₂S), só reagem com o CO₂ atmosférico quando ele estiver em altas concentrações.

Pelo fato de produzirem, durante a sua hidratação, hidróxido de cálcio (CH) e silicato de cálcio hidratado (C-S-H) nas suas várias formas, são considerados os compostos de maior importância para a carbonatação.

Como o C₃S, é o que produz maior quantidade de hidróxido de cálcio na sua hidratação, ele é considerado o composto anidro do cimento que tem a maior importância no mecanismo da carbonatação (RICHARDSON, 1988; MEHTA; MONTEIRO, 2008).

2.4 Fatores que Influenciam a Carbonatação

Vários pesquisadores, tais como, Richardson (1988), Parrot (1992), Helene (1993), Houst; Wittmann (2002) preconizam que os fatores que influenciam a carbonatação são:

- Fatores ambientais, como a umidade relativa do ar, incidência de chuvas, temperatura ambiente, concentração de CO₂ do ar, tipo de ambiente, ventos e exposição ao sol.
- Fatores referentes às características do concreto, como sua composição, condições de execução e grau de hidratação das partículas do aglomerante.

2.4.1 Fatores Ambientais

2.4.1.1 Umidade Relativa

A umidade ambiente influencia as reações de carbonatação. Ainda que o concreto não esteja saturado, ele pode conter água livre, oriunda da umidade interna, que tem a tendência de entrar em equilíbrio com a umidade relativa externa menor que 100%, e perder parte dessa água.

A hidratação do cimento, a porosidade e outras propriedades do concreto são afetadas diretamente pelas condições de umidade do ambiente, pois as reações de carbonatação só ocorrem na fase aquosa das matrizes cimentícias, onde é necessário que o CO₂ esteja dissolvido para depois reagir com os compostos do cimento.

Segundo (Parrot, 1989; Houst; Wittmann, 2002), a carbonatação é muito dependente da umidade externa do ambiente.

Conforme Verbeck (1958) a carbonatação está relacionada com a umidade relativa do ar, conforme se observa na Figura 2.4, mostrando que quando os níveis de UR se situar entre 50 – 70% o processo de carbonatação é favorecido.

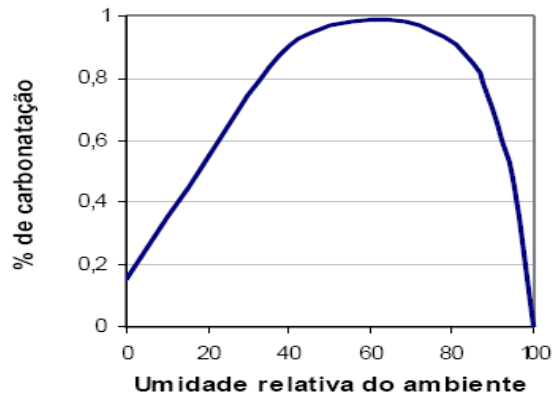


Figura 2.4 - Variação da velocidade de carbonatação com a umidade (VERBECK , 1958).

Em ambientes de baixa umidade relativa, existe uma tendência a uma maior perda de água livre e, como conseqüência, a quantidade de água livre disponível para reagir com o CO_2 será menor, ocasionando uma menor profundidade de carbonatação. Isto pode ser observado na Figura 2.4 (PARROT, 1992; MEHTA; MONTEIRO, 2008).

Segundo o BRE Digest 263 (1982) as maiores taxas de carbonatação ocorrem na faixa citada por Verbeck (1958), que corresponde às condições ótimas de umidade. Portanto, abaixo de 50% falta água para que haja a reação de carbonatação e, acima de 95%, praticamente não ocorre a carbonatação.

Na prática, a relação de umidade relativa com a profundidade de carbonatação em função do tempo é bastante complexa devido aos randômicos ciclos de umedecimento e secagem a que as estruturas de concreto armado podem estar expostas (ANDRADE, 1989; PARROTT, 1992; HELENE, 1993).

2.4.1.2 Incidência de Chuvas

Quando o concreto está exposto à incidência de chuvas, a água livre muda de maneira radical: uma parte dela é absorvida pela superfície e a outra parte penetra por capilaridade. Assim, a umidade das estruturas de concreto depende do período e do volume de precipitação higrométrica, permanecendo saturadas por um tempo razoável. Nesta circunstância, a difusão do CO_2 é bastante dificultada, havendo a possibilidade de a carbonatação ser bem menor (STEFFENS; DINKLER; AHRENS, 2002).

No período de estiagem, uma parte da água livre é evaporada, facilitando as condições para que a umidade do concreto de cobrimento da armadura alcance a condição de máxima carbonatação (ANDRADE; SARRÍA; ALONSO, 1999).

Assim, conclui-se que a profundidade de carbonatação resultante seja um somatório dos efeitos de molhagem e secagem da superfície do concreto. Para alguns autores essa profundidade de carbonatação é menor nos locais sujeitos à molhagem e secagem do que naqueles protegidos de chuvas, mesmo em ambientes externos (AHRENS, 2002).

Segundo Andrade; Alonso, (1999), o concreto protegido de chuvas, com o início do das chuvas ocorre um crescimento gradual da umidade interna desse concreto, atingindo seu máximo e em seguida diminui gradualmente com o término das chuvas. Já no concreto não protegido de chuvas o aumento na umidade relativa interna é imediato, diminuindo também gradualmente.

2.4.1.3 Temperatura Ambiental

As reações químicas são bastante influenciadas pela variação de temperatura do ambiente. No entanto, no mecanismo da carbonatação, a velocidade das reações é controlada, principalmente, pelo grau de saturação dos poros, que, por sua vez, controla a difusão do CO₂ nos poros capilares do concreto (HOUST; WITTMANN, 2002).

A temperatura tem um comportamento característico na umidade relativa interna do concreto. Em uma temperatura mais alta, acima de 25°C a 30°C, como a evaporação da água livre não se dá rapidamente, no início ela evapora e aumenta a umidade relativa interna próxima à superfície, passando a diminuir depois. Com um volume menor de água, o concreto não terá água suficiente para as reações de carbonatação (LOGENDRAN, 1999; STEFFENS; DINKLER; AHRENS, 2002).

No entanto, o inverso ocorre em temperaturas abaixo de 5°C a 10°C. No início, a umidade relativa é menor, para depois aumentar, porque um volume maior de água será acumulado no interior do concreto.

Assim, com um volume maior de água livre disponível, a depender da saturação, ou não, dos poros, a velocidade das reações de carbonatação deverá ser bem maior (STEFFENS; DINKLER; AHRENS, 2002).

2.4.1.4 Concentração de CO₂

A carbonatação do concreto é um fenômeno natural que ocorre quando o concreto é exposto às condições ambientais e, mesmo nesses ambientes naturais, as profundidades alcançadas pela carbonatação são pequenas, devido às baixas taxas de difusão do CO₂ atmosférico, necessitando, assim, de um longo período de tempo para atingir poucos milímetros (PAPADAKIS *et al.*, 1992; HELENE, 1993).

A difusão é mais lenta do que as reações de carbonatação e diminui muito se a umidade exceder 60%. Quando as concentrações de CO₂ atingirem valores maiores, a carbonatação será determinada pelas características do concreto e da fração de CO₂ disponível para a reação (RICHARDSON, 1988; STEFFENS; DINKLER; AHRENS, 2002).

Em concentrações elevadas de CO₂, como nas regiões urbanas, o mecanismo de carbonatação poderá ter maior intensidade, ou não, dependendo de outros fatores que também proporcionam condições necessárias à carbonatação (VERBECK, 1958; HELENE, 1993).

Richardson (1988) classifica os ambientes em urbanos, suburbanos, rurais e costeiros, dependendo da concentração de CO₂, observando uma tendência de maior taxa de carbonatação, na ordem crescente: ambientes costeiros, rurais, suburbanos e urbanos.

Entretanto, outros fatores devem ser considerados, por exemplo, o local efetivo onde está inserida a estrutura, os locais urbanos com grande tráfego de veículos, ambientes internos de garagens e ambientes industriais nos quais ocorre à queima de combustíveis fósseis. Nesses locais, as concentrações de CO₂ tendem a serem maiores. Na Tabela 2.1 são apresentadas as concentrações de CO₂ de acordo com o ambiente que a estrutura de concreto está inserida.

Tabela 2.1: Classificação dos ambientes de acordo com diversos autores em função da concentração de CO₂.

Ambiente	Concentração de CO ₂ (% em volume)	
	NEVILLE (1997)	SAETTA; VITALINI (2003)
Ambiente rural	0,03	0,015
Cidade	0,3 a 1	0,036
Ambiente de laboratório não ventilado	> 0,1	-
Ambiente industrial	-	0,045

2.4.1.5 Outros Aspectos Ambientais

A taxa de carbonatação, além de ser afetada pelos fatores ambientais já citados, também o é, pelas condições de exposição interna ou externa. Por exemplo, o mesmo concreto acondicionado em ambiente não protegido de chuvas, em ambientes externo protegido de chuva e em ambiente interno, tem carbonatação crescente, nesta ordem.

A taxa de carbonatação em ambientes internos chega a ser de duas vezes para concreto com cimento *Portland* comum e de 1,69 vezes maior para concreto com escória nas pesquisas de Litvan; Meyer (1986), de três vezes maiores, nas pesquisas de Richardson (1988) e de 1,85 vezes maior nas pesquisas de Steffens; Dinkler; Ahrens, (2002), do que as taxas de carbonatação em ambientes externo não protegido de chuvas.

2.4.2 Fatores internos ao Concreto

São de fundamental importância as condições ambientais de exposição do concreto no mecanismo da carbonatação. Entretanto, além destes fatores, temos as características do concreto, tais como o proporcionamento da mistura; o grau de hidratação; a relação água/cimento; que tanto influencia na porosidade, a microestrutura e resistência; a redução da quantidade de Ca(OH)₂ nos poros do concreto, que depende do tipo e teor do material cimentante; as condições de execução, destacando-se os procedimentos de cura; e a geometria da peça, também afetam o mecanismo da carbonatação (VERBECK, 1958; HELENE; MITTIDIARI FILHO; THOMAZ, 1995).

2.4.2.1 Idade e Grau de Hidratação do Concreto

Nas primeiras idades, o concreto encontra-se saturado e, posteriormente, com a ocorrência das reações de hidratação e evaporação da água, ocorre a sua secagem. Nas condições iniciais de umidade relativa alta, a difusão do CO₂ através do concreto e as reações de carbonatação praticamente não ocorrem (PARROT, 1989; ROSEMBERG, 1989; ANDRADE, 1989; HELENE, 1993). Contudo, com o passar do tempo, os grãos do aglomerante vão se hidratando e os espaços vazios vão sendo ocupados pelos produtos sólidos hidratados e a água livre vai sendo evaporada até atingir um ponto de umidade em equilíbrio com o meio ambiente (MEHTA; MONTEIRO, 2008).

A explicação para isso é porque o grau de hidratação das partículas do aglomerante avança com o tempo, modificando a umidade interna e a estrutura da pasta da zona de transição da matriz cimentícia (MEHTA; MONTEIRO, 2008).

Nas idades mais avançadas, o mecanismo da carbonatação é restringido pela menor permeabilidade do concreto. Deste modo, as reações de carbonatação, por serem diretamente influenciadas pela umidade interna e pela estrutura interna das matrizes cimentícias, são influenciadas também pela idade e pelo grau de hidratação do concreto como verificado por Parrot (1992).

2.4.2.2 Agregado

O agregado tem algumas características, como tipo, dimensão e forma, que afetam a trabalhabilidade do concreto fresco, a durabilidade do concreto endurecido e também a resistência à difusão do CO₂ (RICHARDSON, 1988). Consequentemente, o concreto produzido com agregado de forma mais arredondada será mais fácil de ser lançado e, dependendo das condições de transporte, lançamento, adensamento e cura, poderão ser mais densos e ter maior resistência à penetração de agentes agressivos, como o CO₂ (RICHARDSON, 1988; MEHTA; MONTEIRO, 2008).

Quando o agregado for leve, ele é mais poroso e, dependendo da comunicação, ou não, entre os seus poros, poderá ocorrer a formação de caminhos que conduzam à maior difusão do CO₂ (RICHARDSON, 1988).

A forma do agregado deve ser também considerada, por exemplo, se for lamelar ou alongada, estes tendem a se orientar segundo um plano, e um acúmulo de água pode ocorrer na parte inferior, fenômeno denominado de exsudação interna. Se esse fenômeno ocorrer muito próximo à superfície, nessas zonas a carbonatação será maior (MEHTA; MONTEIRO, 2008).

Outra forma de influência do agregado na carbonatação acontece quando este reage com os álcalis do cimento, formando produtos expansivos. A reação álcali-agregado que ocorre gera uma rede de fissuras por onde o CO₂ penetra mais facilmente (ANDRADE, 1989).

2.4.2.3 Qualidade do Concreto

A possibilidade do CO₂ atmosférico penetrar no concreto através da superfície é função da qualidade do concreto. Além da especificação de uma relação água/cimento adequada que garanta maior resistência e menor permeabilidade, o grau de hidratação do aglomerante, o tipo e o teor do aglomerante e do agregado, e as condições de cura e a espessura de cobertura do concreto merecem atenção especial para evitar o aparecimento de fissuras (ANDRADE, 1989).

Deve-se ressaltar, também, a importância da dosagem, lançamento, transporte e adensamento. Por exemplo, um concreto com elevado abatimento, mesmo com baixa relação água/cimento, quando vibrado excessivamente, pode gerar a exsudação interna e criar uma rede de capilares interconectados que vai desde a superfície até todo volume do concreto. Além disso, uma cura deficiente ou a falta desta pode também provocar o aparecimento de uma rede de capilares na superfície, facilitando o acesso de agentes agressivos (AÏCTIN, 2000).

A cura do concreto tem como objetivo evitar a retração, devido à evaporação precoce da água, durante um período suficiente para que este atinja um nível mínimo de resistência mecânica. Quanto maior for o tempo de cura, maior será o grau de hidratação do cimento, maior a resistência e menor a permeabilidade (MEHTA; MONTEIRO, 2008, AÏCTIN, 2000).

Do ponto de vista da carbonatação, as condições e o tempo de cura têm grande efeito nas propriedades e, conseqüentemente, na durabilidade do concreto. Com a ampliação do tempo de cura, em ambiente com temperatura e umidade controladas, diminui a

profundidade de carbonatação. Com relação ao cobrimento do concreto, a (NBR 6118, 2007) faz referência às classes de concreto para estabelecer os valores da relação água/cimento e cobrimento nominal, de acordo com as classes de agressividade do meio, observados nas Tabelas 2.2, 2.3 e 2.4.

Tabela 2.2: Recomendações de relações água/cimento do concreto em função da agressividade ambiental segundo a NBR 6118, 2007.

Concreto	Tipo	Classe de agressividade			
		I	II	III	IV
Relação água/cimento (em massa)	Concreto armado	< 0,65	< 0,60	< 0,55	< 0,45
	Concreto protendido	< 0,60	< 0,55	< 0,50	< 0,45
Classe de concreto (NBR 8953)	Concreto armado	> C20	> C25	> C30	> C40
	Concreto protendido	> C25	> C30	> C35	> C40

Tabela 2.3: Classes de agressividade do meio em função das condições de exposição segundo a NBR 6118, 2007.

Microclima Macroclima	Ambientes Internos		Ambiente externo e obras em geral	
	Seco UR < 65%	Úmido ou ciclos de molhagem/secagem	Seco UR < 65%	Úmido ou ciclo de molhagem e secagem
Rural	I	I	I	II
Urbano	I	II	I	II
Marinha	II	III	-	III
Industrial	II	III	II	III
Especial	II	III ou IV	III	III ou IV
Respingo maré	-	-	-	IV
Submersa > 3	-	-	-	I
Solo	-	-	Não agressivo	Úmido e agressivo II, III ou IV

Tabela 2.4: Recomendações de classe de resistência do concreto em função da agressividade de ambiental e do cobrimento nominal segundo a NBR 6118, 2007.

Tipo de estrutura	Componente ou elemento	Classe de agressividade Cobrimento nominal (mm)			
		I	II	III	IV
Concreto armado	Laje	20	25	35	45
	Viga/Pilar	25	30	40	50
Concreto protendido	Todos	30	35	45	55

Assim, além de obedecidos os cobrimentos especificados por norma, cuidados especiais devem ser tomados na mistura, transporte, lançamento, adensamento, cura e desmoldagem para se evitar o aparecimento de fissuras, garantindo, assim, a menor permeabilidade e, conseqüentemente, melhor qualidade do concreto. Esses cuidados são os mais importantes nas propriedades de difusividade, permeabilidade e absorção capilar de água e gases (HELENE, 2001).

2.5 Ensaio de Carbonatação

De acordo com Mitre; Barbosa; Helene, (2002), ao compararem os resultados da carbonatação nos ensaios realizados em pastas de cimento, argamassas e concretos, encontraram para uma mesma relação água/cimento, excluindo a absorção de parte d'água pelo agregado, diferenças significativas nas profundidades de carbonatação.

Quando nas pastas de cimento com mesma relação água/cimento, a profundidade de carbonatação foi maior, é decorrente de uma maior retração da pasta. Essa retração leva ao aparecimento de fissuras que possibilitam a entrada do CO₂.

Os ensaios utilizados para medir a profundidade de carbonatação podem ser naturais e acelerados.

2.5.1 Ensaio Naturais

Estes ensaios são efetuados colocando-se em exposição os corpos-de-prova, em ambiente natural, sem ajuste ou controle de parâmetros físicos do meio, em concentrações volumétricas de CO₂, da ordem de 0,015% a 0,045% em volume, protegido ou não de chuvas, ou em ambientes de laboratório nas concentrações de CO₂ do ambiente, com umidade e temperatura controlada, ou não.

Para os ensaios de carbonatação natural o ambiente mais utilizado é o de laboratório onde a umidade e a temperatura são controladas. Talvez porque, segundo Steffens; Dinkler; Ahrens (2002), os parâmetros envolvidos na exposição ao ar livre são mais difíceis de serem controlados. Quando os corpos-de-prova são expostos ao ar livre e submetidos a períodos de chuvas, nas áreas mais expostas têm menor carbonatação durante esse período.

2.5.2 Ensaio Acelerados

Nesse tipo de ensaio os corpos-de-prova são submetidos a elevadas concentrações de CO₂. Para alguns autores, como Mehta; Monteiro(2008), o concreto submetido a altas concentrações de CO₂ pode sofrer alterações em sua microestrutura, que deve ser investigada, porque a reação do CO₂ com o hidróxido de cálcio, numa carbonatação mais rápida, pode resultar numa instabilidade dos compostos formados. No entanto, nas pesquisas de Al-Kadhimi *et al.* (1995), o concreto carbonatado em altas pressões e altas concentrações de CO₂ proporcionou microestrutura similar à do concreto carbonatado naturalmente.

2.5.3 Medidas de Carbonatação

A baixa alcalinidade do concreto é resultado da carbonatação. Saber a medida de profundidade de carbonatação é muito importante para se controlar o tempo necessário até a despassivação da armadura.

O método usual consiste em pulverizar uma superfície recém fraturada do concreto com fenolftaleína ou timolftaleína, que são soluções indicadoras de pH. A solução de fenolftaleína é composta de 1 g de fenolftaleína dissolvida em 99 g de álcool.

A fenolftaleína apresenta uma coloração em vermelho carmim se o pH estiver acima de 9, enquanto que, se a superfície estiver carbonatada esta permanece incolor.

Contudo, para o pH igual a 9,0, a fenolftaleína indica uma profundidade que não corresponde necessariamente a um concreto não carbonatado ou um concreto parcialmente carbonatado (PARROT, 1989).

Este procedimento é o mais prático, embora existam outros procedimentos mais precisos, como análise mineralógica, análise térmica, difração de raios X, radiografia de nêutron e microscopia eletrônica (RICHARDSON, 1988).

Capítulo 3

3 REDES NEURAIS ARTIFICIAIS

3.1 Introdução

A busca pelo domínio das redes neurais tem atraído atenção crescente nos últimos anos. Desde 1943, quando Warren McCulloch e Walter Pitts apresentaram o primeiro modelo de neurônios artificiais, a cada dia, novas e mais sofisticadas propostas têm sido feitas. O estudo dos neurônios e as suas interligações com o cérebro é uma das áreas mais importantes da Biologia moderna. Para ilustrar sua importância entre 1901 a 1991, cerca de dez por cento dos prêmios Nobel de Fisiologia e Medicina foi atribuído aos cientistas que contribuíram para a compreensão do cérebro (ROJAS, 1996).

As redes neurais artificiais são sistemas paralelos e distribuídos, compostos por unidades de processamento simples (neurônios), que podem mapear funções matemáticas não-lineares. Estas unidades são dispostas em uma ou mais camadas, interligadas por conexões. Na maioria dos modelos, estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar as entradas recebidas por cada neurônio da rede.

As redes neurais artificiais demonstram capacidade que vai muito além de, simplesmente, mapear relações de entrada e saída, são capazes de extrair informações não apresentadas de forma explícita através dos exemplos e de atuar como mapeadores universais de funções multivariáveis. O funcionamento destas redes tem inspiração em uma estrutura física concebida pela natureza: o cérebro humano (BRAGA, 2000).

As redes neurais artificiais extraem seu poder computacional de sua distribuição de estrutura maciçamente paralela e da sua habilidade de aprender / generalizar, isto é, produzindo saídas adequadas para entradas que não estavam presentes durante a aprendizagem.

Estas duas capacidades de processamento de informação tornam possível a resolução de problemas complexos nas mais diferentes áreas do conhecimento, como economia, medicina, engenharia, computação, agronomia, entre outras (HAYKIN, 2001).

Atualmente, as Redes Neurais Artificiais são aplicadas na resolução de uma grande quantidade de problemas com sucesso. Dentre as principais áreas de aplicação de RNA, podem-se citar os sistemas de controle, reconhecimento de padrões e aproximações de funções (Castro, 1995).

Este capítulo aborda as principais características das RNA. A topologia MLP (*multilayer perceptron*) é discutida de forma mais detalhada, pois será usada como ferramenta auxiliar na estimação da profundidade de carbonatação do concreto.

3.1.1 Notas Históricas

O estudo da neurociência tem facilitado a compreensão de como se processa internamente o funcionamento do cérebro humano. Baseado nesse entendimento, os diferentes ramos da inteligência artificial, dentre os quais estão as redes neurais artificiais, também avançam buscando desenvolver algoritmos computacionais que tornem executável o modelo matemático desse comportamento para a reprodução de tarefas cognitivas. O breve histórico apresentado a seguir é baseado em (HAYKIN, 2001).

A era moderna das redes neurais artificiais teve início com o trabalho pioneiro de 1943, intitulado “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”, do psiquiatra e neuroanatomista Warren Maculloch e do matemático Walter Pitts. Neste trabalho eles descreveram um cálculo lógico das redes neurais, que unifica os estudos de neurofisiologia e da lógica matemática. Eles assumem que o seu modelo formal de um neurônio seguia uma lei do “tudo ou nada”. Assim, uma rede com um número suficiente dessas unidades simples e com conexões sinápticas ajustadas apropriadamente e operando de forma simultânea, realizaria, em princípio, a computação de qualquer função.

O trabalho pioneiro de McCulloch-Pitts sobre o neurônio influenciou Von Neumann na construção do EDVAC (*Electronic Discrete Variable Automatic Computer*), que foi desenvolvido a partir do ENIAC (*Electronic Numerical Integrator and Computer*), o primeiro computador eletrônico de propósito geral construído na University of Pennsylvania no período de 1943 a 1946.

Em 1948, Wiener publicou um livro bastante significativo, intitulado *Cybernetics*, que descreve novos conceitos importantes sobre controle, comunicação e processamento estatístico de sinais.

O ano de 1949 foi considerado muito significativo para o desenvolvimento das redes neurais artificiais, com a publicação do livro de Donald Hebb “*The Organization of Behavior*”, no qual foi apresentada uma nova teoria baseada no processo de aprendizagem que ocorre no cérebro humano, servindo de base para o desenvolvimento de modelos computacionais de sistemas adaptativos e de aprendizagem. O livro influenciou bastante os psicólogos, entretanto, não teve nenhuma repercussão na comunidade de engenharia.

Nos anos seguintes, novos estudos na área aperfeiçoaram ainda mais o desenvolvimento das redes neurais artificiais, como, por exemplo, a proposta de criação por Gabor de um filtro adaptativo não-linear e do conceito de memória associativa, que inseriu a matriz de aprendizagem.

Em 1958, quinze anos após a publicação do clássico artigo de McCulloch e Pitts, Frank Rosenblatt criou a rede Perceptron, com uma estrutura simples contendo duas camadas de neurônios, usada com sucesso para o reconhecimento de caracteres. Portanto, um método inovador de aprendizagem supervisionada. Mais tarde, criou o teorema da convergência do perceptron. Paralelamente, em 1960, Bernard Widrow e Marcian Hoff criaram o algoritmo do Mínimo Quadrado médio (*Least Mean-Square*), e o usou para formular o ADALINE (*Adaptive Linear Element*), a primeira rede capaz de imitar o cérebro humano usando processadores paralelos.

Posteriormente, este modelo foi generalizado para várias camadas, passando a ser denominado de Madaline (multiple-adaline).

A diferença básica entre o Perceptron e o ADALINE está no processo de aprendizagem. A maioria dos modelos de redes neurais atualmente utilizados foi concebida nestes anos (HAYKIN, 2001, GUERRA, 2006).

Os anos de glória da rede Perceptron de Rosenblatt se sucederam durante toda a década de 60. Entretanto, em 1969, sua credibilidade foi severamente questionada devido às críticas feitas por Mavin Minsky e Seymour Papert, com a publicação “*Perceptron*”, onde argumentavam que as redes neurais artificiais apresentavam limitações fundamentais em suas aplicações, não possuíam capacidade de aprendizado para resolver problemas simples, nem sustentação matemática.

Foi então, que as redes neurais artificiais atravessaram um período de descrédito e abandono durante toda a década de 70. Mesmo assim, alguns pioneiros mantiveram-se firmes em suas convicções, fazendo surgir diversos trabalhos significativos.

As pesquisas com as redes neurais artificiais só voltaram a recuperar sua credibilidade com o trabalho do físico e biólogo John Hopfield, em 1982, que se contrapuseram as afirmações de Minsky e Papert, provocando um novo interesse nas pesquisas de redes neurais artificiais.

A partir de então, os trabalhos desenvolvidos, mas não divulgados por incógnitos pesquisadores nos anos de descrédito, surgiram como uma avalanche de publicações.

A retomada das pesquisas sobre o tema fez brotar o desenvolvimento de novas teorias, projetos e aplicações, como, por exemplo, a introdução do algoritmo *backpropagation* em 1986.

3.1.2 Inspirações Biológicas

O cérebro humano contém em torno de 100 bilhões de neurônios. Cada um destes neurônios processa e se comunica com milhares de outros continuamente e em paralelo (BRAGA et al., 2000). A Figura 3.1 ilustra o arranjo do circuito neuronal.




Figura 3.1 – Componentes do circuito neuronal (disponível em:

<http://www.Incc.bt/~laboinfo/tutorialRN> acessado em 11 agosto 2009).

Um neurônio característico é composto por um corpo celular ou soma, um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. Os dendritos formam uma malha de filamentos ao redor do neurônio.

O axônio é composto de um tubo longo e fino que se divide em ramos terminados em pequenos bulbos quase tocando os dendritos dos outros neurônios.

O espaço entre o fim do bulbo e os dendritos é conhecido como sinapse, através da qual as informações se propagam.

É pela sinapse que os nodos se unem funcionalmente, formando redes neurais.

A Figura 3.2, ilustra o modelo simplificado de um neurônio biológico.




Figura 3.2– Modelo simplificado de neurônio biológico típico (disponível em:

(<http://www.Incc.bt/~laboinfo/tutorialRN> acessado em 11 agosto 2009).

As sinapses funcionam como válvulas e são capazes de controlar a transmissão do fluxo de informação entre os nodos na rede neural. O efeito das sinapses é variável, e é esta variação que dá ao neurônio a capacidade de adaptação.

Os sinais oriundos dos neurônios pré-sinápticos são passados para o corpo dos neurônios pós-sinápticos, onde são comparados com os outros sinais recebidos pelos mesmos.

Se o percentual em um intervalo curto de tempo é suficientemente alto, a célula dispara, produzindo um impulso que é transmitido para as células seguintes (nodos pós-sinápticos).

Este sistema simples é responsável pela maioria das funções realizadas pelo cérebro.

A capacidade de realizar funções complexas surge com a operação em paralelo de todos os 100 bilhões de nodos do cérebro humano.

3.2 Neurônios Artificiais

Um neurônio artificial é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. A Figura 3.3 mostra o modelo de um neurônio artificial, que forma a base para o projeto de redes neurais artificiais.

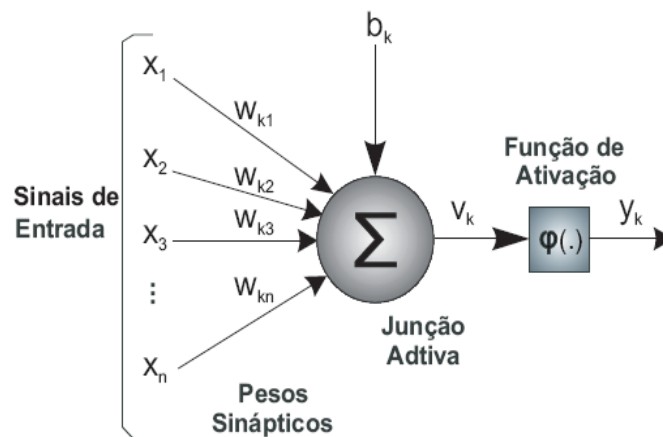


Figura 3.3- Modelo de um neurônio artificial (HAYKIN, 2001)

De acordo com Haykin, o modelo neuronal é identificado por cinco elementos básicos e suas semelhanças com o neurônio biológico:

- 1- Um conjunto de sinapses ou entradas, cada qual caracterizada por seu correspondente peso. De modo específico é, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso sináptico w_{kj} . Ao contrário de uma sinapse do cérebro humano, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos e positivos;
- 2 – Um somador, para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio. Essas operações constituem um combinador linear;
- 3 - Uma função de ativação, para restringir a amplitude da saída de um neurônio. Na literatura ela também é referida como uma função que limita o intervalo permissível de amplitude do sinal de saída a um valor finito.

O intervalo normalizado característico da amplitude de saída de um neurônio é o intervalo fechado $[0,1]$ ou alternativamente $[-1,1]$;

4 - Um bias (ou termo de polarização) aplicado externamente, sendo representado na Figura 3.3 por b_k , que tem a função de aumentar ou diminuir a entrada líquida da função de ativação, dependendo dele ser positivo ou negativo, respectivamente;

5 - Uma saída y_k , representada pelo axônio, que fornece o valor do sinal de saída do neurônio k .

O neurônio artificial tem como função realizar o somatório ponderado dos pesos sinápticos, dos elementos do vetor de entrada e aplicar este resultado como entrada de uma função de ativação.

Em termos matemáticos, pode-se descrever um neurônio k através das seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (3.2)$$

Em que

- $x_1, x_2, x_3, \dots, x_m$ são os sinais de entrada;
- $w_{k1}, w_{k2}, w_{k3}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ;
- u_k é a saída do somador do neurônio k ;
- b_k são as bias do neurônio k ;
- $\varphi(\bullet)$ é a função de ativação;
- y_k é o sinal de saída do neurônio k .

O modelo neuronal descrito na Figura 3.3 inclui também um bias aplicado externamente, representado por b_k .

Ele serve para aumentar os graus de liberdade da rede e tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, permitindo, assim, melhor adaptação ao conhecimento fornecido. O uso das bias b_k tem o efeito de aplicar uma transformação afim à saída do somador u_k do modelo da Figura 4.3, como mostrado por

$$v_k = u_k + b_k \quad (3.3)$$

Em particular, dependendo se o bias b_k é positivo ou negativo, a relação entre o potencial de ativação v_k do neurônio k e a saída do somador u_k é modificada na forma ilustrada na Figura 3.4.




Figura 3.4: Transformação afim produzida pela presença de umas bias.

3.2.1 Função de Ativação

O modelo de McCulloch e Pitts propiciou a derivação de vários outros modelos que permitem a produção de uma saída qualquer, não necessariamente zero ou um, e com diferentes funções de ativação (BRAGA et al, 2000).

A função de ativação converte o somatório das entradas ponderado pelos pesos em um sinal de ativação de entrada para o neurônio. Em seguida a função de ativação converte a somatória das ativações das entradas em ativação de saída e diferencia a decisão neural baseada no potencial interno do neurônio, determinando o valor a serem enviados aos demais neurônios.

Em uma rede neural artificial, cada unidade de processamento está associada a um estado de ativação que é determinado pela função de ativação, que pode ser discreta ou contínua, dependendo do modelo que se quer representar.

Nas Figuras 3.5 e 3.6 estão representadas algumas funções de ativação. As mais utilizadas são: a linear, a degrau, a tangente hiperbólica, a rampa e a sigmóide logística.




Figura 3.5 (a) Função Linear (b) Função Degrau (c) Função Rampa




Figura 3.6 (a) Função Tangente Hiperbólica (b) Função Sigmóide

A função de ativação pode ter muitas formas simples ou complexas. Em uma rede neural, cada unidade de processamento está associada a um estado de ativação que se quer representar com o modelo.

A função escolhida para o estado de ativação é responsável pelo sinal a ser transmitido por um determinado neurônio aos demais a ele conectados.

A função de ativação é também conhecida como limiar lógico. Em geral, cada função tem sua característica, conforme descrita por (SILVA et al, 2004):

- Função linear é a função que não limita a saída da rede neural e é usada para armazenar entrada e saída de dados. Quando aplicada aos neurônios esta atua como aproximadores lineares;
- Função degrau é a função muito utilizada para neurônios que assumem decisões binárias, ou seja, limita a saída do neurônio somente a dois valores, sendo muito utilizada como classificadora;
- Função sigmóide logística é uma função limitada que assume valores entre um limite superior e um inferior (0 e 1), sem jamais atingi-los.
- Função sigmóide tangente hiperbólica é uma função limitada, definida no intervalo de -1 e $+1$.

As funções tangentes hiperbólicas e sigmóides são as mais utilizadas em redes neurais artificiais, porque apresentam diversas características, tais como: semi-lineares, contínuas, simétricas, deriváveis em toda sua extensão, monotonicamente crescente e limitada por assíntotas horizontais.

3.3 Principais Arquiteturas de Redes Neurais

A arquitetura de uma rede neural tem um aspecto importante na sua concepção, uma vez que ela limita o tipo de problema que pode ser tratado pela rede. Redes com uma única camada de nós, por exemplo, conseguem resolver problemas linearmente separáveis, enquanto que as redes recorrentes são mais apropriadas para resolver processamento temporal (BRAGA, 2000).

A arquitetura é a maneira como os neurônios da rede estão estruturados. Esta estruturação está intimamente ligada com o algoritmo (regras) de aprendizagem usado para treinar a rede. Existem várias estruturas que diferem umas das outras em função do número de camadas e pela forma como seus neurônios interagem.

A literatura existente traz algumas sugestões oriundas de experiências realizadas que podem servir como balizamento; mas a definição de parâmetros, como o algoritmo de treinamento, o tipo de conexão, o número de camadas e de neurônios por camada, não possui uma regra pré-determinada. Assim, a estrutura da rede deve ser produzida pela análise do problema e pela experimentação.

Inicialmente, o número de camadas e a quantidade de neurônios em cada camada são definidos em função da análise dos dados e da complexidade do problema, não havendo números pré-estabelecidos.

Quanto à topologia (que corresponde ao modo pelo qual os vários elementos em uma rede são interconectados), esta é determinada por sucessivos refinamentos do modelo. Entretanto, é necessário e imprescindível que a quantidade de neurônios esteja dentro de uma faixa aceitável, isto é, não pode haver neurônios demais ou de menos, pois o excesso ou a falta podem causar perda de sensibilidade ou memorização de dados (fase que a rede deixa de aprender), evento que prejudicaria a generalização dos dados.

Segundo Silva et al (2004), dentre os fatores que influenciam estes ajustes estão: número de exemplos de treinamento, quantidade de ruído, complexidade da função a ser aprendida e distribuição estatística dos dados.

Alguns exemplos de arquiteturas de redes neurais artificiais são apresentados na Figura 3.6 quanto ao número de camadas:




Figura 3.6 – Arquiteturas de redes neurais.

- Redes de camada única – existe um só nó entre qualquer entrada e qualquer saída da rede (Figura 3.6 (a) e (b));
- Redes de múltiplas camadas – existe mais de um neurônio entre alguma entrada e alguma saída da rede (Figura 3.6 (c) e (d)).

3.3.1 Conexões entre as Unidades de Processamento

Existem várias formas de interação entre os neurônios constituintes de uma rede neural artificial. Quanto aos nós, estes podem ter conexões do tipo:

- *Feedforward*, ou acíclica – a saída de um neurônio na *i-ésima* camada da rede não pode ser usada como entrada de nós em camadas de índice menor ou igual a *i* de acordo com a Figura 3.6 (a) e (c), vista anteriormente.
- *Feedback*, ou cíclica – a saída de algum neurônio na *i-ésima* camada da rede é usada como entrada de nós em camadas de índice menor ou igual a *i* conforme Figura 3.6 (b).

Quanto à conectividade as redes neurais artificiais podem ser classificadas:

- Rede fracamente ou parcialmente conectada Figura 3.6 (c) e (d).
- Rede completamente conectada Figura 3.6 (a) e (b).

3.3.2 Redes Alimentadas Adiante com Camada Única

Em uma rede neural acíclica, os neurônios estão organizados na forma de camadas. Na forma mais simples desse tipo de rede, tem-se uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios (nós computacionais), mais nunca vice-versa. Ou seja, esta rede é estritamente do tipo alimentada adiante ou acíclica, conforme ilustrado na Figura 3.7, para o caso de quatro nós tanto na camada de entrada como na de saída.

Esta rede é chamada de rede de camada única, pois se refere à camada de saída de nós computacionais (neurônios). A camada de entrada de nós de fonte não é considerada porque nela não é realizada qualquer computação (HAYKIN, 2001).




Figura 3.7 – Rede alimentada adiante ou acíclica com uma única camada de neurônios.

3.3.3 Redes Alimentadas Diretamente com Múltiplas Camadas

A segunda classe de uma rede alimentada adiante se distingue pela presença de uma ou mais camadas ocultas, cujos nodos computacionais são chamados correspondentemente de neurônios ocultos ou unidades ocultas. A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de uma maneira vantajosa. Adicionando-se uma ou mais camadas ocultas, a rede se torna capaz de extrair estatísticas de ordem elevada. Assim, a rede adquire uma perspectiva global apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais.

A habilidade de os neurônios ocultos extraírem estatísticas de ordem elevada é particularmente precisa e valiosa quando o tamanho da camada de entrada é relativamente grande (HAYKIN, 2001).


Os nós de fonte da camada de entrada da rede fornecem os respectivos elementos do padrão de ativação (vetor de entrada), que constituem em sinais de entrada aplicados aos neurônios (nós computacionais) na segunda camada, isto é, na primeira camada oculta.

Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada, e assim por diante para o resto da rede.

Caracteristicamente, os neurônios em cada camada da rede têm como suas entradas apenas os sinais de saída da camada precedente.

O conjunto de sinais dos neurônios da camada de saída (final) da rede constitui a resposta global da rede para o padrão de ativação fornecido pelos nós de fonte da camada de entrada (primeira).

A Figura 3.8 apresenta uma rede neural de múltiplas camadas alimentada adiante para o caso de uma única camada oculta, que possui quatro neurônios de fonte, quatro neurônios ocultos e dois neurônios de saída. A rede ilustrada na Figura 3.8 é totalmente conectada, no sentido de que cada um dos nós de uma camada da rede está conectado a todos os nós da camada adjacente seguinte. Se alguns dos elos de comunicação (conexões sinápticas) estiverem faltando na rede, diz-se que a rede é parcialmente conectada (HAYKIN, 2001).



Camada de entrada de
neurônios de fonte

Camada de
neurônios ocultos

Camada de neurônios
de saída

Figura 3.8 – Rede alimentada adiante ou acíclica totalmente conectada com uma camada oculta e uma camada de saída.

3.3.4 Redes Recorrentes

Uma rede neural recorrente se distingue de uma rede neural alimentada adiante ou acíclica por ter pelo menos um laço de realimentação. Uma rede recorrente pode consistir, por exemplo, de uma única camada de neurônios com todos os neurônios alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios, como ilustra a Figura 3.9.

Na estrutura apresentada na figura, não há laços de auto-realimentação na rede. Auto-realimentação se refere a uma situação onde a saída de neurônio é realimentada para a sua própria entrada. A rede recorrente mostrada na Figura 3.9 também não tem neurônios ocultos (HAYKIN, 2001).




Figura 3.9 – Rede recorrente sem laços de auto-realimentação e sem neurônios ocultos.

3.4 Processos de Aprendizado

As redes neurais artificiais possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam a partir de seu ambiente. Para isso, foram desenvolvidos diversos algoritmos de aprendizagem, ou seja, conjunto de regras definidas para que uma rede neural possa aprender uma determinada função. Estes algoritmos, cada qual com suas vantagens e desvantagens, diferem basicamente, pela maneira com a qual o ajuste dos pesos é feito.

A utilização de uma rede neural na solução de uma tarefa passa inicialmente por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões apresentados a ela, criando assim uma representação própria para o problema. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando (BRAGA, 2000).

Uma definição geral do que vem a ser aprendizagem pode ser expressa da seguinte forma:

“Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando, sendo o tipo específico de aprendizagem realizada definido pela maneira particular como ocorrem os ajustes realizados nos parâmetros”. Essa definição do processo de aprendizagem implica a seguinte seqüência de eventos (HAYKIN, 2001):

1. A rede neural é estimulada por um ambiente.
2. A rede neural sofre modificações nos seus parâmetros como resultado dessa estimulação.
3. A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna.

Diversos métodos para treinamento de redes foram desenvolvidos, podendo ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não – supervisionado.

3.4.1 Aprendizado Supervisionado

Este método de aprendizado é o mais comum no treinamento das redes neurais, tanto de neurônios com pesos como de neurônios sem pesos. É chamado de aprendizagem supervisionado porque a entrada e a saída desejada para a rede são fornecidas por um supervisor (professor) externo. O objetivo é ajustar os parâmetros da rede de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos. Toda vez que for apresentada à rede neural uma entrada, deverá ser verificado se a saída obtida confere com a saída desejada. Sendo diferente, a rede neural deverá ajustar os pesos das conexões para minimizar o erro.

A minimização da diferença é incremental, já que pequenos ajustes são feitos nos pesos a cada etapa de treinamento, de tal forma que estes caminhem para uma solução. A soma dos erros quadráticos de todas as saídas é normalmente utilizada como medida de desempenho da rede e também como função de custo a ser minimizada pelo algoritmo de treinamento.

A desvantagem do aprendizado supervisionado é que, na ausência do professor, a rede não conseguirá aprender novas estratégias para situações não-cobertas pelos exemplos do treinamento da rede. A Figura 3.10 ilustra o mecanismo de aprendizado supervisionado.

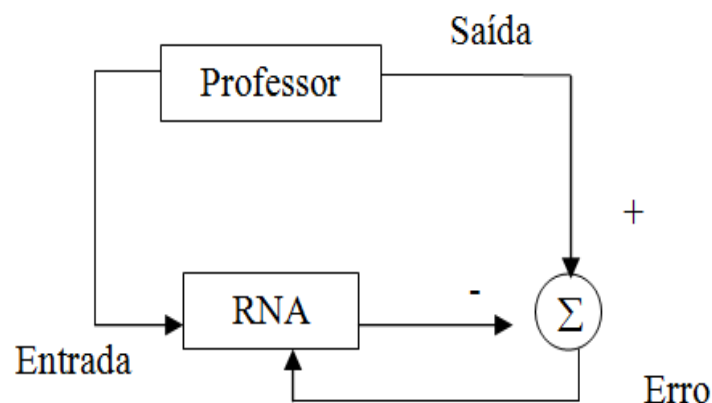


Figura 3.10 – Aprendizado supervisionado

3.4.2 Aprendizado Não-Supervisionado

Apesar da semelhança entre o aprendizado supervisionado e o aprendizado dos seres humanos, muito dos sistemas biológicos ocorrem através de aprendizado não-supervisionado, como, por exemplo, os estágios iniciais dos sistemas de visão e audição.

No aprendizado não-supervisionado não há um professor ou supervisor para acompanhar o processo de aprendizado.

Significando que não há exemplos rotulados da função a ser aprendida pela rede. Para este algoritmo somente os padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui pares de entrada e saída.

A partir do momento que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características da entrada e criar novas classes ou grupos automaticamente.

Este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada, caso contrário seria impossível obter quaisquer padrões ou características dos dados de entrada (BRAGA, 2000). A Figura 3.11 ilustra o mecanismo de aprendizado não-supervisionado.




Figura 3.11 – Aprendizado não-supervisionado

A estrutura do sistema de aprendizado não-supervisionado pode adquirir uma variedade de formas diferentes. Ela pode, por exemplo, consistir em uma camada de entrada, uma camada de saída, conexões feedforward da entrada para a saída e conexões laterais entre os neurônios da camada de saída.

Outro exemplo é uma rede feedforward com múltiplas camadas, em que a livre organização precede na base de camada por camada. Nesses dois exemplos, o processo de aprendizado consiste em modificar repetidamente o peso sináptico de todas as conexões do sistema em resposta às entradas (BRAGA, 2000).

O aprendizado por competição é um caso particular de aprendizado não-supervisionado. Neste caso, para um dado padrão de entrada, as saídas competem entre si com o objetivo de serem ativadas e, dessa forma, seus pesos serão atualizados no treinamento. As unidades de entrada são diretamente conectadas às unidades de saída, que por sua vez, podem estar ligadas entre si por meio de conexões laterais. A unidade de saída com maior ativação inicial terá maior chance de vencer a disputa das outras unidades.

Segundo Braga (2000), a unidade mais forte se torna ainda mais forte e seu efeito inibidor sobre todas as outras unidades torna-se dominante, com o passar do tempo, todas as outras unidades de saída ficarão completamente inativas, exceto a vencedora.

3.5 Algoritmos de Otimização e de Treinamento

O aprendizado supervisionado, descrito na seção 3.7.1, é uma forma de aprendizagem por correção de erro. Como medida de desempenho para o sistema, utiliza-se o erro quadrático médio ou a soma dos erros quadráticos sobre a amostra de treinamento, definida como uma função dos parâmetros livres do sistema.

Esta função pode ser visualizada como uma superfície multidimensional de desempenho de erro, ou simplesmente uma superfície de erro, com os parâmetros da rede como coordenadas.

A verdadeira superfície de erro é obtida pela média sobre todos os exemplos possíveis de entrada-saída. Toda e qualquer operação do sistema sob supervisão do professor é representada como um ponto sobre a superfície de erro.

Para que o sistema melhore seu desempenho ao longo do tempo, o ponto de operação deve ser movido para baixo sucessivamente em direção a um ponto mínimo da superfície, que pode ser um mínimo local ou um mínimo global.

Um sistema de aprendizado supervisionado é capaz de fazer isso com a informação útil que ele tem sobre o gradiente da superfície de erro, correspondente ao comportamento corrente do sistema.

O gradiente de uma superfície de erro em qualquer ponto é um vetor que aponta na direção da descida mais íngreme. Na verdade, no caso do aprendizado supervisionado, o sistema pode usar a estimativa instantânea do vetor gradiente, supondo que os índices dos exemplos sejam os mesmos dos instantes de tempo (HAYKIN, 2001).

3.5.1 Algoritmos de Otimização

O aprendizado em uma rede neural consiste, de certa forma, em uma tarefa de otimização, visto que, o objetivo desse aprendizado é minimizar a função de erro quadrático médio (VICENTE, 2002).

Há varias técnicas para a otimização de funções multidimensionais não-lineares como a função erro encontrada nas redes neurais. Genericamente, um algoritmo iterativo de otimização no espaço de parâmetros \mathbf{w} consiste em uma busca em que, a cada passo, são determinados uma direção e um tamanho de passo, conforme indicado na equação 3.4.

$$\mathbf{w}_{t+1} = \mathbf{w}_t + \alpha_t + \mathbf{d}_t \quad [\text{Eq.3.4}]$$

Onde \mathbf{w}_{t+1} é o parâmetro que está sendo calculado, \mathbf{w}_t é o parâmetro do passo anterior, α_t é o tamanho do passo utilizado e \mathbf{d}_t é a direção do passo.

É importante ressaltar que a notação em negrito indica um vetor. Quanto mais informação sobre a geometria da superfície definida pela função erro for utilizada, mais eficiente será o algoritmo. Considere a expansão da função erro, $E(\mathbf{w})$, em torno de um ponto \mathbf{w}_1 , dada por

$$E(\mathbf{w}) \cong E(\mathbf{w}_1) + (\mathbf{w} - \mathbf{w}_1) \nabla E(\mathbf{w}_1) + \frac{1}{2} (\mathbf{w} - \mathbf{w}_1) \mathbf{H} (\mathbf{w} - \mathbf{w}_1) \quad [\text{Eq.3.5}]$$

Em que $\nabla E(\mathbf{w}_1)$ é a gradiente da função erro e \mathbf{H} é a matriz conhecida como Hessiano, definida por:

$$\mathbf{H}_{jk} = \frac{\partial^2 E}{\partial w_j \partial w_k} \Big|_{w_1} \quad [\text{Eq.3.6}]$$

Suponha que $\mathbf{w}_1 = \mathbf{w}^*$ seja um extremo de E , então

$$E(\mathbf{w}) \cong E(\mathbf{w}^*) + \frac{1}{2} (\mathbf{w} - \mathbf{w}^*) \mathbf{H} (\mathbf{w} - \mathbf{w}^*) \quad [\text{Eq.3.7}]$$

Dessa forma, podem-se calcular os autovalores do Hessiano,

$$\mathbf{H} \mathbf{u}_k = \lambda_k \mathbf{u}_k \quad [\text{Eq.3.8}]$$

E expandir o vetor $(\mathbf{w} - \mathbf{w}^*)$ na base dos autovalores de \mathbf{H} , escrevendo

$$E(\mathbf{w}) \cong E(\mathbf{w}^*) + \frac{1}{2} \sum_k \lambda_k \alpha_k^2 \quad [\text{Eq.3.9}]$$

Assim, os autovalores do Hessiano indicam direções ortogonais que diagonalizam a matriz \mathbf{H} . De (3.9) pode-se concluir que, a fim de que \mathbf{w}^* defina um mínimo, é necessário que todos os autovalores sejam positivos. Além disso, a velocidade de convergência do erro é maior em direção ao autovalor (VICENTE, 2002).

A seguir, serão apresentadas algumas técnicas utilizadas para aperfeiçoar a função de erro quadrático médio em redes neurais.

3.5.1.1 Gradiente Descendente

Este método consiste na escolha do negativo do gradiente da função erro como direção para cada passo da otimização. O tamanho de cada passo é definido por uma taxa de aprendizagem η , conforme expressão:

$$\mathbf{w}_{t+1} = \mathbf{w}_t - \eta \nabla E(\mathbf{w}_t) \quad [\text{Eq.3.10}]$$

A taxa de aprendizagem η deve respeitar a condição (3.11), onde λ_{\max} é o maior autovalor do Hessiano.

$$\eta < \frac{2}{\lambda_{\max}} \quad [\text{Eq.3.11}]$$

Quanto maior for o produto da taxa de aprendizagem pelo autovalor máximo, mais rápida será a convergência. Quando o Hessiano possuir um espectro de autovalores amplo, as várias direções apresentarão tempos de convergência bem diferentes.

O processo total de convergência é determinado pela região de convergência mais lenta, ou seja, a direção com menor autovalor.

Em geral, a gradiente descendente é bastante ineficiente, mas várias formas de melhorar seu desempenho foram propostas, entre elas a adição de um termo de momentum e a redução do número de passos necessários para a convergência pela utilização de um esquema para minimização (VICENTE, 2002).

A adição do termo de momentum é representada por

$$w_{t+1} = w_t - \eta \nabla E(w_t) + \mu(w_t - w_{t-1}) \quad [\text{Eq.3.12}]$$

Onde $0 \leq \mu \leq 1$. Este termo tem o mesmo sinal da última variação, assim, se uma componente foi reduzida ela continuará sendo reduzida. Em geral, isso será uma vantagem em trechos da superfície de erro em forma de vale, com pouca curvatura na direção do mínimo e muita curvatura em outra direção qualquer.

O termo de momentum, nesse caso, adicionará certa inércia à direção do mínimo, aumentando a taxa de convergência.

Uma forma de reduzir o número de passos necessários para a convergência é a redução do número de dimensões do problema apenas à direção do gradiente, o que pode ser feito pela introdução de um algoritmo da otimização unidimensional a cada passo da otimização, como mostrado na equação (3.13).

$$w_{t+1} = w_t - \lambda * \nabla E(w_t) \quad [\text{Eq.3.13}]$$

Onde $\lambda *$ é definido como o mínimo de

$$E(\lambda) = E(w_t - \lambda \nabla E(w_t)) \quad [\text{Eq.3.14}]$$

A minimização unidimensional em 3.14 pode ser realizada utilizando uma busca linear, que também permite aumentar, consideravelmente, a velocidade de convergência do gradiente descendente.

3.5.1.2 Gradiente Conjugado

A equação (3.14) garante que a função seja minimizada na direção do gradiente $\nabla_t E$, no entanto, o passo seguinte $\nabla_{t+1} E$ não garante que λ^* continue sendo o mínimo da função erro. Assim cada passo pode destruir parte do trabalho de otimização do passo anterior.

Uma maneira de solucionar esse problema é impor que a nova direção do passo $t + 1$ seja tal que a gradiente no novo ponto do espaço dos parâmetros não tenha componentes na direção do último passo da otimização, ou seja,

$$\nabla E(w_{t+1} + \lambda d_{t+1})d_t = 0 \quad [\text{Eq.3.15}]$$

A correção necessária para se atingir o mínimo da função erro pode ser expandida em uma base de vetores mutuamente conjugados, ou seja, vetores que formam uma base ortogonal com métrica definida pelo Hessiano \mathbf{H} , conforme representa a equação 3.16.

$$w^* - w_1 = \sum_{i=1}^N \alpha_i d_i \quad [\text{Eq.3.16}]$$

Onde N é a dimensão do espaço de parâmetro.

Seja o vetor de parâmetros definido como

$$w_j = w_1 + \sum_{i=1}^{j-1} \alpha_i d_i \quad [\text{Eq.3.17}]$$

Dessa forma, tem-se a correção na componente j do vetor de parâmetros dada, alternativamente, por:

$$w_{j+1} = w_j + \alpha_j d_j \quad [\text{Eq.3.18}]$$

A equação 3.18 expressa como cada componente do vetor de parâmetros é corrigida a partir da componente anterior. Assim, a otimização utilizando gradiente conjugado ocorre por otimização de cada um componente por vez.

3.5.1.3 Gradiente Conjugado Escalado

Para uma superfície quadrática, a amplitude de cada passo de otimização é dada pela equação:

$$\alpha_j = - \frac{d_j \nabla E(w_j)}{d_j H d_j} \quad [\text{Eq.3.19}]$$

Para evitar o cálculo da Hessiana em 3.19 o algoritmo do gradiente conjugado utiliza a cada passo uma otimização linear. Esta otimização linear possui duas vantagens: requer um grande número de avaliações de valor da função sendo otimizada e a convergência do algoritmo de gradientes depende da qualidade de cada otimização unidimensional.

Com o objetivo de evitar o uso de otimizações unidimensionais a cada passo e o cálculo da Hessiana, foi criado o algoritmo do gradiente conjugado escalado.

A idéia central deste algoritmo é utilizar uma aproximação numérica para o termo envolvendo a Hessiana em 3.19.

Esta aproximação é possível quando a função a ser minimizada for quadrática e a Hessiana for positiva definida. Uma matriz é positiva definida se, e somente se, todos os seus autovalores forem maiores que zero.

Para superfícies genéricas, nada garantirá que a Hessiana seja positiva definida e a um passo de otimização. Utilizando a equação (3.19) poderá aumentar o valor da função em algumas direções. Para se usar a aproximação numérica e minimizar esses efeitos, pode-se corrigir a equação 3.19 da seguinte forma

$$\alpha_j = -\frac{d_j \nabla E(w_j)}{d_j H d_j + \gamma_j \|d_j\|^2} \quad [\text{Eq.3.20}]$$

O parâmetro γ regula a escala de cada passo. Por isso, o nome gradiente conjugado escalado. Esse parâmetro é inicializado como $\gamma_j = 1$. Quanto maior for o parâmetro de escala, menor será a amplitude do passo de otimização. A escala apropriada depende de quanto a função sendo otimizada é localmente diferente de uma superfície quadrática. Se a função for exatamente quadrática, $\gamma = 0$, se a função for distante de uma função quadrática, γ deve aumentar (VICENTE, 2002).

3.5.2 Algoritmo de Treinamento

Qualquer que seja o método de otimização utilizado, é necessário calcular o gradiente da função erro, por meio de um algoritmo de treinamento. No caso de uma MLP (*Multi Layer Perceptron*), uma maneira bastante eficiente de realizar esse cálculo, conhecido como algoritmo *backpropagation*, foi proposta inicialmente na década de sessenta e depois redescoberta várias vezes (VICENTE, 2002).

O algoritmo *backpropagation* é um algoritmo supervisionado que utiliza pares (entrada e saída desejada) para ajustar os pesos da rede, por meio de um mecanismo de correção de erros.

O treinamento ocorre em duas fases, denominadas de *forward* e *backward*, em que cada fase percorre a rede em um sentido.

A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entrada. A fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. Os dados seguem da entrada para a saída no sentido *forward* e os erros, da saída para a entrada no sentido *backward*.

O algoritmo *backpropagation* faz com que os pesos da camada de saída sejam os primeiros a serem ajustados e, posteriormente, os pesos das camadas restantes, corrigindo-os de trás para frente, com o objetivo de reduzir o erro. Este processo é repetido durante o aprendizado até que o erro se torne aceitável. A Figura 3.12 ilustra essas duas fases (BRAGA, 2000).

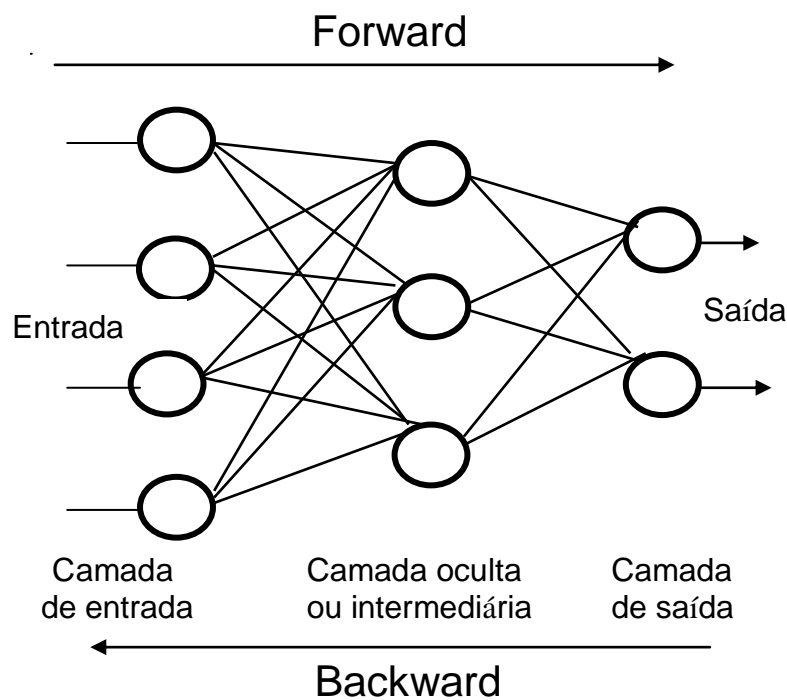


Figura 3.12 – Etapas de propagação e retro propagação do algoritmo backpropagation.

Na fase *backward*, o padrão de saída é comparado com a saída desejada e um sinal de erro é calculado para cada elemento de saída.

O sinal de erro é então retro- propagado da camada de saída para cada elemento da camada intermediária anterior que contribui diretamente para a formação da saída.

Entretanto, cada elemento da camada intermediária recebe apenas uma porção do sinal de erro total, proporcional apenas à contribuição relativa de cada elemento na formação da saída original.

Este processo se repete camada, por camada até que cada elemento da rede receba um sinal de erro que descreva sua contribuição relativa para o erro total. Com base no sinal de erro recebido, os pesos das conexões são então atualizados para cada elemento de modo a fazer a rede convergir para um estado que permita a codificação de todos os padrões do conjunto de treinamento (VIEIRA, 2003).

O algoritmo *backpropagation* consiste, basicamente, dos passos (VICENTE, 2002).

1. Dada a entrada \mathbf{x} , calculam-se os campos pós-sinápticos h_m por toda a rede.

$$h_{(n)}^m = \sum_{j=1}^N w_{jm} X_{(n)}^j \quad \text{e} \quad h_0^{(n)} = \sum_{m=1}^M w_{m0} \tanh(h_{(n)}^m) \quad [\text{Eq.3.21}]$$

Onde h_m é o campo pós-sináptico após o neurônio m e h_0 é o campo pós-sináptico após o neurônio da camada de saída.

2. Calcula-se o erro na saída e propaga para as camadas anteriores utilizando a equação (3.22)

$$\delta_m^{(n)} = \delta_0^{(n)} w_{m0} (1 - \tanh^2(h_{(n)}^m)) \quad [\text{Eq.3.22}]$$

Onde $\delta_0^{(n)}$ é o erro calculado na saída e $\delta_m^{(n)}$ é o erro calculado para o neurônio m da camada oculta, a partir do erro de saída.

3. Calcula-se, enfim, os gradientes da função erro utilizando:

$$\frac{\partial E}{\partial w_{jm}} = \sum_{n=1}^P \delta_m^{(n)} X_j^{(n)} \quad \text{e} \quad \frac{\partial E}{\partial w_{m0}} = \sum_{n=1}^P \delta_0^{(n)} a_m^{(n)} \quad [\text{Eq.3.23}]$$

Onde $\frac{\partial E}{\partial w_{jm}}$ é o gradiente da função erro para o neurônio m da camada oculta j e

$\frac{\partial E}{\partial w_{m0}}$ o gradiente da função erro para o neurônio m da camada de saída.

3.6 Modelos de Redes Neurais

Há vários tipos ou modelos de redes neurais que são utilizados para resolução de problemas. Alguns dos principais modelos existentes são apresentados a seguir.

3.6.1 Redes Perceptron

O *perceptron* é a forma mais simples de uma rede neural usada para a classificação de padrões linearmente separáveis, ou seja, padrões que se encontram em lados opostos de um hiperplano. Basicamente, ele consiste de um único neurônio com pesos sinápticos ajustáveis e bias, que é um elemento especial da camada de entrada, cujo sinal tem sempre valor 1.

O *perceptron* construído com apenas um neurônio é limitado a realizar classificação com mais de duas classes. Entretanto, as classes devem ser linearmente separáveis para que o *perceptron* funcione adequadamente. Por este motivo, seu sucesso foi interrompido frente às duas críticas de Minsky e Papert.

O ponto importante é que, uma vez, que se considera a teoria básica do *perceptron* como um classificador de padrões, é necessário considerar apenas o caso de um único neurônio. Mas, a extensão da teoria para o caso de mais de um neurônio é trivial (HAYKIN, 2001).

O *perceptron* pode possuir vários neurônios, mas apenas uma única camada de processamento. Sua aplicabilidade é limitada, contudo, o *perceptron* foi muito importante na história das redes neurais, já que foi o primeiro modelo para aprendizagem supervisionada.

3.6.2 Redes MLP (*Multi Layer Perceptron*)

As pesquisas com as redes neurais artificiais só voltaram a recuperar sua credibilidade com o trabalho do físico e biólogo John Hopfield, em 1982, que se contrapuseram as afirmações de Minsky e Papert, provocando um novo interesse nas pesquisas de redes neurais artificiais.

A partir do trabalho de Hopfield, novas técnicas foram desenvolvidas, entre elas, as redes *Perceptron* Multicamadas (MLP). Atualmente as MLP são as mais utilizadas, devido a sua facilidade de implementação e simplicidade.

As redes MLP possuem um poder de processamento muito superior ao *Perceptron* original, devido ao fato de sua estrutura apresentar camadas intermediárias de neurônios, passando a conter pelo menos três camadas de unidades de processamento.

Os *perceptrons* de múltiplas camadas têm sido aplicados com sucesso para resolver diversos problemas de difícil solução, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de retropropagação de erro ou *backpropagation* (HAYKIN, 2001).

3.6.3 Redes Adaline

Desenvolvida em 1960 por Widrow e Hoff, o modelo ADALINE, chamado inicialmente de ADaptive Linear Element e posteriormente de ADaptive Linear Neuron, depois da popularização de sua regra de aprendizado dentro da área de redes neurais, surgiu na literatura quase que simultaneamente com o *Perceptron*.

Ambos os modelos são baseados na idéia de se ter elementos de processamento executando operações de soma ponderada e posterior comparação com um valor limiar. ADALINE é uma rede de uma única camada que utiliza o algoritmo *backpropagation* e é usada, principalmente, para reconhecimento de padrões, porém reconhece somente os padrões nos quais foi treinada.

A grande contribuição de Widrow e Hoff foi sem dúvida o desenvolvimento da Regra Delta, elaborada para treinar as redes ADALINE. A Regra Delta, também conhecida por Regra de Widrow-Hoff ou Algoritmo LMS (*Least Mean Square*), é baseada no sinal de erro sendo, portanto, uma regra de aprendizado supervisionado.

O princípio básico dessa regra é alterar, em cada apresentação de um par de entradas /saída desejada do conjunto de treinamento, os pesos da rede na direção que diminui os quadrados do erro da saída. Em outras palavras, a Regra Delta é um procedimento de otimização que usa a direção do gradiente executado a cada iteração (YONEYAMA, 2000).

O modelo ADALINE tem seus pesos adaptados em função do erro de sua saída linear, antes da aplicação da função de ativação, daí o nome ADAptive Linear NEuron. Isso leva a uma função de custo a ser minimizada que é quadrática nos pesos de entrada, o que é bastante conveniente para minimização pelo método do gradiente. O ajuste do peso é feito em função do erro da saída linear (BRAGA, 2000).

Quando transposta para uma rede de multicamadas é denominada de MADALINE (*Multilayer ADALINE*) e apresenta um alto grau de tolerância a falhas.

3.7 Aplicações de Redes Neurais Artificiais

Desde 1943, quando Warren McCulloch e Walter Pitts apresentaram o primeiro modelo de neurônios artificiais, a cada dia, novas e mais sofisticadas propostas têm sido apresentadas. Ao longo de todo esse tempo, as redes neurais vêm se aprimorando e ganhando espaço nas neurociências, matemática, ciências físicas e engenharia.

Por ter seus fundamentos na interdisciplinaridade, suas aplicações estão direcionadas às mais diversas áreas do conhecimento.

Na área das Geociências, as Redes Neurais Artificiais tem sido aplicadas em processamento de imagens de satélite e geração de Sistemas de Informação Geográfica (Galo, 2000; Andrade e Centeno, 2003; Espinhosa, 2004; Galvão e Menezes, 2005). Análise de erros na propagação de sinais GPS (Leandro, 2004), na área de geologia (Fleck e Pedreira, 2003). Agrupamento de dados sísmicos através do algoritmo de Kohonen. Inteligência Artificial aplicada em engenharia de estruturas (Castro, 2009), na área de engenharia elétrica (Santos, 2008), Predição de intensidade do campo elétrico da onda de superfície utilizando redes neurais artificiais (Melo, 2008).

No próximo capítulo serão descritos o processo de formação, tratamento e separação dos dados, a metodologia adotada para escolha das melhores arquiteturas, bem como os resultados de treinamento e desempenho das redes neurais artificiais.

CAPÍTULO 4

4. MATERIAL E MÉTODO

4.1 Obtenção dos dados da profundidade de Carbonatação

Devido a grande dificuldade e o tempo que demandaria para se construir uma investigação experimental que medisse a profundidade de carbonatação, optou-se por utilizar os dados do artigo apresentado no ENTAC 2006 dos pesquisadores (MEIRA, G. R. et al. 2006).

A pesquisa realizada pelos autores teve lugar na cidade de João Pessoa – Paraíba, por um período de cerca de quatro anos de monitoramento onde o objetivo era medir a velocidade de avanço da frente de carbonatação do concreto em condições naturais de exposição.

Para a realização do estudo, foram utilizados pilaretes de concreto fabricados nas dimensões de 15 x 15 x 140 cm, com relações água/cimento de 0,50, 0,57 e 0,65 e cimento comercial CPIIF-32. Os elementos de concretos armados sofreram cura úmida de sete dias e, em seguida, foram expostos em ambiente de atmosfera marinha em pontos que estão a 10, 100, 200 e 500m em relação ao mar.

4.2 Medidas de carbonatação

Para avaliar a profundidade de carbonatação foram realizadas medições após 6, 10, 14, 18 e 46 meses em cilindros de concretos extraídos dos pilaretes. Estas medidas foram realizadas após a aplicação de solução de fenolftaleína a 1%, através de um paquímetro aferido, identificando-se a profundidade carbonatada em doze pontos distintos.

Neste sentido foram obtidas as 96 observações que se constituíram nas variáveis de entrada e de saída da rede neural artificial e estão listadas na tabela 4.2 do Apêndice 1.

4.3 Escolhas das Variáveis de Entrada

Como em todo processo de modelagem, a familiaridade com a escolha da variável de entrada de um modelo de previsão, é uma tarefa muito importante, pois, a seleção inapropriada das variáveis de entrada fará com que a rede neural artificial não realize de forma satisfatória seu trabalho. A quantidade de informações (número de entradas), deve atender a dois critérios principais:

- 1) Quando o número de informações for pequeno em relação à complexidade do problema, a rede dificilmente conseguirá resultados satisfatórios;
- 2) Se o número de informações for muito grande, a rede poderá ser muito complexa (grande número de conexões), o que pode torná-la instável.

Dessa forma, suas entradas devem conter informações que descrevam e se correlacionem com as principais características do problema a ser resolvido.

Neste trabalho, a elaboração de cada arquitetura para o estudo de previsão da profundidade de carbonatação do concreto foi definida a partir número de neurônios das camadas de entrada e saída.

Para todas as arquiteturas estudadas, a camada de entrada é composta de 3 (três) neurônios (variáveis independentes), definidos assim:

Neurônio 1: Relação água/cimento(a/c)

Neurônio 2: A distância do mar ao posto de monitoramento(metros)

Neurônio 3: Idade do corpo de prova (anos)

Para a camada de saída de cada arquitetura foi designado apenas um único neurônio (variável resposta) representando a profundidade média de carbonatação do concreto (mm).

4.4 Determinação das Arquitetura da Rede Neural

Neste trabalho foram projetadas doze arquiteturas do tipo MLP (*Multi Layer Perceptron*) estudadas para variadas configurações de rede com três ou quatro camadas sendo uma camada de entrada, uma ou duas camadas intermediárias ou (escondidas) e uma camada de saída.

Para todas as redes construídas foi determinado o número de 150000 iterações como o número máximo de iterações permitidas para o treinamento com o programa *qnet2000* que utiliza o algoritmo *backpropagation*, conhecido como algoritmo de retropropagação de erro.

O algoritmo de retropropagação calcula o erro na saída da rede e retropropaga pela rede, de modo a modificar os pesos para minimizar o erro da próxima saída.

O programa *qnet2000* possibilita a definição de até oito camadas intermediárias de neurônios (nós) e a escolha de quatro funções de ativação diferentes (sigmóide, tangente hiperbólica, secante hiperbólica e gaussiana), além de permitir ao usuário controlar todos os parâmetros durante o processo de treinamento de forma a melhorar a eficiência.

4.4.1 Tratamento e Separação dos Dados

As redes neurais artificiais que utilizam o algoritmo *backpropagation*, necessitam que todos os dados utilizados no treinamento sejam normalizados entre 0 (zero) e 1 (um), porque as diferentes funções de ativação que calculam os valores dos neurônios, fornecem valores dentro deste intervalo. Apesar de o programa *qnet2000* utilizado fazer automaticamente a normalização dos dados de entrada e de saída da rede, uma dificuldade surge em virtude do usuário não ter acesso ao processo de normalização executado pelo software, impossibilitando, assim, que o mesmo verifique a confiabilidade das operações de normalização realizadas.

Nesta pesquisa, todas as variáveis envolvidas na elaboração dos modelos de simulação da estimativa de profundidade de carbonatação do concreto armado utilizando redes neurais artificiais foram normalizadas no intervalo compreendido entre os números 0,15 e 0,85.

Esta normalização foi feita considerando-se uma relação linear do tipo $f(x) = ax + b$ entre os valores máximos e mínimos de cada uma das variáveis envolvidas no problema, conforme apresentado na Tabela 4.1.

Tabela 4.1 – valores máximos e mínimos das variáveis de entrada e saída da rede.

Variáveis				
	Entrada			Saída
Amplitude	Relação A/C	Distância do Mar (metros)	Idade do corpo de Prova (anos)	Profundidade de Carbonatação (mm)
Máximo	0,65	500	3,60	10,00
Mínimo	0,50	10	0,50	0,50

Assim, evita-se que o neurônio funcione na sua região de saturação (valores de saída próximos dos limites superior e inferior das funções de ativação), ou que valores de entrada com grandezas diferentes interfiram no processo de aprendizado da rede. Os dados normalizados estão demonstrados em tabela no Apêndice 2.

As equações 4.1 e 4.2 são utilizadas para normalizar e desnormalizar os valores de saída da rede neural.

$$f(x) = ax + b \quad [4.1]$$

$$x = \frac{f(x) - b}{a} \quad [4.2]$$

Para treinar as arquiteturas projetadas usou-se as variáveis da Tabela 4.2, dividindo-se em três grupos mutuamente exclusivos:

- O conjunto de treinamento utilizado no ajuste dos pesos;
- O conjunto de validação utilizado como um pseudoteste para avaliar a capacidade de generalização da rede durante o processo de aprendizagem;
- O conjunto de teste usado exclusivamente para medir a taxa de erro do sistema e o seu valor correspondente a uma medida do desempenho real do sistema.

Dessa forma, as (96) variáveis foram divididos em conjunto de treinamento, conjunto de validação e conjunto de teste, obedecendo às seguintes proporções:

- Conjunto de treinamento – 62,5% , dos dados;
- Conjunto de validação – 18,75% , dos dados;
- Conjunto de teste – 18,75% , dos dados;

Durante o processo de treinamento, cada dado do conjunto de treinamento, um par entrada-saída, é apresentada à rede uma única vez por ciclo de treinamento.

Para se evitar que a rede neural artificial durante o treinamento apresente tendenciosidade devido à má distribuição dos dados de cada conjunto, estes foram selecionados por um processo aleatório.

4.4.2 Processo de Treinamento e Escolha da Melhor Arquitetura

Neste trabalho todas as redes que foram projetadas possuem a arquitetura do tipo *Perceptron multicamadas com algoritmo de aprendizagem supervisionado*.

De acordo com Cybenko (1988) a vantagem de se arranjar os neurônios nas diferentes camadas intermediárias, possibilita a solução de problemas não linearmente separáveis.

Os neurônios das camadas escondidas variam entre um e vinte e como os valores de entrada e saídas são sempre positivos adotou-se para todas as camadas de entradas/saídas a

função de ativação sigmóide logística $y = \frac{1}{1 + e^{-x}}$.

Para cada arquitetura projetada foi realizado um treinamento com o seguinte número de iterações 1000, 10000; 30000; 60000; 100000 e 150000.

O número máximo de iterações (épocas) é de 150.000. O treinamento termina quando o número máximo de épocas for atingido ou se o erro médio quadrático (“Mean Square Error”) do conjunto de treinamento for igual a zero.

Para se fazer o treinamento pelo algoritmo de aprendizagem *backpropagation* é necessário a escolha de dois parâmetros que são utilizados pelo programa para controlar o ajuste dos pesos: a taxa de aprendizagem (η) ETA e o fator β (momentum). Estes parâmetros controlam o incremento dado aos valores de w_{ij} durante o processo de treinamento da rede pelo algoritmo de retropropagação.

A adoção de valores para (η) ETA muito elevados, próximos de 1,0 (um), acelera o treinamento da rede, possibilitando um aumento da instabilidade e saturação no processo de treinamento, que, em algum momento, pode levar a não convergência numérica do algoritmo.

Se forem utilizados valores baixos para a taxa de aprendizagem pode ocorrer uma melhora na convergência numérica, no entanto, aumenta relativamente à probabilidade do modelo ficar preso a mínimos locais, além de tornar o treinamento bastante lento.

O fator β (momentum) tem por objetivo minimizar a possibilidade do algoritmo ficar preso a mínimos locais e está mais relacionado com a estabilidade do algoritmo de retropropagação, sendo normalmente adotados valores entre 0,0 e 1,0.

Neste trabalho os valores adotados para a taxa de aprendizagem η e para o fator β foram 0,4 e 0,8, respectivamente. A escolha se deu após a realização de varias simulações.

CAPÍTULO 5

5 SIMULAÇÃO COMPUTACIONAL

Este capítulo apresenta as simulações realizadas e os resultados das arquiteturas das redes descritas no capítulo 4.

5.1 Análise e Discussão do Treinamento

Durante a fase de treinamento das doze arquiteturas de redes projetadas e estudadas no capítulo anterior, selecionou-se dentre estas as seis que apresentaram melhor desempenho durante o treinamento. O desempenho das redes foi avaliado através do coeficiente de determinação (R^2) e da raiz do erro quadrático médio (root mean square error) nas fases de treinamento e validação fornecidos pelo programa *qnet2000*. As arquiteturas escolhidas foram às seguintes: R1[3-3-1], R2 [3-4 -1], R3[3-8-1], R4[3-12-1], R5[(3-16-1], R6[3-20-1] e encontram-se indicadas nas Figuras 5.1 a 5.6

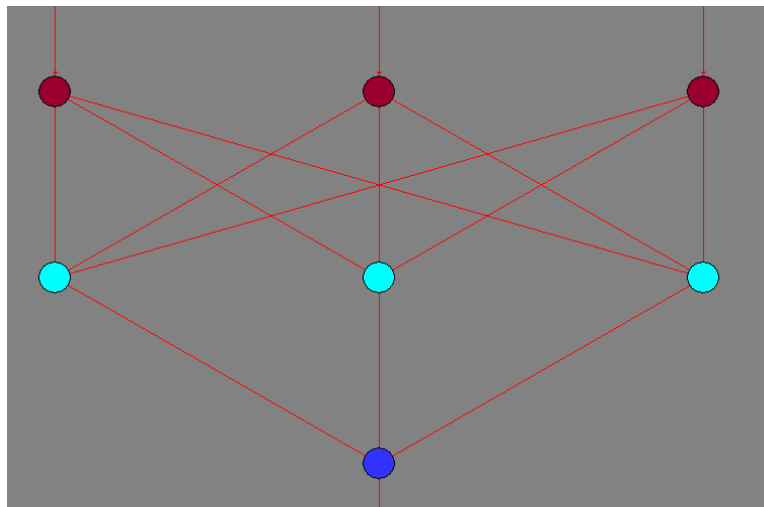


Figura 5.1 – Arquitetura da rede [3-3-1].

A arquitetura [3-3-1], ¹ está baseada na seguinte estrutura: A rede tem uma camada de entrada dos dados, uma camada escondida (com três neurônios) e uma camada de saída (com um neurônio), conforme exemplifica a figura 5.1

¹ Alguns Autores não contam a camada de entrada de nós de fonte, por considerar que na camada de entrada não é realizada qualquer operação (Haykin, 2001).




Figura 5.2 – Arquitetura da rede [3-4-1].




Figura 5.3 – Arquitetura de rede [3-8-1].




Figura 5.4 – Arquitetura de rede [3-12-1]




Figura 5.5. – Arquitetura de rede [3-16-1].




Figura 5.6.- Arquitetura de rede [3-20-1].

Durante todo o processo de simulação de cada uma das arquiteturas procedeu-se o monitoramento simultâneo dos processos de treinamento e validação no sentido de verificar a ocorrência de treinamento excessivo (overfitting). O treinamento excessivo ocorre quando, a partir de um determinado número de iterações, o erro médio calculado no processo de validação aumenta, apesar da diminuição contínua deste erro durante o treinamento.

Esta averiguação foi feita para todas as seis arquiteturas citadas na seção 5.1 na procura da arquitetura que melhor represente o fenômeno estudado. O desempenho foi medido através dos valores da raiz quadrada do erro médio (root mean squared error – RMSE) fornecido através de várias simulações feita pelo programa QNET donde resultou o número ótimo de

20 neurônios para a arquitetura de camadas que exibiu melhor desempenho global com o erro médio de 0,058 que foi o menor dentre as arquiteturas estudadas .

A figura 5.7 mostra a variação do erro médio em função da quantidade de neurônios ocultos. Para todas as arquiteturas estudadas a função de ativação utilizada foi a sigmóide, o número de camadas ocultas foi um e a única variável considerada foi a quantidade de neurônios ocultos.

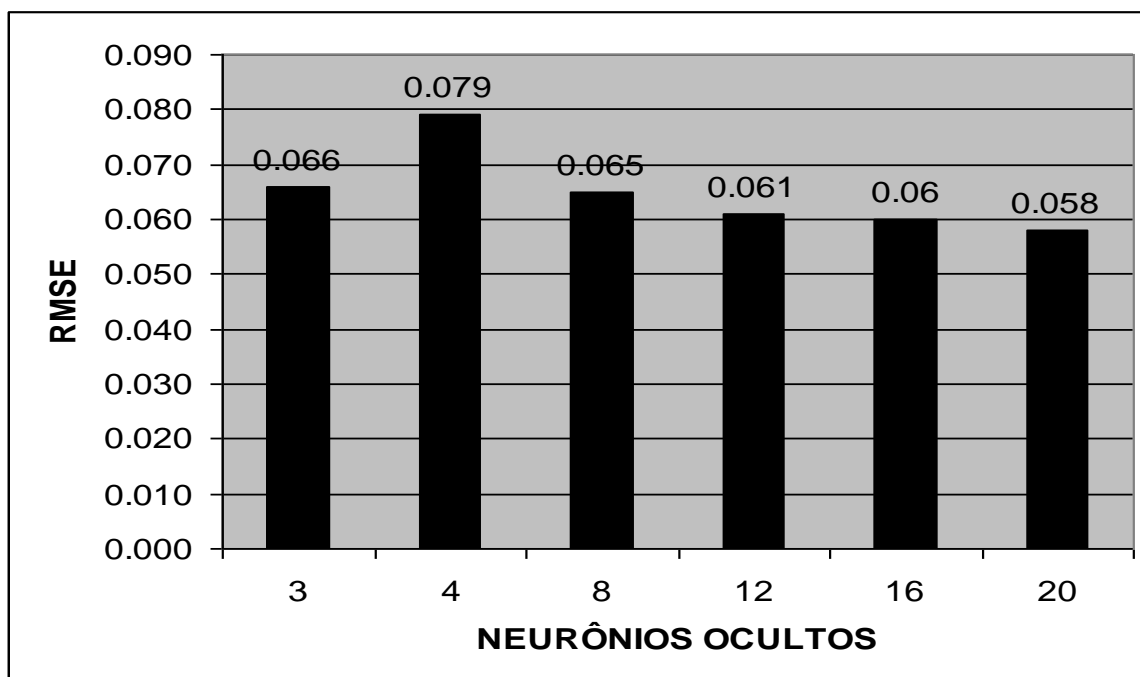


Figura 5.7 – Determinação da quantidade ótima de neurônios nas camadas ocultas

5.2 Resultados das Simulações com Redes Neurais

Nesse estudo foram realizados treinamentos e simulações testando o uso de diferentes topologias para avaliar a capacidade de generalização das Redes Neurais Artificiais aplicadas ao modelamento da profundidade de Carbonatação.

Os resultados obtidos após a simulação das redes na fase de treinamento e validação encontram-se nas Figuras 5.8 a 6.1 e mostram a evolução da raiz do erro médio quadrático (RMS) e do coeficiente de determinação (R^2) calculado entre os valores fornecidos pela rede durante as fases de treinamento




Figura 5.8 – Evolução do erro com o número de iterações na fase de treinamento do modelo de estimação da profundidade de carbonatação do concreto armado.




Figura 5.9- Evolução do erro com o número de iterações na fase de teste do treinamento do modelo de profundidade de carbonatação do concreto armado.

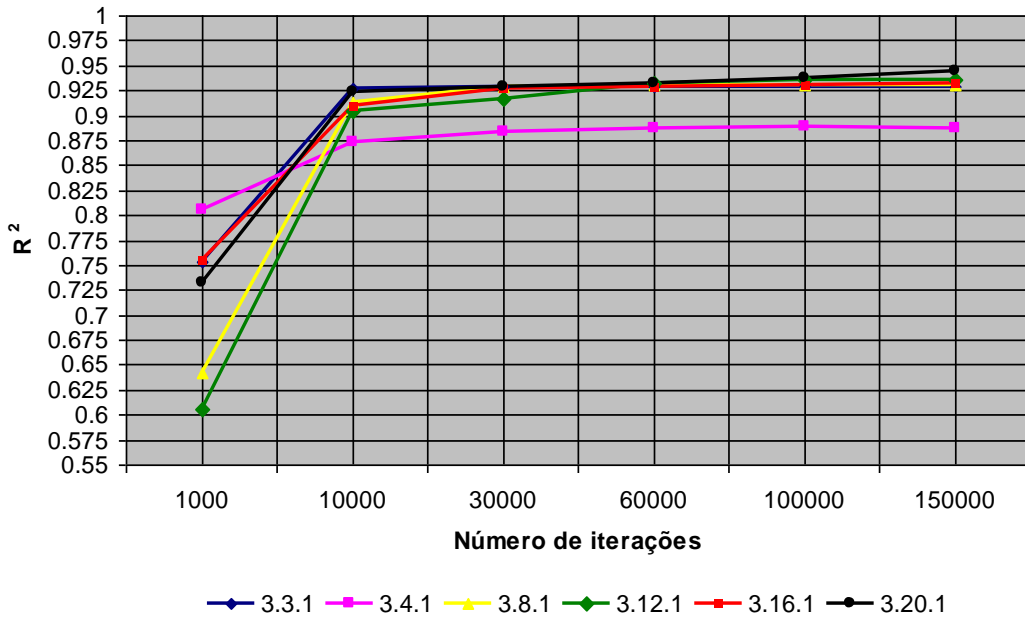


Figura 6.0 – Evolução do coeficiente de determinação (R^2) como o número de iterações na fase de treinamento do modelo de estimação da profundidade de carbonatação do concreto armado.




Figura 6.1 – Evolução do coeficiente de determinação (R^2) com o número de iterações na fase de teste do treinamento modelo de estimação da profundidade de carbonatação do concreto armado.

Analisando o resultado da Figura 5.8, pode-se verificar que do ponto de vista do conjunto de treinamento (curva do erro versus número de iterações) a rede que apresentou melhor desempenho foi a [3-20-1] para 150000 iterações, seguida das arquiteturas [3-16-1] e [3-12-1] nessa ordem. Enquanto que, na fase de teste do treinamento (curva do erro versus número de iterações) Figura 5.9, o desempenho ao final das 150000 iterações foi igual para as três arquiteturas de redes.

Observando a Figura 6.0, a evolução das curvas do coeficiente de determinação (R^2) versus número de iterações na fase de treinamento, foi a rede [3-20-1] que obteve o melhor desempenho seguida das redes [3-12-1] e [3-16-1]. Entretanto, na fase do teste do treinamento Figura 6.1, mostra que as redes partiram de pontos diferentes e alcançaram igualmente o máximo para 150000 iterações.

Dado que o desempenho dos três modelos citados foi igual, o critério de decisão sobre o melhor modelo foi tomada com base na topologia que, usando o conjunto de validação, apresentou a maior capacidade preditiva, com menor número de neurônios na camada escondida.

Nessa perspectiva, a rede neural de arquitetura [3-12-1], mostrada na Figura 6.2, foi a escolhida para a estimativa da profundidade de carbonatação do concreto.




Figura 6.2 – Arquitetura do modelo de estimativa da carbonatação do concreto

O modelo [3.12.1] proposto neste trabalho apresentou resultados satisfatórios no treinamento.

Na fase de desenvolvimento do modelo as correlações entre os valores calculados pela rede para a estimação da profundidade de carbonatação do concreto e os valores reais fornecidos foi encontrada a correlação de 0,909246 e o erro de 0,075164, na fase de treinamento, e a correlação de 0,580536 e erro de 0,102216, na fase de teste, como mostra as Figuras 6.3, 6.4 e 6.5 e que podem ser consideradas aceitáveis.

Definição de Rede		Controle de treinamento	
3-12-1-150000 t		Iterações Máximas	150000
Camadas de Rede	3	Início Cont. de Aprendizagem	1
Nós de entrada	3	Taxa de Aprendizagem	0,037103
Nós de saída	1	Taxa de Aprendizagem Máx.	0,205000
Nós escondidos	12	Taxa de Aprendizagem Mim.	0,010000
Funções e transferência	Sigmoid	Momentum	0,800000
Conexões	48	Padrões por Atualização	60
Padrões de treinamento	60	Atualização de tela	5
Padrões de Teste	18	Taxa Salvamento automático	500
Modo de treinamento	Padrão	Tolerância	0,000000
Treinamento Rede total	1/0	Sair com erro RMS	0,000000
Resultados Treinamento			
Iteração	150000	Velocidade de Treinamento (cps) 9438k	
Percentual Completado	100%	Tempo Restante 0:0:0	
		Erro RMS	Correlação
		Conjunto de treinamento	0,075164 0,909246
		Conjunto de Teste	0,102216 0,580536

Figura 6.3 resultados de erro e correlação extraídos do programa Qnet 2000 para a rede [3-12-1] na fase de treinamento do modelo.




Figura 6.4 – Correlação entre os valores calculados pela rede e os valores fornecidos de profundidade de carbonatação do concreto na fase de treinamento do modelo.




Figura 6.5 – Erro entre os valores calculados pela rede e os valores fornecidos da profundidade de carbonatação na fase de treinamento do modelo.

Verifica-se através dos resultados apresentados neste trabalho, que as redes neurais artificiais demonstram ser uma ferramenta eficiente na modelagem de problemas não lineares e de comportamento complexo.

Com o objetivo de confirmar a confiabilidade da arquitetura eleita como a melhor, foi apresentada ao software os 18,75% dados restantes reservados para a validação do modelo. Executada a simulação, o modelo também apresentou resultados satisfatórios na validação.

Durante o desenvolvimento do modelo de ajustamento os valores calculados pela rede para a estimação da profundidade de carbonatação e os valores reais fornecidos foi encontrada a correlação de 0,995957 e o erro de 0,008333 como mostra as Figuras 6.6, 6.7 e 6.8. Ressalta-se, entretanto, que os parâmetros internos do programa *qnet2000* foram mantidos iguais aos da fase do treinamento.

Definição de Rede		Controle de treinamento	
3-12-1-15000v		Iterações Máximas	150000
Camadas de Rede	3	Início Cont. de Aprendizagem	1
Nós de entrada	3	Taxa de Aprendizagem	0.107500
Nós de saída	1	Taxa de Aprendizagem Máx.	0.107500
Nós escondidos	12	Taxa de Aprendizagem Mim.	0.010000
Funções de transferência	Sigmoid	Momentum	0.800000
Conexões	48	Padrões por Atualização	18
Padrões de Treinamento	18	Atualização de tela	5
Padrões de Teste	0	Taxa Salvamento automático	500
Modo de treinamento	Padrão	Tolerância	0.000000
Treinamento Rede total	1/1	Sair com erro RMS	0.000000
Resultados Treinamento			
Iteração	150000	Velocidade de Treinamento (cps)	5232k
Percentual Completado	100%	Tempo Restante	0:0:0
Erro RMS Correlação			
Conjunto de treinamento	0,008333	0,995961	
Conjunto de Teste			

Figura 6.6 – Resultado do erro e correlação extraído do programa *qnet 2000* para a rede [3-12-1] na fase de validação do modelo.




Figura 6.7 – Correlação entre os valores calculados pela rede e os valores fornecidos da profundidade de carbonatação do concreto na fase de validação.




Figura 6.8 – Erro entre os valores calculados pela rede e os valores fornecidos da profundidade de carbonatação do concreto na fase de validação.

CAPÍTULO 6

6 Conclusões e Sugestões para Trabalhos Futuros

6.1 Conclusões

A partir dos resultados obtidos é possível extrair as seguintes conclusões:

- Os bons resultados apresentados pela arquitetura [3-12-1] durante a pesquisa, recomendam que a aplicação de redes neurais artificiais apresenta potencial para produzir métodos numéricos robustos e flexíveis para a estimativa da profundidade de carbonatação do concreto.
- O maior obstáculo em se utilizar as redes neurais na solução de problemas de engenharia reside na dificuldade do estabelecimento de uma arquitetura interna adequada para o problema que se está lidando.
- Neste trabalho, a dificuldade de se eleger a melhor arquitetura, foi em parte superada adotando-se uma estratégia de treinamento e validação simultânea que permitiu a identificação da melhor arquitetura para o problema.
- A vantagem em se utilizar as redes neurais artificiais na solução de problemas complexos de engenharia é que estas redes podem ser “treinadas” para aprender as relações existentes entre os parâmetros de entrada e saída de determinado problema. A capacidade de aprendizagem e generalização da informação aprendida, através de um conjunto reduzido de exemplos e posterior fornecimento de respostas coerentes para estes dados, que não são conhecidos, é uma demonstração da potencialidade das redes neurais artificiais. Esta característica é de grande relevância quando se está lidando com situações nas quais o estabelecimento de uma descrição de relações funcionais entre as variáveis envolvidas em um determinado problema ou são excessivamente complexas ou simplesmente não estão disponíveis.
- Todas essas características fazem das redes neurais artificiais uma ferramenta extremamente poderosa para solução de problemas complexos nas áreas das engenharias e a cada dia vem sendo mais utilizada por pesquisadores em todo o mundo.

6.2 Sugestões para Trabalhos Futuros

- Realizar ensaios de carbonatação natural utilizando corpos de provas moldados em laboratório, variando relação água/cimento e diferentes níveis de exposição.
- Realizar estudo semelhante substituindo o algoritmo de treinamento do gradiente da função erro calculado pelo algoritmo *backpropagation* pelo algoritmo de *Levenberg-Marquart*.
- Realizar estudo para o desenvolvimento de outros tipos de redes neurais artificiais com utilização de diferentes algoritmos de treinamento, que permitam avaliar de fato se o algoritmo escolhido e utilizado é o que possui maior capacidade de explicação dos dados;
- Realizar estudo comparativo entre o modelo matemático clássico que representa o comportamento da profundidade de carbonatação e o modelo de redes neurais artificiais;

REFERÊNCIAS BIBLIOGRÁFICAS

AÏCTIN, Pierre-Claude. **Concreto de Alto desempenho**. 1. ed. São Paulo: Pini, 2000. 667p.

AL-KADHIMI, T. K. H. *et al.* *An accelerated carbonation procedure for studies on concrete*. **Advances in Cement Research**, v.8, n.30, p.47-59, 1996.

ANDRADE, C. **Corrosão de armaduras**. São Paulo, Escola Politécnica da Universidade de São Paulo – Curso de Pós-Graduação em Engenharia de Construção Civil e Urbana. 1992.

ANDRADE, C.; SARRÍA, J.; ALONSO, C. *Relative humidity in the interior of concrete exposed to natural and artificial weathering*, **Cement and Concrete Research**, v.29, 1249– 1259, 1999.

ANDRADE, C. Manual para diagnóstico de obras deterioradas por corrosão de armaduras. Tradução e adaptação: Antônio Carmona e Paulo Helene. São Paulo: Pini, 1992. 104 p.

ANDRADE, Andréia Faria; CENTENO, Jorge Antonio Silva. Integração de informações espectrais e de forma na classificação de imagens com redes neurais. *Boletim Ciências Geoidais*, Curitiba, v.9, n.2, p.217-231

ANDRADE, J. J. O. **Contribuição à previsão de vida útil das estruturas de concreto armado atacadas pela corrosão das armaduras: iniciação por cloretos**. Porto Alegre: UFRGS, 2001. Tese (Doutorado em engenharia), 2001. 278p.

AMERICAN CONCRETE INSTITUTE. **Building code requirements for structural concrete concrete (aci 318-05) and commentary (aci 318r-05) reported by aci committee 318**. ACI 318-05, Estados Unidos da América, 2005. 430p.

_____. **Guide to Durable Concrete**. ACI 201.2R-01, Estados Unidos da América, 2001. 41p.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5732**: Cimento Portland comum. Rio de Janeiro, 1991.

_____. **NBR 6118: 2007**: Projeto de estruturas de concreto: Procedimento. Rio de Janeiro, 2008.

BRAGA, Antônio de Pádua; LUDERMIR, Tereza Bernarda; CARVALHO, André Carlos. **Redes Neurais Artificiais**: Teoria e aplicações. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora, 2000, 262p.

BRE - **The durability of steel in concrete: part 1; mechanism of protection and corrosion.** Garston, Building Research Establishment Digest, Digest 263, jul. 1982, p.7

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

CASTRO, Fernando C.C. de **RECONHECIMENTO E LOCALIZAÇÃO DE PADRÕES EM IMAGENS UTILIZANDO REDES NEURAIAS ARTIFICIAIS COMO ESTIMADORES DE CORRELAÇÃO ESPECTRAL.** 1995. 81.f. dissertação (mestrado em Engenharia Elétrica) Pontifícia Universidade Católica do Rio Grande do Sul.

CARMONA, TOMAS G. **Modelos de Previsão da Despassivação das Armaduras em Estruturas de concreto Sujeitas à Carbonatação.** São Paulo, Universidade de São Paulo PCC. USP, 2005 (Dissertação de Mestrado).

CASCUDO, OSWALDO. *O controle da corrosão de armaduras em concreto: inspeção e técnicas eletroquímicas.* São Paulo: Pini, 1997.

CASTRO, LI CHONG LEE BACELAR DE. *Inteligência Computacional Aplicada à Engenharia de Estruturas.* 130p., Tese de Doutorado – Universidade de Brasília, 2009.

COELHO, Maria Antonina Magalhães. **Contribuição ao estudo da carbonatação e retração em concretos com elevados teores de escória de alto forno.** Dissertação (Mestrado). Universidade Federal do Espírito Santo. Centro Tecnológico. Vitória, 2002.

CHURCHLAND, P.S. SEJNOWSKI, T J. **The Computational Brain,** Cambridge, MA: MIT Press, 1992.

ESPINHOSA, Maria Cristina. **Utilização de sensoriamento remoto orbital e redes neurais artificiais no mapeamento de macrófitas aquáticas emersas em grandes reservatórios.** 2004.112f. Dissertação (Mestrado em Ciências Cartográficas) Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista. Presidente Prudente, 2004.

FERREIRA, Rui Miguel. *Avaliação dos ensaios de durabilidade do betão.* Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia, Universidade do Minho, Braga, 2000. 246 f.

FLECK, Ernesto Marchioni; PEDREIRA, Carlos Eduardo; SANTOS, Rogério. **Agrupamento de dados sísmicos através do algoritmo de Kohonen.** In: Congresso Brasileiro de Redes Neurais, 6., São Paulo. Anais. São Paulo, 2003

GABOR, D. *“Communication Theory and cybernetic”*, IRE Transactions on Circuit Theory, vol. CT-1, pp.19-31.

GALVÃO, Wougran Soares; MENESES, Paulo Roberto. **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

GALO, M.L.B.T. **Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo.** 2005. 205f. Tese (Doutorado em Engenharia Ambiental) Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos, 2005.

GARTNER, Leslie; HIATT, James. **Tratado de Histologia.** Rio de Janeiro: Editora Guanabara - Koogan, 1999. 425p.

G. Cybenko, “ Continuous Valued neural networks with two hidden layers are sufficient”, Department of Computer Science, Tufts University, Medford, MA, USA, Tech. Rep., 1988

GUERRA, Fabio Alessandro. **Análise de métodos de agrupamentos para o treinamento de redes neurais de base radial aplicadas à identificação de sistemas.** 2006. 131f. Dissertação (mestrado em engenharia de produção e sistemas) Pontifícia Universidade Católica do Paraná.

HAYKIN, Simon. **Redes Neurais: princípios e prática.** Porto Alegre: Editora Bookman, 2001. 900p.

HELENE, P. R. do L. **Contribuição ao estudo da corrosão em armaduras de concreto armado.** Tese (Livre Docência) – Escola Politécnica da Universidade de São Paulo. São Paulo. 1993.

HELENE, Paulo R. do L., MITIDIERI FILHO, Cláudio V; THOMAS, Ercio. Influência do tipo de cimento e da relação a/c na carbonatação do concreto: estimativa da vida útil de projeto. Reunião Anual do Ibracon. **Anais.** São Paulo. 1995.

HOUST, Yves F., WITTMANN, Folker H. *Depth profiles of carbonates formed during natural carbonation.* **Cement and Concrete Research**, v.2151, p.1 –8, 2002.

LAPA, José Silva. **Patologia, Recuperação e Reparo das Estruturas de Concreto.** Monografia (especialização em construção Civil) – Universidade Federal de Minas Gerais Escola de Engenharia. Belo Horizonte. 2008

LEANDRO, Rodrigo F. A new technique to TEC regional modeling using a neural network. In: PROCEEDINGS OF THE ION GNSS, Long Beach. Anais. Long Beach: 2004.

MATALA, Seppo. *Carbonation mechanism in the granulated blast furnace slag concrete*. In: International Congress on the Chemistry of Cement, 10 th. **Proceedings**. Detroit, p.1-30, 1994.

MEIRA, G. R.; PADARATZ, I. J.; JUNIOR, J. C. B., **CARBONATAÇÃO NATURAL DE CONCRETOS: RESULTADOS DE CERCA DE QUATRO ANOS DE MONITORAMENTO**. XI Encontro Nacional de Tecnologia no Ambiente Construído ENTAC – 2006.

MEHTA, P. K.; MONTEIRO, P. J. M. **Concreto: estrutura, propriedades e materiais**. 1 edição. São Paulo: Pini, 1994.

MEHTA, P. K.; MONTEIRO, P. J. M. **Concreto: microestrutura, propriedades e materiais**. 3ed. São Paulo: Pini, 2008.

MELO, KÁTIA CRISTINA BARBOSA LOSCHI DE. **Predição de intensidade do campo elétrico da onda de superfície utilizando redes neurais artificiais** (Distrito Federal) 2008. Universidade de Brasília.

MITRE, Marcos; BARBOSA, Paulo, HELENE, Paulo. **Influência do traço na carbonatação de concretos, argamassas e pastas**. In: **Revista Ibracon**. Nº 31. Rio de Janeiro. 2002.

NAKAMURA, J. **NBR 6118: da durabilidade**. *Téchne*, São Paulo, ano 12, n. 86, p. 24 – 30, maio 2004.

NGALA, V. T.; PAGE, C. L. *Effects of carbonation on pore structure and diffusion properties of hydrated cements pastes*. *Cement and concrete Research*, v. 27, n. 67, p.995- 1007, 1997.

NEVILLE, ADAM MATTHEW. **Propriedades do concreto**. 2 ed São Paulo: Pini, 1997.

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

PAPADAKIS, V.G. *et al*. *Effect of composition, environmental factors and cement-linemortar coating on concrete carbonation*. *Materials and Structures*, v.25, p. 293-304, 1992.

PARROTT, 1989. *Modeling of Hydration reactions and concrete properties*. In: **Materials Science of Concrete**. Ed. Skalny, J. P., American Ceramic Society, 1989. v. 1.

PARROTT, 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.

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

R, ROJAS. **Neural Networks**, Springer – Verlag, Berlim, 1996

REINKE, Meriéle. **Utilização de redes neurais aplicada a mapeamentos hidrogeológicos**. 2008, 100f. Dissertação de (Mestrado Meio Ambiente e Recursos Minerais) Universidade do Vale do Sinos - Unisinos.

RUSSELL, Peter Norvig. **Inteligência Artificial**. Rio de Janeiro: Elsevier, 2004. 1021p.

SANJUAN, M. A. Cálculo Del período de iniciación de La corrosión de la armadura Del hormigón. Madri, 1992. Tese (Doutorado), Universidad Complutense de Madri.

SANTOS, Arineu Felix dos. **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.

SILVA, Paulo Fernando A. *Durabilidade das estruturas de concreto aparente em atmosfera urbana*. 1. ed. São Paulo: Pini, 1995. 152 p. ISBN 85-7266-043-7.

SILVA, Antonio; RAMOS, Rui; SOUZA, Léa; RODRIGUES, Daniel; MENDES, José. SIG – Uma plataforma para introdução de técnicas emergentes no planejamento urbano regional e de transportes: uma ferramenta 3D para análise ambiental urbana, avaliação multicritério, redes neurais artificiais. São Carlos: Editora dos Autores, 2004. 221p.

STEFFENS, Alexander, DINKLER, Dieter; AHRENS, Hermann. *Modeling carbonation for corrosion risk prediction of concrete structures*. **Cement and Concrete Research**, v. 32, p. 935-941, 2002.

TULA, L. S. **Contribuição ao estudo da Resistência à corrosão de armaduras de aço inoxidável**. São Paulo, 2000. 259p. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo.

TUUTTI, K. **Corrosion steel in concrete**, Swedish Cement and Concrete, Stockholm, 1982. 469 p.

VASCONCELOS, Augusto Carlos de; CARRIERI JÚNIOR, Renato. **A escola brasileira do concreto armado**. 1. ed. São Paulo: Axis Mundi, 2005. 207 p. ISBN 85- 85554- 34- 7.

VALENÇA, Mêuser; *Aplicando redes neurais: um guia completo*. Editôra Livro Rápido Elógica Olinda – Pernambuco ISBN 85.89501-81-7

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

VICENTE, R. **Redes Neurais para Inferência Estatística**. Universidade de São Paulo. São Paulo, Brasil, 2002.

VIEIRA, R. C., ROISENBERG, M. *Redes Neurais Artificiais: Um breve tutorial*. Laboratório de Conexionismo e Ciências Cognitivas, Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil, 2003.

WEE, T. H.; SURYAVANSHI, A.K.; LOGENDRAN, D. *Pore structure controlling the carbonation of a hardened cement matrix blended with mineral admixture*. **Advances in Cement Research**, v. 11, n. 2, p. 81-95, 1999.

YONEYAMA, T., Nascimento, C.L. *Inteligência Artificial em Controle e Automação*. Editora Edgard Blucher Ltda em co-edição com FAPESP, São Paulo, Brasil, 2000.

Apendice 1

Tabela 4.2. Características por corpos de provas utilizados no estudo da profundidade de carbonatação.

Relação (a/c)	Distância do mar (metros)	Idade corpo de prova (anos)	Profundidade Carbonatação (mm)
0,50	10	0,50	0,60
0,50	10	0,60	1,10
0,50	10	0,70	1,50
0,50	10	1,50	2,10
0,50	10	3,60	4,00
0,50	100	0,50	0,50
0,50	100	0,70	0,90
0,50	100	1,30	1,60
0,50	100	1,50	2,00
0,50	100	3,60	4,10
0,50	200	0,50	1,00
0,50	200	0,70	1,40
0,50	200	1,30	1,60
0,50	200	1,50	2,50
0,50	200	3,60	5,10
0,50	500	0,50	1,00
0,50	500	0,70	1,50
0,50	500	1,30	2,50
0,50	500	1,50	3,10
0,50	500	3,60	5,40
0,57	10	0,50	1,30
0,57	10	0,70	1,50
0,57	10	1,30	2,90
0,57	10	1,50	3,00
0,57	10	3,60	4,90
0,57	100	0,50	1,50
0,57	100	0,70	2,10
0,57	100	1,30	3,20
0,57	100	1,50	3,50
0,57	100	3,60	5,70
0,57	200	0,50	1,60
0,57	200	0,70	2,20
			Continuação

Apendice 1

Tabela 4.2. Características por corpos de provas utilizados no estudo da profundidade de carbonatação.

Relação (a/c)	Distância do mar (metros)	Idade corpo de prova (anos)	Profundidade Carbonatação (mm)
0,57	200	1,30	3,10
0,57	200	1,50	4,10
0,57	200	3,60	6,50
0,57	500	0,50	2,00
0,50	10	0,50	0,60
0,50	10	0,70	1,10
0,50	10	1,30	1,50
0,50	10	1,50	2,10
0,50	10	3,60	4,00
0,50	100	0,50	0,50
0,50	100	0,70	0,90
0,50	100	1,30	1,60
0,50	100	1,50	2,00
0,50	100	3,60	4,10
0,50	200	0,50	1,00
0,50	200	0,70	1,40
0,50	200	1,30	1,60
0,50	200	1,50	2,50
0,50	200	3,60	5,10
0,50	500	0,50	1,00
0,50	500	0,70	1,50
0,50	500	1,30	2,50
0,50	500	1,50	3,10
0,50	500	3,60	5,40
0,65	10	0,50	1,50
0,65	10	0,70	2,10
0,65	10	1,30	3,70
0,65	10	1,50	4,50
0,65	10	3,60	8,50
0,65	100	0,50	2,00
0,65	100	0,70	2,70
0,65	100	1,30	4,50
			Continuação

Apendice 1

Tabela 4.2. Características por corpos de provas utilizados no estudo da profundidade de carbonatação.

Relação (a/c)	Distância do mar (metros)	Idade corpo de prova (anos)	Profundidade Carbonatação (mm)
0,65	100	1,50	5,10
0,65	100	3,60	9,50
0,65	200	0,50	2,30
0,65	200	0,70	2,90
0,65	200	1,30	4,00
0,65	200	1,50	5,50
0,65	200	3,60	10,0
0,65	500	0,50	2,10
0,65	500	0,70	3,10
0,65	500	1,30	4,60
0,65	500	1,50	5,00
0,65	500	3,60	10,0
0,57	10	0,50	1,30
0,57	10	0,70	1,50
0,57	10	1,30	2,90
0,57	10	1,50	3,00
0,57	10	3,60	4,90
0,57	100	0,50	1,50
0,57	100	0,70	2,10
0,57	100	1,30	3,20
0,57	100	1,50	3,50
0,57	100	3,60	5,70
0,57	200	0,50	1,60
0,57	200	0,70	2,20
0,57	200	1,30	3,10
0,57	200	1,50	4,10
0,57	200	3,60	6,50
0,57	500	0,50	2,00
0,57	500	0,70	3,00
0,57	500	1,30	4,20
0,57	500	1,50	4,50
0,57	500	3,60	7,50
			Conclusão

Fonte: Artigo apresentado no XI Encontro Nacional de Tecnologia no Ambiente Construído – ENTAC 2006

APÊNDICE 2

Tabela 4.3 – Normalização das variáveis – 0,15 a 0,85

Relação (a/c)	Distância do Mar (metros)	Idade Corpo de Prova (anos)	Profundidade Carbonatação (mm)
0.150000	0.150000	0.150000	0.1577778
0.150000	0.150000	0.172581	0.1966667
0.150000	0.150000	0.195161	0.2277778
0.150000	0.150000	0.375806	0.2744445
0.150000	0.150000	0.850000	0.4222223
0.150000	0.278572	0.150000	0.1500001
0.150000	0.278572	0.195161	0.1811112
0.150000	0.278572	0.330645	0.2355556
0.150000	0.278572	0.375806	0.2666667
0.150000	0.278572	0.850000	0.4300000
0.150000	0.421429	0.150000	0.1888890
0.150000	0.421429	0.195161	0.2200001
0.150000	0.421429	0.330645	0.2355556
0.150000	0.421429	0.375806	0.3055556
0.150000	0.850000	0.850000	0.5077778
0.150000	0.850000	0.150000	0.1888890
0.150000	0.850000	0.150000	0.2277778
0.150000	0.850000	0.195161	0.3055556
0.150000	0.850000	0.330645	0.3522223
0.150000	0.150000	0.375806	0.5311111
0.476667	0.150000	0.850000	0.2122223
0.476667	0.150000	0.150000	0.2277778
0.476667	0.150000	0.195161	0.3366667
0.476667	0.150000	0.330645	0.3444445
0.476667	0.278572	0.375806	0.4922223
0.476667	0.278572	0.850000	0.2277778
0.476667	0.278572	0.150000	0.2744445
0.476667	0.278572	0.195161	0.3600000
0.476667	0.278572	0.330645	0.3833334
0.476667	0.421429	0.375806	0.5544445
0.476667	0.421429	0.850000	0.2355556
0.476667	0.421429	0.150000	0.2822223
0.476667	0.421429	0.195161	0.3522223
0.476667	0.421429	0.330645	0.4300000
0.476667	0.850000	0.375806	0.6166667
0.476667	0.150000	0.850000	0.2666667
0.150000	0.150000	0.150000	0.1577778
0.150000	0.150000	0.150000	0.1966667

Tabela 4.3 – Normalização das variáveis – 0,15 a 0,85

Relação (a/c)	Distância do Mar (metros)	Idade Corpo de Prova (anos)	Profundidade Carbonatação (mm)
0.150000	0.150000	0.195161	0.2277778
0.150000	0.150000	0.330645	0.2744445
0.150000	0.278572	0.375806	0.4222223
0.150000	0.278572	0.850000	0.1500001
0.150000	0.278572	0.150000	0.1811112
0.150000	0.278572	0.195161	0.2355556
0.150000	0.278572	0.330645	0.2666667
0.150000	0.421429	0.375806	0.4300000
0.150000	0.421429	0.850000	0.1888890
0.150000	0.421429	0.150000	0.2200001
0.150000	0.421429	0.195161	0.2355556
0.150000	0.421429	0.330645	0.3055556
0.150000	0.850000	0.375806	0.5077778
0.150000	0.850000	0.850000	0.1888890
0.150000	0.850000	0.150000	0.2277778
0.150000	0.850000	0.195161	0.3055556
0.150000	0.850000	0.330645	0.3522223
0.150000	0.150000	0.375806	0.5311111
0.850000	0.150000	0.850000	0.2277778
0.850000	0.150000	0.150000	0.2744445
0.850000	0.150000	0.195161	0.3988889
0.850000	0.150000	0.330645	0.4611111
0.850000	0.278572	0.375806	0.7722222
0.850000	0.278572	0.850000	0.2666667
0.850000	0.278572	0.150000	0.3211112
0.850000	0.278572	0.195161	0.4611111
0.850000	0.278572	0.330645	0.5077778
0.850000	0.421429	0.375806	0.8500000
0.850000	0.421429	0.850000	0.2900001
0.850000	0.421429	0.150000	0.3366667
0.850000	0.421429	0.195161	0.4222223
0.850000	0.421429	0.330645	0.5388889
0.850000	0.850000	0.375806	0.8888889
0.850000	0.850000	0.850000	0.2744445
0.850000	0.850000	0.150000	0.3522223
0.850000	0.850000	0.195161	0.4688889
0.850000	0.850000	0.330645	0.5000000
0.850000	0.150000	0.375806	0.8888889

Tabela 4.3 – Normalização das variáveis – 0,15 a 0,85

Relação (a/c)	Distância do Mar (metros)	Idade Corpo de Prova (anos)	Profundidade Carbonatação (mm)
0.476667	0.150000	0.850000	0.2122223
0.476667	0.150000	0.150000	0.2277778
0.476667	0.150000	0.195161	0.3366667
0.476667	0.150000	0.330645	0.3444445
0.476667	0.150000	0.375806	0.4922223
0.476667	0.278572	0.850000	0.2277778
0.476667	0.278572	0.150000	0.2744445
0.476667	0.278572	0.195161	0.3600000
0.476667	0.278572	0.330645	0.3833334
0.476667	0.278572	0.375806	0.5544445
0.476667	0.421429	0.850000	0.2355556
0.476667	0.421429	0.150000	0.2822223
0.476667	0.421429	0.195161	0.3522223
0.476667	0.421429	0.330645	0.4300000
0.476667	0.421429	0.375806	0.6166667
0.476667	0.850000	0.850000	0.2666667
0.476667	0.850000	0.150000	0.3444445
0.476667	0.850000	0.195161	0.4377778
0.476667	0.850000	0.330645	0.4611111
0.476667	0.850000	0.375806	0.6944445