

**APLICAÇÕES DE REDES NEURAIIS PARA A ANÁLISE INVERSA DE
ESTRUTURAS DE CONCRETO**

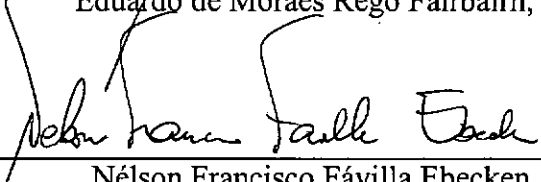
Evandro da Silveira Goulart

TESE SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA CIVIL.

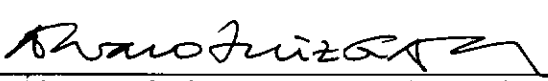
Aprovada por:



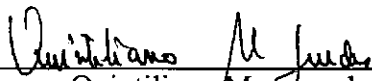
Eduardo de Moraes Rego Fairbairn, Dr. Ing.



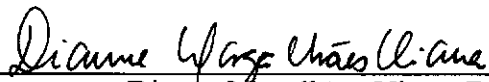
Néelson Francisco Fávilla Ebecken, D. Sc.



Alvaro Luiz Gayoso de Azeredo Coutinho, D.Sc



Quintiliano Mascarenhas Guedes, M. Sc.



Dianne Magalhães Viana, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

ABRIL DE 1999

GOULART, EVANDRO DA SILVEIRA

Aplicações de Redes Neurais para a Análise Inversa de Estruturas de Concreto [Rio de Janeiro] 1999

VIII, 70 p. 29.7 cm (COPPE/UFRJ, M.Sc., Engenharia Civil, 1999)

Tese - Universidade Federal do Rio de Janeiro, COPPE

1. Concreto
2. Redes Neurais Artificiais
3. Análise Inversa

I. COPPE/UFRJ II. Título (série)

Para toda a minha Família que sempre me incentivou.
Em especial para meu Pai, João Patrício Goulart, minha Mãe, Ilza da Silveira Goulart,
e meu Avô, Ângelo Sabóia Goulart.

Agradecimentos

Agradecimentos em “Teses” são quase sempre iguais. Muitas vezes são copiados de outras teses, alterando-se apenas os personagens. É muito prático fazer isso, principalmente quando há tarefas mais importantes como, por exemplo, a própria tese.

No entanto, não há como fugir dos agradecimentos ao NACAD (Núcleo de Atendimento em Computação de Alto Desempenho) pelo fato de tornar possível o uso do CRAY J90, tampouco das Centrais Elétricas de Furnas S.A., personificada nos engenheiros Quintiliano Guedes e Adolfo Goldener que contribuíram para o desenvolvimento da tese.

Quem poderia deixar de lembrar do pessoal responsável pelo suporte técnico do Laboratório de Computação, a famosa B-103 (Célio, Sassá, Johnny, Thelmo e Bino).

O espaço é pequeno para citar tantos amigos. Vou começar pela Carmen que, apesar de sempre me convocar para ser o assador dos churrascos da turma, foi companheira e sempre me ajudou muito, assim como a Veranize, a Beth, a Norma, a Dianne, o Jefferson, o Paulo de Tarso, o Nilo, a Mônica, a Patrícia, a Stefânia, a Érika.

Apesar das comidas dos restaurantes da COPPE ficarem muito aquém daquelas preparadas pela minha mãe, a hora do almoço tornava-se um grande evento principalmente quando reunia-se Luís Alfredo (o contador de estórias), Ebenezer (Ivens), Ivan, Roberto (Baiano), Roberto (Mineiro), Paulo Mappa e eu.

Vou sempre lembrar dos meus inseparáveis companheiros de Forró, Carlos (Paulista) e Fábio (Alemão-Paraná), que, incansavelmente, toda a semana estavam comigo na Quinta do Bosque, ou Lagoinha, ou Ballroom, ou Malagueta, ou Niemayer, ou ...

A dura vida de estudante requer, necessariamente, a passagem por uma, ou mais, “repúblicas”. Na que estive durante o mestrado foi caracterizada pelo companheirismo e pelo bom humor. Por ela passaram: Fábio (Narigudo), Roberto (Mineiro), Alessandro (Maratona), Bruno (Mezenga), Marcos (Quinto Elemento) e Júlio (Baiano).

Agradeço especialmente a dois professores da COPPE: ao Landau, por ter acreditado em meu potencial, e ao Dudu (Eduardo Fairbairn), pela magnífica orientação e amizade.

É preciso lembrar e agradecer aos meus professores de iniciação científica da Universidade Federal de Santa Maria: Paulo Sarkis, Maria Isabel Lopez e Carla Danielletto.

Resumo da tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para obtenção do grau de Mestre em Ciências (M.Sc.)

APLICAÇÕES DE REDES NEURAIIS PARA A ANÁLISE INVERSA DE ESTRUTURAS DE CONCRETO

Evandro da Silveira Goulart

Abril de 1999

Orientador: Eduardo de Moraes Rego Fairbairn

Programa: Engenharia Civil

Redes Neurais Artificiais (RNA) são modelos computacionais eficientes que têm mostrado sua força na resolução de difíceis problemas em Inteligência Artificial e vêm se consolidando como uma nova e eficiente ferramenta para se lidar com problemas complexos.

Na presente tese, a técnica de Análise Inversa (ou Retroanálise) utilizando RNA é apresentada, inicialmente, através de um modelo mecânico bastante simples. Para este primeiro exemplo, são determinados os parâmetros correspondentes a um modelo probabilístico de fissuração do concreto e fica demonstrado que a metodologia é operacional e confiável.

Em seguida é apresentada uma análise da UHE de Funil, uma barragem de dupla curvatura situada no estado do Rio de Janeiro. Os dados considerados nesta análise são o resultado de 26 anos de observação. Neste caso, as constantes elásticas e também as viscoelásticas do modelo da cadeia de Maxwell são determinadas utilizando a metodologia apresentada nesta tese.

Foi possível então concluir, baseados nos resultados apresentados nesta tese, que as RNA, mesmo aquelas de arquitetura bastante simples usadas no presente trabalho, constituem-se numa ferramenta precisa e operacional que pode ser usada para a determinação, através de análise inversa, de parâmetros relativos à análise de estruturas de concreto.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

INVERSE ANALYSIS OF CONCRETE STRUCTURES BY USING ARTIFICIAL NEURAL NETWORKS

Evandro da Silveira Goulart

April/1999

Advisors: Eduardo de Moraes Rego Fairbairn

Department: Civil Engineering

Artificial Neural Networks (ANN) are computational structures which have shown their capabilities to solve complex problems and may be considered as a new and efficient engineering tool.

In the present thesis, the technique of Inverse Analysis (or Backanalysis) using ANN is presented, firstly by means of a very simple mechanical model. For this first example, the parameters corresponding to probabilistic cracking model are determined and it is shown that the methodology is operational and reliable.

Then, it is presented an analysis of the Funil dam, a double curvature arch dam placed in the state of Rio de Janeiro, Brazil. Based on 26 years of observation the elastic constants and also the viscoelastic parameters of the Maxwell chain model are found by using the methodology presented in this thesis.

The conclusion is that the results presented in this work indicated that even the simple architecture ANN used in this thesis, may be considered as an accurate and operational tool, which can be used to determine, by inverse analysis, the parameters corresponding to concrete structures.

ÍNDICE

	pág.
Capítulo 1 - Introdução.....	01
1.1 - Considerações Preliminares.....	01
1.2 - Organização da Tese.....	02
Capítulo 2 - Redes Neurais Artificiais.....	04
2.1 - Inteligência Artificial.....	04
2.2 - O que são Redes Neurais Artificiais.....	05
2.3 - Neurônio Biológico.....	06
2.4 - Neurônio Artificial.....	08
2.5 - Função de Ativação.....	10
2.6 - Arquitetura das Redes.....	11
2.7 - Treinamento da Rede.....	14
2.8 - Modelo Matemático de uma RNA do tipo <i>feedforward</i> com <i>backpropagation</i> e 3 camadas de neurônios.....	15
Capítulo 3 - Aplicação: Retroanálise do Modelo Probabilístico para Fissuração do Concreto usando Redes Neurais Artificiais.....	21
3.1 - Introdução ao Modelo Probabilístico.....	21
3.2 - Apresentação do Problema.....	23
3.3 - Análise Inversa usando Redes Neurais Artificiais.....	28
Capítulo 4 - Aplicação: Retroanálise para a Identificação dos Parâmetros Elásticos da Barragem Casca de Funil.....	39
4.1 - Introdução.....	39
4.2 - Monitoramento e Ensaios.....	41
4.3 - Retroanálise Neural.....	43

4.4 - Método dos Elementos Finitos.....	51
4.5 - Modelo Híbrido.....	53
Capítulo 5 - Aplicação: Retroanálise para a Identificação dos Parâmetros Viscoelásticos da Barragem Casca de Funil.....	54
5.1 - Introdução.....	54
5.2 - Dados Experimentais e seus Componentes.....	56
5.3 - Método dos Elementos Finitos.....	58
5.4 - Retroanálise Neural Viscoelástica.....	59
Capítulo 6 - Conclusões.....	66
6.1 - Considerações Finais.....	66
Referências Bibliográficas.....	67

CAPÍTULO 1

INTRODUÇÃO

1.1) Considerações Preliminares

Redes Neurais Artificiais são modelos computacionais inspirados em processos observados em redes naturais de neurônios do cérebro humano e têm mostrado sua força na resolução de difíceis problemas em Inteligência Artificial. Essa técnica vem se consolidando como uma nova e eficiente ferramenta para se lidar com problemas complexos em que extensas massas de dados devem ser modelados e analisados em um contexto multidisciplinar.

A capacidade básica das Redes Neurais é a do reconhecimento de padrões a partir de exemplos. Isto é realizado através do ajuste de pesos de conexões de acordo com algum tipo de algoritmo de aprendizado.

As várias aplicações apresentadas no presente trabalho tem como objetivo a utilização dessa poderosa ferramenta para a realização de Análises Inversas ou Retroanálises visando a determinação de parâmetros característicos de estruturas de concreto.

As aplicações compreendem em duas fases: de treinamento e de exploração. O conjunto de treinamento, obtido através de Análises Diretas, é composto por um conjunto de entrada e outro de saída que serão usados para o treinamento da Rede Neural. O conjunto de entrada é caracterizada por vários conjuntos de pontos discretos relativos às curvas de resposta estrutural, obtidas pelo MEF, que têm correspondência com conjuntos formado de parâmetros característicos, relativos ao material, que formam o conjunto de saída.

A etapa de exploração é a Retroanálise propriamente dita. Consiste em fornecer como entrada na Rede Neural dados obtidos experimentalmente para que ela forneça os parâmetros desejados referentes à estrutura analisada.

Como citado anteriormente, as Análises Diretas proporcionarão a montagem do conjunto de treinamento das Redes Neurais. Nessa etapa, a estrutura em estudo é modelada e um código computacional é usado de tal forma que, ao inserirmos os parâmetros característicos da estrutura como dados de entrada, o programa nos forneça curvas de resposta estrutural.

Para a realização da Análise Direta foi utilizado inicialmente um programa que corresponde a um modelo mecânico bastante simples. Posteriormente (Capítulos 4 e 5) foi utilizado um código computacional [VIANA, 98] baseado no Método dos Elementos Finitos que permite a execução de modelos com alto grau de complexidade. Esse código, desenvolvido para ser executado no Computador CRAY J90, é resultado de pesquisas anteriores desenvolvidas pela COPPE e possui rotinas paralelizadas e vetorizadas.

Os resultados de recentes pesquisas que vêm sendo desenvolvidas em colaboração entre equipes da COPPE e FURNAS visando a aplicação de técnicas de identificação de parâmetros através de Redes Neurais Artificiais com aplicações na análise de barragens, são apresentadas como exemplos nesta tese.

1.2) Organização da Tese

CAPÍTULO 2 - São apresentados de maneira sucinta os principais conceitos relacionados às Redes Neurais Artificiais. São descritos o funcionamento e os elementos básicos que compõe o neurônio biológico e o neurônio artificial, além da definição das etapas referentes à concepção de uma Rede Neural Artificial, isto é, esclarecimentos sobre função de ativação, arquitetura de redes e regra de aprendizado. Para finalizar o capítulo, é apresentado o modelo de rede do tipo *Feedforward* com algoritmo de aprendizado *Backpropagation* e três camadas de neurônios.

CAPÍTULO 3 - Da necessidade de resolver o problema inverso apresentado por [FAIRBAIRN et al, 98] utilizando um procedimento que não falhasse para alguns parâmetros característicos do material analisado e que não fosse computacionalmente custoso, surgiu a idéia de resolver tal problema aplicando uma técnica chamada de Redes Neurais que [SARAIVA, 97] usou para melhorar simulações de Monte Carlo na Análise da Confiabilidade de Estruturas.

Nesse capítulo, além da apresentação do problema, que envolve uma peça de concreto com deslocamento controlado em um ensaio de tração simples, procura-se provar a viabilidade da utilização Redes Neurais Artificiais para Análise Inversa fazendo-se uso de um conjunto de treinamento relativamente pequeno.

CAPÍTULO 4 - Nesse capítulo, assim como no Capítulo 5, o objeto de estudos é a Usina Hidrelétrica de Funil. A equipe de FURNAS forneceu a malha de elementos finitos e dados referentes à estrutura e seu funcionamento.

Para a identificação dos parâmetros reológicos do modelo elástico, através da retroanálise neural, considerou-se o concreto da barragem e a rocha da fundação como sendo materiais elásticos.

Um dos objetivos dessa etapa é a obtenção dos parâmetros por meio de um método numérico considerando toda a estrutura da UHE e comparar com valores experimentais obtidos por meio de ensaios em laboratório de corpos de prova extraídos da estrutura. A obtenção de tais parâmetros elásticos permitirá a montagem de um Modelo Híbrido, que desempenha um papel fundamental na automação do monitoramento de barragens.

CAPÍTULO 5 - A retroanálise neural viscoelástica visa a determinação de parâmetros do Modelo da Cadeia de Maxwell tendo como objeto de estudos a UHE de Funil. O objetivo é encontrar um conjunto desses parâmetros de tal forma que o código computacional, usado para a análise através do Método dos Elementos Finitos, forneça valores de deslocamentos da estrutura, quando submetida a um carregamento hidrostático, próximos aos dados obtidos experimentalmente.

CAPÍTULO 6 - São apresentadas as conclusões do trabalho.

CAPÍTULO 2

REDES NEURAIS ARTIFICIAIS

2.1) Inteligência Artificial

Ao tentar criar sistemas inteligentes artificiais, nada mais natural que observar o cérebro humano cujo funcionamento difere radicalmente do de computadores. Talvez a característica mais marcante do cérebro seja o grande número de elementos computacionais (neurônios), na ordem de bilhões, e a característica mais surpreendente, para quem está acostumado com o rapidíssimo mundo dos computadores, é a relativa lentidão de seus elementos computacionais. Aparentemente essa deficiência na velocidade dos componentes é compensada pela existência de um enorme número deles e pela sua operação em paralelo [PESSOA, 91].

Existem dois paradigmas no que se refere a cognição (aquisição de um conhecimento): o Cognitívismo e o Conexionismo.

O cognitívismo assume que a inteligência humana é um fenômeno de propósito geral, não necessariamente amarrada à arquitetura do cérebro, isto é, não é preciso observar a estrutura interna do cérebro e o seu funcionamento para estudar ou simular inteligência.

O conexionismo defende a necessidade de observarmos como as informações biológicas restringem os tipos de computações que podem ser realizadas pelo cérebro, ou seja, que pelo menos em parte os processos cognitivos dependem da arquitetura cerebral. Os defensores dessa abordagem acreditam que é válido investigar aspectos biológicos e que estes possam inspirar seus modelos.

Princípios utilizados para elaboração de modelos conexionistas:

- Elementos computacionais simples e lentos
- Existência de ligações inibitórias e excitatórias
- Processamento paralelo/distribuído
- Neurônios devem trocar mensagens simples
- Aprendizado se dá por ajuste de pesos

2.2) O que são Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA), também chamadas de **Arquiteturas Conexionistas** ou de **Processamento Paralelo e Distribuído**, são consideradas um paradigma de processamento de informações inspirado na estrutura paralela de processos do cérebro humano [KLIR, 95].

As Redes Neurais têm mostrado sua força na resolução de problemas difíceis em inteligência artificial e também como um aproximador universal. Consiste em simples unidades computacionais, chamadas **neurônios** que são fortemente conectadas e dispostas em **camadas**. Cada conexão tem uma resistência que é representada por um valor chamado **peso**. Para que uma RNA desenvolva uma determinada tarefa é preciso treiná-la.

Redes Neurais não podem fazer nada que não pode ser feito usando técnicas de computação tradicionais, mas podem fazer, com certa facilidade, algumas coisas que seriam muito difíceis através de técnicas tradicionais. Em particular, as RNA podem criar um modelo através dos dados de treinamento. Isto é particularmente útil com dados de sensoriamento ou com dados de um processo complexo. Para esses casos pode haver um algoritmo, mas este geralmente não é conhecido ou tem muitos parâmetros para serem determinados. É mais fácil deixar a cadeia de neurônios aprender através de exemplos.

O projeto e implementação de uma Rede Neural exige a consideração de 3 etapas principais, segundo [LOPEZ, 95] :

1) Definição da Arquitetura da Rede. Nessa etapa determina-se a forma em que as camadas que contêm os neurônios são interconectadas ou dispostas e, também, o modo de transmissão de sinais entre neurônios. Portanto, a escolha do tipo da arquitetura da rede envolve a definição dos seguintes parâmetros:

- Número de camadas
- Número de neurônios por camada
- Regra de propagação do sinal

2) Determinação da Função de Ativação dos neurônios. Tem como principal objetivo definir o sinal que será propagado de um neurônio para outro.

3) Definição da Regra de Aprendizado, isto é, o algoritmo de implementação que definirá o modo com o qual será feito o Treinamento das Redes de tal forma a reconhecer um determinado padrão ou sinal.

2.3) Neurônio Biológico

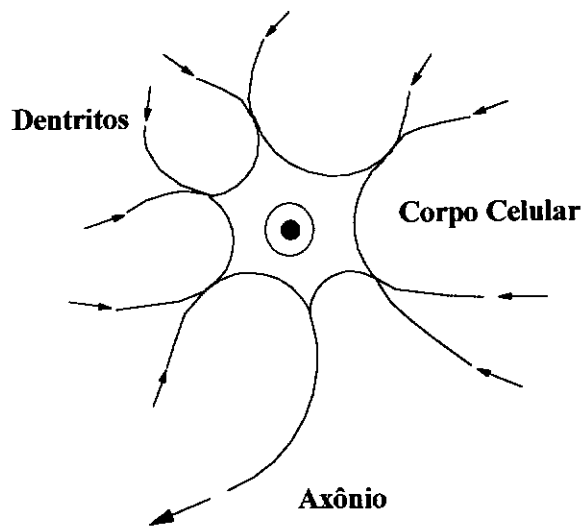


Figura 2.1 - Neurônio Biológico

Para uma compreensão mais clara dos principais conceitos e definições das Redes Neurais Artificiais, tornam-se necessários alguns esclarecimentos básicos relacionados com o funcionamento de um neurônio biológico utilizado para a concepção do método. O neurônio biológico pode ser entendido como um processador de dados ou informações [SARAIVA, 97].

Cada neurônio apresenta os seguintes elementos básicos (ver Figura 2.1):

- Um corpo celular (soma) - é o centro dos processos metabólicos da célula;
- Dendritos - transmite para o corpo celular sinais oriundos dos axônios de outros neurônios;
- Axônio - liga o corpo celular aos dendritos de outros neurônios.

O neurônio possui geralmente um único axônio embora esse possa apresentar algumas ramificações.

Foi a partir da década de 40, através de trabalhos de vários pesquisadores, que se passou a entender o neurônio biológico como sendo basicamente o dispositivo computacional elementar do sistema nervoso que possuía muitas entradas (dendritos) e uma saída (axônio) [KOVÁCS, 96].

São denominadas de conexões sinápticas todas aquelas ligações que conectam o axônio ao dendrito. A região onde ocorrem essas conexões chama-se sinapse. (ver Figura 2.2)

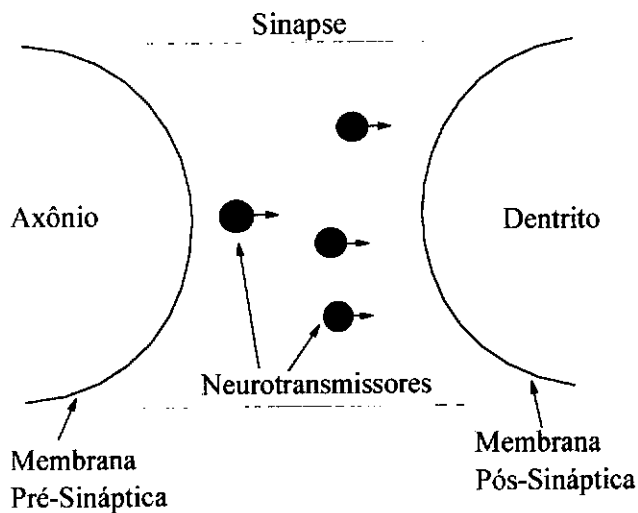


Figura 2.2 - Ilustração de uma Conexão Sináptica

A troca de ‘informações’ entre axônios e dendritos de diferentes neurônios é feita através de substâncias conhecidas como neurotransmissores. Dependendo do tipo de neurotransmissor a conexão sináptica pode ser excitatória ou inibitória. Uma conexão excitatória provoca uma alteração no potencial eletroquímico da membrana pré-sináptica que contribui para a formação de um impulso nervoso no axônio enquanto que uma conexão inibitória age no sentido oposto [KOVÁCS, 96].

A formação de um potencial de ação na membrana axonal ocorre quando esta sofre uma despolarização suficientemente acentuada para cruzar um determinado valor conhecido como limiar de disparo (*threshold*).

2.4) Neurônio Artificial

A unidade computacional básica de uma RNA são os neurônios.

O modelo do neurônio artificial é apresentado na Figura 2.3 e possui os seguintes elementos básicos:

- Sinal de entrada representado pelo vetor $x^t = \{x_1, x_2, \dots, x_n\}$;
- Vetor com os pesos ou conexões sinápticas $w^t = \{w_1, w_2, \dots, w_n\}$;
- Valor do limiar de disparo, θ ;
- Função de ativação, g ;
- Sinal de saída, y ;

O sinal de saída do neurônio que depende do somatório da multiplicação dos sinais de entrada por seus respectivos pesos $\sum_{i=1}^n w_i x_i$, é definido por:

$$y = g\left(\sum_{i=1}^n w_i x_i - \theta\right) \quad (2.1)$$

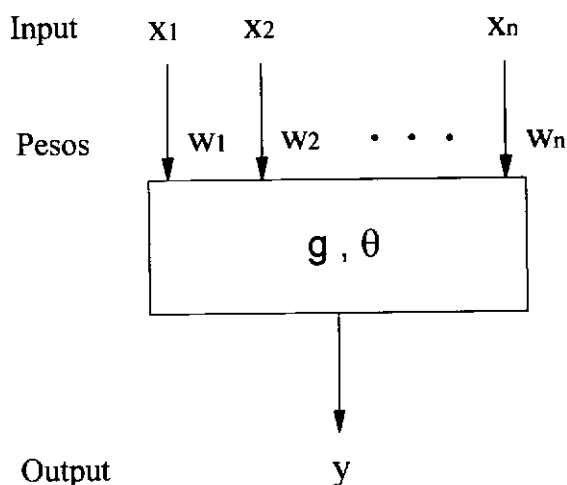


Figura 2.3 - Neurônio Artificial

Por conveniência o valor do limiar de disparo é representado por um input extra, $x_0 = -1$, e associado a um peso $w_0 = \theta$. Essa consideração altera a expressão (2.1), que passa a ser da seguinte forma:

$$y = g\left(\sum_{i=0}^n w_i x_i\right) \quad (2.2)$$

Portanto o modelo de neurônio que passará a ser utilizado no presente texto será o da Figura 2.4 .




Figura 2.4 - Estrutura do Neurônio Artificial que será utilizado durante o trabalho.

2.5) Função de Ativação

As funções de ativação mais utilizadas em trabalhos recentes são as funções sigmóide e a tangente hiperbólica.

No presente trabalho será utilizada a função sigmóide, também conhecida como função logística. É definida pela expressão:

$$g_{\beta}(v) = [1 + e^{-\beta \cdot v}]^{-1} \quad (2.3)$$




Figura 2.5 - Função Sigmóide para diferentes valores de Beta (β)

A função sigmóide, por ser muito simples e eficiente, têm sido muito empregada nas aplicações modernas na ativação dos neurônios em redes com múltiplas camadas.

O programa Neuroshell utiliza essa função considerando $\beta = 1$.

2.6) Arquitetura das Redes

Existem arquiteturas que permitem às redes neurais um treinamento **supervisionado** e **não supervisionado**. Outra classificação importante está relacionada quanto ao modo como os neurônios da rede se interligam: redes **realimentadas** e **não realimentadas**.

Podemos destacar duas maneiras de processamento de informações em redes neurais: **processamento em camadas** (*feedforward*) e **estabilização** (*settling*).

A arquitetura de Kohonen permite um tipo de rede **não supervisionada** que tem a habilidade para aprender sem utilização de sinais de saída nos padrões utilizados como amostra. As sinapses são ajustadas de tal maneira a tornar possível o agrupamento das entradas de acordo com suas principais características. Estas redes podem separar padrões de dados em um número específico de categorias. Nesse tipo de topologia é interessante enxergar o processamento como um processo de **estabilização**. O processamento nesse tipo de rede consiste em um estímulo inicial, isto é, um padrão de ativação inicial, onde a rede converge para um estado estável o qual representa o resultado da rede [NEUROHELL, 93].

O *feedforward*, processamento de múltiplas camadas que será utilizado no presente trabalho, é um dos tipos de arquitetura mais utilizados na modelagem de redes neurais. É considerado **supervisionado** pois é conhecida, para cada valor de entrada, a saída desejada. Isto torna possível calcular o erro e corrigir as sinapses. Essa arquitetura é classificada como **não realimentada**, pois os seus neurônios estão conectados apenas com os elementos processadores de camadas posteriores. O encaminhamento do sinal na rede é do tipo progressivo ou direto [SARAIVA, 97].

Numa rede do tipo feedforward sempre haverá uma única camada de entrada e uma única camada de saída, o que não ocorre com o número de camadas ocultas cujo valor é opção do usuário. Sabe-se que não há necessidade de utilização de mais que três camadas ocultas para esse tipo de rede. No presente trabalho constatou-se que apenas

com uma camada oculta é possível treinar redes que serão utilizadas em retroanálises de problemas em engenharia.

No que diz respeito ao número de neurônios, o da camada de entrada é definido pelo número de entradas e o da camada de saída pelo número de saídas. Já para a(s) camada(s) ocultas(s) não há uma regra universal para a definição do número de neurônios. O programa Neuroshell usado nesse trabalho para auxiliar no treinamento das redes neurais considera que,

$$NOC = \frac{0,5.(I + O) + \sqrt{P}}{NCAM} \quad (2.4)$$

onde,

I - número de entradas;

O - número de saídas;

P - número de amostras usadas para treinar a rede;

NCAM - número de camadas ocultas

NOC - número de neurônios que será utilizado em cada camada oculta

Por exemplo, supondo uma rede *feedforward* de três camadas, com uma entrada de dois neurônios (I=2), uma camada oculta (NCAM=1), uma saída com um neurônio (O=1) e tendo à disposição para treinamento 10 amostras (P=10) representando o padrão, é possível obter o número por camada segundo o critério do Neuroshell.

$$NOC = \frac{0,5.(1 + 2) + \sqrt{10}}{1}$$
$$NOC = 4,66$$

A rede acima descrita está representada na figura 2.6 .

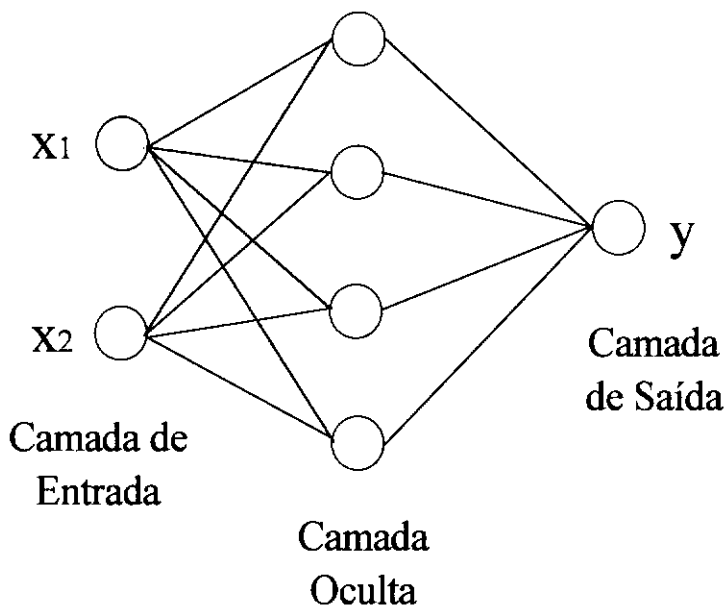


Figura 2.6 - Rede Neural do Tipo *Feedforward* com 3 Camadas.

A Tabela 2.1 traz esquematizados alguns exemplos de redes que podem ser obtidas para treinamento segundo o critério citado anteriormente. Nas várias colunas há a variação do número de inputs, outputs, amostras utilizadas para treinamento, camadas ocultas e, por fim, o número de neurônios da camada oculta.

Entradas	Saídas	Amostras	Camadas Ocultas	Neurônios Ocultos
26	2	21	1	18
9	2	8	1	8
16	3	10	1	12

Tabela 2.1 - Dados referentes a exemplos de RNA treinadas no Neuroshell.

2.7) Treinamento da Rede

O treinamento consiste em ajustar as sinapses, isto é, os pesos de cada neurônio de maneira que, para uma determinada entrada, uma saída específica seja obtida. Esses ajustes são feitos com a utilização de algoritmos de treinamento. Um dos mais utilizados é o *Backpropagation*.

O treinamento de uma rede neural do tipo *backpropagation* usa um algoritmo de gradiente decrescente no qual o erro quadrado médio entre a saída obtida no treinamento da rede e a saída desejada é minimizado através da alteração dos pesos das conexões. Se o erro da rede atinge um valor menor ou igual ao limiar especificado, a rede convergiu e pode ser considerada treinada [KLIR, 95].

Para treinarmos uma RNA é preciso um conjunto de treinamento composto por valores de entrada e saída. Esse conjunto irá conter p amostras do tipo $\langle X_p, T_p \rangle$, onde X_p representa a entrada e T_p a saída desejada. Cada amostra deverá estar de acordo com o padrão que se deseja que a rede aprenda. O treinamento procede em ciclos. Em cada um deles, todas as amostras são utilizadas para auxiliar na atualização dos pesos das conexões de tal forma que ao inserirmos na rede a entrada X_p ocorra um erro mínimo entre o valor de saída da rede Y e o valor desejado T_p .

Nessa etapa, uma boa escolha quanto ao conjunto de treinamento é imprescindível para que o algoritmo possa convergir.

Podemos agora descrever a estrutura matemática de uma rede multicamada do tipo *feedforward* com algoritmo *backpropagation* e função sigmóide.

2.8) Modelo matemático de uma RNA do tipo *Feedforward* com *Backpropagation* e três camadas de neurônios

Antes de apresentarmos a formulação do algoritmo *backpropagation*, vamos descrever o algoritmo de gradiente decrescente. Para tal será utilizada uma rede, representada na Figura 2.8, sem camadas ocultas, isto é, possui uma camada de entrada e uma de saída, cujos neurônios de entrada são representados por NE_n e os neurônios de saída por NS_m .




Figura 2.8 - RNA usada para apresentar os conceitos do Algoritmo do Gradiente Decrescente.

Como é um aprendizado supervisionado, um conjunto de treinamento com os pares entrada-saída será utilizado. Temos então $\langle X_p, T_p \rangle$, onde:

$X_p = \langle x_1^p, x_2^p, \dots, x_n^p \rangle$ representa o conjunto de entrada

$T_p = \langle t_1^p, t_2^p, \dots, t_n^p \rangle$ representa o conjunto de saída desejado

$Y_p = \langle y_1^p, y_2^p, \dots, y_n^p \rangle$ representa o conjunto de saída gerado pela rede

De posse de X_p , T_p e Y_p , o erro da rede é usualmente expresso em termos da função de erro quadrático,

$$E_p = \frac{1}{2} \sum_{k=1}^m (t_k^p - y_k^p)^2 \quad (2.5)$$

$$E_p = \frac{1}{2} \sum_{k=1}^m \left(t_k^p - g_\beta \left(\sum_{i=0}^n W_{ki} \cdot x_i^p \right) \right)^2$$

A constante $\frac{1}{2}$ é usada somente por conveniência computacional [KLIR, 95]. Como citado anteriormente, assumiu-se que $x_0^p = 1$ para representar o limiar de disparo do neurônio k com peso W_{k0} .

Certamente a função (2.5) será sempre positiva e convergirá para zero na medida que a rede for se aproximando da solução para cada amostra do conjunto de treinamento $\langle X_p, T_p \rangle$. O erro acumulativo de cada ciclo relacionado com todo o conjunto de treinamento é dado por

$$E = \sum_p E_p \quad (2.6)$$

Para cada dado de treinamento (amostra) do conjunto $\langle X_p, T_p \rangle$, a função de erro depende dos pesos da RNA. Segundo o algoritmo do gradiente descendente, nós podemos reduzir o valor de (2.5) alterando cada peso W_{ki} por um valor ΔW_{ki} proporcional ao gradiente negativo de E_p , que é dado por

$$\Delta W_{ki} = -\eta \frac{\partial E_p}{\partial W_{ki}} \quad (2.7)$$

onde η é uma constante positiva conhecida por Taxa de Aprendizagem. A escolha dessa taxa influencia na precisão final da aproximação assim como na velocidade de convergência. Em geral, uma boa aproximação pode ser obtida se η for pequeno, mas a convergência é lenta e pouco confiável.

Para calcular a derivada parcial, vamos rescrever (2.5) :

$$E_p = \frac{1}{2} \sum_{k=1}^m (t_k^p - g_\beta(a_k^p))^2$$

onde

$$a_k^p = \sum_{i=0}^n W_{ki} \cdot x_i^p$$

então

$$\frac{\partial E_p}{\partial W_{ki}} = -[t_k^p - g_\beta(a_k^p)] \cdot \dot{g}_\beta(a_k^p) \cdot x_i^p$$

$$\frac{\partial E_p}{\partial W_{ki}} = -[t_k^p - y_k^p] \cdot \dot{g}_\beta(a_k^p) \cdot x_i^p$$

sendo que \dot{g}_β denota a derivada da função sigmóide, que pode ser escrita na forma

$$\dot{g}_\beta(a_k^p) = \beta \cdot g_\beta(a_k^p) \cdot [1 - g_\beta(a_k^p)]$$

$$\dot{g}_\beta(a_k^p) = \beta \cdot y_k^p \cdot [1 - y_k^p]$$

introduzindo δ_k^p

$$\delta_k^p = (t_k^p - y_k^p) \cdot \dot{g}_\beta(a_k^p)$$

$$\delta_k^p = (t_k^p - y_k^p) \cdot \beta \cdot y_k^p (1 - y_k^p)$$

Logo, a correção dos pesos pelo método do gradiente descendente é dado pela expressão

$$\Delta W_{ki} = \eta \cdot \delta_k^p \cdot x_i^p$$

e o novo peso passa a ser

$$W_{(k+1),i} = W_{ki} + \Delta W_{ki} \tag{2.8}$$

Vamos agora descrever o algoritmo *backpropagation* para uma RNA com 3 camadas descrita na Figura 2.9 . Já foi citado que o *backpropagation* é baseado no algoritmo de gradiente decrescente, descrito anteriormente.

Camada de Entrada

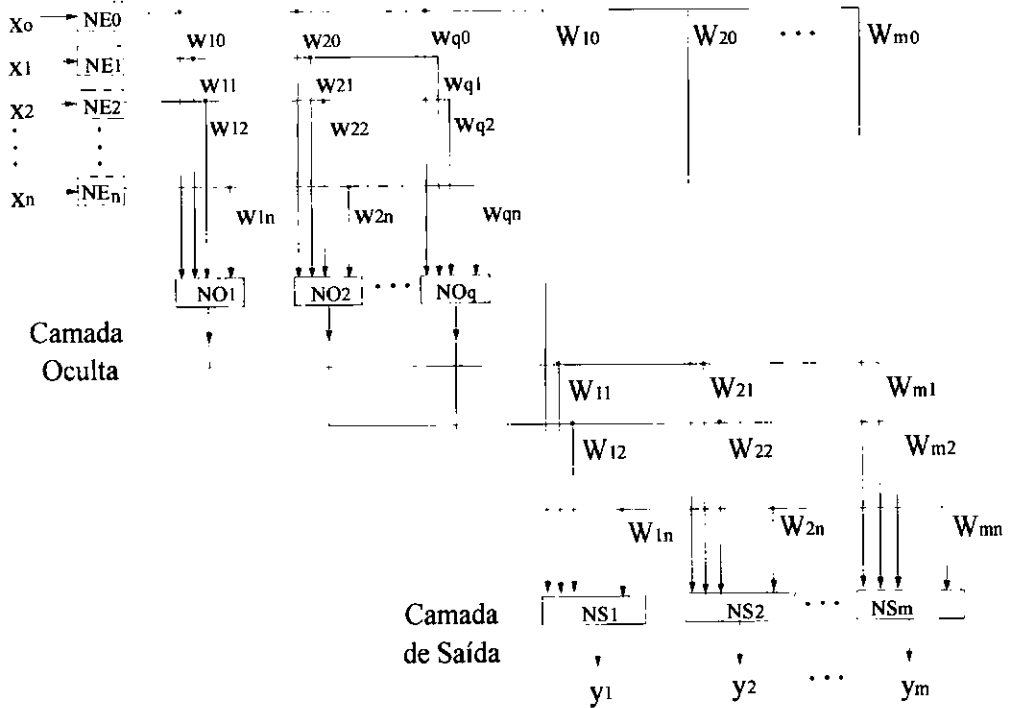


Figura 2.9 - RNA usada para apresentar os conceitos do Algoritmo *Backpropagation*.

Dado um input X_p , os neurônios HN_j da camada oculta recebem como entrada total

$$h_j^p = \sum_{i=0}^n w_{ji} \cdot x_i^p$$

e produz como saída total

$$z_j^p = g_\beta(h_j^p)$$

$$z_j^p = g_\beta\left(\sum_{i=0}^n w_{ji} \cdot x_i^p\right)$$

Os neurônios da camada de saída recebem como entrada total

$$o_k^p = \sum_{j=1}^q W_{kj} \cdot z_j^p$$

$$o_k^p = W_{k0} \cdot x_0^p + \sum_{j=1}^q W_{kj} \cdot g_\beta \left(\sum_{i=0}^n w_{ji} \cdot x_i^p \right)$$

onde $z_0^p = x_0^p$ por convenção.

Por sua vez essa camada produz como saída

$$y_k^p = g_\beta(o_k^p)$$

$$y_k^p = g_\beta \left(\sum_{j=0}^q W_{kj} \cdot z_j^p \right)$$

$$y_k^p = g_\beta \left(W_{k0} \cdot x_0^p + \sum_{j=1}^q W_{kj} \cdot g_\beta \left(\sum_{i=0}^n w_{ji} \cdot x_i^p \right) \right)$$

Usando esta equação nós podemos agora expressar a função de erro como

$$E_p = \frac{1}{2} \sum_{k=1}^m (t_k^p - y_k^p)^2$$

$$E_p = \frac{1}{2} \sum_{k=1}^m \left(t_k^p - g_\beta \left(\sum_{j=0}^q W_{kj} \cdot z_j^p \right) \right)^2$$

$$E_p = \sum_{k=1}^m \left(t_k^p - g_\beta \left(W_{k0} \cdot x_0^p + \sum_{j=1}^q W_{kj} \cdot g_\beta \left(\sum_{i=0}^n w_{ji} \cdot x_i^p \right) \right) \right)^2 \quad (2.9)$$

e a partir disso fazer os ajustes apropriados nos pesos W_{kj} e w_{ji} .

Para os pesos W_{kj} , associados às conexões da camada oculta com a saída, nós temos

$$\begin{aligned}\Delta W_{ki} &= -\eta \frac{\partial E_p}{\partial W_{ki}} \\ \Delta W_{ki} &= \eta \cdot (t_k^p - y_k^p) \cdot \dot{g}_\beta(o_k^p) \cdot z_j^p \\ \Delta W_{ki} &= \eta \cdot \delta_k^p \cdot z_j^p\end{aligned}\tag{2.10}$$

onde

$$\delta_k^p = (t_k^p - y_k^p) \cdot \dot{g}_\beta(o_k^p)$$

Para os pesos w_{ji} , associados às conexões da camada de entrada com a oculta, temos

$$\begin{aligned}\Delta w_{ji} &= -\eta \frac{\partial E_p}{\partial w_{ji}} \\ \Delta w_{ji} &= -\eta \frac{\partial E_p}{\partial z_j^p} \frac{\partial z_j^p}{\partial w_{ji}} \\ \Delta w_{ji} &= \eta \cdot [(t_k^p - y_k^p) \cdot \dot{g}_\beta(o_k^p) \cdot W_{kj}] \cdot [\dot{g}_\beta(h_j^p) \cdot x_i^p] \\ \Delta w_{ji} &= \eta \cdot \delta_j^p \cdot x_i^p\end{aligned}\tag{2.11}$$

onde

$$\delta_j^p = \delta_k^p \cdot W_{kj} \cdot \dot{g}_\beta(h_j^p)$$

O algoritmo *backpropagation* procede em ciclos. Em cada ciclo, nós aplicamos todos os pares entrada-saída de um dado conjunto treinamento. Para cada par $\langle X_p, T_p \rangle$, é calculado o erro E_p através de (2.9) e são atualizados os pesos W_{kj} associados às conexões da camada de saída com os valores ΔW_{ki} obtidos segundo (2.10) assim como os pesos w_{ji} associados a camada oculta são atualizados por valores Δw_{ji} calculados por (2.11). É também calculado o erro acumulativo E através da expressão (2.6) com um erro máximo E_{\max} . Se $E < E_{\max}$, o algoritmo termina, caso contrário, um novo ciclo é iniciado [KLIR, 95].

CAPÍTULO 3

APLICAÇÃO: RETROANÁLISE DO MODELO PROBABILÍSTICO PARA FISSURAÇÃO DO CONCRETO USANDO REDES NEURAS ARTIFICIAIS

3.1) Introdução ao Modelo Probabilístico

O enfoque probabilístico, baseado no Método de Monte Carlo, tem sido utilizado recentemente para simular a fissuração do concreto em análises através do Método dos Elementos Finitos. Quando um procedimento baseado nesse enfoque é usado, N amostras de um vetor de variáveis randômicas (resistência à tração, módulo de Young, etc.) são geradas segundo uma determinada função de densidade de probabilidade. Se considerarmos que as incertezas desses parâmetros do material variam segundo uma distribuição normal, o resultado indicado pelas N amostras correspondentes a uma simulação dependerá da média e do desvio padrão que definem a função de densidade de Gauss.

É intuitiva a consideração de que quanto mais fina a discretização (ou seja, quanto menores os elementos finitos) quão maior será a heterogeneidade localizada do material, ou seja, o desvio padrão na distribuição gaussiana. Há fórmulas [ROSSI, 87] para a determinação da média e desvio padrão em função do tamanho dos elementos finitos e do tamanho dos agregados graúdos.

O problema é que esses parâmetros estatísticos não podem ser completamente determinados, a priori, com precisão. Nesse capítulo, Redes Neurais Artificiais são usadas para determinar os valores da distribuição estatística (sendo uma distribuição normal: a média e o desvio padrão) para uma dada resposta da estrutura (por exemplo, uma curva carga-deslocamento) seguido de um procedimento de análise inversa.

Aqui iremos nos referir ao Método Direto de Monte Carlo (MDMC) desenvolvido por Rossi (ver [ROSSI, 87], [ROSSI, 94], [ROSSI, 96], [ROSSI, 97]) para simulação da fissuração do concreto, pois este tem-se apresentado mais promissor que os métodos baseados em enfoques não-probabilísticos, uma vez que é capaz de capturar os efeitos de escala da fratura do concreto [ROSSI, 87] [ROSSI, 94].

O modelo de Rossi apresenta um processo estocástico em escala local do material, considerando que fissuras surgem dentro do concreto com diferentes energias de dissipação, dependendo da distribuição dos constituintes e erros iniciais. Assume-se que é possível modelar o comportamento local do material no concreto através de um comportamento elástico frágil perfeito. Sendo dessa forma, a distribuição randômica de energia de fissuração local pode ser substituída por uma distribuição randômica de tensões locais.

A função de distribuição estatística [ROSSI, 87] foi obtida experimentalmente através de um grande número de ensaios de tração direta e uma lei normal foi encontrada para descrever muito bem a distribuição experimental obtida. O uso de um modelo com elementos finitos para simular o comportamento do concreto submetido a trações controladas permitiu reproduzir os principais fenômenos encontrados nesse tipo de teste: efeito de escala e a relação entre o comportamento após o pico de tensão e a concentração de tensões, o mecanismo de ruptura e o comportamento biaxial do concreto.

O modelo probabilístico de Rossi pode ser muito melhorado se a distribuição estatística dos parâmetros característicos do material puder ser determinada pela análise inversa, onde a entrada é uma curva experimental correspondendo, por exemplo, a uma curva $P - \delta$ obtida de um ensaio de 3 pontos da RILEM, e a saída é a média e o desvio padrão. Mediante a Análise Inversa poderia ser possível determinar a distribuição estatística para vários problemas onde uma análise experimental é impossível de ser realizada. Por exemplo, se os elementos finitos de um problema discreto são muito pequenos será impossível determinar, através de testes experimentais, a resistência e a distribuição estatística dentro da peça real, já que a deveríamos, para realizar tais ensaios, extrair da estrutura corpos de prova tão pequenos quanto os elementos finitos.

Em um artigo recente [FAIRBAIRN et al, 99], apresentaram um algoritmo capaz de resolver o problema inverso para encontrar os parâmetros probabilísticos correspondentes a uma dada resposta estrutural. Contudo, o procedimento proposto pode ser melhorado já que não converge para alguns casos e também é computacionalmente custoso.

Sendo assim desenvolvemos no quadro desta tese, um procedimento para fazer esta análise inversa baseado na aplicação de Redes Neurais. Para mostrar sua viabilidade, usamos o mesmo modelo mecânico simplificado apresentado na referência [FAIRBAIRN et al, 99]. Foi constatado que o uso de RNA reduz o custo computacional permitindo a aplicação do presente procedimento na análise inversa para problemas mais complexos.

3.2) Apresentação do Problema

Vamos considerar uma peça de concreto com deslocamento controlado em um ensaio de tração simples. Supõe-se que esta peça é composta de m camadas (elementos) como mostra a Figura 3.1 . Todas as camadas têm sua relação constitutiva elasto-frágil com uma resistência à tração individual chamada $f_{c,i}$. Como simplificação consideramos que o módulo de elasticidade é constante (não heterogêneo) para todas as camadas.

Esta tensão pode ser caracterizada por uma distribuição normal dada pela expressão

$$g(f_c) = \frac{1}{f_{c,\sigma}} e^{-0,5D^2} \quad (3.1)$$

sendo

$$D = \frac{f_c - f_{c,\mu}}{f_{c,\sigma}}$$

onde $g(f_c)$ é a função de densidade para a resistência a tração, $f_{c,\mu}$ e $f_{c,\sigma}$ são a média e o desvio padrão da distribuição, respectivamente.




Figura 3.1: Modelo mecânico para ensaio de tração simples.

Agora é possível obter uma amostra de m valores de $f_{\alpha,i}$, cada um correspondendo a uma camada, usando uma rotina padrão para geração de números aleatórios correspondentes a uma determinada distribuição normal.

Isso nos permite calcular a curva carga-deslocamento para o corpo de prova, correspondendo a uma amostra, segundo a seqüência abaixo, que será chamada de **Procedimento 1**.

1 - Aplicar um deslocamento $\delta_k = \delta_{k-1} + \Delta\delta$, onde $\delta_0 = 0$ e $\Delta\delta$ é um dado incremento de δ . O deslocamento δ é suposto constante para todas as camadas, o que corresponde a imaginar que o mecanismo de aplicação de deslocamento é suficientemente rígido para manter o paralelismo entre as faces.

2 - Calcular a tensão para todas as camadas acompanhando a relação constitutiva da Figura 3.1, o que pode ser escrito como

$$\sigma_{k,i} = \frac{E}{h} \cdot \delta_k \quad \text{se} \quad \delta_k \leq w_{u,i}$$

$$\sigma_{k,i} = 0 \quad \text{se} \quad \delta_k > w_{u,i}$$

3 - Calcular a força para cada camada usando

$$P_{k,i} = \sigma_{k,i} \cdot A_i$$

4 - Calcular a força total do corpo de prova usando

$$P_k = \sum_{i=1}^m P_{k,i}$$

5 - Se $k < 0$ e $P_k = 0$ fim do procedimento. Senão, ir para passo 1.

Procedimento 1

Nesse ponto pode-se implementar uma simulação de Monte Carlo baseando-se no algoritmo apresentado acima. Então, um número n de amostras é gerado (segundo a mesma distribuição normal) e as correspondentes curvas $P - \delta$ são computadas segundo o procedimento 1.

Temos a $j^{\text{ésima}}$ amostra correspondente à $j^{\text{ésima}}$ curva $P - \delta$ que é composta por valores discretos de P e δ chamados P_k^j e δ_k^j , com j correspondendo à amostra e k aos valores discretos de P e δ . Os valores discretos de δ são, no presente caso, impostos os mesmos para todas as curvas j .

Isso torna possível calcular a curva média com a seguinte expressão

$$P_k^{\text{media},j} = \frac{\sum_{l=1}^j P_k^l}{j} \quad (3.2)$$

O procedimento termina quando

$$\|P_k^{\text{media},j} - P_k^{\text{media},j-1}\| < TOL1$$

onde $TOL1$ é um dado valor para verificar a convergência do procedimento.

Essa simulação de Monte Carlo está resumida em três etapas principais que são mostradas no **Procedimento 2**:

- 1 - Para uma amostra j , calcular a curva (P_k^j, δ_k^j) segundo o Procedimento 1.
- 2 - Calcular os valores de $P_k^{medio,j}$ segundo fórmula (3.1).
- 3 - Encerra o procedimento se $\|P_k^{media,j} - P_k^{media,j-1}\| < TOL1$. Senão, voltar para o passo 1.

Procedimento 2.

Para uma determinada distribuição caracterizada por uma média e um desvio padrão da resistência à tração (a entrada do sistema) tem-se uma curva média $P - \delta$ obtida através de uma simulação de Monte Carlo caracterizada pelos valores $(P_k^{media} - \delta_k)$ obtidos como descrito anteriormente no Procedimento 2.

O Procedimento 2 pode ser retratado na Figura 3.2 .

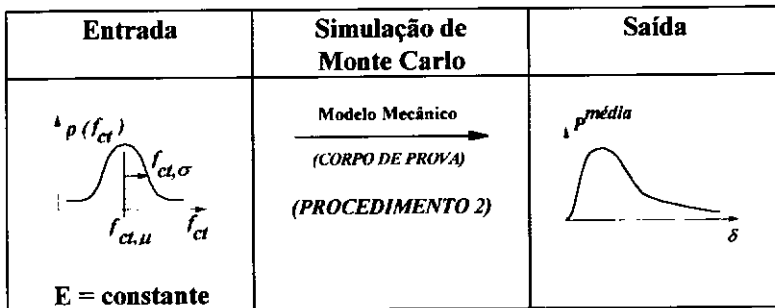


Figura 3.2 - Croqui da Simulação de Monte Carlo

Como exemplo, vamos considerar um corpo de prova com dimensões 100x100x200 mm, módulo de Young $E = 20\ 000$ MPa, $f_{\alpha,\mu} = 4$ MPa e $f_{\alpha,\sigma} = 2$ MPa. O resultado da Simulação de Monte Carlo que convergiu para 120 amostras está na Figura 3.3 .




Figura 3.3 - Simulação de Monte Carlo

Já é possível iniciarmos a Análise Inversa, isto é, encontrar a distribuição normal caracterizada por $f_{\alpha,\mu}$ e $f_{\alpha,\sigma}$ que correspondem a uma dada curva $P-\delta$, considerando-se o módulo de elasticidade constante, ou seja conhecido com incerteza nula.

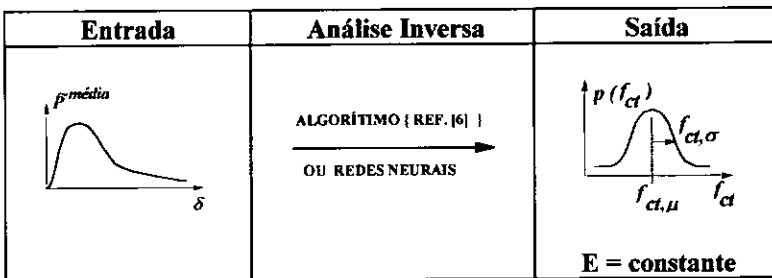


Figura 3.4 - Croqui da Análise Inversa.

A solução para esse problema será útil para determinar, por exemplo, qual distribuição normal dos parâmetros do material corresponde aos resultados médios obtidos através de ensaios experimentais.

Num primeiro enfoque deste problema inverso, um procedimento foi proposto na referência [FAIRBAIRN et al, 99]. Contudo, como afirmado pelos autores, mesmo que tenha sido provada a viabilidade em várias análises, é computacionalmente custoso operar o algoritmo que pode falhar para alguns parâmetros e também porque o esforço computacional é muito grande.

Visto que Redes Neurais Artificiais já têm sido aplicadas para melhorar as simulações de Monte Carlo [SARAIVA, 97], um estudo foi feito para determinar se elas são capazes de resolver esse problema de uma maneira otimizada.

3.3) Análise Inversa Usando Redes Neurais Artificiais

A técnica da análise inversa com RNA consiste, primeiramente, em realizar-se um certo número de simulações de Monte Carlo (aproximadamente 20 simulações), correspondendo à Análise Direta, para obter um determinado número de amostras que serão utilizadas como conjunto de treinamento da Rede Neural. Cada amostra consiste de uma curva $P^{media} - \delta$ que será considerada como entrada da RNA e os valores $f_{\alpha,\mu}$ (média da resistência à tração) e $f_{\alpha,\sigma}$ (desvio padrão da resistência à tração) que serão considerados como saída da rede.

Os valores de $f_{\alpha,\mu}$ (média) são dados por 1.0, 1.5, 2.0, 2.5, 3.0, 3.5 e 4.0 e os valores de $f_{\alpha,\sigma}$ (desvio padrão) são divididos em três grupos :

Grupo 1	$f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{3}$
Grupo 2	$f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{2}$
Grupo 3	$f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{1.5}$

Tabela 3.1 - Relação entre a média e os três grupos de desvio padrão.

Os valores de $f_{\alpha,\mu}$ e $f_{\alpha,\sigma}$ (ambos em MPa) considerados para a obtenção do conjunto de treinamento principal estão nas Tabela 3.2, 3.3 e 3.4.

Média	1,0	1,5	2,0	2,5	3,0	3,5	4,0
Desvio Padrão	0,33	0,50	0,67	0,83	1,00	1,17	1,33

Tabela 3.2 - Grupo 1. Valores de treinamento onde $f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{3}$

Média	1,0	1,5	2,0	2,5	3,0	3,5	4,0
Desvio Padrão	0,50	0,75	1,00	1,25	1,50	1,75	2,00

Tabela 3.3 - Grupo 2. Valores de treinamento onde $f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{2}$

Média	1,0	1,5	2,0	2,5	3,0	3,5	4,0
Desvio Padrão	0,67	1,00	1,33	1,67	2,00	2,33	2,67

Tabela 3.4 - Grupo 3. Valores de treinamento onde $f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{1.5}$

De posse dos vários pares $f_{\alpha,\mu}$ e $f_{\alpha,\sigma}$, que serão as saídas da RNA, obtem-se com o Método de Monte Carlo as diversas curvas $P^{media} - \delta$ (ver Figuras 3.5, 3.6 e 3.7) relativas aos valores das três tabelas acima. Em todas elas consideramos o módulo de elasticidade com incerteza nula.




Figura 3.5 - Curvas $P^{media} - \delta$ relativas ao Grupo 1.




Figura 3.6 - Curvas $P^{media} - \delta$ relativas ao Grupo 2.




Figura 3.7 - Curvas $P^{media} - \delta$ relativos ao Grupo 3.

Portanto, o conjunto de treinamento envolve 21 amostras, sendo cada amostra, por sua vez, formada por um par $f_{\alpha,\mu} - f_{\alpha,\sigma}$ e por sua respectiva curva $P^{media} - \delta$.

Utilizando-se uma RNA *feedforward* com três camadas, algoritmo de aprendizado do tipo *backpropagation*, taxa de aprendizado $\eta = 0.1$ e função de ativação sigmóide e de posse do conjunto de treinamento, faz-se a Rede Neural ajustar seus pesos de tal forma a aprender o padrão desejado. .

A camada de entrada é composta de 26 neurônios, uma vez que as curvas $P^{media} - \delta$, usadas como entrada, são definidas através de 26 valores discretos que variam de uma curva para a outra, ao contrário dos deslocamentos que são os mesmos para todas as curvas.

A camada de saída possui apenas dois neurônios referentes à média ($f_{\alpha,\mu}$) e ao desvio padrão ($f_{\alpha,\sigma}$) da resistência à tração do corpo de prova analisado.

Como estão sendo usadas 21 amostras para a RNA ser treinada, 26 neurônios na camada de entrada e 2 neurônios na camada de saída, a camada oculta terá 18 neurônios, de acordo com a expressão (2.4) do Capítulo 2, que relata o modo como o programa Neuroshell calcula o número de neurônios das camadas ocultas.

Um esquema da RNA utilizada para esse treinamento encontra-se na Figura 3.8 .

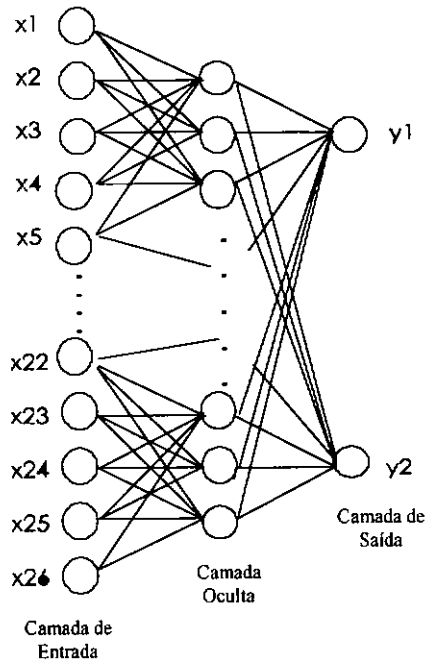


Figura 3.8 - Esquema da RNA do exemplo do corpo de prova tracionado

Concluído o aprendizado da RNA, é possível resolver o problema inverso esquematizado na Figura 3.4 , isto é, entrar com os valores da curva $P^{media} - \delta$ e descobrir qual o par , $f_{\alpha,\mu}$ e $f_{\alpha,\sigma}$, corresponde à curva dada como entrada.

Com a finalização da etapa de treinamento, é preciso analisar os dados que a rede produz, verificando se estão corretos ou não. Basicamente essa análise pode ser feita em duas etapas. A primeira consiste em utilizar dados conhecidos da rede (as amostras do conjunto de treinamento) usando-os como entrada para verificar a diferença entre os valores obtidos com os valores desejados para a média e para o desvio padrão. A segunda consiste em utilizar dados desconhecidos da rede.

Em cada uma dessas etapas é analisada a porcentagem de erro entre os valores da média e do desvio padrão desejados utilizados na Análise Direta em relação aos obtidos através da RNA. É calculado também o Erro Quadrático Médio (EQM).

O Neuroshell fornece um Coeficiente de Correlação das curvas treinadas. Tanto para a Média como para o Desvio Padrão o valor obtido para o coeficiente foi igual a 1.0, indicando que a rede está bem treinada. Valores próximos de zero indicariam uma rede mal treinada.

As Figuras 3.9 e 3.10 apresentam os valores desejados para a Média e Desvio Padrão e os obtidos com a RNA.

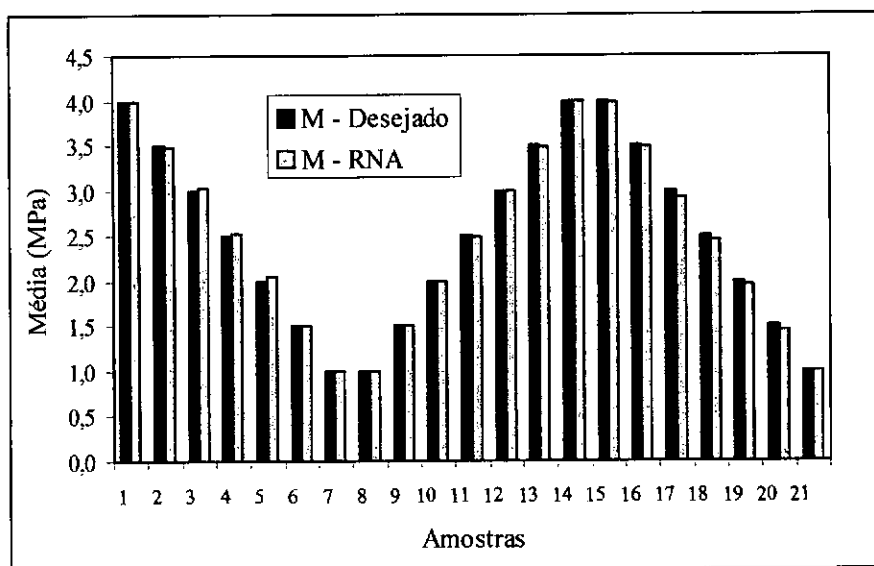


Figura 3.9 - Comparação dos valores desejados para a Média e os obtidos pela RNA.

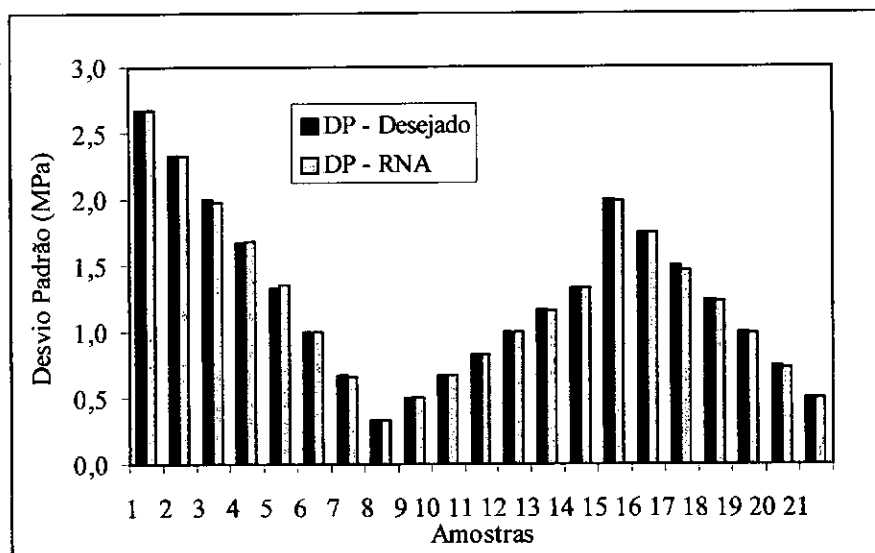


Figura 3.10 - Comparação dos valores desejados do Desvio Padrão e os obtidos pela RNA.

Na primeira etapa de comparação dos dados usados no treinamento com os obtidos através da rede, obteve-se os valores mostrados nas Tabelas 3.5 e 3.6 e nas Figuras 3.11 e 3.12 .

Na Tabela 3.5 , a coluna com os valores M1 refere-se às médias $f_{\alpha,\mu}$ utilizadas no treinamento. Na coluna com os valores M2 encontram-se os resultados obtidos pela RNA.

A expressão que define o Erro Quadrático Médio (EQM) para os valores da média é a seguinte

$$EQM = \frac{\sum (M1 - M2)^2}{P}$$

onde P é o número total de amostras.

O valor do EQM para a média foi 0.00095.

A expressão que define o cálculo do erro em porcentagem é

$$Erro(\%) = \frac{(M1 - M2).100}{M1}$$

Amostra	An.Direta	RNA	(M1-M2)	dM ²	Amostra	Erro da Média em %
	M1	M2				
1	1,0	1,00000	0,00000	0,000E+00	1	0,00
2	1,0	1,00000	0,00000	0,000E+00	2	0,00
3	1,0	1,00000	0,00000	0,000E+00	3	0,00
4	1,5	1,50614	-0,00614	3,771E-05	4	-0,41
5	1,5	1,45144	0,04856	2,358E-03	5	3,24
6	1,5	1,51123	-0,01123	1,261E-04	6	-0,75
7	2,0	1,99069	0,00931	8,665E-05	7	0,47
8	2,0	1,95762	0,04238	1,796E-03	8	2,12
9	2,0	2,04461	-0,04461	1,990E-03	9	-2,23
10	2,5	2,49271	0,00729	5,313E-05	10	0,29
11	2,5	2,45170	0,04830	2,333E-03	11	1,93
12	2,5	2,53015	-0,03015	9,089E-04	12	-1,21
13	3,0	2,99329	0,00671	4,501E-05	13	0,22
14	3,0	2,92883	0,07117	5,065E-03	14	2,37
15	3,0	3,03879	-0,03879	1,504E-03	15	-1,29
16	3,5	3,48500	0,01500	2,250E-04	16	0,43
17	3,5	3,48900	0,01100	1,210E-04	17	0,31
18	3,5	3,49300	0,00700	4,900E-05	18	0,20
19	4,0	4,00000	0,00000	0,000E+00	19	0,00
20	4,0	3,98064	0,01936	3,750E-04	20	0,48
21	4,0	3,99690	0,00310	9,588E-06	21	0,08
Somatório						
				0,01708		
EQM						
				0,00095		

Tabela 3.5 - Comparação das Médias $f_{a,\mu}$ usadas no treinamento e a obtidas com a RNA.




Figura 3.11 - Erro da Média usada no treinamento e a obtida com a RNA .

Amostra	An.Direta	RNA	(DP1-DP2)	dDP^2	Amostra	Erro do Desv.
	DP1	DP2				Pad. em %
1	0,33333	0,33333	0,00000	3,947E-16	1	0,00
2	0,50000	0,49483	0,00517	2,672E-05	2	1,03
3	0,66667	0,66290	0,00376	1,417E-05	3	0,56
4	0,50000	0,50232	-0,00232	5,370E-06	4	-0,46
5	0,75000	0,72764	0,02236	5,000E-04	5	2,98
6	1,00000	1,00221	-0,00221	4,867E-06	6	-0,22
7	0,66667	0,67275	-0,00608	3,702E-05	7	-0,91
8	1,00000	0,98438	0,01562	2,441E-04	8	1,56
9	1,33333	1,34903	-0,01569	2,463E-04	9	-1,18
10	0,83333	0,82806	0,00527	2,780E-05	10	0,63
11	1,25000	1,23550	0,01450	2,101E-04	11	1,16
12	1,66667	1,67867	-0,01200	1,440E-04	12	-0,72
13	1,00000	0,99989	0,00011	1,310E-08	13	0,01
14	1,50000	1,46762	0,03238	1,049E-03	14	2,16
15	2,00000	1,98148	0,01852	3,429E-04	15	0,93
16	1,16700	1,16200	0,00500	2,500E-05	16	0,43
17	1,75000	1,74100	0,00900	8,100E-05	17	0,51
18	2,33000	2,33200	-0,00200	4,000E-06	18	-0,09
19	1,33333	1,33050	0,00284	8,041E-06	19	0,21
20	2,00000	1,99355	0,00645	4,160E-05	20	0,32
21	2,66667	2,66570	0,00097	9,330E-07	21	0,04
Somatório						
				0,00301		
				EQM		
				0,00017		

Tabela 3.6 - Comparação dos Desvios Padrões usados no treinamento e o obtidos com a RNA .




Figura 3.12 - Erro dos Desvios Padrões usados no treinamento e os obtidos com a RNA.

Na Tabela 3.6 , a coluna com os valores DP1 referem-se aos desvios padrão $f_{\alpha,\sigma}$ utilizados no treinamento. Na coluna com os valores DP2 encontram-se os resultados obtidos pela RNA.

A expressão que define o EQM para os valores do desvio padrão é a seguinte

$$EQM = \frac{\sum(DP1 - DP2)^2}{P}$$

onde P é o número total de amostras.

O valor do EQM para o desvio padrão foi de 0.00017.

A expressão que define o cálculo do erro em porcentagem é

$$Erro(\%) = \frac{(DP1 - DP2) \cdot 100}{DP1}$$

Na segunda etapa da análise dos dados gerados pelas RNA, são utilizadas curvas $p^{media} - \delta$ desconhecidas , isto é, que não foram utilizadas no treinamento. Para a obtenção desse conjunto de curvas, considerou-se os valores de $f_{\alpha,\mu}$ (média) da Tabela 3.7 .

1.1	1.2	1.3	1.4	1.6	1.7	1.8	1.9	2.1	2.2
2.3	2.4	2.6	2.7	2.8	2.9	3.1	3.2	3.3	3.4
3.6	3.7	3.8	3.9	4.1					

Tabela 3.7 - Valores selecionados para a média.

Os valores do $f_{\alpha,\sigma}$ (desvio padrão) foram dessa vez divididos em cinco grupos:

Grupo 1	$f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{3}$
Grupo 2	$f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{2.5}$
Grupo 3	$f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{2}$
Grupo 4	$f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{1.75}$
Grupo 5	$f_{\alpha,\sigma} = f_{\alpha,\mu} \cdot \frac{1}{1.5}$

Tabela 3.8 - Relação entre a média e os cinco grupos de desvio padrão.

Nessa etapa consideram-se 5 valores de desvio padrão para cada valor de média, ao invés dos 3 valores considerados anteriormente para a obtenção do conjunto de treinamento.

De posse desses valores de média e desvio padrão, obtêm-se 125 curvas $P^{media} - \delta$, através da Análise Direta, para serem utilizadas como entrada na RNA e verificar o erro em porcentagem e o EQM dos valores de média e desvio padrão gerados pelas redes em relação aos valores desejados.

O EQM nessa etapa para a média foi 0.00208 e para o desvio padrão de 0.00066.

A Figura 3.13 mostra a porcentagem de erro da média e do desvio padrão para as 125 curvas desconhecidas usadas como input na RNA.




Figura 3.13 - Erro da Média e do Desvio Padrão para curvas desconhecidas da RNA.

Um pequeno aumento do EQM ao utilizar-se dados desconhecidos da rede já era esperado. No caso da Média, que variou de 1 a 4, o EQM ficou em torno de 0.002 e no caso do Desvio Padrão, que variou de 0.33 a 2.67, ficou em torno de 0.00066.

Ao utilizar-se dados conhecidos da rede, as porcentagens de erro, mostradas nas figuras 3.11 e 3.12, são sempre menores que 4%. Por outro lado, para as 125 amostras (ver Figura 3.13) desconhecidas usadas como entrada na rede verificam-se erros menores que 8%. Em ambos os casos os erros são pequenos, indicando um bom treinamento da rede.

Com tudo isso fica provado que é possível treinar uma rede com poucas amostras, o que viabiliza a metodologia para casos em que as Análises Diretas representam um custo de tempo elevado.

Verifica-se então a facilidade da utilização da Análise Inversa com o emprego de Redes Neurais para a determinação de parâmetros estatísticos do modelo probabilístico para a fissuração do concreto. A partir desta constatação, diversas outras aplicações foram realizadas fazendo-se uso do Método dos Elementos Finitos [FAIRBAIRN et al, 99a].

CAPÍTULO 4

APLICAÇÃO: RETROANÁLISE PARA A IDENTIFICAÇÃO DOS PARÂMETROS ELÁSTICOS DA BARRAGEM CASCA DE FUNIL.

4.1) Introdução

O modelo, chamado de híbrido pelos engenheiros de barragens, corresponde a um gráfico onde no eixo das abcissas são marcados os valores experimentais obtidos de leituras de uma variável na estrutura real e no eixo das ordenadas são marcados os valores da mesma variável obtidos por intermédio de uma simulação. Sendo assim, considerando-se uma banda de incerteza, pode-se determinar a tendência da evolução da variável escolhida para análise (ver Figura 4.12).

O modelo híbrido presta um valioso auxílio no controle dos deslocamentos medidos nas barragens e, portanto, no controle da segurança destas estruturas. Apresenta-se neste capítulo um modelo híbrido especialista no controle dos deslocamentos horizontais absolutos, cuja componente devida à variação do nível d'água no reservatório é calculada com base na teoria da elasticidade. A componente devida à temperatura é modelada estatisticamente.

O modelo híbrido é ilustrado no controle do deslocamento horizontal absoluto de um ponto da casca da barragem de Funil de FURNAS CENTRAIS ELÉTRICAS S.A. Esta barragem é do tipo casca com dupla curvatura e está localizada no Rio Paraíba no município de Itatiaia, Estado do Rio de Janeiro. Ela possui uma altura de 85m e o comprimento do arco de coroamento é igual a 360m. As espessuras da casca são iguais a 3,6 m e 26,0 m no fecho do arco de coroamento e no soco, respectivamente [CBGB, 89]. Uma fotografia da barragem de Funil pode ser vista na Figura 4.1, e um desenho da seção transversal é mostrado na Figura 4.2 .



Figura 4.1 – Fotografia da UHE de Funil.




Figura 4.2 – Seção transversal da barragem de Funil.

4.2) Monitoramento e Ensaio

Os deslocamentos horizontais de pontos da abóbada da barragem de Funil são monitorados mediante rede geodésica de trilateração e um conjunto de pêndulos (direto e invertido) juntamente com um prumo ótico. Na presente tese, são usados, na retroanálise neural, os deslocamentos horizontais radiais medidos pelos pêndulos e o prumo ótico, no fecho e rins do arco da cota 464 e nos rins do arco da cota 441 (ver esquema na Figura 4.3).

Foram consideradas as medições efetuadas nos cinco pontos acima, no período de 25/01/93 a 26/01/98. Neste período não foi constatada nenhuma componente de tendência nas séries temporais dos deslocamentos medidos.

A análise quantitativa destas séries, mediante regressão multilinear acoplada com análise de variância, permitiu a caracterização das componentes hidrostáticas dos referidos deslocamentos. Na Figura 4.4 podem-se observar estas funções com suas incertezas padronizadas [FAIRBAIRN et al, 99b].

Os valores médios dos parâmetros elásticos obtidos mediante ensaios realizados com os materiais da barragem (concreto) e sua fundação (rocha) são os seguintes:

Módulo de Elasticidade do Concreto: $E_c = 2.89 \cdot 10^4 \text{ MPa}$;

Coefficiente de Poisson do Concreto: $\nu_c = 0.25$;

Módulo de Elasticidade da Rocha: $E_r = 5.46 \cdot 10^4 \text{ MPa}$;

Coefficiente de Poisson da Rocha: $\nu_r = 0.28$




Figura 4.3 – Esquema da instrumentação.

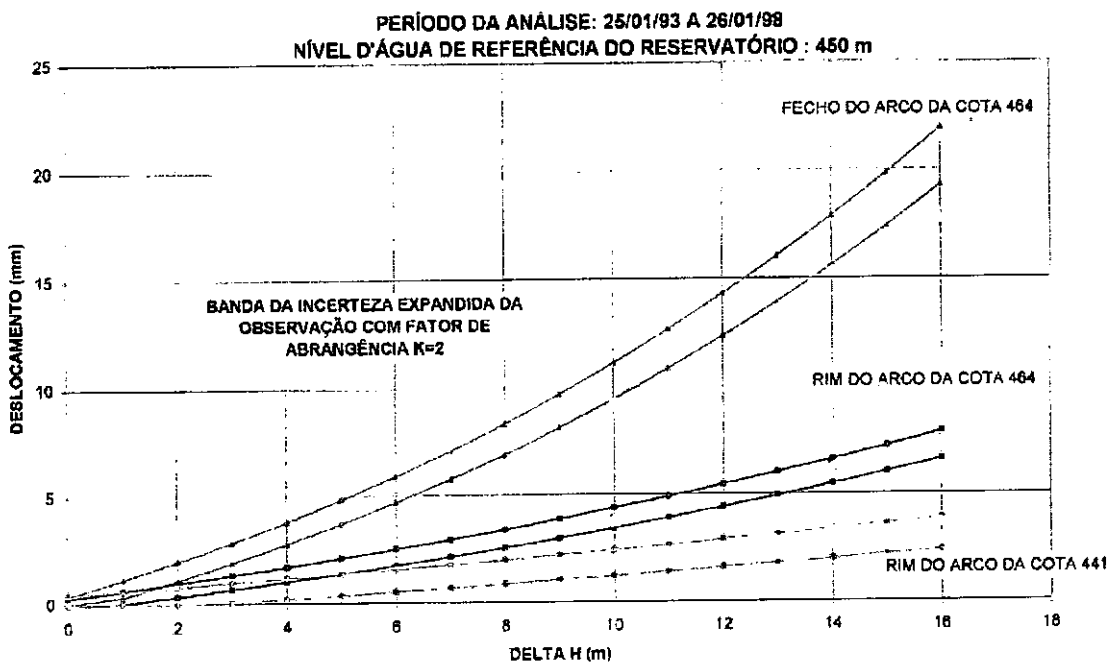


Figura 4.4 – Caracterização das componentes hidrostáticas.

4.3) Retroanálise Neural

Para a realização da retroanálise neural dos parâmetros elásticos da barragem de Funil precisa-se definir inicialmente quais seriam os conjuntos de treinamento da RNA. Os conjuntos de treinamento são obtidos através de análise elástica (direta) realizada pelo Método dos Elementos Finitos (MEF), onde são arbitrados valores para os módulos de elasticidade e coeficientes de Poisson do concreto e da rocha respectivamente.

Assim sendo, para um conjunto de entrada de 4 parâmetros elásticos:

$$\{E_c, \nu_c, E_r, \nu_r\} \quad (4.1)$$

Executa-se um programa para cálculo de deslocamentos baseado no MEF para 3 níveis d'água (466 m, 464 m, 460 m) e para o nível de referência de 450 m. Para cada nível d'água toma-se 5 deslocamentos, correspondendo aos 5 pontos de leitura mostrados na Figura 4.3 . Tem-se, então, um vetor de 15 valores que corresponde a saída da análise direta:

$$\left\{ \begin{array}{ccccc} d_{\text{fecho}}^{NIVEL466} & d_{\text{rim,e,cot a464}}^{NIVEL466} & d_{\text{rim,e,cot a441}}^{NIVEL466} & d_{\text{rim,d,cot a464}}^{NIVEL466} & d_{\text{rim,d,cot a441}}^{NIVEL466} \\ d_{\text{fecho}}^{NIVEL464} & d_{\text{rim,e,cot a464}}^{NIVEL464} & d_{\text{rim,e,cot a441}}^{NIVEL464} & d_{\text{rim,d,cot a464}}^{NIVEL464} & d_{\text{rim,d,cot a441}}^{NIVEL464} \\ d_{\text{fecho}}^{NIVEL460} & d_{\text{rim,e,cot a464}}^{NIVEL460} & d_{\text{rim,e,cot a441}}^{NIVEL460} & d_{\text{rim,d,cot a464}}^{NIVEL460} & d_{\text{rim,d,cot a441}}^{NIVEL460} \end{array} \right\} \quad (4.2)$$

Uma análise preliminar indicou que algumas simplificações poderiam ser realizadas: por um lado, os deslocamentos dos rins esquerdos e direitos são praticamente simétricos, o que permite reduzir o conjunto de valores descrito em (4.2) para um conjunto de nove valores; por outro lado, uma análise de sensibilidade (ver Tabela 4.1) mostrou que o problema é muito pouco sensível a variações dos parâmetros das fundações (rocha) o que permitiu reduzir o conjunto descrito em (4.1) para 2 valores $\{E_c, \nu_c\}$, sendo os valores dos módulos de elasticidade e de Poisson da rocha de fundação fixados como aqueles obtidos dos ensaios, isto é, $E_r = 5.46 \cdot 10^4 \text{ MPa}$; $\nu_r = 0.28$.

Ec	vc	Er	vr	Nível do Carregamento = 466			Nível do Carregamento = 464			Nível do Carregamento = 460		
				Fecho	rim,e,cota 464	rim,e,cota 441	Fecho	rim,e,cota 464	rim,e,cota 441	Fecho	rim,e,cota 464	rim,e,cota 441
2,5	0,21	5,56	0,27	23,43	6,40	3,15	17,92	5,35	2,67	10,82	3,28	1,73
2,8	0,21	5,56	0,27	20,95	5,74	2,83	16,47	5,04	2,72	9,67	2,94	1,56
12%	0%	0%	0%	-10,58%	-10,35%	-10,11%	-8,09%	-5,79%	1,87%	-10,63%	-10,37%	-9,83%
2,5	0,21	5,56	0,27	23,43	6,40	3,15	17,92	5,35	2,67	10,82	3,28	1,73
2,5	0,245	5,56	0,27	23,41	6,28	3,10	17,90	5,25	2,63	10,90	3,22	1,71
0%	17%	0%	0%	-0,06%	-1,91%	-1,34%	-0,11%	-1,87%	-1,50%	0,74%	-1,83%	-1,16%
2,5	0,245	5,45	0,27	23,42	6,29	3,11	17,90	5,25	2,64	10,90	3,22	1,71
2,5	0,245	5,56	0,27	23,41	6,28	3,10	17,90	5,25	2,63	10,90	3,22	1,71
0%	0%	2%	0%	0,05%	0,08%	0,23%	0,00%	0,00%	0,38%	0,00%	0,00%	0,00%
2,5	0,245	5,56	0,22	23,42	6,28	3,11	17,90	5,25	2,63	10,90	3,22	1,71
2,5	0,245	5,56	0,27	23,41	6,28	3,10	17,90	5,25	2,63	10,90	3,22	1,71
0%	0%	0%	23%	0,03%	0,03%	0,06%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%

Tabela 4.1 - Análise feita, via MEF, para verificar a influência de cada parâmetro nos deslocamentos da estrutura.

A Tabela 4.1 está dividida em quatro partes principais. Na primeira delas, temos dois pares de valores de E_c, ν_c, E_r, ν_r e seus respectivos deslocamentos obtidos pelo MEF para os 3 níveis de carregamento. Porém um quarteto difere do outro em 12% no valor do módulo do concreto (E_c) o que acarretou uma alteração significativa nos deslocamentos, na ordem dos 10%.

Na segunda parte temos um quarteto diferindo do outro em 17% no valor do Coeficiente de Poisson do Concreto (ν_c) sem acarretar significativas mudanças nos valores dos deslocamentos, ficando na ordem dos 2%.

Na terceira parte o primeiro quarteto difere do outro em 2% no Módulo de Elasticidade da Rocha (E_r), e também não modifica significativamente os deslocamentos.

Por fim, na quarta parte, o primeiro quarteto difere do outro em 23% no Coeficiente de Poisson da Rocha (ν_r), sem praticamente nenhuma alteração nos deslocamentos.

De acordo com o que foi exposto considera-se apenas os valores do Módulo de Elasticidade e o Coeficiente de Poisson do Concreto.

A análise direta pode ser então esquematizada como:

$$\{E_c, \nu_c\} \xrightarrow{MEF} \left\{ \begin{array}{ccc} d_{\text{fecho}}^{NIVEL466} & d_{\text{rim,e,cot a 464}}^{NIVEL466} & d_{\text{rim,e,cot a 441}}^{NIVEL466} \\ d_{\text{fecho}}^{NIVEL464} & d_{\text{rim,e,cot a 464}}^{NIVEL464} & d_{\text{rim,e,cot a 441}}^{NIVEL464} \\ d_{\text{fecho}}^{NIVEL460} & d_{\text{rim,e,cot a 464}}^{NIVEL460} & d_{\text{rim,e,cot a 441}}^{NIVEL460} \end{array} \right\} \quad (4.3)$$

Considerando as incertezas associadas aos parâmetros elásticos anteriores, foram gerados 8 vetores paramétricos $\{E_c, \nu_c\}$ e executado o procedimento descrito acima, sendo calculados os nove deslocamentos radiais indicados em (4.3).

Este conjunto de valores (indicado na Tabela 4.2) é então usado para o treinamento da rede neural, sendo os deslocamentos radiais considerados como entrada da rede e os módulos elásticos considerados como saída da rede.

Amostra	Constantes Elásticas (OUTPUT)		Deslocamentos Radiais (mm) - (INPUT)								
	Ec (1E+04 MPa)	vc	Nível do Carregamento = 466			Nível do Carregamento = 464			Nível do Carregamento = 460		
			Fecho	rim,e,cota 464	rim,e,cota 441	Fecho	rim,e,cota 464	rim,e,cota 441	Fecho	rim,e,cota 464	rim,e,cota 441
1	2,80	0,23	21,684	7,74	3,826	16,409	6,494	3,29	10,264	3,973	2,145
2	2,80	0,26	21,691	7,554	3,758	16,413	6,343	3,232	10,276	3,879	2,106
3	2,90	0,23	20,947	7,479	3,701	15,85	6,276	3,182	9,916	3,84	2,074
4	2,90	0,26	20,954	7,301	3,635	15,854	6,13	3,127	9,926	3,749	2,038
5	3,00	0,23	20,259	7,236	3,584	15,329	6,072	3,082	9,59	3,716	2,009
6	3,00	0,26	20,266	7,064	3,52	15,333	5,932	3,028	9,601	3,628	1,973
7	3,10	0,23	19,616	7,009	3,475	14,842	5,882	2,988	9,286	3,599	1,948
8	3,10	0,26	19,622	6,842	3,413	14,846	5,746	2,936	9,296	3,514	1,913

Tabela 4.2 – Conjunto de treinamento para a rede neural

Os valores dos deslocamentos radiais obtidos na estrutura são mostrados na Tabela 4.3 e representados na Figura 4.5 . Esses valores serão utilizados como entrada, após o treinamento da rede neural, para fornecerem os valores de saída que são E_c e ν_c .

Deslocamentos Radiais (mm) Obtidos na Estrutura Real								
Nível do Carregamento = 466			Nível do Carregamento = 464			Nível do Carregamento = 460		
Fecho	rim,e,cota 464	rim,e,cota 441	Fecho	rim,e,cota 464	rim,e,cota 441	Fecho	rim,e,cota 464	rim,e,cota 441
20,603	7,273	3,149	16,734	6,049	2,689	10,294	3,909	1,83

Tabela 4.3 - Deslocamentos obtidos através de medições feitas na estrutura.

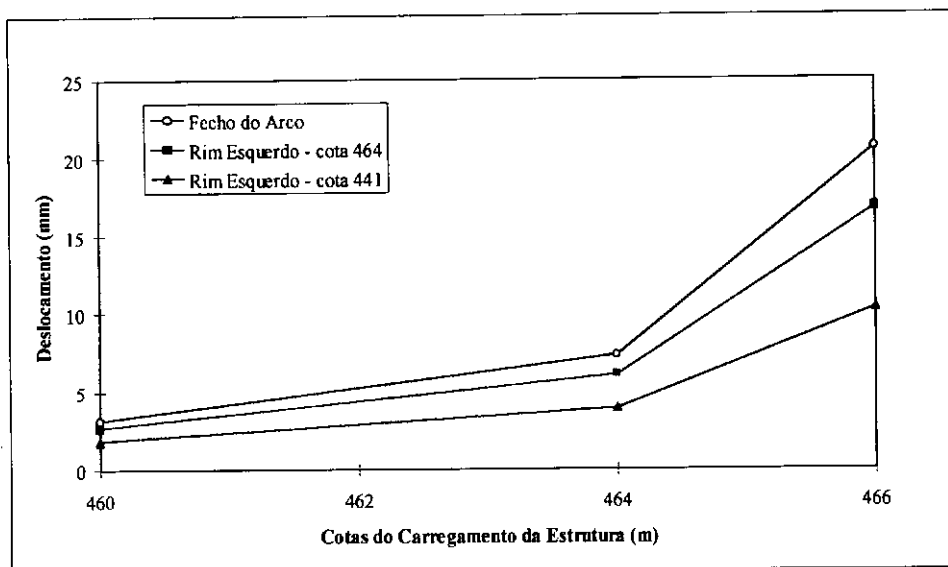


Figura 4.5 - Gráfico com os deslocamentos obtidos através de medições feitas na estrutura

De posse do conjunto de treinamento, fez-se a Rede Neural ajustar seus pesos de tal forma a aprender o padrão desejado. Foi utilizada um RNA *feedforward* com três camadas, algoritmo de aprendizado do tipo *backpropagation*, taxa de aprendizado $\eta = 0.1$ e função de ativação sigmóide.

A camada de entrada era composta de 9 neurônios, uma vez que esse é o número de deslocamentos radiais á disposição nessa análise.

A camada de saída era composta por apenas dois neurônios referentes ao Módulo de Elasticidade do Concreto (E_c) e ao Coeficiente de Poisson (ν_c).

Como estão sendo usadas 8 amostras para a RNA ser treinada, 9 neurônios na camada de entrada e 2 neurônios na camada de saída, a camada oculta terá 8 neurônios, de acordo com a expressão (2.4) do Capítulo 2 que relata o modo como o programa Neuroshell calcula o número de neurônios das camadas ocultas.

Um esquema da RNA utilizada para esse treinamento está na Figura 4.6 .

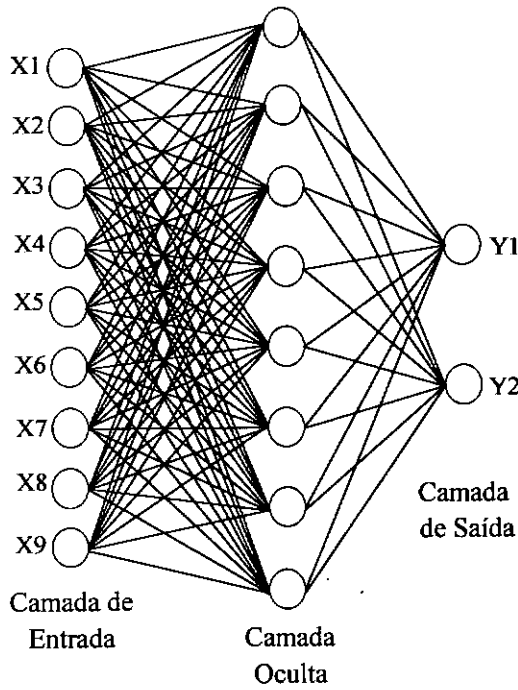


Figura 4.6 - Esquema da Rede Neural.

Os Coeficientes de Correlação fornecidos pelo Neuroshell para esse caso estão na Tabela 4.4 .

E_c	ν_c
0.995	1.000

Tabela 4.4 - Coeficientes de Correlação da RNA que será usada na retroanálise elástica

As Figuras 4.7 e 4.8 apresentam os valores desejados para E_c e ν_c assim como os obtidos com a RNA. Nas Tabelas 4.5 e 4.6 estão os valores e o cálculo do EQM.

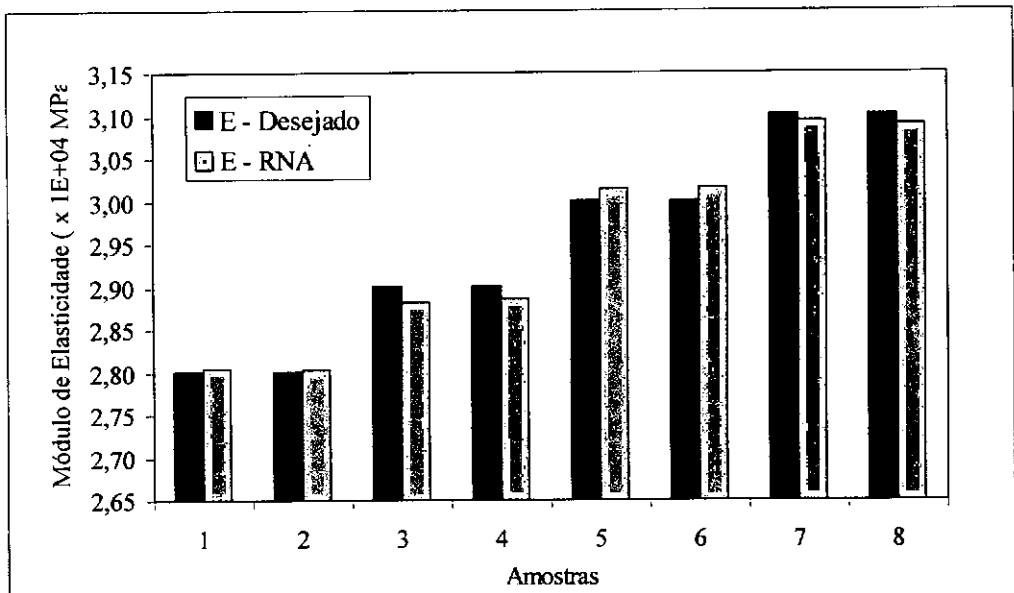


Figura 4.7 - Comparação dos valores desejados para E_c e os obtidos pela RNA.

Amostras	E_c - Desejado	E_c - RNA	$dx = (x1-x2)$	dx^2
1	2,80	2,805	-0,00485	0,00002
2	2,80	2,803	-0,00277	0,00001
3	2,90	2,883	0,01724	0,00030
4	2,90	2,887	0,01336	0,00018
5	3,00	3,015	-0,01475	0,00022
6	3,00	3,016	-0,01590	0,00025
7	3,10	3,094	0,00574	0,00003
8	3,10	3,090	0,00978	0,00010
Somatório				
0,00111				
EQM				
0,00014				

Tabela 4.5 - Comparação dos E_c usados no treinamento e os obtidos com a RNA.




Figura 4.8 - Comparação dos valores desejados para v_c e os obtidos pela RNA.

Amostras	v_c - Desejado	v_c - RNA	$dx = (x1-x2)$	dx^2
1	0,23	0,230	-4,620E-05	2,134E-09
2	0,26	0,260	3,161E-04	9,992E-08
3	0,23	0,230	0,000E+00	0,000E+00
4	0,26	0,260	0,000E+00	0,000E+00
5	0,23	0,230	0,000E+00	0,000E+00
6	0,26	0,260	0,000E+00	0,000E+00
7	0,23	0,230	0,000E+00	0,000E+00
8	0,26	0,260	2,381E-04	5,669E-08
Somatório				
1,587E-07				
EQM				
1,984E-08				

Tabela 4.6 - Comparação dos v_c usados no treinamento e os obtidos com a RNA.

Fornecidos os deslocamentos radiais (Tabela 4.3) obteve-se através de RNA os valores dos parâmetros elásticos, que são dados por:

$$\{E_c = 2.945 \cdot 10^4 \text{ MPa}, \nu_c = 0.260\} \quad (4.4)$$

Conhecendo-se os valores para E_c e ν_c , realiza-se uma Análise Direta usando-se um programa para cálculo dos deslocamentos da estrutura no caso baseado no MEF. Verifica-se, então, se estes deslocamentos estão corretos. Esse procedimento está representado na Tabela 4.7. A Figura 4.9 mostra os gráficos dos deslocamentos obtidos experimentalmente e pelo MEF.

Constantes Elásticas (OUTPUT da RNA)		Deslocamentos Radiais (mm) - Leituras Experimentais (INPUT)								
		Nível 466			Nível 464			Nível 460		
E_c (*1e4MPa)	ν_c	fecho	rim,e,cota 464	rim,e,cota 441	fecho	rim,e,cota 464	rim,e,cota 441	fecho	rim,e,cota 464	rim,e,cota 441
2,945	0,260	20,603	7,273	3,149	16,734	6,049	2,689	10,294	3,909	1,830

Constantes Elásticas (INPUT)		Deslocamentos Radiais (mm) - Obtidos pelo MEF (OUTPUT)								
		Nível 466			Nível 464			Nível 460		
E_c (*1e4MPa)	ν_c	fecho	rim,e,cota 464	rim,e,cota 441	fecho	rim,e,cota 464	rim,e,cota 441	fecho	rim,e,cota 464	rim,e,cota 441
2,945	0,260	20,638	7,192	3,582	15,615	6,039	3,081	9,777	3,693	2,008

Erro	-0,035	0,081	-0,433	1,119	0,010	-0,392	0,517	0,216	-0,178
------	--------	-------	--------	-------	-------	--------	-------	-------	--------

Tabela 4.7 – Resultados da análise com rede neural

Pontos de Leitura	Dados Numéricos	Dados Experimentais	$dx=(x1-x2)$	dx^2
1	20,638	20,603	0,035	0,00123
2	15,615	16,734	-1,119	1,25216
3	9,777	10,294	-0,517	0,26729
4	7,192	7,273	-0,081	0,00656
5	6,039	6,049	-0,010	0,00010
6	3,693	3,909	-0,216	0,04666
7	3,582	3,149	0,433	0,18749
8	3,081	2,689	0,392	0,15366
9	2,008	1,830	0,178	0,03168
				Somatório
				1,94683
				EQM
				0,21631

Tabela 4.8 - Dados experimentais e os dados numéricos obtidos via MEF.

Os pontos de leitura citados na Tabela 4.8 e Figura 4.9 seguem a seguinte ordem: 1 a 3 são do fecho do arco; 4 a 6 são do rim esquerdo da cota 464; 7 a 9 são do rim esquerdo da cota 441.

Para cada trio desses, o primeiro é referente ao nível de carregamento 466, o segundo ao nível 464 e o terceiro ao 460.




Figura 4.9 - Valores de deslocamentos (mm) experimentais e obtidos com o MEF.

4.4) Método dos Elementos Finitos

O programa de análise de barragens utilizado nesta tese, cuja descrição detalhada pode ser vista na referência [VIANA, 98] se baseia numa implementação do método dos elementos finitos voltada para supercomputadores paralelo/vetoriais com arquitetura de memória compartilhada, como o CRAY J90 disponível no Núcleo de Atendimento em Computação de Alto Desempenho da COPPE/UFRJ.

Apesar de a análise apresentada no presente capítulo não demandar um esforço computacional considerável, a idéia é de estendermos o presente estudo para a identificação de parâmetros viscoelásticos para que possam ser levados em conta os fenômenos correspondentes às deformações do concreto no tempo (fluência, etc.) que serão abordados no capítulo seguinte.

Com este programa é possível a realização de análises elásticas lineares e viscoelásticas com envelhecimento, através do emprego da cadeia generalizada de Maxwell. Ele dispõe de elementos hexaédricos trilineares, onde, no caso de análises viscoelásticas, os resíduos em cada passo de tempo são avaliados em apenas um ponto de integração de Gauss. Para que seja evitada a formação de modos de energia de deformação nula, emprega-se uma técnica de correção dos modos espúrios. Desta forma, o esforço computacional para se avaliar estes resíduos, em alguns casos, reduz-se à metade quando comparados ao métodos tradicionais [VIANA, 98].

Além disso, em cada passo de tempo, ou para cada caso de carregamento, o sistema de equações lineares resultante é solucionado pelo método dos gradientes conjugados pré-condicionado. Emprega-se uma técnica de implementação elemento-por-elemento onde apenas os termos não nulos da parte superior da matriz de rigidez dos elementos é armazenada. A matriz de pré-condicionamento é avaliada através dos blocos-diagonais nodais, representando o acoplamento dos graus de liberdade em cada nó da malha.

A Figura 4.10 apresenta a malha de elementos finitos utilizados para obter os deslocamentos na estrutura quando esta é submetida ao carregamento hidrostático.




Figura 4.10 - Malha de Elementos Finitos da UHE de Funil utilizada na análise

A Figura 4.11 mostra os valores, em metros, dos deslocamentos obtidos na análise elástica através do MEF quando a estrutura está submetida ao carregamento hidrostático referente a cota 450 m .




Figura 4.11 - Deslocamentos obtidos, via MEF, com o nível da água na cota 450 m.

O programa resultante é completamente vetorizado e paralelizado, através da utilização de algoritmos de coloração de malhas. Testes de desempenho para a solução de um problema viscoelástico com aproximadamente 211.000 graus de liberdade indicam o alto grau de eficiência computacional alcançada por esta implementação [VIANA, 98]. A versão otimizada atinge 72 Mflop/s em uma CPU do CRAY J90. O tempo de execução paralela desta análise viscoelástica é de aproximadamente 5 minutos, com speed-up de 3.5 em uma máquina com 4 CPUs .

4.5) Modelo Híbrido

A identificação neural dos parâmetros elásticos da barragem de Funil possibilita a montagem de um modelo híbrido cuja componente devida à ação hidrostática é calculada pelo MEF. Na Figura 4.12 mostra-se uma aplicação do modelo híbrido no controle do deslocamento radial horizontal do fecho do arco da cota 464 da barragem de Funil. Um modelo deste tipo desempenha um papel fundamental na automação do monitoramento de barragens [FAIRBAIRN et al, 99b].




Figura 4.12 – Modelo Híbrido

CAPÍTULO 5

APLICAÇÃO: RETROANÁLISE PARA A IDENTIFICAÇÃO DOS PARÂMETROS VISCOELÁSTICOS DA BARRAGEM CASCA DE FUNIL.

5.1) Introdução

O Modelo de Cadeia de Maxwell (MCM) tem sido usado desde 1974 [BAZANT, 74] para simular o comportamento da fluência do concreto, considerado como um material viscoelástico com envelhecimento. Ver [BAZANT, 93].

Esse modelo tem sido também implementado em vários programas comerciais, como o DIANA e o CESAR-LCPC. O Modelo de Maxwell é baseado na aproximação da função de relaxação do concreto através de uma série finita de Dirichlet do tipo

$$R(t, t') = \sum_{\mu=1}^{n-1} E_{\mu}(t') \cdot \exp\left(-\frac{t-t'}{\tau_{\mu}}\right) + E_n(t') \cdot \exp\left(-\frac{t-t'}{\infty}\right) \quad (5.1)$$

onde:

$R(t, t')$ - função de relaxação no tempo t para um concreto carregado na idade t' ;

n - número de termos da série;

$E_{\mu}(t')$ - coeficiente elástico na idade t' ;

τ_{μ} - constantes chamadas de tempo de relaxação, geralmente impostas pelo usuário;

Na equação (5.1), o termo n da série finita apresenta $\tau_n = \infty$ para que a função de relaxação tenda para o valor $E_n(t')$ quando $t \rightarrow \infty$, apresentando um patamar inferior, como é o caso do concreto.

O Modelo da Cadeia de Maxwell representado pela equação (5.1) está esquematizado na Figura 5.1 .

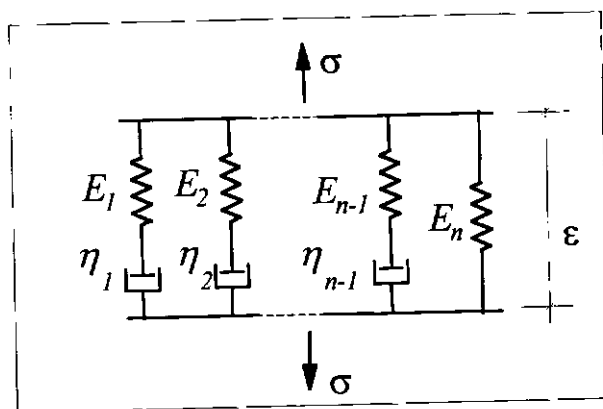


Figura 5.1 - Representação do Modelo de Cadeias de Maxwell.

O MCM é um modelo material onde parâmetros, principalmente os módulos E_μ , podem ser determinados pelo ajuste de funções de relaxação ou de fluência, dadas pelas normas, empregando-se curvas experimentais obtidas em ensaios de relaxação ou de fluência em corpos de prova em laboratório.

Sendo assim, se valores discretos da função $R(t, t')$ são conhecidos, é possível encontrar os módulos $E_\mu(t')$ que a representem utilizando, por exemplo, o método dos mínimos quadrados.

O MCM tem obtido boas aproximações para concretos usados em várias barragens de grande porte utilizando um reduzido número de termos da série, com n variando de 5 até 10 [BAZANT, 74] [FAIRBAIRN et al, 94].

No presente trabalho, valores experimentais de deslocamento no tempo foram obtidos em uma estrutura real e com carregamento e condições de contorno muito mais complexas que os corpos de prova de laboratório submetidos a tensões ou deformações constantes. A estrutura é a UHE de Funil, uma barragem do tipo casca com dupla curvatura possuindo uma capacidade de 216 MW, situada no Rio Paraíba do Sul no Município de Itatiaia, Estado do Rio de Janeiro. Essa mesma estrutura foi objeto de estudo no Capítulo 4, onde realizou-se a identificação dos parâmetros elásticos (E_c, ν_c) do concreto.

A barragem possui uma altura de 85m e o comprimento do arco de coroamento é de 360m.

Os deslocamentos radiais de alguns pontos da estrutura, a temperatura ambiental e o nível do reservatório foram medidos durante 26 anos. O problema é, então, encontrar os coeficientes E_μ do MCM referente ao concreto da estrutura de tal forma que estes sejam capazes de representar as componentes viscoelásticas do deslocamentos lidos durante esse período.

De posse dos parâmetros que definem o modelo do comportamento viscoelástico do material para o comportamento de fluência e relaxação, é possível estabelecer um procedimento computacional que permita comparar os deslocamentos medidos com os obtidos através do código computacional. A diferença entre esses valores de deslocamento maior que um determinado erro, indica que algum comportamento anormal (por exemplo reação álcali-agregado) está ocorrendo na estrutura. Isso permite a utilização de um procedimento para monitoramento da durabilidade da barragem.

5.2) Dados Experimentais e seus Componentes

A análise da barragem de Funil considera que o deslocamento u tem três componentes como mostra a equação (5.2).

$$u = u_e + u_T + u_V \quad (5.2)$$

onde:

u_e - componente elástica de origem hidrostática

u_T - componente elástica de origem térmica

u_V - componente viscoelástica

Estes três componentes foram separadas segundo o modelo estatístico de Gauss-Marcoff homocedástico, tendo sido obtidas com as seguintes equações para os componentes do deslocamento radial do fecho do arco da barragem [GUEDES, 98]:

$$u_e = C_1 \cdot (69,646 - 119,108H + 72,407H^3) \quad (5.3a)$$

$$u_T = C_1 \left[0,879 \cdot \text{sen} \left(\frac{2\pi t}{365} \cdot C_2 \right) + 5,877 \cdot \text{cos} \left(\frac{2\pi t}{365} \cdot C_2 \right) \right] \quad (5.3b)$$

$$u_V = C_1 \left[21,256 \left(1 - \exp \left(-0,0003 \left(\frac{t}{C_2} \right) \right) \right) \right] \quad (5.3c)$$

onde,

$$H = \frac{\left[\frac{NR}{C_3} - 382,5 \right]}{81,5}$$

sendo

NR - o nível do reservatório

t - tempo a partir de 10 de agosto de 1971

C_1 - 1mm

C_2 - 1 dia

C_3 - 1m

Na Figura 5.2, os valores dos deslocamentos radiais medidos no fecho do arco de coroamento estão plotados juntamente com os valores obtidos pelas equações (5.2) e (5.3). O período da análise vai do dia 10 de agosto de 1971 até o dia 26 de janeiro de 1998.




Figura 5.2 - Valores de deslocamentos: modelado e observado.

5.3) Método dos Elementos Finitos

O código computacional para análises viscoelásticas foi executado num computador CRAY J90. O código usa elementos hexaédricos trilineares com um ponto de integração de Gauss. Em cada passo de carregamento, o sistema de equações lineares resultante é solucionado pelo método dos gradientes conjugados pré-condicionado [VIANA, 98].

O alto desempenho de computadores vetoriais como o CRAY J90 reside na capacidade de execução de somas ou multiplicações simultaneamente. Ao realizar a otimização de um código computacional, deve ser considerada a obtenção de maiores taxas de vetorização que depende do número de acessos à memória, da alocação dos dados e do uso de vetores com tamanho adequado ao número de registradores vetoriais. Quanto ao processo de paralelização, o fundamento está em proporcionar tarefas que possam ser executadas simultaneamente em diferentes processadores.




Figura 5.3 - Malha de Elementos Finitos da UHE de Funil utilizada na análise.

5.4) Retroanálise Neural Viscoelástica

Como citado anteriormente, as RNA exigem um conjunto de treinamento composto por várias amostras, onde cada uma dessas é composta por valores de entrada e saída. Para o treinamento, no caso da retroanálise neural viscoelástica, utiliza-se curvas da componente viscoelástica do deslocamento radial do fecho do arco de coroamento em relação ao tempo (entrada) obtidas pelo MEF e seus correspondentes parâmetros E_μ (saída) da cadeia de Maxwell.

Então um conjunto de cadeias de Maxwell é gerado, considerando a variação dos valores de E_μ e fixando os valores de n e de τ_μ , de tal forma a obterem-se suas correspondentes curvas de deslocamento no tempo com auxílio do código computacional em 3D baseado no MEF. Essa etapa é considerada como sendo a Análise Direta.

Na fase da Análise Direta, a estrutura é composta por dois materiais: barragem de concreto viscoelástico e fundação de rocha com comportamento elástico.

No Capítulo 4, (Ver também [FAIRBAIRN et al, 99b]), determinaram-se para essa mesma UHE de Funil os valores do coeficiente de Poisson e o módulo de elasticidade tanto para o concreto como para a rocha. Esses valores estão explicitados na Tabela 4.5 no capítulo anterior.

Na análise viscoelástica considerou-se que o carregamento da barragem era correspondente a uma função degrau para a qual a pressão é relacionada ao nível 460m do reservatório. Foi considerado, também, que esta carga foi aplicada a partir do dia 10 de agosto de 1971, quando o reservatório já estava cheio. Por essa razão, já que o concreto tinha mais de um ano de idade de carregamento, não é considerado como um material com envelhecimento, isto é, os $E_{\mu}(t')$ são constantes em t' .

Através da equação (5.1) é possível verificar que o módulo de elasticidade $E(t') = R(t, t')$ é igual ao somatório dos $E_{\mu}(t')$. Portanto este somatório em cada cadeia que fará parte do conjunto de treinamento da rede neural deverá ser igual ao Módulo de elasticidade obtido na retroanálise do Capítulo 4, $E_c = 2,945.10^4$ MPa.

Apenas para simplificar a escolha dos trios de E_{μ} , considerou-se que:

$$\sum_{\mu=1}^n E_{\mu}(t') = 2,940.10^4 \text{ MPa}$$

Para a geração das cadeias de Maxwell variaram-se os valores de E_{μ} e fixaram-se os valores de n e de τ_{μ} baseando-se em experiência já obtida em trabalhos anteriores [FAIRBAIRN, 94]:

$$n = 3; \quad \tau_1 = 10^2; \quad \tau_2 = 10^3; \quad \tau_3 = 10^{31}$$

Os valores de E_{μ} que foram usados para a geração do conjunto de treinamento estão na Tabela 5.1 .

		AMOSTRAS									
		Cadeia 1	Cadeia 2	Cadeia 3	Cadeia 4	Cadeia 5	Cadeia 6	Cadeia 7	Cadeia 8	Cadeia 9	Cadeia 10
E1		0,5	0,43	0,4	0,4	0,4	0,39	0,38	0,4	0,37	0,35
E2		1,94	1,97	1,97	1,87	1,92	1,97	1,97	1,95	1,98	1,98
E3		0,5	0,54	0,57	0,67	0,62	0,58	0,59	0,59	0,59	0,61

Tabela 5.1 - Valores de E_{μ} usados no conjunto de treinamento.

Para o treinamento utilizou-se uma RNA *feedforward* com três camadas, algoritmo de aprendizado do tipo *backpropagation*, taxa de aprendizado $\eta = 0.1$ e função de ativação sigmóide.

A camada de entrada teve 16 neurônios correspondentes a valores discretos da curva de deslocamentos no tempo.

A camada de saída terá três neurônios referentes aos três valores de E_μ .

Como estão sendo usadas 10 amostras para a RNA ser treinada, 16 neurônios na camada de entrada e 3 neurônios na camada de saída, a camada oculta terá 12 neurônios, de acordo com a expressão (2.4) do Capítulo 2.

Um esquema da RNA utilizada para esse treinamento está na Figura 5.4.




Figura 5.4 - Esquema da Rede Neural.

Os Coeficientes de Correlação fornecidos pelo Neuroshell para analisarmos o treinamento da Rede Neural estão na Tabela 5.2.

E_1	E_2	E_3
0.996	0.994	0.994

Tabela 5.2 - Coeficientes de Correlação da RNA usada na retroanálise viscoelástica

As Figuras 5.5, 5.6 e 5.7 apresentam os valores desejados para E_1 , E_2 e E_3 , assim como os obtidos com a RNA. Nas Tabelas 5.3, 5.4 e 5.5 estão os valores e o cálculo do EQM.




Figura 5.5 - Comparação dos valores desejados para E_1 e os obtidos pela RNA.

Amostras	E1 - Desejado	E1 - RNA	$dx = (x1-x2)$	dx^2
1	0,5	0,49799	0,00201	4,041E-06
2	0,43	0,43651	-0,00651	4,235E-05
3	0,4	0,39816	0,00184	3,387E-06
4	0,4	0,40109	-0,00109	1,196E-06
5	0,4	0,40233	-0,00233	5,450E-06
6	0,39	0,38687	0,00313	9,769E-06
7	0,38	0,37702	0,00298	8,862E-06
8	0,35	0,35647	-0,00647	4,187E-05
9	0,4	0,39899	0,00101	1,014E-06
10	0,37	0,36898	0,00102	1,033E-06
Somatório				
1,190E-04				
EQM				
1,190E-05				

Tabela 5.3 - Comparação dos E_1 usados no treinamento e os obtidos com a RNA.




Figura 5.6 - Comparação dos valores desejados para E_2 e os obtidos pela RNA.

Amostras	E2 - Desejado	E2 - RNA	$dx = (x1-x2)$	dx^2
1	1,94	1,93803	0,00197	3,893E-06
2	1,97	1,97037	-0,00037	1,391E-07
3	1,97	1,97241	-0,00240	5,784E-06
4	1,87	1,87163	-0,00163	2,660E-06
5	1,92	1,90995	0,01005	1,010E-04
6	1,97	1,97317	-0,00317	1,006E-05
7	1,97	1,97395	-0,00395	1,559E-05
8	1,98	1,98000	0,00000	0,000E+00
9	1,95	1,95408	-0,00408	1,663E-05
10	1,98	1,97950	0,00050	2,490E-07
Somatório				
				1,560E-04
EQM				
				1,560E-05

Tabela 5.4 - Comparação dos E₂ usados no treinamento e os obtidos com a RNA.




Figura 5.7 - Comparação dos valores desejados para E₃ e os obtidos pela RNA.

Amostras	E3 - Desejado	E3 - RNA	$dx = (x1-x2)$	dx^2
1	0,5	0,50495	-0,00495	2,446E-05
2	0,54	0,53399	0,00601	3,609E-05
3	0,57	0,56647	0,00353	1,248E-05
4	0,67	0,66595	0,00405	1,641E-05
5	0,62	0,63147	-0,01147	1,315E-04
6	0,58	0,57797	0,00203	4,110E-06
7	0,59	0,58916	0,00084	7,139E-07
8	0,61	0,60756	0,00244	5,941E-06
9	0,59	0,59236	-0,00236	5,593E-06
10	0,59	0,58830	0,00170	2,885E-06
Somatório				
				2,401E-04
EQM				
				2,401E-05

Tabela 5.5 - Comparação dos E₃ usados no treinamento e os obtidos com a RNA.

Assim que a rede concluiu seu aprendizado, foi possível realizar a retroanálise neural viscoelástica. Como conjunto de entrada foram usados os valores da curva experimental u_v obtida através da equação (5.3c). A saída gerada pela rede está na Tabela 5.6 .

E_1 (10^4 MPa)	E_2 (10^4 MPa)	E_3 (10^4 MPa)	$\sum E_\mu$ (10^4 MPa)
0.350	1.980	0.620	2.950

Tabela 5.6 - Resultados da retroanálise neural viscoelástica.

Os valores da Tabela 5.6 serão usados, então, para a execução do programa de elementos finitos. A curva resultante da cadeia será comparada com a experimental obtida através da expressão (5.3c) e ambas estão representadas na Figura 5.8. A Tabela 5.8 mostra os valores das curvas numéricas e experimentais e o Erro Quadrático Médio.

Tempo	Deslocamentos (mm)		(x1-x2)	d ²
	Experimental	Modelo Neural		
0,01	20,00	19,41	0,59	0,3431
91,25	20,57	20,62	-0,05	0,0022
182,5	21,13	21,47	-0,34	0,1145
365	22,20	22,78	-0,58	0,3310
730	24,18	24,92	-0,74	0,5453
1095	25,95	26,73	-0,78	0,6110
1825	28,96	29,71	-0,75	0,5619
2555	31,38	31,96	-0,58	0,3346
3285	33,32	33,66	-0,33	0,1120
4015	34,88	34,95	-0,07	0,0043
4745	36,14	35,94	0,20	0,0400
5475	37,14	36,70	0,45	0,1994
6205	37,95	37,29	0,67	0,4438
6935	38,60	37,75	0,86	0,7331
7665	39,12	38,11	1,02	1,0342
8395	39,54	38,39	1,15	1,3239
9125	39,88	38,62	1,26	1,5878
				Somat.
				8,3221
				EQM
				0,4895

Tabela 5.8 - Comparação entre os valores experimentais com os valores numéricos com a utilização do modelo neural.




Figura 5.8 - Comparação entre os resultados numéricos utilizando a cadeia formada pelo modelo neural e a curva experimental u_v .

CAPÍTULO 6

CONCLUSÕES

6.1) Considerações Finais

A presente tese realizou análises inversas com o emprego de Redes Neurais para a obtenção de parâmetros correspondentes aos seguintes modelos de estruturas de concreto:

- modelo probabilístico de fissuração
- modelo elástico-linear
- modelo viscoelástico-linear da cadeia de Maxwell generalizada

Os modelos citados acima têm diferentes graus de sofisticação e consideram o material sob diferentes pontos de vista, quais sejam: determinístico, probabilístico, elástico, inelástico, instantâneo, diferido, etc. Além disso, foi analisado um caso real de engenharia relativo à Usina Hidrelétrica de Funil.

Para todos os casos a retroanálise realizada com Redes Neurais apresentou resultados precisos para redes de arquitetura bastante simples. Além deste fato devemos chamar a atenção para a operacionalidade e simplicidade da metodologia proposta tendo em vista que não demanda um grande esforço computacional para a sua realização.

Desta forma ficou demonstrado que as técnicas de Análise Inversa associadas ao emprego de Redes Neurais podem ser uma ferramenta útil para a identificação de parâmetros característicos de estruturas de concreto.

Referências Bibliográficas

- [BAZANT, 74] BAZANT,Z.P., WU, S.T., “Rate type creep law of aging concrete based on Maxwell chain”, *Material and Structures*, v.7, n. 37, pp. 45-60, 1974.
- [BAZANT, 93] BAZANT,Z.P., CAROL, I., *Creep and Shrinkage of concrete* 1ed., E&FN Spon, 1993.
- [BENITEZ, 97] BENITEZ, J.M., CASTRO, J.L., “Are artificial neural networks black boxes?”, *IEEE Transactions on Neural Networks*, v. 8 n.5, pp. 1156-1164, 1997.
- [CBGB, 89] CBGB, ELETROBRAS, IBRACON, “Concreto Massa no Brasil: Memória Técnica”, Rio de Janeiro, 1989.
- [DÉSIR, 99] DÉSIR, J.M.D., MOHAMED, B.R., ULM, F.-J., FAIRBAIRN, E.M.R., “Steel-Concrete Interface: Revisiting constitutive and numerical modeling”, *Computers and Structures*, a ser publicado, 1999.
- [FAIRBAIRN, 94] FAIRBAIRN, E.M.R., “L’expérience brésilienne dans l’utilisation du modèle rheologique de Maxwell pour la résolution du problem thermo-mecanique des barrages en béton”, *Annales de l’ITBTP* n. 520, Série: Théories et Méthodes de Calcul 343, pp. 150-179, Paris, 1994.
- [FAIRBAIRN, 97] FAIRBAIRN, E.M.R., PAZ, C.N.M., ALVES, J.L.D., SILVA, R.C.C., “Evaluation of constitutive relations for numerical of concrete cracking”, XVIII CILAMCE, Brasília-DF, Vol. 2, pp. 709-715, 1997.

- [FAIRBAIRN,98] FAIRBAIRN, E.M.R., EBECKEN, N.F.F., GOULART, E., PAZ, C.N.M., “Probabilistic modeling of concrete cracking: using neural networks to solve the inverse problem”, In: *Advances in Engineering Computational Technology*, , v. 1, pp. 215-219, Edinburgh - Escócia, 1998.
- [FAIRBAIRN,99] FAIRBAIRN, E.M.R., GUEDES, Q.M., ULM, F.-J., “An inverse problem analysis for the determination of probabilistic parameters of concrete behavior modeled by a statistical approach”, *Materials and Structures*, v.32 n.45, pp. 339-345, 1999.
- [FAIRBAIRN,99a] FAIRBAIRN, E.M.R., PAZ, C.N.M., EBECKEN, N.F.F., ULM, F.-J., “Use of neural networks for fitting of FE probabilistic scaling model parameters”, *International Journal of Fracture*, aceito para publicação em 1999.
- [FAIRBAIRN,99b] FAIRBAIRN, E.M.R., GUEDES, Q.M., GOULART, E., et al., “Retronálise neural para a identificação dos parâmetros elásticos da barragem casca de Funil”, In: XXIII Seminário Nacional de Grandes Barragens, Belo Horizonte-MG, 1999.
- [GUEDES, 98] GUEDES, Q. M., “Componentes de Deslocamento na Barragem de Funil”, Publicação Interna - FURNAS, 1998.
- [KLIR, 95] KLIR, J.J., YUAN, B., *Fuzzy sets and fuzzy logic - theory and applications* 2 ed. Binghamton, 1995.
- [LOPEZ, 95] LOPEZ, T.A.P., *Avaliação do Dano de Fadiga em Plataformas de Petróleo em Tempo Real*, Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 1995.

- [NEUROSHEL,93] NEUROSHELL 2 , “User’s Manual” , Ward Systems Group, Inc., 1993.
- [PESSOA, 91] PESSOA, L.A.F.C., *Introdução às Redes Neurais Artificiais*. In: Relatório Técnico Científico: Desenvolvimento da Inteligência Artificial e Engenharia do Conhecimento no Brasil, COPPE, PADCT, Rio de Janeiro, 1991.
- [ROSSI, 87] ROSSI, P., RICHER, S., “Numerical modelling of concrete cracking based on a stochastic approach”, *Materials and Structures*, v. 20, pp. 334-337, 1987.
- [ROSSI, 94] ROSSI, P., WU, X., LE MAOU, F., BELLOC, A. ,”Scale effect on concrete in tension”, *Materials and Structures*, v. 27, pp. 437-444, 1994.
- [ROSSI, 96] ROSSI, P., ULM, F.-J., HACHI, F., “Compressive behavior of concrete: physical mechanisms and modeling”, *Journal of Engineering Mechanics ASCE*, v. 122 n. 11, pp. 1038-1043, 1996.
- [ROSSI, 97] ROSSI, P., ULM, F.-J., “Size effects in the biaxial behavior of concrete: physical mechanisms and modeling”, *Materials and Structures, RILEM*, v. 30, pp. 210-216, 1997.
- [SARAIVA, 97] SARAIVA, J.M.F., *Utilização de Redes Neurais em Conjunto com o Método de Monte Carlo na Análise da Confiabilidade de Estruturas*, Tese de D.Sc., COPPE/UF RJ, Rio de Janeiro, RJ, Brasil, 1997.

- [SCHOFER,95] SCHOFER,J.L., IVAN,J.N., KOPPELMAN,F.S. and
MASSONE, L.L.E., “Real-Time Data Fusion for Arterial
Street Incident Detection Using Neural Network”,
*Transportation Research Record 1497, TRB, National
Research Council*, pp. 27-35, 1995.
- [TAHA, 95] TAHA, M.A. and HANNA, A.S., “Evolutionary Neural
Network Model for the Selection of Pavement Maintenance
Strategy”, *Transportation Research Record 1497, TRB,
National Research Council*, pp. 70-76, 1995.
- [VIANA, 98] VIANA, D.M., *Simulação paralela de problemas
viscoelásticos em estruturas de concreto massa*, Tese de D.Sc.,
COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 1998.