



**UNIVERSIDADE TÉCNICA DE LISBOA
INSTITUTO SUPERIOR TÉCNICO**

**APLICAÇÃO DE REDES NEURONAIS AO CONTROLO
DE SEGURANÇA DE BARRAGENS DE BETÃO**

Juan Tomé Caires da Mata

(Licenciado)

Dissertação elaborada no Laboratório Nacional de Engenharia Civil
para a obtenção do grau de Mestre em Engenharia de Estruturas pela Universidade
Técnica de Lisboa, no âmbito do protocolo de cooperação entre o IST e o LNEC

Orientadora: Doutora Eliane Teixeira Alves Portela

Co-orientador: Mestre Joaquim Luís Ramos Dias

Júri

Presidente: Doutor João Carlos de Oliveira Fernandes de Almeida
Vogais: Engenheiro Domingos Manuel Ribeiro da Silva de Matos
Doutora Eliane Teixeira Alves Portela
Mestre Joaquim Luís Ramos Dias

Julho de 2007

Aos meus Pais

APLICAÇÃO DE REDES NEURONAIS AO CONTROLO DE SEGURANÇA DE BARRAGENS DE BETÃO

Resumo

O objectivo principal do controlo de segurança estrutural de uma barragem de betão consiste na garantia de que a estrutura cumpra satisfatoriamente as funções para que foi construída, mantendo a funcionalidade e a integridade estrutural. Esta actividade é suportada pela observação da obra e apoia-se em modelos de comportamento.

A avaliação das condições de segurança e funcionalidade da estrutura apoia-se na utilização de modelos. Em termos práticos, quando se dispõe de um número significativo de resultados da observação, podem ser definidos modelos que permitem caracterizar o comportamento normal das estruturas sem recorrer explicitamente aos princípios da Mecânica, como por exemplo, os métodos de interpretação quantitativa e/ou, ainda, com os modelos de redes de neurais artificiais, objecto de investigação deste trabalho. Estes modelos são elaborados e calibrados a partir do conhecimento do comportamento da estrutura a solicitações passadas.

A partir da resposta do modelo para uma dada grandeza observada, para as solicitações a que a estrutura está sujeita, é possível avaliar se a evolução de uma grandeza se mantém satisfatória ou se existe alguma alteração no comportamento que justifique um estudo mais aprofundado.

As redes neuronais artificiais vêm sendo objecto de intensa pesquisa e desenvolvimento recente, dada a sua capacidade de tratamento de um grande número de informações e a adaptação a sistemas e processos de natureza diversificada e complexa.

O principal objectivo deste trabalho é investigar as potencialidades da utilização de modelos para interpretação do comportamento de barragens de betão a partir de redes neuronais artificiais do tipo Perceptrão Multicamada, nomeadamente para a análise de algumas grandezas que são observadas com carácter sistemático nas barragens portuguesas.

Seleccionou-se para caso de estudo a barragem do Alto Rabagão. Algumas das grandezas mais representativas do comportamento da obra foram analisadas com recurso aos modelos de redes neuronais. Os resultados obtidos foram comparados directamente com os resultados dos modelos de interpretação quantitativa, avaliando-se o seu desempenho relativamente aos valores observados.

APPLICATION OF NEURAL NETWORKS TO THE SAFETY CONTROL OF CONCRETE DAMS

Abstract

The main purpose of the structural safety control of a concrete dam is to assure the ability of the dam to perform the function for which it was built. This activity is based in the observation of dams and is supported by behaviour models.

The evaluation of the structural safety and serviceability is supported by the use of models. In practice, whenever a large amount of monitoring data is available, it is possible to use models which are able to characterize the structural normal behaviour but that are not explicitly based on Mechanical principles, such as statistical models of quantitative analysis and/or artificial neural networks. These models are developed and calibrated from the knowledge of the structural response to previous loads.

From the comparison of the model response with the observed behaviour, it is possible to evaluate if that behaviour is developing satisfactorily or if it exists any trend in the behaviour that justifies specific studies.

Artificial neural networks have been object of intense research and recent development, due to there ability to deal with a large amount of information and to adjust to systems and processes with diversified and complex nature.

The main purpose of this research is to study the possibility of using artificial Multilayer Perceptron neural networks to interpret the behaviour of concrete dams, namely to analyse some parameters that have been systematically observed in Portuguese dams.

Alto Rabagão dam is presented as a case study. The most representative quantities of the structural behaviour were analyzed using artificial neural network models. The results of these models were compared with the results of statistical models of quantitative analysis and the performance of both models was evaluated.

APLICAÇÃO DE REDES NEURONAIS AO CONTROLO DE SEGURANÇA DE BARRAGENS DE BETÃO

Palavras chave

Barragem de betão

Controlo de segurança

Observação de barragens

Redes neuronais artificiais

Perceptrão Multicamada

APPLICATION OF NEURAL NETWORKS TO THE SAFETY CONTROL OF CONCRETE DAMS

Key words

Concrete dam

Safety control

Dam monitoring

Artificial neural network

Multilayer Perceptron

Agradecimentos

A realização deste trabalho só foi possível com os meios disponibilizados pela Direcção do Laboratório Nacional de Engenharia Civil, pelo Director do Departamento de Barragens de Betão (DBB), Eng.º Carlos Alberto de Brito Pina, que também deu um grande incentivo à escolha do tema, e pelo Chefe do Núcleo de Observação, Eng.º António Lopes Batista, que proporcionou excelentes condições para a minha formação no âmbito da engenharia de barragens e efectuou uma revisão do texto.

O meu agradecimento especial vai para os meus orientadores, que sem a sua ajuda o presente trabalho não teria cumprido os objectivos propostos. À Eng.ª Eliane Portela, pela organização, conhecimento, rigor, ambição e incentivo que a sua orientação incutiu, sendo a principal responsável para que os resultados finais fossem da melhor qualidade. Ao Eng.º Joaquim Dias, pela sua motivação, empenho, disponibilidade, rapidez e espírito crítico na apresentação de sugestões através de interessantes trocas de opiniões.

O contributo de outras pessoas foi também significativo, pelo que desejo manifestar o meu reconhecimento e agradecimento:

- ao Eng.º António Tavares de Castro, pela disponibilidade, interesse e motivação, resultando sempre em frutuosas trocas de impressões e na transmissão de muito do conhecimento adquirido;
- ao Eng.º Jorge Pereira Gomes, pelas constantes trocas de ideias, clarificação de conceitos e apoio na resolução de problemas informáticos;
- aos Técnicos João Amante e Manuel Andrade, por me terem “apadrinhado” e pelos ensinamentos ministrados durante as inspecções a diversas barragens de betão;
- aos Profs. Luís Borges de Almeida e Fernando Silva, por terem permitido a frequência das aulas da disciplina de Redes Neurais e Aprendizagem Automática do curso de Electrotecnia e Computadores do IST;
- aos colegas do DBB, em particular às Eng.ªs Luísa Braga Farinha e Ana Fonseca, aos Eng.ºs José Mora Ramos, José Piteira Gomes, José Vieira de Lemos, Sérgio Oliveira, Ricardo Resende e Ivo Dias, aos Técnicos Fernando Garcia Martins, António Tavares, Pedro Pavia Moreira, Hélder Vitória, Jorge Gião Santos e

Carlos Resende, e ao pessoal administrativo, pelo apoio prestado sempre que solicitado.

Os apoios e contributos referidos foram orientados pelo rigor técnico e científico, mas assentaram também num espírito de amizade, tornando o trabalho mais aliciante e agradável.

Aos meus tios, primas e amigos, da Madeira, IST, LNEC, Salsa, entre outros, pela qualidade de vida que a sua companhia me proporcionou, à minha tia Lurdes, por ter cuidado de mim com muito carinho, e à Ana, pelo seu incentivo ao meu desenvolvimento pessoal e profissional.

Por último, e mais importante, aos meus Pais, por me darem tudo o que têm, principalmente pelo amor e carinho sempre transmitidos. Esta tese é também fruto do vosso trabalho. Obrigado.

Índice do Texto

1. INTRODUÇÃO	1
1.1. Enquadramento geral	1
1.2. Justificação do tema e objectivos do trabalho	2
1.3. Estrutura da dissertação	3
2. CONTROLO DE SEGURANÇA DE BARRAGENS DE BETÃO	5
2.1. Introdução.....	5
2.2. Tipos de barragens de betão	6
2.3. Controlo de segurança.....	7
2.4. Observação do comportamento estrutural	9
2.5. Observação e interpretação do comportamento de barragens.....	11
2.6. Observação das principais acções.....	14
2.6.1. Peso próprio	14
2.6.2. Água	14
2.6.3. Temperatura	16
2.6.4. Acções dinâmicas.....	18
2.7. Propriedades dos materiais	18
2.7.1. Caracterização da fundação	18
2.7.2. Caracterização do betão.....	19
2.8. Observação da resposta estrutural	20
2.8.1. Deslocamentos	20
2.8.2. Movimentos de juntas e fissuras.....	22
2.8.3. Rotações	23
2.8.4. Tensões e extensões.....	24
2.8.5. Caudais	24
2.9. Erros na medição de grandezas	25
2.10. Frequência das leituras e validação dos resultados	27
2.11. Modelos e métodos de análise	27
2.12. Métodos de interpretação quantitativa	31
2.12.1. Introdução.....	31
2.12.2. Modelos de interpretação quantitativa utilizados no controlo de segurança de barragens	34
2.12.3. Efeito do nível da água na albufeira.....	35

2.12.4. Efeito da temperatura	35
2.12.5. Efeito do tempo	36
2.12.6. Constante k	37
2.12.7. Estimativa dos parâmetros: Regressão múltipla pelo método dos mínimos quadrados	37
2.12.8. Campos de aplicabilidade.....	39
2.12.9. Análise dos resultados	39
3. FUNDAMENTOS DAS REDES NEURONAIIS ARTIFICIAIS.....	41
3.1. Introdução	41
3.2. Breve caracterização biológica	43
3.3. Modelo básico do neurónio artificial.....	45
3.4. Perspectiva histórica das redes neuronais artificiais	46
3.4.1. Modelo de McCulloch e Pitts	46
3.4.2. Sínapse de Hebb.....	47
3.4.3. Perceptrão de Rosenblatt	49
3.4.4. ADALINE	51
3.4.5. MADALINE	55
3.4.6. Desmotivação científica.....	55
3.4.7. Renascimento	56
3.5. Redes Perceptrão Multicamada.....	56
3.5.1. Arquitectura	56
3.5.2. Nomenclatura adoptada	58
3.6. Aprendizagem	60
3.6.1. Generalização	61
3.6.2. Função de custo.....	62
3.6.3. Regra de aprendizagem – retropropagação do erro	63
3.6.4. Critérios de paragem do treino	67
3.6.5. Técnicas de aceleração – Termo de momento	68
3.6.6. Pré-processamento dos dados.....	69
3.7. Escolha do programa de redes neuronais	71
4. APLICAÇÃO AOS RESULTADOS DA OBSERVAÇÃO DA BARRAGEM DO ALTO RABAGÃO.....	73
4.1. Introdução	73
4.2. Estado actual da aplicação de redes neuronais no controlo de segurança de barragens de betão	74

4.3.	Caracterização da barragem do Alto Rabagão	77
4.4.	Definição e exploração do sistema de observação	79
4.5.	Grandezas analisadas	83
4.6.	Aspectos gerais dos modelos Perceptrão Multicamada aplicados à barragem do Alto Rabagão.....	85
4.6.1.	Metodologia utilizada na aprendizagem.....	85
4.6.2.	Normalização das entradas e saídas.....	86
4.6.3.	Avaliação do desempenho das RNs.....	87
4.7.	Modelos Perceptrão Multicamada das acções.....	89
4.7.1.	Temperatura.....	89
4.7.2.	Pressão hidrostática.....	94
4.7.3.	Subpressões.....	95
4.8.	Modelos Perceptrão Multicamada da resposta da estrutura.....	98
4.8.1.	Deslocamentos horizontais.....	98
4.8.2.	Deslocamento na fundação da barragem.....	107
4.8.3.	Movimentos de abertura e fecho de juntas.....	110
4.8.4.	Caudais drenados e infiltrados.....	113
4.9.	Comparação entre modelos de redes neuronais e de interpretação quantitativa.....	119
4.9.1.	Subpressões.....	119
4.9.2.	Deslocamentos horizontais.....	120
4.9.3.	Deslocamento na fundação da barragem.....	123
4.9.4.	Movimentos de abertura e fecho de juntas.....	124
4.9.5.	Caudais drenados e infiltrados.....	126
4.10.	Análise de sensibilidade dos modelos de redes neuronais.....	127
4.10.1.	Análise do deslocamento horizontal radial do fio prumo FP1 à cota 879,25m.....	127
5.	CONSIDERAÇÕES FINAIS	131
5.1.	Síntese do trabalho realizado.....	131
5.2.	Discussão dos resultados obtidos.....	132
5.3.	Desenvolvimentos futuros.....	133
	REFERÊNCIAS BIBLIOGRÁFICAS	135
	BIBLIOGRAFIA	141

Índice das Figuras

Figura 2.1 – Componentes da segurança de barragens.....	8
Figura 2.2 – Imagens relacionadas com o controlo de segurança ambiental, estrutural e hidráulico/operacional.....	9
Figura 2.3 – Fases da vida da obra [Castro, 1998].....	10
Figura 2.4 – Escala limnimétrica.....	15
Figura 2.5 – Piezómetros	16
Figura 2.6 – Estação meteorológica, termómetro de máxima e mínima e termohigrógrafo.....	16
Figura 2.7 – Fio de prumo	21
Figura 2.8 – Cabeça de extensómetro de fundação	22
Figura 2.9 – Bases de alongâmetro.....	23
Figura 2.10 – Base tridimensional	23
Figura 2.11 – Drenos.....	25
Figura 2.12 – Modelo em argamassa, para ensaio à rotura.....	28
Figura 2.13 – Malha de um modelo de elementos finitos.....	29
Figura 2.14 – Resultado de um modelo de interpretação quantitativa	30
Figura 2.15 – Arquitectura de uma rede neuronal do tipo Perceptrão Multicamada.....	30
Figura 3.1 – Ramos da inteligência artificial	41
Figura 3.2 – Esquema de um neurónio biológico.....	44
Figura 3.3 – Diagrama esquemático de um neurónio genérico.....	45
Figura 3.4 – Evolução cronológica do desenvolvimento das redes neuronais artificiais [Patterson, 1996].....	46
Figura 3.5 – Modelo simplificado do neurónio de McCulloch e Pitts	46
Figura 3.6 – Esquemas de neurónios com N entradas e com função de activação escalão unitário.....	47
Figura 3.7 – Modelo do Perceptrão de Rosenblatt.....	49
Figura 3.8 – Separabilidade de classes.....	50
Figura 3.9 – Modelo ADALINE	51
Figura 3.10 – Modelo da rede para a obtenção da função de custo	52
Figura 3.11 – Esquema de um percurso de optimização por gradiente	53
Figura 3.12 – Funções lógicas ‘E lógico’, ‘OU lógico’ e ‘OU exclusivo’	54
Figura 3.13 – Efeito do passo de adaptação	55

Figura 3.14 – Arquitectura de uma rede neuronal Perceptrão Multicamada	57
Figura 3.15 – Rede estritamente directa	57
Figura 3.16 – Rede recorrente	58
Figura 3.17 – Nomenclatura adoptada para uma rede Perceptrão Multicamada	58
Figura 3.18 – Esquema de obtenção do erro em cada padrão.....	63
Figura 3.19 – Critério de paragem utilizando a validação cruzada	68
Figura 3.20 – Efeito do termo de momento	69
Figura 4.1 – Localização da barragem do Alto Rabagão.....	77
Figura 4.2 – Planta da barragem do Alto Rabagão – Trechos em abóbada e gravidade.....	77
Figura 4.3 – Sistema de observação na zona da abóbada: rede de drenagem e piezométrica	81
Figura 4.4 – Sistema de observação na zona da abóbada: aparelhagem eléctrica, bases de alongâmetro, fios de prumo e extensómetros de fundação.....	82
Figura 4.5 – Esquema de uma rede neuronal Perceptrão Multicamada com três entradas, com duas unidades de processamento e funções de activação tangente hiperbólica na camada intermédia e funções de activação lineares na camada de saída	85
Figura 4.6 – Definição dos conjuntos de aprendizagem e de previsão.....	86
Figura 4.7 – Instrumentos de leitura da temperatura.....	90
Figura 4.8 – Valores observados e da RN2 para as temperaturas no betão no bloco KL	92
Figura 4.9 – Valores observados e da RN1 para as temperaturas no betão no bloco GH	93
Figura 4.10 – Valores observados e da RN3 para as temperaturas no betão no bloco OP.....	94
Figura 4.11 – Evolução da cota da albufeira da barragem do Alto Rabagão entre 1980 e 2005.....	94
Figura 4.12 – Piezómetro utilizado nos modelos de RNs das subpressões.....	95
Figura 4.13 – Valores observados e do modelo de RN para as subpressões no PPM68 (período de aprendizagem e de previsão)	97
Figura 4.14 – Componentes radial e tangencial do deslocamento horizontal.....	98
Figura 4.15 – Fios prumo utilizados nos modelos de RNs de deslocamentos radiais.....	99
Figura 4.16 – Bases de coordinómetro dos FP1 e FP2.....	100

Figura 4.17 – Valores observados e do modelo de RN para os deslocamentos radiais do FP1 - 791 m (período de aprendizagem e de previsão)	103
Figura 4.18 – Valores observados e do modelo de RN para os deslocamentos radiais do FP1 – 879,25 m (período de aprendizagem e de previsão)	103
Figura 4.19 – Fio prumo utilizado nos modelos de RNs de deslocamentos tangenciais.....	104
Figura 4.20 – Valores observados e do modelo de RN para os deslocamentos tangenciais do FP3 – 879,25 m (período de aprendizagem e de previsão)	106
Figura 4.21 – Extensómetro de fundação utilizado nos modelos de RNs de deslocamentos na fundação no E6-46	107
Figura 4.22 – Valores observados e da RN1 para os deslocamentos na fundação no E6-46 (período de aprendizagem e de previsão)	109
Figura 4.23 – Base de alongâmetro utilizada nos modelos de RNs de movimentos de abertura e fecho de juntas.....	110
Figura 4.24 – Valores observados e do modelo RN1 adoptado para o movimento de abertura e fecho da junta Q na base BA064 (período de aprendizagem e de previsão)	112
Figura 4.25 – Bica totalizadora utilizada nos modelos de RNs de caudais (e respectivos drenos afluentes)	113
Figura 4.26 – Valores observados e dos modelos RN1 e RN4 para os caudais da Bica 1 (Período de aprendizagem e de previsão).....	117
Figura 4.27 – Valores observados e dos modelos RN1 e RN4 para os caudais da Bica 1 (Período de previsão).....	117
Figura 4.28 – Evolução dos resíduos ao longo do tempo relativos ao modelo RN1.....	118
Figura 4.29 – Comparação entre os valores observados e dos modelos RN1 e de IQ adoptados para as subpressões no PPM68m (período de aprendizagem e de previsão).....	120
Figura 4.30 – Comparação entre os valores observados e dos modelos RN2 e de IQ para o deslocamento radial no FP1 – 791 m (período de aprendizagem e de previsão)	121
Figura 4.31 – Comparação entre os valores observados e dos modelos RN2 e de IQ para o deslocamento radial no FP1 – 879,25 m (período de aprendizagem e de previsão).....	122

Figura 4.32 – Comparação entre os valores observados e dos modelos RN1 e de IQ para o deslocamento tangencial no FP3 – 879,25 m (período de aprendizagem e de previsão).....	123
Figura 4.33 – Comparação entre os valores observados e dos modelos RN1 e de IQ para os deslocamentos no E6 – 46 (período de aprendizagem e de previsão).....	124
Figura 4.34 – Comparação entre os valores observados e dos modelos RN1 e de IQ adotados para os movimentos de abertura e fecho da junta Q na BA064 (período de aprendizagem e de previsão).....	125
Figura 4.35 – Comparação entre os valores observados e dos modelos RN4 e de IQ adotados para os caudais da Bica 1 (período de aprendizagem e de previsão).....	126
Figura 4.36 – Comparação dos modelos de IQ e RN referente ao efeito da temperatura na resposta para as cotas de água 875 m, 870 m, 860 m e 855 m	128
Figura 4.37 – Comparação dos modelos de IQ e RN2 referente ao efeito da cota da albufeira na resposta nos dias 20, 100, 180 e 260 do ano.....	129

Índice dos Quadros

Quadro 2.1 – Grandezas a medir e localização dos respectivos instrumentos no caso de barragens abóbada, adaptado de [Ramos, 2004].....	13
Quadro 2.2 – Alguns métodos ou equipamentos de medida e respectiva precisão, adaptado de [Portela, 1999]	26
Quadro 3.1 – Exemplos de funções de activação.....	60
Quadro 4.1 – Número total de instrumentos existentes na zona em abóbada da barragem do Alto Rabagão [Silva e Portela, 1995].....	83
Quadro 4.2 – Instrumentos utilizados no estudo e datas das observações iniciais	84
Quadro 4.3 – Identificação dos instrumentos utilizados na modelação da temperatura no betão.....	89
Quadro 4.4 – Entradas e saídas das RNs para modelação das temperaturas no betão.....	91
Quadro 4.5 – Período de aprendizagem nos modelos de RNs de temperaturas no betão.....	91
Quadro 4.6 – Desempenho das melhores RNs obtidas para as temperaturas no betão.....	92
Quadro 4.7– Desempenho da RN2 para as saídas de temperaturas do betão no bloco KL.....	93
Quadro 4.8 – Piezómetro utilizado na modelação de subpressões	95
Quadro 4.9 – Entradas e saídas utilizadas nos modelos de RNs das subpressões no PPM68	96
Quadro 4.10 – Período de aprendizagem e previsão nos modelos de RNs de subpressões	96
Quadro 4.11 – Desempenho dos melhores modelos de RNs de subpressões no PPM68	97
Quadro 4.12 – Desempenho da RN1 para as subpressões no PPM68	97
Quadro 4.13 – Bases de coordenómetro dos FP1 e FP2 utilizadas na modelação de deslocamentos radiais.....	100
Quadro 4.14 – Entradas e saídas utilizadas nos modelos de RNs de deslocamentos radiais nos FP1 e FP2	101

Quadro 4.15 – Período de aprendizagem e previsão nos modelos de RNs de deslocamentos radiais nos FP1 e FP2.....	102
Quadro 4.16 – Desempenho dos melhores modelos de RNs de deslocamentos horizontais radiais nos FP1 e FP2.....	102
Quadro 4.17 – Desempenho da RN2 relativo aos deslocamentos radiais no bloco KJ às cotas 791 m e 879,25 m.....	104
Quadro 4.18 – Bases de coordenómetro utilizados para modelação de deslocamentos horizontais tangenciais do FP3.....	105
Quadro 4.19 – Entradas e saídas utilizados nas RNs de deslocamentos tangenciais no FP3	105
Quadro 4.20 – Período de aprendizagem e previsão nos modelos de RNs de deslocamentos tangenciais no FP3.....	105
Quadro 4.21 – Desempenho dos melhores modelos de RNs de deslocamentos tangenciais no FP3	105
Quadro 4.22 – Desempenho da RN1 nas saídas de deslocamentos tangenciais às cotas 831,2 m e 879,25 m.....	106
Quadro 4.23 – Extensómetro de fundação utilizado nos modelos de RNs.....	107
Quadro 4.24 – Entradas e saídas nos modelos de RNs dos deslocamentos na fundação no E6-46.....	108
Quadro 4.25 – Período de aprendizagem e previsão nos modelos de RNs de deslocamentos na fundação no E6-46	108
Quadro 4.26 – Desempenho dos melhores modelos de RNs de deslocamentos na fundação no E6-46.....	109
Quadro 4.27 – Desempenho da RN1 para os deslocamentos na fundação no E6-46...	110
Quadro 4.28 – Base de alongâmetro utilizada nos modelos de RNs.....	110
Quadro 4.29 – Entradas e saídas utilizadas nos modelos de RNs para a abertura e fecho da junta Q na base BA064.....	111
Quadro 4.30 – Período de aprendizagem e previsão nos modelos de RNs de abertura e fecho da junta Q da base BA064.....	111
Quadro 4.31 – Desempenho dos melhores modelos de RNs de abertura e fecho da junta Q da base BA064	112
Quadro 4.32 – Desempenho da RN1 para a abertura e fecho da junta Q na base BA064	113
Quadro 4.33 – Bica utilizada na modelação dos caudais e indicação dos drenos afluentes	114

Quadro 4.34 – Entradas e saídas nos modelos de RNs de caudais na Bica 1	115
Quadro 4.35 – Período de aprendizagem e previsão nos modelos de RNs de caudais na Bica 1	116
Quadro 4.36 – Desempenho dos melhores modelos de RNs de caudais na Bica 1	116
Quadro 4.37 – Desempenho das RN1 e RN4 para os caudais da Bica 1	118
Quadro 4.38 – Desempenho da interpretação quantitativa e da rede neuronal para as subpressões no PPM68m	120
Quadro 4.39 – Desempenho da interpretação quantitativa e da rede neuronal para o deslocamento radial no FP1	122
Quadro 4.40 – Desempenho da interpretação quantitativa e da rede neuronal para o deslocamento tangencial no FP3 – 879,25 m	123
Quadro 4.41 – Desempenho da interpretação quantitativa e da rede neuronal para os deslocamentos na fundação no E6–46	124
Quadro 4.42 – Desempenho da interpretação quantitativa e da rede neuronal para os movimentos de abertura e fecho da junta Q na BA064	125
Quadro 4.43 – Desempenho da interpretação quantitativa e da rede neuronal para os caudais da Bica 1	126

Lista de Siglas

CPPE	Companhia Portuguesa de Produção de Electricidade
DBB	Departamento de Barragens de Betão
FEUP	Faculdade de Engenharia da Universidade do Porto
ICOLD	International Commission of Large Dams
INAG	Instituto da Água
IQ	Interpretação Quantitativa
IST	Instituto Superior Técnico
LNEC	Laboratório Nacional de Engenharia Civil
RN	Rede Neuronal
RSB	Regulamento de Segurança de Barragens

Lista de Símbolos

a	número de dias entre o 1º enchimento e a data do início da análise;
a_j	coeficiente a ajustar, relativo à $j^{\text{ésima}}$ função de aproximação para o efeito do nível da água na albufeira;
A_i	amplitude na entrada x_i da rede neuronal;
A_k	amplitude na saída y_k^L da rede neuronal;
b	limiar de disparo;
b_j	coeficiente a ajustar, relativo à $j^{\text{ésima}}$ função de aproximação para o efeito da temperatura;
B_i	desfasamento na entrada x_i ;
B_k	desfasamento na saída y_k^L da rede neuronal;
c_j	coeficiente a ajustar, relativo à $j^{\text{ésima}}$ função de aproximação para o “efeito do tempo”,
C, C'	funções de custo;
$C(DO)$	cota da albufeira no dia da observação DO (m);
d	valor desejado da saída do neurónio;
\overline{d}_k	média dos valores desejados na saída k da rede neuronal;
d^p	valor desejado na rede quando apresentado o padrão p ;
d_k^p	valor desejado para a saída da unidade k da camada de saída, para o padrão p ;
D	número de dias após 1 de Janeiro do mesmo ano a que corresponde a data da observação DO (1, 2, ..., 365);
DO	dia da observação do exemplo de treino (dia/mês/ano);
E^p	erro obtido quando apresentado o padrão p ;

EAM^k	erro absoluto médio na saída k ;
$EAMax^k$	erro absoluto máximo na saída k ,
$EAMin^k$	erro absoluto mínimo na saída k ;
EQM^k	erro quadrático médio na saída k ;
EQM^{rede}	erro quadrático médio da rede neuronal;
$EQMN^k$	erro quadrático médio normalizado na saída k ;
$f()$	função de activação;
$f_j()$	$j^{ésima}$ função de aproximação para o efeito do nível da água na albufeira;
$g_j()$	$j^{ésima}$ função de aproximação para o efeito da temperatura;
g_{ij}^l	gradiente da função de custo em ordem ao peso que liga a unidade i da camada $l-1$ à unidade j da camada l ;
$g_{ij,n}^l$	componente do gradiente calculado na iteração n , na direcção de w_{ij}^l ;
h	altura de água na albufeira (m);
k	constante que corresponde à diferença entre os valores observados e os calculados no início do período de calibração;
L	índice da camada de saída;
LIB	limite inferior da banda;
LSB	limite superior da banda;
M	número de elementos de saída da rede neuronal;
n	número da iteração;
N	número total de observações na interpretação quantitativa ou número total de entradas na rede neuronal;
$N(DO)$	número de dias desde 1ª observação até a dia da observação DO ;

P	número total de termos no modelo de interpretação quantitativa, ou número total de padrões do conjunto de treino da rede neuronal;
$q_j(\)$	$j^{\text{ésima}}$ função de aproximação para o “efeito do tempo”;
Q	número de unidades de processamento na camada intermédia;
r^k	coeficiente de correlação na saída k ;
R^2	coeficiente de determinação múltipla;
s	valor da activação do neurónio;
$s_j^{l,p}$	valor da activação da unidade j da camada l , para o padrão p ;
t	número de dias entre a campanha e o início da análise;
t_d	número de dias decorridos desde o início do ano até à data da observação;
t_m	número de minutos decorridos desde o início do dia até a observação;
$TB(X, Y, DO)$	temperatura do betão a meia espessura no bloco X à cota Y (m) em DO (°C);
U	valor estimado da grandeza em análise;
$U(h_i, \theta_i, t_i)$	valor estimado da grandeza em análise na observação i , que depende da pressão hidrostática, da temperatura e do instante em que se realiza a observação;
$U_h(h_i),$ $U_\theta(\theta_i),$ $U_t(t_i)$	parcelas da grandeza U correspondentes ao efeito elástico do nível de água na albufeira, ao efeito elástico da temperatura e ao “efeito do tempo” na $i^{\text{ésima}}$ observação, respectivamente;
w_i	peso sináptico associado à entrada i ;
$w_{i,n}$	peso na ligação da entrada i , na iteração n ;
w_{ij}^l	peso que liga a unidade i da camada $l-1$ à unidade j da camada l ;
x_i	valor de entrada i ;

x_i^{\max}	máximo valor da entrada x_i ;
x_i^{\min}	mínimo valor da entrada x_i ;
$x_i^{\text{normalizado}}$	valor da entrada x_i normalizado;
x_i^p	entrada da unidade i , para o padrão p ;
\mathbf{X}	matriz dos termos associados às acções;
X_j	$j^{\text{ésimo}}$ termo associado às acções na interpretação quantitativa;
y	saída do neurónio;
y^p	valor da saída da rede neuronal quando apresentado o padrão p ;
$y_i^{l,p}$	saída da unidade i da camada l , para o padrão p ;
$y_k^{L,\max}$	máximo valor da saída y_k^L ;
$y_k^{L,\min}$	mínimo valor da saída y_k^L ;
$y_k^{L,\text{normalizado}}$	valor normalizado de y_k^L ;
$\overline{y_k^L}$	média dos valores da rede neuronal na saída k ;
$y_{,n}$	valor obtido na saída do neurónio, na iteração n ;
\mathbf{Y}	matriz do valor estimado da grandeza em análise;
α	termo de momento;
β_j	coeficiente correspondente ao termo X_j ;
$\boldsymbol{\beta}$	vector dos coeficientes correspondentes aos termos de \mathbf{X} ;
Δw_i	variação do peso na ligação da entrada i ;
$\Delta w_{i,n}$	variação do peso na ligação da entrada i , na iteração n ;

Δw_{ij}^l	variação do peso que liga a unidade i da camada $l-1$ à unidade j da camada l , na iteração n ;
ε	vector dos resíduos;
ε_i	resíduo da $i^{\text{ésima}}$ observação, dado pela diferença entre o valor estimado e o valor observado;
η	passo da adaptação.

1. INTRODUÇÃO

1.1. Enquadramento geral

É inquestionável que a água é um bem essencial e um elemento indispensável à actividade do homem. Estima-se que quase três quartos da superfície terrestre seja água, no entanto, a água doce é relativamente escassa, pelo que é necessária a preservação e defesa da sua qualidade. Este aspecto, associado à enorme importância que têm no sector energético, fazem das barragens elementos essenciais da actividade humana.

Na actualidade, a construção de uma barragem é baseada num conjunto de interesses económicos, políticos e ambientais, norteados por um aspecto comum: o interesse no aproveitamento e gestão de recursos hídricos nas máximas condições de segurança.

Como é do consenso geral, todas as obras em exploração devem verificar as exigências regulamentares de segurança. Assim, torna-se cada vez mais importante a utilização de rigorosas técnicas de observação e o desenvolvimento de modelos de referência credíveis para a interpretação e a previsão do seu comportamento com o intuito de serem tomadas, quando necessárias, decisões referentes às medidas a implementar quer em termos de exploração, conservação, reabilitação ou demolição.

O contínuo controlo de segurança destas obras deve ser efectuado a vários níveis, isto é, deve contemplar o controlo de uma forma individual e no seu todo, nas várias vertentes de segurança: ambiental, estrutural e hidráulico/operacional.

O controlo de segurança, do ponto de vista estrutural, durante o período de exploração normal, é uma actividade suportada principalmente pela observação da obra e apoia-se em modelos de comportamento. Os modelos utilizados na interpretação do comportamento estrutural constituem idealizações (com maiores ou menores simplificações) da realidade, tanto no que respeita às solicitações como no que respeita à barragem.

Neste sentido, este trabalho pretende contribuir na abordagem de novos modelos com base em novas tecnologias, como é o caso das redes neuronais artificiais. A utilização de modelos baseados em redes neuronais artificiais é uma área de

investigação promissora por se tratar de uma ferramenta com uma grande capacidade de adaptação a sistemas de natureza diversificada.

O principal objectivo deste trabalho é investigar a aplicabilidade das redes neuronais artificiais na interpretação do comportamento estrutural de barragens de betão, bem como verificar se estes modelos são ferramentas adequadas no controlo de segurança destas obras.

Para cumprir os objectivos estabelecidos foram desenvolvidos modelos de redes neuronais do tipo Perceptrão Multicamada para interpretação e previsão do comportamento de algumas das principais grandezas observadas no controlo de segurança estrutural das barragens de betão, nomeadamente, os deslocamentos, os caudais e as subpressões.

Com o intuito de avaliar a qualidade e as mais valias dos modelos de redes neuronais, os seus resultados foram comparados e confrontados com os resultados de modelos de interpretação quantitativa (IQ), os quais são frequentemente utilizados no controlo de segurança das barragens de betão portuguesas. Os modelos de IQ consideraram o mesmo conjunto de dados utilizados nos modelos de redes neuronais.

1.2. Justificação do tema e objectivos do trabalho

A análise da evolução das grandezas observadas, ao longo do tempo, é importante na compreensão do comportamento de uma barragem de betão e na garantia das exigências em termos de segurança. Para uma adequada interpretação do comportamento destas obras é necessário dispor de modelos de comportamento. Desta forma, a implementação de vários tipos de modelos, de modo a poderem ser comparados os resultados, é uma medida importante na selecção dos modelos mais adequados.

Uma vez estabelecidos os modelos de comportamento é possível caracterizar o comportamento normal de uma barragem. Sempre que sejam observados desvios relativamente a este comportamento torna-se necessário proceder a uma análise para identificar eventuais anomalias na obra. Assim, um dos principais objectivos deste trabalho consistiu na investigação das potencialidades da aplicação de redes neuronais artificiais do tipo Perceptrão Multicamada no apoio às actividades de controlo de segurança de barragens de betão. Assim, foram desenvolvidos modelos para a interpretação do comportamento de barragens de betão a partir deste tipo de redes neuronais artificiais, nomeadamente para a análise de algumas grandezas que são

observadas com carácter sistemático nestas obras. Escolheu-se como caso de estudo a barragem do Alto Rabagão.

1.3. Estrutura da dissertação

O texto da dissertação está organizado em cinco capítulos. O primeiro e presente capítulo faz a introdução ao tema.

No segundo capítulo efectua-se uma abordagem geral sobre as actividades desenvolvidas no controlo de segurança de barragens de betão, com ênfase nos aspectos da observação e interpretação do comportamento estrutural. Apresentam-se os principais tipos de modelos utilizados actualmente na interpretação e previsão do comportamento das principais grandezas observadas nas barragens de betão. De seguida, indicam-se os métodos e os equipamentos de medida dessas grandezas, com referência aos respectivos erros de medição. Por último são descritos em pormenor os conceitos relativos aos modelos de interpretação quantitativa de resultados, já que são estes os modelos adoptados para comparação de resultados com os modelos de redes neuronais artificiais.

No terceiro capítulo faz-se uma breve introdução às redes neuronais artificiais. Começa-se por apresentar uma descrição básica do funcionamento de um neurónio, seguindo-se a apresentação de alguns conceitos gerais e uma síntese da evolução histórica dos principais desenvolvimentos nesta matéria e, finalmente, caracterizam-se as redes neuronais Perceptrão Multicamada, focando-se aspectos como a sua arquitectura, o seu funcionamento, a aprendizagem e a capacidade de generalização.

No quarto capítulo referem-se alguns dos trabalhos internacionais sobre o tema desta tese encontrados na literatura, abordando-se aspectos que se consideraram importantes para a boa prática na utilização de modelos de redes neuronais Perceptrão Multicamada. Segue-se uma breve descrição da barragem do Alto Rabagão, ilustrando de forma simplificada alguns elementos do sistema de observação, indicando-se também a relevância que a observação de determinadas grandezas, em locais estratégicos, tem na tomada de decisões. De seguida apresentam-se os aspectos comuns adoptados na produção dos modelos de redes neuronais para a análise de cada uma das grandezas. Após a caracterização dos processos gerais, apresentam-se os modelos propriamente ditos, descrevendo-se para cada uma das redes neuronais todos os elementos necessários à sua elaboração, entre os quais as entradas, as saídas, os conjuntos de aprendizagem e previsão, e os desempenhos globais da rede neuronal e de cada saída,

quando aplicável. Segue-se a apresentação dos modelos de interpretação quantitativa, onde foram utilizados conjuntos de dados iguais aos utilizados nos modelos de redes neuronais, apresentando-se comparações de desempenhos dos dois tipos de modelos. Finalmente, efectua-se uma “análise de sensibilidade” para aferir o desempenho dos modelos de redes neuronais e ainda verificar se o modelo representou satisfatoriamente as respostas às acções nas grandezas analisadas.

No quinto, e último capítulo, apresenta-se uma análise crítica dos resultados conseguidos e perspectivam-se os desenvolvimentos futuros.

2. CONTROLO DE SEGURANÇA DE BARRAGENS DE BETÃO

2.1. Introdução

A preocupação em torno da segurança de barragens de betão tem sido um assunto sempre actual e de importância crescente devido a um conjunto de factores, de entre os quais se destacam:

- o elevado número de barragens em exploração e o seu crescente envelhecimento, algumas com mais de 50 anos de vida;
- o facto de existirem obras de grandes dimensões, que podem ultrapassar os 100 m de altura, e com capacidades de armazenamento elevadas;
- a forte probabilidade de estas obras ultrapassarem o tempo de vida útil para o qual foram projectadas, mesmo que apresentem alguns sinais de deterioração;
- o aumento das preocupações das sociedades em relação aos riscos inerentes às barragens, em termos de segurança das populações e do meio ambiente;
- a elaboração e a implementação de legislação referente às barragens, a qual permite a regularização e uniformização dos processos de controlo de segurança;
- a evolução da ciência e da tecnologia nesta matéria.

O actual estado do conhecimento na engenharia de barragens, a nível nacional e internacional, é o resultado de estudos efectuados em diversas vertentes, como por exemplo, na instrumentação, na caracterização das propriedades dos materiais e do comportamento das estruturas e no controlo de segurança. Uma das consequências destes estudos e do permanente acompanhamento das barragens é a obtenção de obras mais seguras [Portela, 1999].

Uma vez que todas as obras em exploração devem verificar as exigências regulamentares de segurança, torna-se cada vez mais importante a utilização de

rigorosas técnicas de observação e ainda o desenvolvimento de modelos de referência credíveis para a interpretação e a previsão do seu comportamento com o intuito de se tomarem, quando necessárias, decisões referentes às medidas a implementar, em termos de exploração, conservação, reabilitação ou demolição.

Para a compreensão do comportamento estrutural de uma barragem é necessário dispor de modelos que tenham em consideração os diferentes tipos de acções que actuam na estrutura, tanto para condições de exploração normal da albufeira como para as situações excepcionais.

A complexidade deste tipo de obras aconselha a utilização de diversos tipos de modelos de modo a que se obtenha uma validação simultânea do comportamento das observações e dos modelos utilizados [Oliveira, 2000].

2.2. Tipos de barragens de betão

No projecto de uma barragem, qualquer que seja o seu tipo, visam-se dois objectivos essenciais: resistir ao impulso da água que retém e garantir a estanquidade da obra a construir e da sua fundação [INAG, 2001]. Para atingir estes objectivos, existem diversas soluções estruturais, nomeadamente barragens de betão do tipo gravidade, contrafortes, abóbadas ou ainda resultantes de uma mistura das características de algumas das propriedades destes três tipos de barragens.

As barragens gravidade são concebidas e calculadas para resistir, apenas pelo seu peso, ao impulso da água que retém [Varlet, 1966]. A secção transversal tipo de uma barragem gravidade maciça é aproximadamente triangular, sendo a largura da base raras vezes inferior a 80% da altura. O traçado em planta é recto ou com ligeira curvatura. O dimensionamento das barragens gravidade baseia-se geralmente na estabilidade e equilíbrio de elementos verticais isolados. Neste tipo de barragens a segurança ao colapso é, em geral, independente da resistência mecânica do betão. Para poupar material são, muitas vezes, construídas barragens do tipo gravidade aligeirada, à custa de um vazamento efectuado na parte inferior do perfil [Farinha et al, 2004].

Nas barragens de contrafortes a estrutura resistente é constituída por blocos isolados, concretizando um tipo de aligeiramento da estrutura gravidade maciça mais acentuado que o vazamento; teoricamente esses blocos funcionam isoladamente, permitindo a adaptação a condições geotécnicas diferenciadas ao longo da fundação

[Farinha et al, 2004]. É sobre estes elementos resistentes que se “apoia” a estrutura de estanquidade.

Existem diversos tipos de barragens de contrafortes, consoante a natureza da estrutura de estanquidade: barragens em que a estrutura é uma laje; barragens em que esta estrutura é como uma continuidade do contraforte, cuja cabeça é, então, maciça, tendo em certos casos forma arredonda ou polidrica (cabeça de diamante); barragens em que esta estrutura é em arco, designando-se então, a estrutura por barragem de abóbadas múltiplas cilíndricas de pequeno vão [INAG, 2001].

Uma barragem abóbada é uma estrutura com curvatura em planta, com a convexidade voltada para montante, concebida de forma a transmitir o impulso da água principalmente para as encostas e não para o fundo do vale, utilizando para tanto a resistência à compressão do material de que é feita e do maciço rochoso de fundação [Veltrop, 1988]. As barragens abóbadas têm formas geométricas de diverso tipo, condicionadas por diferentes circunstâncias de projecto, entre elas a altura, forma do vale e características do maciço de fundação, podendo designar-se, de acordo com a sua geometria, como abóbadas espessas ou abóbadas delgadas, abóbadas cilíndricas ou abóbadas de dupla curvatura [Farinha et al, 2004].

Existem outros tipos de barragens que misturam as características dos tipos de barragens apresentados, tais como: as barragens arco-gravidade, as barragens de abóbadas múltiplas e as barragens mistas [Farinha et al, 2004].

2.3. Controlo de segurança

O controlo de segurança das barragens consiste na tomada de decisões ao longo das várias fases da vida da obra, tendo por base as actividades de observação. Assim, o principal objectivo das actividades de observação de barragens é a múltipla avaliação dos modelos de simulação do comportamento, das medições efectuadas e dos parâmetros que caracterizam e condicionam esse comportamento, tendo em vista a elaboração e justificação de um juízo sobre as condições de segurança das obras. O que está em causa é o comportamento real da estrutura, nas condições reais em que é explorada, tendo em vista a possibilidade de detecção de eventuais anomalias de funcionamento [Castro, 1998].

Uma vez que o controlo de segurança é uma actividade continuada, permite uma detecção oportuna de eventuais anomalias e uma resposta atempada e eficaz sempre que seja considerado necessário [Gomes et al., 1993].

O contínuo controlo de segurança das obras deve ser feito a vários níveis, isto é, deve contemplar o controlo de uma forma individual e no seu todo, quer do corpo da barragem, da sua fundação, dos órgãos de segurança, das encostas adjacentes, das zonas a jusante e da exploração da albufeira - nas várias vertentes de segurança: ambiental, estrutural e hidráulico/operacional (Figuras 2.1 e 2.2).

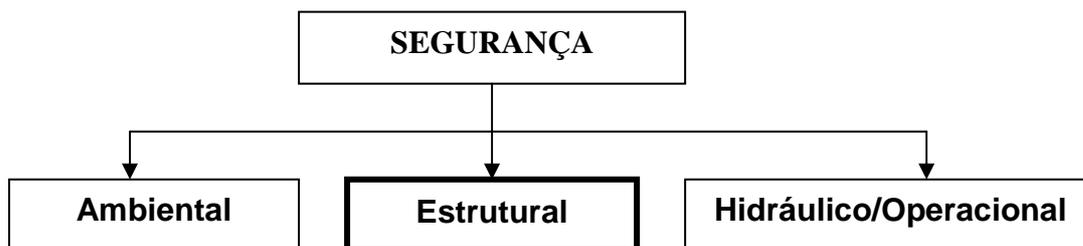


Figura 2.1 – Componentes da segurança de barragens

A segurança ambiental, tal como o nome o diz, engloba os aspectos relacionados com os impactes originados pelo empreendimento no meio ambiente, quer em termos de manutenção de caudais ecológicos, com influência directa na fauna e flora existentes a jusante, quer em relação ao controlo das características e da qualidade da água da albufeira e do solo [Portela, 1999].

A segurança hidráulico/operacional relaciona-se com a adequada exploração e com o bom funcionamento dos órgãos de segurança, assim como com a implementação de sistemas de aviso e alerta para os casos de emergência.

A segurança estrutural é entendida como a capacidade das obras em satisfazer as exigências de comportamento, evitando acidentes e incidentes¹ ao longo da sua vida e é verificada para os principais cenários, correntes e de rotura, que possam vir a ocorrer ou cujo desenvolvimento se observe, durante o tempo de vida das obras [Pedro, 1987].

O controlo de segurança estrutural inclui todas as medidas e intervenções afins necessárias para garantir o adequado funcionamento estrutural da obra.

¹ Designam-se por acidentes anomalias graves, cujo desenvolvimento poderá resultar na rotura da obra. Por incidentes são designadas anomalias que não provocam a rotura, mas que podem comprometer a funcionalidade da obra.



Caudal ecológico



Corpo da barragem



Descarregador de fundo

Figura 2.2 – Imagens relacionadas com o controlo de segurança ambiental, estrutural e hidráulico/operacional

De referir que o desenvolvimento deste trabalho incidirá unicamente numa parte do controlo de segurança estrutural.

2.4. Observação do comportamento estrutural

A análise do comportamento estrutural deve ter em conta o tipo de obra, as acções a que está sujeita e as propriedades dos materiais da própria obra e da envolvente em que está inserida. Por outro lado, as heterogeneidades da sua fundação e das zonas envolventes, assim como o facto das obras estarem sujeitas a diferentes tipos de acções (por exemplo, diferentes condições ambientais e de exploração), leva a afirmar que a análise do comportamento deva ser efectuada obra a obra, tendo sempre em conta todas as variáveis intervenientes.

A diversidade de factores envolventes e a complexidade do comportamento resultante podem, em parte, ser analisados pelos especialistas a partir da implementação de um adequado sistema de observação e da análise das respectivas grandezas observadas.

O controlo de segurança é efectuada de uma forma planificada, sendo realizado com o apoio de um Plano de Observação. Em Portugal, o Plano de Observação é um documento vinculativo, consignado no Regulamento de Segurança de Barragens [RSB, 1990], obrigatório quer para obras novas quer para as antigas, e visa, essencialmente, o controlo de segurança durante as várias fases de vida da obra.

O controlo de segurança estende-se pelas seguintes fases de vida das obras (Figura 2.3):

- fase de projecto: onde é efectuada a verificação da segurança para os cenários correntes e de rotura, começando aqui a definição dos Anteplos de Observação e de primeiro enchimento da albufeira;
- fase de construção: período em que é instalado o sistema de observação, efectuada a caracterização das propriedades dos materiais e realizado o controlo de segurança para os cenários específicos deste período;
- fase do primeiro enchimento: corresponde ao primeiro ensaio de carga real do conjunto barragem-fundação, exigindo-se um plano específico de observação para este importante período;
- fase de exploração: que se divide no período inicial (normalmente os primeiros 5 anos), durante o qual se dá a adaptação da estrutura às condições de funcionamento, passando depois para um período de exploração normal, sobre o qual incidirão a maior parte das análises;
- fase de abandono e demolição.

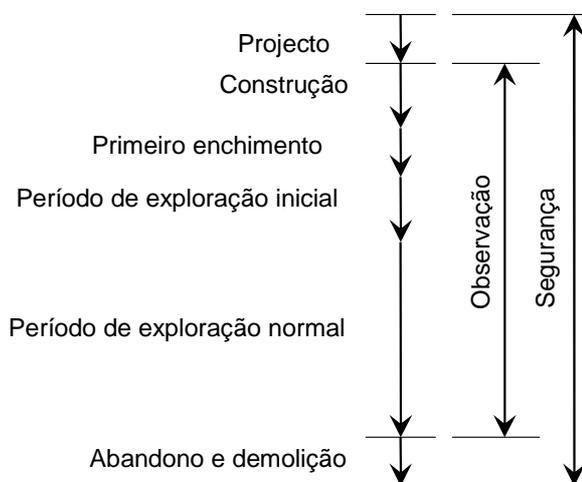


Figura 2.3 – Fases da vida da obra [Castro, 1998]

Um dos elementos principais que o Plano de Observação deve conter é relativo à definição do sistema de observação, o qual permitirá, ao longo da vida da obra, a medição das variáveis representativas das acções, das propriedades estruturais e das respostas estruturais [Pedro, 2001].

Uma correcta definição do sistema de observação e da sua utilização na fase de exploração permitirá [Portela, 1999]:

- caracterizar o desempenho da estrutura, em função de acções permanentes, variáveis e de ciclos de carga/descarga;
- verificar se a barragem mantém um desempenho satisfatório;
- disponibilizar meios para o acompanhamento de eventuais medidas de reparação e reabilitação decorrentes de deteriorações que ocorram na estrutura e respectiva fundação, assim como controlar o comportamento da obra durante a aplicação dessas medidas, de forma a não resultarem outros danos ou modificações significativas das propriedades estruturais que afectem adversamente o desempenho da obra;
- sugerir alterações ao regime de exploração.

2.5. Observação e interpretação do comportamento de barragens

Uma vez instalado o sistema de observação adequado aos cenários de acidente e incidente mais prováveis para cada tipo de obra, assim como para a detecção das deteriorações mais comuns, é possível, graças à observação continuada de cada grandeza, identificar e acompanhar a evolução de possíveis cenários.

A título exemplificativo e para barragens do tipo abóbada, apresenta-se a importância que algumas grandezas têm no diagnóstico e na tomada de decisão [Ramos, 2004]:

- a perda de resistência mecânica da fundação, designadamente na zona dos rins, ou a cedência de apoio nestas zonas ou nos encontros, pode originar deslocamentos não elásticos no contacto e manifestar-se também nos deslocamentos da superestrutura;
- a deterioração da cortina de impermeabilização, a erosão ou lixiviação de materiais de preenchimento das fracturas e a colmatação da drenagem têm reflexo nos caudais e subpressões, podendo também influenciar os deslocamentos, quer ao nível do contacto, quer na superestrutura. Assim, no que diz respeito à fundação da barragem, deve ser prevista a medição, particularmente na zona dos rins, dos deslocamentos na superfície de contacto e das subpressões no plano da drenagem ou imediatamente a jusante deste, bem

como dos caudais drenados dreno a dreno e ainda do caudal total e parcial por zonas da fundação;

- a perda de continuidade estrutural, grave em barragens abóbada, manifesta-se nos deslocamentos relativos entre as superfícies das juntas de contracção, tendo em princípio também influência nos deslocamentos da superestrutura;
- a degradação por reacções químicas e a degradação das argamassas e caldas de ligação por lixiviação, ao diminuir a rigidez estrutural, pode, em casos de deterioração muito pronunciada, influenciar os deslocamentos da superestrutura. As reacções de carácter expansivo podem ser particularmente gravosas em barragens abóbada, face à grande hiperstaticidade destas estruturas. Assim, no que respeita ao corpo das barragens, deve ser prevista a medição de deslocamentos horizontais, deslocamentos verticais e deslocamentos relativos entre as faces das juntas de contracção;
- a medição dos deslocamentos horizontais e verticais deve ter em conta que nestas obras, mais uma vez face à exigência de continuidade estrutural, é de interesse a obtenção das deformadas da estrutura, quer segundo os arcos, quer segundo as consolas. Por outro lado, a articulação entre medições de deslocamentos horizontais e relativos entre as faces das juntas de contracção, deve agora tirar partido do comportamento tridimensional da estrutura;
- a medição de extensões é do maior interesse nas abóbadas, quer pelo valor mais elevado das tensões, quer pelo facto de a continuidade estrutural ter influência nestas grandezas. Em obras em que as tensões no corpo da estrutura sejam muito elevadas, particularmente se sujeitas a processos expansivos, a observação de extensões e tensões pode ser do maior interesse.

No Quadro 2.1 adaptado de [Ramos, 2004], são apresentadas algumas zonas da obra e correspondentes grandezas cuja medição é considerada importante em barragens do tipo abóbada.

Quadro 2.1 – Grandezas a medir e localização dos respectivos instrumentos no caso de barragens abóbada, adaptado de [Ramos, 2004]

Grandeza	Equipamento ou método	Zona da obra
Deslocamentos horizontais	Fios de prumo direitos e invertidos, geodesia de posição	Em vários blocos e a várias cotas de forma a permitir a obtenção de deformadas Pontos situados nos rins, próximo do contacto betão-rocha (Fios de prumo invertidos)
Deslocamentos verticais	Extensómetros de fundação, nivelamento	Pontos situados nos rins próximo do contacto betão-rocha a montante e a jusante
Movimentos relativos entre faces de juntas de contracção	Bases de alongâmetro, medidores de movimento de juntas	Principais juntas de contracção, próximo do coroamento e da inserção, em articulação com os pontos em que são observados deslocamentos horizontais
Caudais	Drenos e bicas	Caudal dreno a dreno; caudais parciais por zonas da obra: fundo do vale, encosta esquerda, encosta direita; caudal total
Subpressões	Piezómetros	Na superfície de contacto da barragem com a fundação, particularmente nos rins e nos encontros
Extensões no betão	Extensómetros	Em todo o corpo da barragem, particularmente no fecho dos arcos, em pontos próximos de montante e jusante, e nos rins a jusante
Tensões no betão	Tensómetros	Em pontos seleccionados de acordo com objectivos específicos
Nível da albufeira	Escala de níveis	Nível de água a montante Nível de água a jusante, em barragens com nível a jusante significativo
Temperatura	Temperatura ambiente: termógrafo e termómetro de máxima e mínima	Em local seleccionado próximo da barragem
	Termómetros de resistência eléctrica; pares termoeléctricos	Em todo o corpo da barragem de forma a caracterizar o estado térmico em articulação com outra aparelhagem eléctrica que permita medição de temperatura

No domínio da exploração dos sistemas de observação existem nos últimos anos avanços tecnológicos que contribuem para a melhoria das actividades relacionadas com o controlo de segurança das barragens. Entre estes avanços, destacam-se os mais recentes sistemas de recolha automática, que contribuem para o desenvolvimento de metodologias de controlo de segurança em tempo real, e os sensores de fibra óptica que permitem, inseridos em sistemas de recolha automática, obter parâmetros representativos da resposta da estrutura em diversos pontos da estrutura.

2.6. Observação das principais acções

Nas barragens de betão, as acções mais importantes são as gravíticas (pesos próprios) e as que se relacionam com as variações do nível da água a montante e a jusante, e com as variações de temperatura do ar e da água, devendo também ser caracterizadas as acções químicas e as acções dinâmicas, entre outras.

Para uma caracterização adequada das acções é importante que sejam obtidas medidas fiáveis relativamente a todo o domínio de variação, de forma a não prejudicar a análise das observações e consequentemente a qualidade da calibração dos modelos de análise estrutural.

2.6.1. Peso próprio

Dada a baixa dispersão do peso específico do betão, uma estimativa do peso próprio é efectuada considerando as propriedades dos materiais e a geometria do corpo da barragem.

2.6.2. Água

A acção mecânica da água sobre um sólido permeável pode considerar-se como a sobreposição da pressão hidrostática sobre as superfícies que constituem o contorno, admitindo que estas são impermeáveis, com as subpressões nos interstícios do interior do sólido. Normalmente o betão é considerado impermeável. Desta forma as acções mecânicas da água nas barragens de betão e suas fundações induzem, nas zonas submersas: pressões hidrostáticas sobre os paramentos e subpressões resultantes da percolação nos meios porosos e fracturados [Batista, 1998].

2.6.2.1. Pressão hidrostática

A acção da água relativamente à pressão hidrostática é avaliada, principalmente, através da medição periódica do nível de água na albufeira e, quando necessário, da medição do nível de água a jusante. Esta medição pode ser realizada através de escalas limnimétricas localizadas na albufeira (Figura 2.4), quer junto à barragem ou ao longo das margens, de forma a serem de fácil leitura. Em algumas obras são utilizados limnígrafos, os quais permitem um registo contínuo dos níveis de água na albufeira.

Actualmente são comuns sistemas de recolha automática que permitem a consulta remota do nível de água das albufeiras.



Figura 2.4 – Escala limnimétrica

2.6.2.2. Subpressão

As subpressões instaladas no maciço de fundação são observadas em piezómetros distribuídos ao longo de furos orientados em função da localização das cortinas de impermeabilização e de drenagem, das características das discontinuidades da fundação, dos estados de tensão mais desfavoráveis na base da barragem e em função dos resultados da permeabilidade e absorções medidas na fase de tratamento da fundação.

Nos piezómetros (Figura 2.5) instalados em galerias ou em locais onde a pressão ultrapassa a cota do terreno, a medida da pressão é efectuada em manómetros acoplados. Nos casos em que a água não chega ao manómetro, faz-se a medição do nível freático por meio de uma sonda [INAG, 2001].



Manómetro de um piezómetro simples



Manómetros de um leque piezométrico

Figura 2.5 – Piezómetros

2.6.2.3. Acções de natureza físico-química da água

São realizados ensaios físicos e químicos da água da albufeira e da água drenada para análise de agressividade da água para o betão e para os produtos de injeção do tratamento da fundação, e, ainda, dos materiais arrastados, com vista à avaliação, ao longo do tempo, de fenómenos de deposição de materiais, de alteração do maciço rochoso de fundação e do grau de deslramento das cortinas.

2.6.3. Temperatura

As variações de temperatura no interior do betão e nos paramentos são devidas às variações térmicas do ar e da água que envolvem a barragem. Os valores da temperatura do ar podem ser obtidos por termómetros de máxima e mínima (Figura 2.6), instalados em locais representativos das condições ambientais em obra e devidamente protegidos da acção directa dos raios solares. Actualmente a maior parte das barragens de betão possuem estações meteorológicas mais modernas, permitindo um registo contínuo de leituras [INAG, 2001]. A temperatura da água da albufeira é medida a diferentes profundidades através de sondas termométricas (Figura 2.6).



Estação meteorológica



Term. de máxima e mínima



Sonda termométrica

Figura 2.6 – Estação meteorológica, termómetro de máxima e mínima e termohigrógrafo

As temperaturas no interior do corpo da barragem são obtidas por instrumentos de resistência eléctrica embebidos no betão da obra, nomeadamente por termómetros de resistência eléctrica, podendo também ser medidas por outros instrumentos eléctricos que permitem a obtenção desta grandeza, tais como os extensómetros de resistência e os medidores de movimentos de junta [Castro, 1998].

No período construtivo das barragens, por se tratarem de obras com grandes volumes de betão, são atingidas temperaturas internas muito elevadas resultantes da libertação do calor de hidratação. Na hidratação do cimento liberta-se calor, provocando nos volumes de betão uma importante subida de temperatura nos primeiros dias após a betonagem, verificando-se em seguida uma diminuição lenta dessa temperatura até se atingir o equilíbrio com o exterior, ao fim de alguns meses [Batista, 1998].

A caracterização das variações térmicas do ar pode ser efectuada, de forma aproximada, pela sobreposição de duas ondas sinusoidais, uma de período anual e outra de período diário. Enquanto que a onda térmica anual afecta toda a barragem, a onda térmica diária apenas afecta uma zona superficial com cerca de 0,5 a 0,8 metros de profundidade junto aos paramentos expostos ao ar. O efeito da onda térmica diária apenas é importante nos casos em que possa agravar as tensões de tracção susceptíveis de provocar fendilhação junto aos paramentos, sendo normalmente previstas armaduras de pele para minorar as consequências desses efeitos [Batista, 1998].

Durante a fase do primeiro enchimento ocorre uma alteração significativa das temperaturas na barragem, devido à criação da albufeira. Esta alteração afecta principalmente o paramento de montante, já que é a superfície que está directamente em contacto com a água. Por conseguinte, a evolução temporal da temperatura no paramento de montante depende do regime de exploração do aproveitamento e do regime hidrológico da região.

Em geral, a temperatura da água das albufeiras praticamente não é influenciada pela onda térmica diária do ar e em profundidade é pouco afectada pelo nível da água na albufeira [Silveira, 1961]. Porém, nas albufeiras de regularização a temperatura da água varia acentuadamente desde a superfície, onde a temperatura é próxima da temperatura do ar, até uma profundidade da ordem dos 20 a 30 metros, mantendo-se constante para maiores profundidades, e o desfasamento da onda térmica anual da temperatura da água, em relação à temperatura do ar, aumenta com a profundidade.

A temperatura da água das albufeiras, nos aproveitamentos a fio de água, varia pouco com a profundidade.

2.6.4. Acções dinâmicas

As barragens de betão e os órgãos de segurança e exploração podem ser solicitados por acções dinâmicas de diversos tipos, nomeadamente por sismos, explosões, pelas vibrações resultantes do funcionamento das centrais e pelo funcionamento dos órgãos de descarga [Gomes 2006].

As acções sísmicas podem ser de origem tectónica ou induzidas² pela criação da albufeira. De uma forma geral, as barragens de betão resistem bem aos sismos, não havendo, até hoje, a registar roturas globais devidas a esta acção. No entanto, é de admitir que em casos de elevados valores das acelerações se dêem danos importantes, capazes de afectar a funcionalidade das obras.

Para caracterizar as acções sísmicas, principalmente em zonas com risco sísmico ou quando relativos a barragens de maior altura e importância estrutural, deve ser instalada uma rede de estações sísmicas distribuída ao longo de toda a zona de influência do conjunto barragem-fundação-maciço, tendo em consideração a caracterização sismo-tectónica da região.

2.7. Propriedades dos materiais

2.7.1. Caracterização da fundação

A construção de barragens de betão recai sobre fundações em maciços rochosos, como tal, a caracterização da fundação é efectuada a partir de estudos geológicos, geotécnicos e hidráulicos efectuados à matriz rochosa e ao maciço integrante da matriz, os quais são realizados antes da elaboração do projecto e visam a sua caracterização em termos de compartimentação, deformabilidade, resistência e permeabilidade, sendo um elemento importante da solução do projecto a adoptar. Para esta caracterização realizam-se ensaios *in situ* e de laboratório.

A informação então obtida é complementada durante a construção através de um levantamento pormenorizado de todos os acidentes ao longo da superfície de inserção, da realização de ensaios *in situ* e em laboratório, e da observação da resposta da fundação à instalação do peso próprio da barragem. É geralmente durante a fase

² Sismicidade induzida - A criação de albufeiras, principalmente as de grandes dimensões, alteram significativamente o equilíbrio de tensões existentes nos maciços rochosos que as suportam, podendo induzir o desenvolvimento de sismos.

construtiva que são definidas as obras de beneficiação das propriedades da fundação, sendo usualmente realizados ensaios de injeção de água para caracterizar a permeabilidade do maciço antes do início e no final destes trabalhos.

Antes e após o tratamento da fundação e posteriormente, de forma espaçada ao longo da vida das obras, devem ser realizados ensaios geofísicos, os quais permitem avaliar a evolução das características mecânicas do maciço, e ainda ensaios de permeabilidade, para avaliar a evolução das propriedades hidráulicas.

As análises das características físico-químicas da água da albufeira, das águas drenadas e dos materiais transportados permitem avaliar, ao longo do tempo, os fenómenos de alteração do maciço de fundação e o grau de deslçamento das cortinas [Farinha, 2000].

2.7.2. Caracterização do betão

Dado o grande volume de betão e o baixo nível de tensões de compressão existente nas barragens de betão, são utilizados betões com baixa dosagem de cimento e com agregados de dimensões máximas da ordem dos 150 mm, tendo em vista a libertação de menores quantidades de calor de hidratação e menores custos de produção. Este betão é designado por betão integral, sendo os ensaios para a avaliação das suas propriedades mecânicas efectuados em laboratório e *in situ*. Nos ensaios *in situ* utilizam-se, por exemplo, equipamentos específicos designados por células de fluência, embebidos no betão do núcleo durante a construção das obras, os quais permitem a determinação do módulo de elasticidade e das leis de fluência do betão [Pinho, 1989].

São também avaliadas as propriedades dos betões a partir de ensaios em provetes de betão crivado, que não é mais do que o betão obtido do betão integral retirando-lhe todos os agregados com dimensões superiores a 38 mm, obtendo-se assim provetes de menores dimensões, os quais podem ser ensaiados em máquinas de ensaios comuns.

Para a avaliação das propriedades mecânicas do betão crivado são realizados ensaios de determinação da resposta à acção de cargas rápidas e lentas de pequena intensidade e ensaios de determinação da relação tensões-deformações até a rotura.

De referir que não é usual a realização de ensaios de caracterização das propriedades térmicas, como a difusibilidade e a condutibilidade, e que ensaios de caracterização das propriedades hidráulicas, tais como a permeabilidade, apenas são comuns em barragens de betão compactado com cilindros, dadas as especificidades deste tipo de obras.

Os valores dos coeficientes de dilatação térmica linear dos betões integrais e crivados podem ser facilmente estimados a partir da evolução das extensões observadas nos extensómetros correctores.

2.8. Observação da resposta estrutural

As respostas estruturais usualmente observadas são os deslocamentos de pontos da estrutura e da fundação, os movimentos relativos entre blocos definidos por juntas ou por outras descontinuidades, as rotações, as tensões e as extensões [Castro, 1998].

2.8.1. Deslocamentos

Os deslocamentos, absolutos ou relativos, são usualmente determinados em pontos representativos do comportamento da barragem, da fundação e dos encontros, através de métodos geodésicos, fios de prumo e extensómetros de fundação.

Os deslocamentos verticais da estrutura podem ser medidos por nivelamento geométrico de precisão, em pontos localizados no coroamento ou nas galerias. O nivelamento geométrico de precisão consiste na determinação de diferenças de cotas entre pontos ligados à estrutura e pontos fixos (ou com deslocamentos conhecidos), com o recurso a equipamento adequado (níveis de precisão e miras de invar) [Gomes, 1986].

Os deslocamentos horizontais da estrutura são usualmente obtidos por métodos de geodesia de posição ou por fios de prumo.

O método geodésico mais utilizado nas barragens portuguesas é o da rede de triangulação exterior. As redes de triangulação exterior são constituídas por conjuntos de vértices, materializados por pilares com fundação adequada e por alvos de pontaria, colocados em pontos da estrutura e do maciço de fundação. A observação da rede consiste na medição dos valores angulares e lineares, de acordo com sequências e regras de operação previamente planeadas, utilizando equipamento adequado (teodolitos e distanciómetros de precisão). Os resultados obtidos são ajustados, validados e transformados em deslocamentos, de acordo com um modelo matemático apropriado.

Embora o *Global Positioning System* (GPS) se tenha vindo a impor como método de posicionamento em Geodesia, não existe muita experiência sobre o seu desempenho na monitorização de deslocamentos em grandes obras de engenharia. Actualmente,

estão a ser efectuados estudos em barragens de betão e de aterro, com o intuito de avaliar o potencial do GPS na observação deste tipo de obras [Lima, 2005].

Os fios de prumo são usualmente instalados em furos que atravessam o corpo da obra e materializam uma vertical, através de um aço de alta resistência, fixado num ponto a cota elevada da estrutura (fio de prumo direito), ou fixado num ponto profundo da fundação (fio de prumo invertido). No primeiro caso, o fio, tenso por acção de um peso de cerca de 600 N, permite obter nos pontos onde é acessível (galerias, plataformas, etc.) os deslocamentos do ponto de fixação em relação a esses pontos, isto é, deslocamentos relativos. No segundo caso, o fio, tenso por acção da impulsão da água contida num reservatório sobre um flutuador nela mergulhado, permite obter nos pontos onde é acessível os deslocamentos relativos ao ponto profundo da fundação que, desde que tal ponto seja considerado fixo, correspondem a deslocamentos absolutos.

Na estrutura são fixadas barras metálicas muito rígidas, de modo a poder estacionar sobre elas o dispositivo de medida amovível utilizado, o coordenómetro óptico, que permite obter as coordenadas rectangulares do fio no plano de medida.

A instalação dos fios de prumos no corpo da barragem é efectuada em zonas onde a informação é mais pertinente em termos de avaliação do comportamento, como, por exemplo, no caso das barragens tipo abóbada, próximo dos encontros, no fecho e nas zonas dos rins.



Fio de prumo direito e invertido



Base de coordenómetro



Coordenómetro óptico

Figura 2.7 – Fio de prumo

Os extensómetros de fundação (Figura 2.8), são utilizados na medição dos deslocamentos da fundação, sendo constituídos por uma vara instalada num furo na fundação ancorada a uma profundidade estabelecida. A leitura, efectuada com deflectómetros de precisão, corresponde à medição da distância entre a extremidade superior da vara e a cabeça de leitura fixa à estrutura (independente da vara). Admitindo que a vara não tem deformações próprias (térmicas ou devido a atritos ao longo do seu encamisamento), obtém-se assim, deslocamentos relativos entre os pontos das ancoragens e a referência fixada à estrutura. A instalação de várias varas no mesmo furo

seladas a diferentes profundidades permite a determinação de deslocamentos relativos entre os vários pontos de selagem.



Figura 2.8 – Cabeça de extensómetro de fundação

Quando colocados próximos dos fios de prumo invertidos permitem a obtenção das três componentes do deslocamento e consequentemente a avaliação dos movimentos da fundação.

Nos nossos dias são cada vez mais implementados nas barragens sistemas de recolha e transmissão automáticos, os quais permitem o registo automático com a frequência desejada das observações dos deslocamentos.

2.8.2. Movimentos de juntas e fissuras

O movimento relativo entre blocos é observado nas juntas de contracção com instrumentação embebida no betão ou à superfície.

No interior do betão, os deslocamentos relativos entre blocos são obtidos por medidores de movimento de juntas de resistência eléctrica embebidos no betão durante a construção da obra.

No que diz respeito à instrumentação à superfície, refira-se as bases de alongâmetro, que não são mais do que peças ancoradas na estrutura, perfazendo um triângulo equilátero. Com um alongâmetro é efectuada a medição de distâncias entre vértices (Figura 2.9), obtendo-se por cálculos geométricos o movimento de abertura e fecho das discontinuidades, assim como do deslizamento no plano do triângulo equilátero [INAG, 2001].



Roseta plana de bases



Utilização do alongâmetro

Figura 2.9 – Bases de alongâmetro

Outros instrumentos de medida à superfície são as bases tridimensionais que permitem as leituras da abertura e fecho de juntas e o deslocamento horizontal e vertical relativo das juntas.

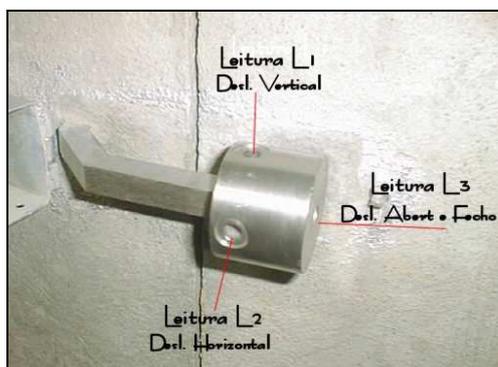


Figura 2.10 – Base tridimensional

A recolha das três componentes de deslocamento relativo atrás referidos pode ser também ser efectuada através de dispositivos de recolha automática instalados nos pontos desejados da obra.

2.8.3. Rotações

A determinação das rotações da base da barragem pode ser obtida a partir dos resultados da observação de extensómetros de fundação colocados em leques ou através da realização do nivelamento de pontos segundo secções transversais normais à base da barragem.

Outra forma possível de determinação das rotações é através de clinómetros de resistência eléctrica, embebidos no betão ou fixados em nichos em galerias, ou mesmo no coroamento, desde que convenientemente protegidos, e que constam de um

transdutor sensível à inclinação de um fio capaz de produzir um sinal eléctrico proporcional ao ângulo de inclinação.

2.8.4. Tensões e extensões

A determinação do estado de tensão é feita, em regra, indirectamente, com extensómetros de resistência eléctrica embebidos durante a construção. A conversão em tensões é feita a partir do conhecimento das características de deformabilidade do betão crivado que envolve estes instrumentos.

A determinação directa de tensões por meio de tensómetros é menos usual, quer pelas dificuldades de instalação destes instrumentos, quer pelo seu preço. Os tensómetros permitem a medição de tensões de compressão, mas não de tracção. No entanto, se colocados em determinadas zonas, complementarmente a grupos de extensómetros, os tensómetros podem ser de grande utilidade na caracterização das relações tensões-deformações no betão [Farinha, 2000].

As tensões de compressão nas barragens abóbada, para cenários correntes, são em regra até cerca de 8 MPa, havendo mesmo algumas obras com valores na ordem dos 10 MPa. Em relação às tensões de tracção, os valores máximos são da ordem de 1 a 1,5 MPa. Estes valores, designadamente na compressão, são relativamente baixos, em relação às resistências. Dada a ordem de grandeza das tensões de tracção instaladas é habitual admitir-se apenas a possibilidade de ocorrência de roturas localizadas.

Em barragens abóbada, a análise de tensões tem uma importância acrescida por auxiliar na verificação das exigências de continuidade estrutural [Ramos, 2004].

2.8.5. Caudais

Também é importante a observação de caudais individuais em cada dreno (Figura 2.11), assim como a determinação de caudais em bicas totalizadoras em diferentes zonas da barragem, incluindo os caudais infiltrados pelo corpo da barragem.

A medição do caudal debitado por um dreno é efectuada de forma indirecta medindo o tempo que um determinado reservatório de volume conhecido demora a ser cheio.



Terminal de um dreno numa galeria de drenagem



Terminais de drenos no paramento de jusante

Figura 2.11 – Drenos

O controlo dos caudais drenados e infiltrados é de grande importância, sendo um dos principais elementos do controlo de segurança, uma vez que, em conjugação com os piezómetros, permite avaliar a eficiência dos sistemas de impermeabilização e drenagem da obra.

2.9. Erros na medição de grandezas

A medição de uma grandeza deve ter como objectivos adoptar um valor como melhor estimativa do verdadeiro valor da grandeza e dar alguma indicação sobre a imprecisão da medida [Lima, 2002].

Os erros de observação normalmente não obedecem a regras simples e podem ter várias causas. Os erros podem resultar do instrumento utilizado (por exemplo se a escala está descalibrada ou o zero da escala desajustado), da pessoa que faz a medição (por exemplo se o cronómetro é disparado demasiado tarde ou muito cedo), entre outros.

Uma forma de minimizar os erros de leitura é através do estabelecimento de procedimentos adequados de recolha de dados, por repetição, por verificação ou por aplicação de relações entre quantidades observáveis diferentes, calibrações periódicas e conservação adequada dos instrumentos [Berberan, 1995].

O valor de uma dada grandeza pode ser obtido de uma forma directa, quando o valor é dado pela leitura directa de um instrumento de medida (régua, manómetro, amperímetro, cronómetro, etc.) e de uma forma indirecta, quando o valor é obtido por cálculos a partir de outras grandezas medidas directamente (por exemplo, um caudal é determinado a partir das medidas directas do volume e do tempo), sendo que este

resultado não pode oferecer maior grau de confiança que qualquer dos resultados das medições directas efectuadas.

Uma quantificação aproximada da precisão obtida com alguns dos métodos ou equipamentos anteriormente referidos é apresentada no Quadro 2.2. As quantidades apresentadas englobam diversos factores que influenciam a precisão da medição, tais como precisão instrumental, métodos operativos, intervenção do operador, modelo funcional para o cálculo da grandeza e configuração do sistema, entre outros [Portela, 1999].

Quadro 2.2 – Alguns métodos ou equipamentos de medida e respectiva precisão, adaptado de [Portela, 1999]

Método ou equipamento de medida	Grandezas	Precisão Aprox.
Termómetro de máxima e mínima	Temperatura do ar	0,5 °C
Termómetro de resistência	Temperatura	0,5 °C
Medidor de nível	Nível da albufeira	0,01 m
	Nível da água a jusante	0,01 m
Fio de prumo	Deslocamento radial	0,2 mm
	Deslocamento tangencial	0,2 mm
Nivelamento	Deslocamento vertical	0,5 mm/km
Extensómetro de fundação	Deslocamento	0,01 mm
Dreno	Caudal	-
Piezómetro	Caudal	-
	Subpressão	0,1 bar
Base de alongâmetro	Abertura	0,02 mm
	Deslizamento numa direcção	0,02 mm
Base tridimensional	Abertura	0,01 mm
	Deslizamento em duas direcções	0,01 mm
Medidor de junta eléctrico	Temperatura	0,5 °C
	Abertura	- (*)
Extensómetro eléctrico	Temperatura	0,5 °C
	Extensão	- (*)
Tensómetro	Temperatura	0,5 °C
	Tensão	- (*)

Obs.: (*) Os equipamentos de resistência eléctrica têm uma precisão de 0,01 Ω .

2.10. Frequência das leituras e validação dos resultados

No Plano de Observação são indicadas as frequências das leituras durante as fases de construção, primeiro enchimento e exploração, bem como os critérios para a sua adaptação em caso de variação rápida das acções, ocorrências excepcionais ou circunstâncias anómalas, tendo em conta o tipo e dimensão da barragem, as características do local e os aspectos específicos da obra [NOIB, 1993].

Logo após a leitura e/ou antes de serem arquivadas, as leituras são validadas através de limites de validação, como forma de detecção de erros grosseiros. Os limites de validação das leituras são estabelecidos a partir das características dos próprios instrumentos, ou pelo histórico, através dos valores extremos eventualmente majorados segundo critérios físicos associados à previsível evolução das grandezas correspondentes.

A validação dos resultados é efectuada comparando-os com os valores previstos por modelos de comportamento. Sempre que se observem valores que se afastem significativamente dos previstos pelos modelos, deve ser efectuado um estudo das causas às quais pode ser atribuída a ocorrência desses valores, do que poderá resultar a reformulação do modelo e a conseqüente reavaliação das condições de segurança da obra.

2.11. Modelos e métodos de análise

Na representação de um fenómeno físico relativo a um determinado sistema³ podem ser utilizados modelos⁴ físicos, matemáticos ou híbridos de vários tipos, de acordo com os conhecimentos existentes sobre o fenómeno físico em causa, os meios disponíveis (materiais e humanos) e o fim pretendido.

A definição do modelo de um sistema consiste no estabelecimento de relações entre as principais componentes desse sistema – sinais de entrada, propriedades do sistema e sinais de saída – para representação dos aspectos relevantes do seu

³ Um sistema pode ser definido como um “conjunto ordenado de componentes ou objectos, físicos ou abstractos, de tal modo interligados e relacionados entre si, que constituem e actuam como um todo que desempenha uma determinada função” (Carvalho, 1989).

⁴ Um modelo é uma “representação, de uma forma utilizável, dos aspectos essenciais do comportamento de um dado sistema, existente ou em concepção” (Eykhoff, 1974).

comportamento. Em geral, conhecem-se os elementos correspondentes a dois destes três grupos e pretende-se determinar ou estimar elementos do terceiro [Castro, 1998].

Na engenharia de barragens o sistema é constituído pelo conjunto barragem-fundação-albufera. Em termos de comportamento estrutural, a avaliação das condições de segurança é efectuada a partir da comparação das observações efectuadas com os valores correspondentes determinados com base em modelos de previsão desse comportamento.

Os modelos apoiam-se em hipóteses simplificativas que são resultantes do tipo de análise a efectuar, sendo que no caso da análise das barragens de betão estão relacionadas com [Gomes, 2005]:

- as características geométricas das estruturas;
- o tipo de comportamento dos materiais (modelos com ou sem superfícies de descontinuidade, com comportamentos lineares e não-lineares, dependentes ou não do tempo, etc);
- as aproximações do comportamento estrutural (equilíbrios planos, tridimensionais e de casca);
- as ligações exteriores.

Os modelos físicos (Figura 2.12) são utilizados no estudo de um determinado fenómeno mecânico observável num protótipo. Os correspondentes métodos experimentais requerem a satisfação da teoria da semelhança, com implicações na escolha dos materiais do modelo, do sistema de carga, dos sistemas de medição das grandezas físicas e na interpretação dos resultados [Gomes, 2005].



Figura 2.12 – Modelo em argamassa, para ensaio à rotura

A utilização de modelos matemáticos para a interpretação do comportamento das obras tem-se vindo a generalizar desde o desenvolvimento de métodos numéricos e dos meios de cálculo necessários à resolução de grandes sistemas de equações.

Na fase de projecto destaca-se a utilização de modelos baseados no método dos elementos finitos (Figura 2.13). No entanto, podem também ser utilizados outros métodos como por exemplo o método dos elementos discretos, o método dos elementos de fronteira, o método das diferenças finitas, etc.

Hoje em dia estes modelos são também de grande utilidade na interpretação do comportamento das obras ao longo de toda a sua vida útil.

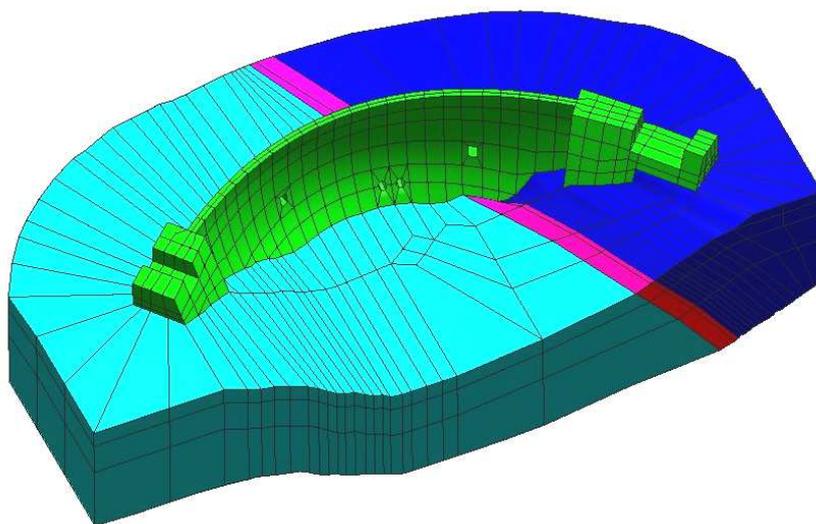


Figura 2.13 – Malha de um modelo de elementos finitos

Durante a fase de exploração da obra, é também comum o recurso a modelos de retroanálise, assim chamados porque se baseiam no tratamento dos resultados da observação.

Os modelos de retroanálise de utilização mais generalizados são os modelos de interpretação quantitativa, os quais se baseiam no estabelecimento de relações funcionais entre as principais acções e as respostas das estruturas a partir da análise dos resultados da observação (Figura 2.14). A descrição deste tipo de modelos é efectuada no item 2.12.

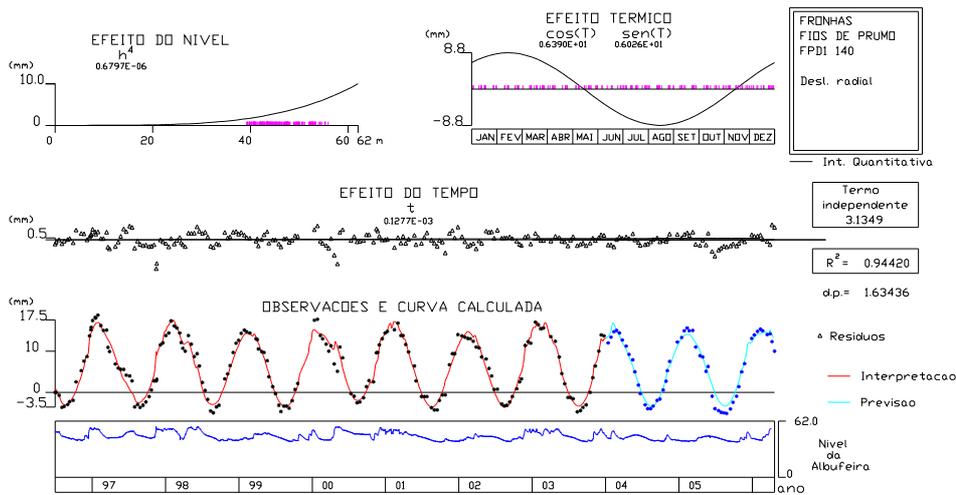


Figura 2.14 – Resultado de um modelo de interpretação quantitativa

Neste mesmo grupo podem ser incluídas as redes neuronais. A criação destes tipos de modelos tem por base a definição de arquiteturas de redes neuronais (Figura 2.15) que poderão ser ensinadas a partir das observações das acções e das respostas da estrutura em análise. O principal objectivo do presente trabalho é a aplicação de redes neuronais artificiais do tipo Perceptrão Multicamada, sendo este tipo de modelos abordado em detalhe nos Capítulos 3 e 4.

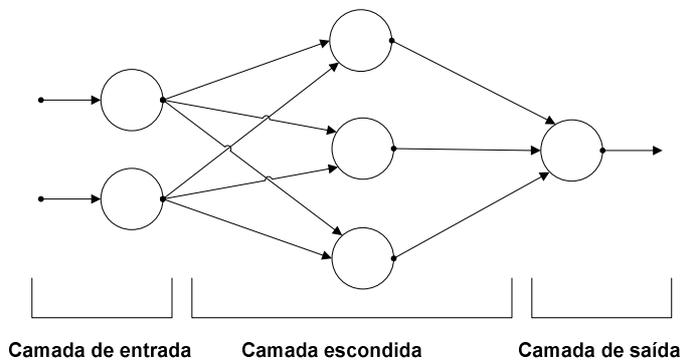


Figura 2.15 – Arquitectura de uma rede neuronal do tipo Perceptrão Multicamada

Um aspecto importante que se deve ter em atenção na análise e interpretação de cada modelo é que eles são elaborados, calibrados e validados a partir de um conjunto de variáveis que pertencem a um domínio de escala e de tempo específicos. Toda a extrapolação dos resultados do modelo fora do seu domínio de validação, deve ser efectuada de forma crítica, no sentido de perceber se existe alguma coerência nas correlações das variáveis.

Uma vez aceite um determinado modelo, é possível verificar se o comportamento observado da estrutura é adequado ou se, pelo contrário, existe alguma alteração neste

comportamento, o qual poderá indicar a necessidade de um estudo mais aprofundado por forma a perceber as causas, sua eventual evolução e potenciais consequências. É nesta perspectiva que a elaboração de modelos, mesmo que com alguma redundância, é indispensável para o controlo de segurança das obras.

No âmbito deste trabalho, apenas serão utilizados os modelos de interpretação quantitativa e de redes neuronais artificiais do tipo Perceptrão Multicamada.

Uma das aplicações mais interessantes das redes neuronais é na análise dos resultados dos sistemas de recolha automática. No entanto, tratando-se do primeiro estudo neste domínio, optou-se pela análise dos resultados provenientes dos instrumentos de recolha manual:

- de forma a evitar nesta fase, os problemas relacionados com a gestão da informação dos sistemas de recolha automática de dados, e;
- porque nestes casos, existe já uma larga experiência consolidada na utilização de modelos de interpretação quantitativa que se considera muito importante para a validação dos modelos de redes neuronais que se propõem.

2.12. Métodos de interpretação quantitativa

2.12.1. Introdução

As respostas do sistema barragem-fundação devem-se à actuação simultânea de um conjunto de acções, entre os quais se destacam a variação do nível da água na albufeira e as variações de temperatura.

A separação das parcelas relativas a cada uma das solicitações é bastante útil do ponto de vista da interpretação do comportamento observado e, portanto, do controlo de segurança. Embora esta separação possa ser obtida através da comparação dos resultados em duas épocas, em que se verifique apenas a variação predominante de uma das solicitações, a forma mais geral de separar os efeitos de cada solicitação consiste na utilização de métodos designados por interpretação quantitativa de resultados.

Estes métodos têm como objectivo identificar um modelo de comportamento, com base na história de obra, o qual se traduz numa relação estatística entre as principais

variáveis ambientais (nível da água na albufeira e variações térmicas) e o efeito do tempo e as grandezas observadas.

Os métodos estatísticos podem ser utilizados em modelos de comportamento representados por expressões analíticas paramétricas [Gomes, 1981], em que as relações entre a variação de cada solicitação e a correspondente resposta são previamente definidos, com base em experiência adquirida, e cujos parâmetros resultam de relações estatísticas entre as observações efectuadas às respostas e às acções predominantes.

Os parâmetros assim obtidos, embora não tenham significado físico em si próprios, representam em conjunto o comportamento estrutural das obras.

De uma forma genérica, pode-se estimar o valor de uma dada grandeza a partir da relação linear

$$U = \sum_{j=1}^P X_j \cdot \beta_j + k + \varepsilon \quad (1)$$

onde

- U – valor observado da grandeza em análise;
- X_j – $j^{\text{ésimo}}$ termo associado às acções (de um total de P termos);
- β_j – coeficiente correspondente ao termo X_j ;
- k – constante que corresponde à diferença entre os valores observados e os calculados no início do período de calibração;
- ε – resíduo da observação, dado pela diferença entre o valor estimado e o valor observado.

Os coeficientes β_j são obtidos através da aplicação do método dos mínimos quadrados durante um período de calibração previamente estabelecido, ou seja, aplica-se a expressão (1) a um grande número de observações (onde são também conhecidos os termos associados às acções), fazendo-se posteriormente uma minimização do somatório dos quadrados da diferença entre os valores previstos e os observados [Swiss Committee on Dams, 2003].

A concretização deste modelo pressupõe a admissão de um conjunto de hipóteses [Gomes, 1981]. Em primeiro lugar referem-se as duas hipóteses de carácter geral:

- os efeitos analisados dizem respeito a um período relativamente ao qual não há modificações estruturais sensíveis da obra (embora se possam admitir, em certos modelos, variações das propriedades dos materiais ao longo do tempo);
- para condições de exploração normal as solicitações predominantes são as variações das pressões da água e da temperatura. A primeira hipótese justifica-se pelo facto de as restantes solicitações, ou estão relacionadas com as solicitações predominantes (como é o caso das subpressões) ou provocam efeitos cuja separação seria inviável face às ordens de grandeza dos erros de observação e aos erros de adequação dos próprios modelos.

Outras hipóteses são, no entanto, necessárias, admitindo-se que:

- as grandezas representativas do comportamento estrutural (deslocamentos, extensões e tensões), em condições de exploração normal, podem decompor-se em duas parcelas independentes, uma de natureza elástica (reversível e instantânea), provocada fundamentalmente pelas variações da pressão hidrostática e da temperatura, e outra considerada apenas função do tempo;
- os efeitos das variações da pressão hidrostática e da temperatura podem ser estudados separadamente, sendo válido o princípio da sobreposição de efeitos.

Em relação à primeira hipótese, os efeitos ditos do tempo são considerados independentes da variação das principais solicitações, o que corresponde a uma aproximação, uma vez que uma parte destes efeitos depende da história das solicitações. É o caso, por exemplo, dos efeitos resultantes da fluência do betão, que estão intimamente relacionados com a evolução das acções da água. Por outro lado, parte dos “efeitos do tempo” são reversíveis, uma vez que as componentes viscoelásticas são recuperáveis, total ou parcialmente, na ausência das solicitações que as originam. No entanto, nas condições normais de exploração das barragens de betão, estes métodos conduzem a resultados satisfatórios na separação dos efeitos observados desde que não se verifiquem variações muito significativas das solicitações actantes, nomeadamente da pressão hidrostática.

Em relação à segunda hipótese, ela equivale à consideração de um comportamento linear para os materiais e para a estrutura, o que, para o nível de tensões nas barragens de betão em condições de serviço, também é razoável [Castro, 1998].

2.12.2. Modelos de interpretação quantitativa utilizados no controlo de segurança de barragens

Os métodos estatísticos baseiam-se na determinação dos parâmetros de um modelo de comportamento que, para cada efeito observado, relaciona as observações das solicitações predominantes – pressão hidrostática e variações de temperatura – com a grandeza observada [Gomes, 1981].

Este método é geral e aplicável a vários tipos de grandezas desde que se respeitem as hipóteses referidas anteriormente. No entanto, é indispensável existir um número suficiente de observações, para que o tratamento estatístico cubra as variações usuais das acções.

Refira-se que os métodos estatísticos são apenas aplicáveis em casos onde estas funções são capazes de reproduzir o verdadeiro comportamento da grandeza. Por isso, as observações devem respeitar a períodos durante os quais não ocorram alterações estruturais importantes. No entanto, são admissíveis variações de certas propriedades dos materiais ao longo do tempo, o que equivale a admitir que as respostas previstas correspondem a valores médios dos parâmetros relativos ao comportamento reológico durante o período em análise [Castro, 1998].

Em geral, os modelos utilizados na previsão de uma determinada grandeza, para os diversos efeitos associados a uma dada época de observação i e num determinado ponto, estão relacionados por uma expressão do tipo

$$U(h_i, \theta_i, t_i) = U_h(h_i) + U_\theta(\theta_i) + U_t(t_i) + k + \varepsilon_i \quad (2)$$

em que

- | | |
|--|---|
| $U(h_i, \theta_i, t_i)$ | – valor observado da grandeza em análise na observação i , que depende da pressão hidrostática, da temperatura e do instante em que se realiza a observação; |
| $U_h(h_i), U_\theta(\theta_i), U_t(t_i)$ | – são, respectivamente, as parcelas daquela grandeza correspondentes ao efeito elástico do nível de água na albufeira, ao efeito elástico da temperatura e ao “efeito do tempo” na $i^{\text{ésima}}$ observação; |
| k | – constante que corresponde à diferença entre valores observados e calculados no início do período de calibração; |
| ε_i | – resíduo da $i^{\text{ésima}}$ observação, dado pela diferença entre o valor estimado e o valor observado. |

Em condições de exploração normal, em que são bem conhecidas as variações das solicitações principais, uma grande parte dos “efeitos do tempo” pode ser justificada pelo comportamento diferido do betão. Assim, a expressão (2) do comportamento de uma determinada grandeza pode ser descrita por

$$U(h_i, \theta_i, t_i) = \sum_{j=1}^{p_1} a_j \cdot f_j(h_i) + \sum_{j=p_1+1}^{p_2} b_j \cdot g_j(\theta_i) + \sum_{j=p_2+1}^P c_j \cdot q_j(t_i) + k + \varepsilon_i \quad (3)$$

onde

- $f_j(\)$ – $j^{\text{ésima}}$ função de aproximação para o efeito do nível da água na albufeira;
- $g_j(\)$ – $j^{\text{ésima}}$ função de aproximação para o efeito da temperatura;
- $q_j(\)$ – $j^{\text{ésima}}$ função de aproximação para o “efeito do tempo”;
- a_j, b_j, c_j – coeficientes a ajustar.

Cada uma das parcelas de (3) pode ser aproximada por um somatório de funções do nível da água na albufeira, da temperatura e do tempo, respectivamente. Seguidamente são apresentadas as funções de aproximação habitualmente utilizadas para representar os efeitos associados a cada uma das principais acções.

2.12.3. Efeito do nível da água na albufeira

Em geral, os efeitos do nível da água podem ser associados a funções polinomiais. As funções de aproximação mais utilizadas são

$$U_h(h) = a_1 \cdot h^4 + a_2 \cdot h^3 + a_3 \cdot h^2 + a_4 \cdot h \quad (4)$$

sendo

- h – altura de água na albufeira (m);
- a_1, a_2, a_3, a_4 – coeficientes a ajustar.

2.12.4. Efeito da temperatura

Os efeitos térmicos mais importantes podem ser relacionadas directamente com as variações da temperatura do ar, caracterizadas fundamentalmente por ondas de período anual e diário. Assim, a evolução dos efeitos térmicos pode ser considerada como a sobreposição de dois tipos de funções periódicas, uma de período anual e outra de período diário. A onda térmica anual pode ser caracterizada por (5),

$$U_{\theta}^{anual}(\theta_1) = b_1 \cdot \cos(\theta_1) + b_2 \cdot \sin(\theta_1) + b_3 \cdot \sin^2(\theta_1) + b_4 \cdot \cos(\theta_1) \cdot \sin(\theta_1) \quad (5)$$

com

$$\theta_1 = \frac{2 \cdot \pi \cdot t_d}{365} \quad 1 \leq t_d \leq 365 \quad (6)$$

De forma similar, tem-se para a onda térmica diária (7),

$$U_{\theta}^{diária}(\theta_2) = b_5 \cdot \cos(\theta_2) + b_6 \cdot \sin(\theta_2) + b_7 \cdot \sin^2(\theta_2) + b_8 \cdot \cos(\theta_2) \cdot \sin(\theta_2) \quad (7)$$

com

$$\theta_2 = \frac{2 \cdot \pi \cdot t_m}{1440} \quad 1 \leq t_m \leq 1440 \quad (8)$$

resultando de (5) e de (7),

$$U_{\theta}(\theta_1, \theta_2) = b_1 \cdot \cos(\theta_1) + b_2 \cdot \sin(\theta_1) + b_3 \cdot \sin^2(\theta_1) + b_4 \cdot \cos(\theta_1) \cdot \sin(\theta_1) + \\ + b_5 \cdot \cos(\theta_2) + b_6 \cdot \sin(\theta_2) + b_7 \cdot \sin^2(\theta_2) + b_8 \cdot \cos(\theta_2) \cdot \sin(\theta_2) \quad (9)$$

em que

- t_d – número de dias decorridos desde o início do ano até à data da observação;
- t_m – número de minutos decorridos desde o início do dia até à observação;
- $b_1, b_2, b_3, b_4,$ – coeficientes a ajustar.
- b_5, b_6, b_7, b_8

Em Portugal a onda térmica anual é a mais importante, sendo que os períodos mais frios e mais quentes são semelhantes, pelo que é possível utilizar apenas os dois primeiros termos.

2.12.5. Efeito do tempo

Esta parcela engloba diversos efeitos que variam ao longo do tempo. Os mais significativos são os que se relacionam com os efeitos diferidos associados às acções elásticas (efeitos de fluência e/ou de relaxação do betão) e os que se relacionam com fenómenos evolutivos (processos de deterioração, como aqueles que se relacionam com as reacções expansivas).

$$U_t(t) = c_1 \cdot t^3 + c_2 \cdot t^2 + c_3 \cdot t + c_4 \cdot \ln\left(1 + \frac{t}{a}\right) \quad (10)$$

onde

- t – número dias entre a campanha e o início da análise⁵;
- a – número de dias entre o 1º enchimento e a data do início da análise;
- c_1, c_2, c_3, c_4 – coeficientes a ajustar.

2.12.6. Constante k

A constante k corresponde à diferença entre valores observados e calculados no início do período de calibração.

2.12.7. Estimativa dos parâmetros: Regressão múltipla pelo método dos mínimos quadrados

Os coeficientes a_j , b_j e c_j são determinados através da resolução pelo método dos mínimos quadrados de um sistema de N equações, em que N é o número de observações seleccionadas para a análise.

De uma forma geral, um dado modelo de previsão do comportamento de uma determinada grandeza Y pode ser descrita por (11) [Swiss Committee on Dams, 2003],

$$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_j \cdot X_j + \dots + \beta_P \cdot X_P + \varepsilon \quad (11)$$

onde P é o número de variáveis independentes ($P+1$ é o número de parâmetros livres), X_j é a $j^{\text{ésima}}$ variável independente, β_j ($j=0, \dots, P$) é o $j^{\text{ésimo}}$ parâmetro desconhecido e ε é o resíduo associado a cada componente de observação.

Considerando, como hipótese, que se utilizam como termos das variáveis independentes h^4 , $\sin(\theta_1)$, $\cos(\theta_1)$ e $\ln\left(1 + \frac{t}{a}\right)$, tem-se, por exemplo,

$$P = 4, \beta_0 = k, \beta_1 = a_1, \beta_2 = b_1, \beta_3 = b_2, \beta_4 = c_4$$

$$X_1 = h^4, X_2 = \cos(\theta_1), X_3 = \sin(\theta_1), X_4 = \ln\left(1 + \frac{t}{a}\right)$$

⁵ O início da análise corresponde ao dia da primeira observação.

Escrevendo para cada campanha de observação i , uma expressão semelhante a (11), obtém-se o sistema de equações:

$$\begin{aligned} y_1 &= \beta_0 + \beta_1 \cdot x_{11} + \beta_2 \cdot x_{21} + \dots + \beta_P \cdot x_{P1} + \varepsilon_1 \\ y_2 &= \beta_0 + \beta_1 \cdot x_{12} + \beta_2 \cdot x_{22} + \dots + \beta_P \cdot x_{P2} + \varepsilon_2 \\ &\dots \\ y_N &= \beta_0 + \beta_1 \cdot x_{1N} + \beta_2 \cdot x_{2N} + \dots + \beta_P \cdot x_{PN} + \varepsilon_N \end{aligned} \quad (12)$$

Representando de forma matricial as equações anteriores, tem-se $\mathbf{Y} = \mathbf{X} \cdot \boldsymbol{\beta} + \boldsymbol{\varepsilon}$, em que

$$\mathbf{Y} = \begin{Bmatrix} y_1 \\ \cdot \\ \cdot \\ y_N \end{Bmatrix}, \quad \mathbf{X} = \begin{bmatrix} x_{11} & \cdot & x_{P1} & 1 \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ x_{1N} & \cdot & x_{PN} & 1 \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{Bmatrix} \beta_1 \\ \cdot \\ \beta_P \\ \beta_0 \end{Bmatrix}, \quad \boldsymbol{\varepsilon} = \begin{Bmatrix} \varepsilon_1 \\ \cdot \\ \cdot \\ \varepsilon_N \end{Bmatrix} \quad (13)$$

No método dos mínimos quadrados os valores dos parâmetros β_j são estimados de forma a minimizar o somatório dos quadrados dos resíduos, ou seja, de forma a minimizar a expressão seguinte [Draper e Smith, 1996],

$$\boldsymbol{\varepsilon}^T \cdot \boldsymbol{\varepsilon} = (\mathbf{Y} - \mathbf{X} \cdot \boldsymbol{\beta})^T \cdot (\mathbf{Y} - \mathbf{X} \cdot \boldsymbol{\beta}) \quad (14)$$

Se a matriz $\mathbf{X}^T \cdot \mathbf{X}$ for invertível, os valores estimados dos parâmetros β_j são dados por

$$\boldsymbol{\beta} = (\mathbf{X}^T \cdot \mathbf{X})^{-1} \cdot \mathbf{X}^T \cdot \mathbf{Y} \quad (15)$$

Com N observações ($N > P$) podem assim estimar-se os parâmetros desconhecidos β_j , onde ε_i é o resíduo da $i^{\text{ésima}}$ observação (diferença entre o valor estimado e o valor observado).

Refira-se novamente que é condição necessária que exista a matriz inversa $(\mathbf{X}^T \cdot \mathbf{X})$, isto é, que tenha determinante não nulo, que é equivalente a dizer que as colunas da matriz \mathbf{X} devem ser linearmente independentes. Além disso, tal como dito anteriormente, o número de observações (exemplos) disponíveis N deve ser superior ao número de parâmetros P a determinar.

De forma a melhorar a qualidade da regressão, as observações devem cobrir todas as combinações de valores que são esperadas para as variáveis, em particular do nível da água na albufeira e das ondas térmicas.

2.12.8. Campos de aplicabilidade

Na interpretação do comportamento das barragens de betão, as grandezas que usualmente são objecto da interpretação quantitativa são os deslocamentos, as extensões e as tensões.

A sua aplicação em movimentos relativos entre blocos, caudais e subpressões pode ser efectuada, mas de uma forma limitada.

Por exemplo, no caso de movimento relativo entre blocos há que ter em conta a falta da condição de correlação entre as variáveis quando a junta está fechada, isto é, os modelos só são válidos quando as juntas estão abertas.

No caso dos caudais e subpressões, devido à não linearidade das relações entre a variação das acções e das respostas, uma vez que a permeabilidade dos maciços depende do estado de tensão instalado, a utilização de métodos estatísticos, que admitem o princípio da sobreposição dos efeitos, não é teoricamente aceitável. Outra limitação a ter em conta é que frequentemente existe um desfasamento entre as acções e as correspondentes respostas, que usualmente não é tido em conta. No entanto, em casos particulares, em que a não linearidade e o desfasamento são pequenos, têm sido por vezes utilizados modelos de interpretação quantitativa com resultados aceitáveis.

2.12.9. Análise dos resultados

Como consequência da aplicação do método dos mínimos quadrados, a média dos resíduos é nula. As hipóteses assumidas para os resíduos podem ser verificadas graficamente ou por via numérica de análise dos resíduos.

O método dos mínimos quadrados apresenta uma boa estimativa nos casos onde as seguintes hipóteses relativamente aos resíduos, $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_N$, são verificadas [Swiss Committee on Dams, 2003]:

- os resíduos não apresentam nenhuma tendência, no sentido em que o valor esperado do erro é $E(\varepsilon_i) = 0$;

- os resíduos têm todos aproximadamente a mesma variância, isto é, $\text{var}(\varepsilon_i) = \sigma^2 = \text{constante}$;
- os resíduos não são correlacionáveis, isto é, $\text{cov}(\varepsilon_i, \varepsilon_j) = \text{corr}(\varepsilon_i, \varepsilon_j) = 0$ para $i \neq j$

Em relação à qualidade da regressão, esta pode ser avaliada de uma forma relativamente expedita a partir do coeficiente de determinação múltipla, R^2 , que é dado por

$$R^2 = \frac{\mathbf{b}^T \cdot \mathbf{X}^T \cdot \mathbf{Y} - N \cdot \bar{Y}^2}{\mathbf{Y}^T \cdot \mathbf{Y} - N \cdot \bar{Y}^2}, \text{ com } 0 \leq R^2 \leq 1 \quad (16)$$

em que a qualidade da regressão é tanto melhor quanto mais próximo da unidade for o coeficiente de determinação múltipla [Draper e Smith, 1996].

3. FUNDAMENTOS DAS REDES NEURONAIS ARTIFICIAIS

3.1. Introdução

Um dos objectivos da inteligência artificial é o desenvolvimento de ferramentas capazes de realizar tarefas cognitivas, as quais, até ao momento, só o homem realiza de uma forma mais eficaz. A inteligência artificial é uma área em desenvolvimento ramificada em diversas vertentes de investigação (Figura 3.1), dentro das quais se encontram as redes neuronais artificiais, os algoritmos genéticos, a lógica Fuzzy, os sistemas periciais e a robótica, entre outras.

Neste capítulo abordam-se as redes neuronais artificiais, dando a conhecer um pouco da sua história, evolução e funcionamento.

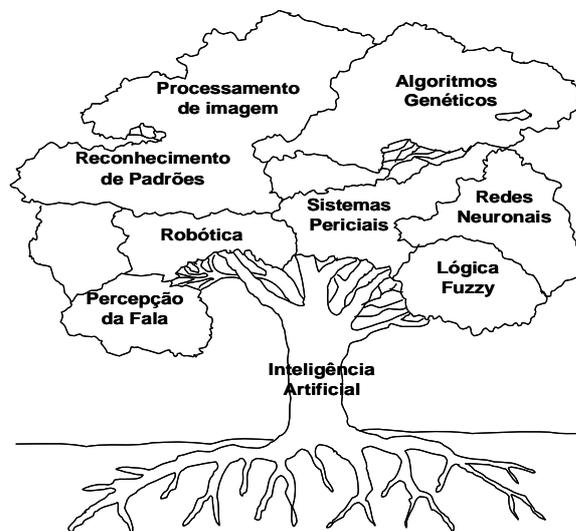


Figura 3.1 – Ramos da inteligência artificial

O interesse na pesquisa e estudo de sistemas de processamento paralelo de informação, como o caso de redes neuronais, pode ter sido originada pela necessidade ou motivação de resolver problemas que, dadas as suas características, não podiam ser resolvidos, ou o eram de forma insatisfatória, pelos sistemas “tradicionais” de Von Neumann, baseados em instruções sequenciais [Bharath e Drosen, 1994].

Os sistemas resultantes de processos sequenciais tendem a ser “quebradiços”, isto é, um contratempo aparentemente ligeiro pode resultar num fracasso catastrófico. Esta circunstância pode ser ilustrada pela história de um veículo espacial concebido para aterrar suavemente em Vénus debaixo da cobertura de nuvens, que caiu redondamente devido a uma vírgula mal colocada no programa. Pelo contrário, as ferramentas que usam representação distribuída tendem a degradar-se com mais elegância. O fracasso de um pequeno número de unidades resultará mais provavelmente numa degradação do desempenho do que num fracasso catastrófico [Franklin, 2000].

O cérebro humano constitui um sistema muito notável, sendo capaz de interpretar informação imprecisa, recolhida pelos sentidos, a uma velocidade impressionante. Por exemplo, uma criança pode facilmente distinguir a cara dos pais, quer em vários perfis como sob diferentes tonalidades de luz [Topping e Bahreininejad, 1997].

Outro exemplo interessante é a capacidade de reconhecer uma pessoa, numa conversa ao telemóvel, através da sua voz. O mais impressionante é que o cérebro aprende, sem instruções de nenhuma classe, a criar as representações internas que tornam possíveis estas capacidades.

Baseados na eficiência dos processos levados a cabo pelo cérebro e inspirados no seu funcionamento, vários investigadores têm vindo a desenvolver, há várias décadas, a Teoria das Redes Neurais Artificiais, as quais, em geral, pretendem simular as redes neuronais biológicas.

As redes neuronais artificiais proporcionaram uma alternativa à computação clássica para os problemas nos quais os métodos tradicionais não produzem resultados convincentes. A título exemplificativo, algumas aplicações frequentes são:

- processamento de imagem e voz;
- reconhecimento de padrões;
- previsão de séries temporais;
- optimização;
- aproximação de funções.

3.2. Breve caracterização biológica

O melhor sistema existente actualmente para a aprendizagem, reconhecimento de padrões e análise de imagens continua a ser o cérebro, tornando-se por isso normal o interesse e a motivação na tentativa de caracterizar a sua estrutura de funcionamento.

Dada a complexidade do sistema em análise, têm sido elaborados modelos simplificados de forma a compreender cada vez melhor o seu funcionamento. No entanto, a forma exacta de como o cérebro funciona continua a ser um dos grandes mistérios da ciência [Russell e Norvig, 1995].

Seguidamente apresenta-se uma breve introdução sobre os fundamentos biológicos e sobre os elementos necessários à compreensão da anatomia (estrutura) e fisiologia (funcionamento) dos neurónios biológicos que serviram de inspiração às primeiras redes neuronais artificiais.

O sistema nervoso actua em conjunto com o sistema endócrino no controlo do corpo.

Controlo do corpo { Sistema nervoso → Contração muscular, fala
Sistema Endócrino → Metabolismo

O sistema nervoso obtém informações do meio ambiente através de sensores que combinados com informações armazenadas resultam em acções do corpo.

Informações sensoriais }
Informações armazenadas } Sistema Nervoso → Acções
(hereditárias/aprendidas) } (Respostas do corpo)

Apenas uma pequena parte das informações obtidas é relevante para o funcionamento do corpo [Bauchspiess, 2004].

Para se ter uma ideia da complexidade do cérebro humano, estima-se que tenha cerca de 10^{11} neurónios, cujo comprimento total somado chega a 10^{14} metros [Bauchspiess, 2004].

O tamanho e a forma dos neurónios são variáveis, tendo as três subdivisões que mostra a Figura 3.2: o corpo central, as dendrites e o axónio.

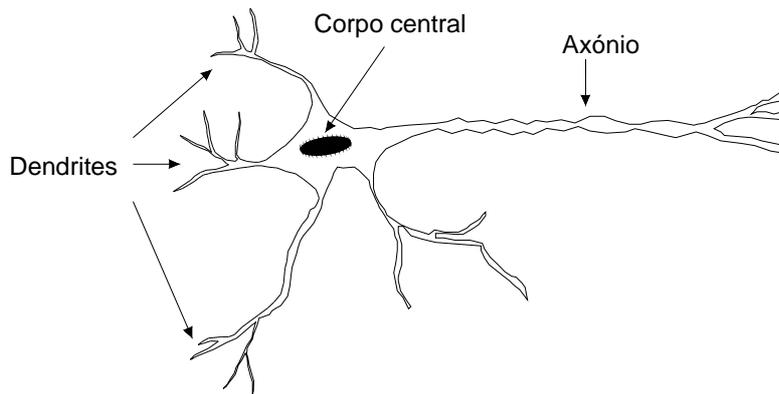


Figura 3.2 – Esquema de um neurónio biológico

O **corpo central** contém o núcleo. Esta parte encarrega-se de todas as actividades metabólicas do neurónio e recebe a informação de outros neurónios.

As **dendrites** estão ligadas ao corpo central e têm ramificações. São os elementos encarregues da recepção de sinais de outros neurónios, através das ligações sinápticas. Ou seja, pode-se dizer que as dendrites são as ligações de entrada do neurónio.

O **axónio** é a “saída” do neurónio e é utilizado para enviar impulsos ou sinais a outros neurónios. Quando o axónio está próximo das suas células de destino, divide-se em muitas ramificações que formam sinapses com as dendrites de outros neurónios.

De uma forma geral, pode dizer-se que as **dendrites** funcionam como receptores dos sinais/estímulos de entrada de cada neurónio. Posteriormente ocorre um processamento no corpo central dos estímulos de entrada, produzindo um impulso eléctrico que se propaga através de um longo canal de saída, o **axónio**, caso a soma das entradas seja maior que um certo limiar. A propagação do sinal é efectuada então pelo axónio até as **sinapses** dos neurónios que lhe estão associados. O fluxo de informação é sempre das dendrites para o axónio.

As **sinapses** são as ligações entre os axónios e as dendrites e podem ser classificadas como excitadoras ou inibidoras conforme a intensidade do estímulo nas dendrites que lhe estão ligadas seja aumentada ou diminuída, respectivamente.

A propagação dos sinais de um neurónio para outro por meio das sinapses é efectuada através de uma complicada reacção electroquímica [Russell e Norvig, 1995], no qual são libertadas substâncias transmissoras do lado do emissor da união. O efeito é o de aumentar ou diminuir o potencial eléctrico dentro do corpo do neurónio receptor.

Se o potencial acumulado no corpo central atinge um determinado limiar, é enviado um impulso, ou potencial de acção pelo axónio. Diz-se então que o neurónio atingiu o **limiar de disparo**.

3.3. Modelo básico do neurónio artificial

Na Figura 3.3 apresenta-se a estrutura de um neurónio artificial típico. Em termos de funcionamento, pode descrever-se [Turban e Aronson, 1997]:

- os neurónios contêm ligações, às quais são atribuídos **pesos** que indicam qual a influência da **entrada** respectiva no sinal de saída;
- os valores de entrada e o limiar de disparo⁶ são combinados através de uma **regra de propagação** (em geral, uma soma ponderada dada por $s = \sum_{i=0}^N w_i \cdot x_i$, com $x_0 = 1$), sendo depois transferido o resultado para uma **função de activação** que fornece o valor de **saída** do neurónio ($y = f(s)$).

As redes neuronais artificiais resultam de ligações de vários neurónios, sendo os pesos ajustados de forma a melhorar o desempenho da rede para o conjunto de exemplos apresentados.

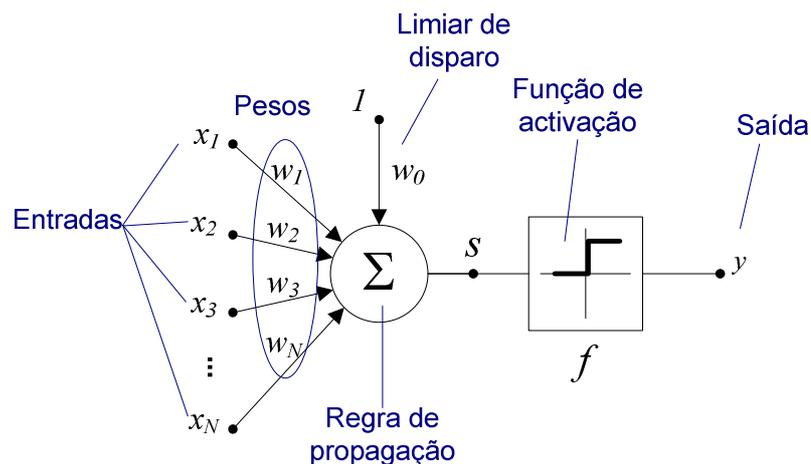


Figura 3.3 – Diagrama esquemático de um neurónio genérico

⁶ O efeito do limiar de disparo equivale a provocar uma translação da função de activação ao longo do eixo das abcissas.

3.4. Perspectiva histórica das redes neuronais artificiais

Na Figura 3.4 é apresentada a evolução cronológica do desenvolvimento das redes neuronais artificiais desde as suas origens até à actualidade.

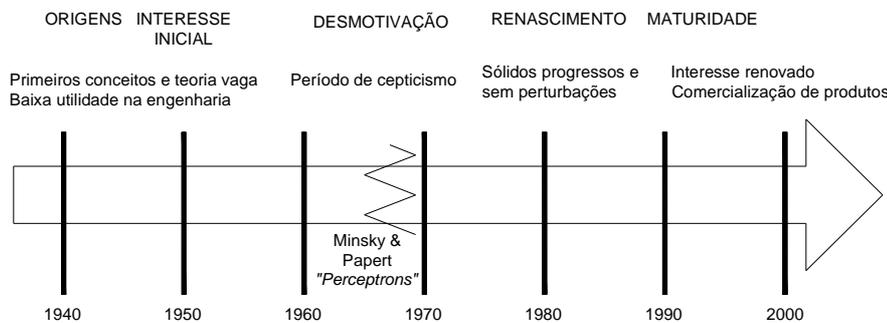


Figura 3.4 – Evolução cronológica do desenvolvimento das redes neuronais artificiais [Patterson, 1996]

De seguida são apresentados os acontecimentos que influenciaram directamente as redes neuronais do tipo Perceptrão Multicamada.

3.4.1. Modelo de McCulloch e Pitts

Resultante dos conhecimentos adquiridos no campo da biologia, a motivação para o desenvolvimento na área da inteligência artificial foi notória. No entanto, as descobertas mais importantes só foram conseguidas após a introdução dos neurónios simples de Warren McCulloch e Walter Pitts, em 1943.

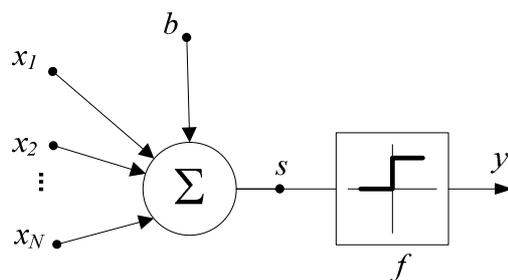


Figura 3.5 – Modelo simplificado do neurónio de McCulloch e Pitts

Estes autores propuseram uma teoria de processamento de informação baseada em elementos muito simples de decisão binária, **neurónios**. Não propuseram, no entanto, a definição de pesos nas ligações dos neurónios. Assim, o neurónio de McCulloch e Pitts (Figura 3.5) pode ser descrito como uma unidade elementar de

processamento, sendo constituído por um conjunto de N ligações de entrada, um limiar de disparo b , e uma ligação de saída y , expressa por

$$y = f \left(\sum_{i=1}^N x_i - b \right) \quad (17)$$

em que

- N – número total de entradas;
- y – saída do neurónio
- $f ()$ – função escalão unitário;
- x_i – entrada i (1 activo, 0 inactivo);
- b – limiar de disparo.

O limiar de disparo é um parâmetro que permite a deslocação da função de activação $f ()$ ao longo do eixo das abcissas.

3.4.2. Sínapse de Hebb

Em 1949, Donald Hebb descreveu no seu livro “Organization of Behaviour” as alterações que ocorriam num neurónio durante a aprendizagem de um animal [Caudill e Butler, 1992]. Por analogia, a regra consistia na aprendizagem por alteração da sinapse, afirmando que se um neurónio contribui de forma significativa para a activação de um outro neurónio, então a influência do peso da sinapse da ligação deve ser proporcionalmente superior, ou seja, o seu contributo na resposta final deve ser reforçada [Kröse e Smagt, 1993].

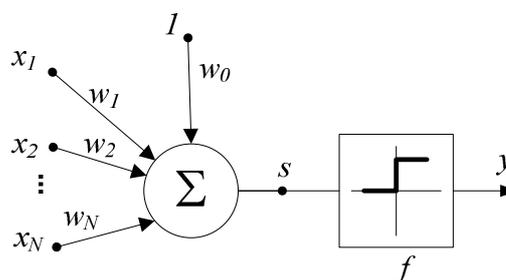


Figura 3.6 – Esquemas de neurónios com N entradas e com função de activação escalão unitário

Dada a configuração do neurónio, existem $N+1$ parâmetros ajustáveis: N pesos das sinapses das ligações de entrada, w_i , com $i = 1, \dots, N$ e o limiar de disparo.

Geralmente o limiar de disparo é substituído pela introdução de uma entrada suplementar de valor unitário, em que o peso da ligação correspondente, w_0 , toma o valor desse limiar.

O **valor da activação** de um neurónio, s , obtém-se utilizando uma regra de propagação (usualmente dado por $s = \sum_{i=0}^N w_i \cdot x_i$ com $x_0 = 1$), sendo o argumento da função de activação $f(s)$.

O conceito da alteração do peso da sinapse na contribuição para a activação de outro neurónio correspondeu a uma primeira regra de aprendizagem por modificação das sinapses. Este princípio ficou conhecido por Regra de Aprendizagem de Hebb ou Sinapse de Hebb.

A explicação matemática desta regra de aprendizagem não foi então formulada. A sua aplicação a uma sinapse pode ser descrita por (18),

$$\Delta w_i = \eta \cdot x_i \cdot y \quad (18)$$

onde

- Δw_i – variação do peso na ligação da entrada i ;
- η – passo da adaptação;
- x_i – valor da entrada i ;
- y – valor de saída do neurónio.

O **passo da adaptação**, η , é um parâmetro positivo não nulo. Se num determinado momento o neurónio está no estado activo e o neurónio que lhe está ligado à sua entrada i , também está activo, então o peso da junção sináptica da ligação entre estes neurónios é aumentado de Δw_i . Ou seja, a actualização do peso da ligação será dada por

$$w_{i,n+1} = w_{i,n} + \Delta w_{i,n} \quad (19)$$

em que

- n – número da iteração;
- $w_{i,n}$ – peso na ligação da entrada i , na iteração n ;
- $\Delta w_{i,n}$ – variação do peso na ligação da entrada i , na iteração n .

3.4.3. Perceptrão de Rosenblatt

Frank Rosenblatt, em 1958, introduziu um modelo computacional semelhante ao de McCulloch e Pitts, também com saídas binárias, apresentando uma função escalão na saída $\{0,1\}$ ou uma função escalão simétrica na saída $\{-1,1\}$, o **Perceptrão** (Figura 3.7). O mais importante é que apresentou um algoritmo iterativo para a obtenção dos pesos sinápticos e provou um teorema acerca da convergência do Perceptrão [Patterson, 1996].

Os pesos nas ligações apenas são alterados quando, para um dado padrão de entrada, a saída é errada. O modelo designado por Perceptrão foi testado não apenas para entradas binárias mas também para entradas analógicas.

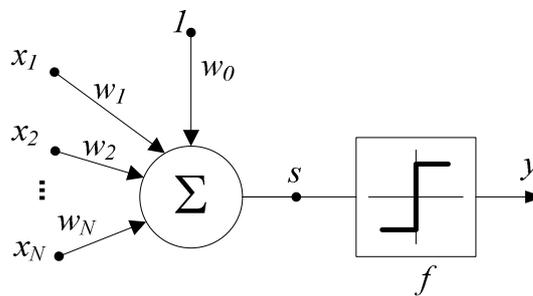


Figura 3.7 – Modelo do Perceptrão de Rosenblatt

3.4.3.1. Teorema da convergência do algoritmo de aprendizagem

O teorema da convergência do algoritmo de aprendizagem pode ser formulado da seguinte forma: “se existir um conjunto de pesos que classifique correctamente todos os padrões do conjunto de entrada, então o algoritmo é capaz de determinar um conjunto de pesos num número finito de iterações, de forma a obter uma classificação correcta de todos os padrões de treino.” [Minsky, 1969]. De referir que é considerado como hipótese que o conjunto de padrões de entrada é um conjunto finito e que o passo de adaptação, η , é suficientemente pequeno.

3.4.3.2. Regra de aprendizagem

A regra de aprendizagem no Perceptrão apresenta uma aprendizagem que não modifica os pesos das ligações cujos neurónios respondam correctamente, podendo ser apresentada pela seguinte expressão,

$$w_{i,n+1} = w_{i,n} + \Delta w_{i,n} \quad (20)$$

em que

$$\Delta w_{i,n} = \begin{cases} -\eta \cdot x_i & \text{se } y_n > d \\ 0 & \text{se } y_n = d \\ \eta \cdot x_i & \text{se } y_n < d \end{cases} \quad (21)$$

$y_n, d \in \{-1, 1\}$

com

- y_n – valor obtido na saída do neurónio, na iteração n ;
- d – valor desejado da saída do neurónio.

3.4.3.3. Limitações

No modelo de funcionamento do Perceptrão, a classificação correcta de todos os padrões de entrada (exemplos) pressupõe que o espaço de padrões seja linearmente separável. A fronteira de decisão é definida por

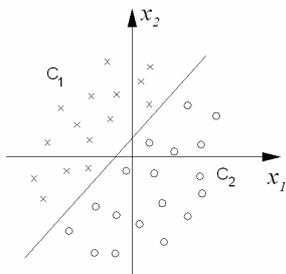
$$w_0 + \sum_{i=1}^N w_i \cdot x_i = 0 \quad (22)$$

De forma a exemplificar o conjunto de validade a que o Perceptrão pode ser aplicado com sucesso, é apresentada em (23) a fronteira de decisão para problemas em que $N = 2$,

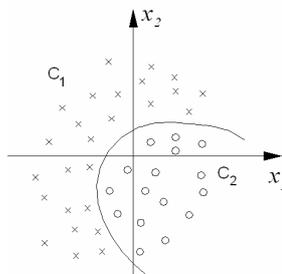
$$w_1 \cdot x_1 + w_2 \cdot x_2 = -w_0 \rightarrow x_2 = -\frac{w_1}{w_2} x_1 - \frac{w_0}{w_2} \quad (23)$$

assim, mostra-se graficamente, através da Figura 3.8, a aplicabilidade e as limitações do modelo Perceptrão.

Problema linearmente separável



Problema não linearmente separável



Problema não separável

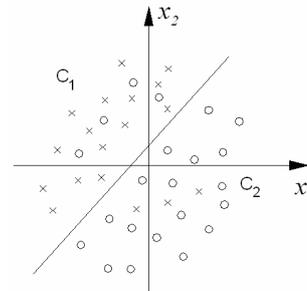


Figura 3.8 – Separabilidade de classes

3.4.4. ADALINE

Ao mesmo tempo que Frank Rosenblatt trabalhava no modelo Perceptrão, Bernard Widrow e o seu estudante Marcian Hoff estudavam um novo modelo. Assim, em 1960, introduziram o modelo ADALINE e a regra de aprendizagem chamada LMS (Least Mean Square) [Kröse e Smagt, 1993].

A ADALINE (Figura 3.9) é semelhante ao Perceptrão, excepto na sua função de activação, a qual é uma função do tipo linear em vez de uma função escalo como no Perceptrão.

A ADALINE apresenta a mesma limitação do Perceptrão no que diz respeito ao tipo de problemas que podem ser resolvidos, uma vez que ambos apenas podem resolver problemas linearmente separáveis.

Em relação à actualização dos pesos, a ADALINE utiliza uma regra de aprendizagem mais potente que a regra de aprendizagem do Perceptrão já que minimiza o erro quadrático à saída da unidade linear. Esta regra serviu de inspiração no desenvolvimento de outros algoritmos, sendo esse um dos grandes contributos deste tipo de redes.

Tendo em conta que o erro quadrático exibido por uma ADALINE é uma hiper-superfície no espaço definido por todos os parâmetros adaptáveis (isto é, pesos), então uma das formas de o minimizar pode ser seguindo a direcção correspondente à máxima derivada direcional do erro, ou seja, o gradiente.

É sabido que esta forma de procura encontra mínimos das referidas hiper-superfícies, do que podem resultar soluções sub-óptimas. Contudo, tal como Widrow e Hoff provaram, a ADALINE origina uma hiper-superfície quadrática, o que implica a existência de um único extremo, global [Pinho, 1996].

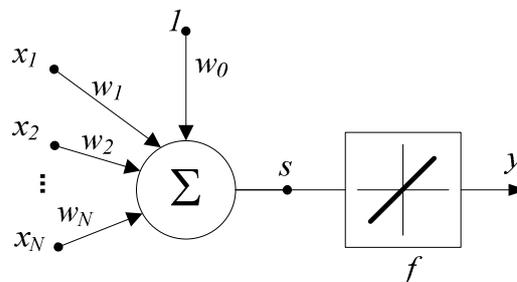


Figura 3.9 – Modelo ADALINE

3.4.4.1. Função de Custo

A regra de aprendizagem consiste em aplicar um método de otimização de forma a minimizar o erro a partir da minimização de uma função de custo C , que pode ser definida pelo erro quadrático médio à saída da ADALINE (Figura 3.10).

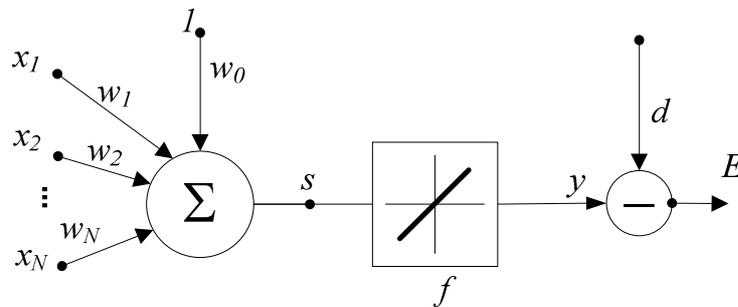


Figura 3.10 – Modelo da rede para a obtenção da função de custo

Ao considerar o conjunto de treino,

$$\mathfrak{S} = \left\{ \left(x_1^1, x_2^1, \dots, x_N^1, d^1 \right), \left(x_1^2, x_2^2, \dots, x_N^2, d^2 \right), \dots, \left(x_1^P, x_2^P, \dots, x_N^P, d^P \right) \right\}$$

constituído pelos P padrões, a função de custo, C' , pode ser expressa por (24),

$$C'(w_0, w_1, \dots, w_N) = \frac{1}{P} \sum_{p=1}^P \left(E^p \right)^2 = \frac{1}{P} \sum_{p=1}^P \left(y^p - d^p \right)^2 \quad (24)$$

com

$$y^p = f(s) = \sum_{i=0}^N w_i \cdot x_i^p$$

em que

- d^p – valor desejado na rede quando apresentado o padrão p (escalar);
- y^p – valor da saída da rede neuronal quando apresentado o padrão p ;
- E^p – erro obtido quando apresentado o padrão p .

Sem perda de generalidade, e de modo a simplificar as expressões finais, é normalmente considerada a minimização de uma função de custo definida pela metade do erro quadrático médio.

$$C(w_0, w_1, \dots, w_N) = \frac{1}{2} C'(w_0, w_1, \dots, w_N) = \frac{1}{2P} \sum_{p=1}^P \left(E^p \right)^2 = \frac{1}{2P} \sum_{p=1}^P \left(y^p - d^p \right)^2 \quad (25)$$

3.4.4.2. Método de gradiente

O método de gradiente (Figura 3.11) é um dos métodos iterativos de otimização mais simples e mais utilizados.

De uma forma geral, considera-se genericamente uma função $C(w_0, w_1, \dots, w_N)$ que se pretende minimizar, em que (w_0, w_1, \dots, w_N) são os argumentos da função. O gradiente da função, $\nabla C(w_0, w_1, \dots, w_N)$, aponta na direcção de crescimento mais rápido de $C(w_0, w_1, \dots, w_N)$. Dado que o objectivo é minimizar a função, torna-se claro que o avanço é dado na direcção de $-\nabla C(w_0, w_1, \dots, w_N)$.

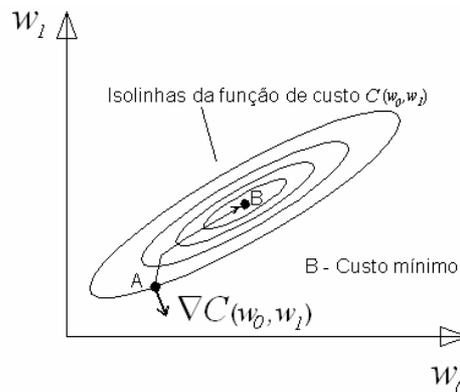


Figura 3.11 – Esquema de um percurso de otimização por gradiente

Em termos práticos, considerando novamente que n representa uma dada iteração e $(w_{0,n}, w_{1,n}, \dots, w_{N,n})$ são os valores dos pesos em n , então este método pode ser descrito por (26),

$$\begin{aligned} \Delta w_{i,n} &= -\eta \cdot \nabla C(w_{0,n}, w_{1,n}, \dots, w_{N,n}) = -\eta \cdot \frac{\partial C(w_{0,n}, w_{1,n}, \dots, w_{N,n})}{\partial w_i} = \\ &= -\eta \cdot \frac{1}{P} \sum_{p=1}^P (y_n^p - d^p) \cdot x_i^p \end{aligned} \quad (26)$$

donde resulta

$$w_{i,n+1} = w_{i,n} + \Delta w_{i,n} = w_{i,n} - \eta \cdot \frac{1}{P} \sum_{p=1}^P (y_n^p - d^p) \cdot x_i^p \quad (27)$$

O parâmetro η , passo da adaptação, é escolhido pelo utilizador e deve ser positivo. Como se observa em (27), o método consiste em ir dando repetidamente passos na

direcção de $-\nabla C(w_{0,n}, w_{1,n}, \dots, w_{N,n})$. A iteração termina quando for satisfeito um critério de paragem predefinido pelo utilizador.

No método de gradiente, os pesos só são alterados ao fim de cada iteração, após a passagem de todo o conjunto de treino, ou seja, após a apresentação de todos os P padrões.

Como referido anteriormente, as limitações do Perceptrão e ADALINE são iguais, diferindo apenas o método de treino pelo que só podem ser resolvidos problemas linearmente separáveis. Dos problemas típicos usados para ilustrar estas limitações (ver Figura 3.12) destacam-se o ‘E lógico’, o ‘OU lógico’ e o ‘OU exclusivo’.

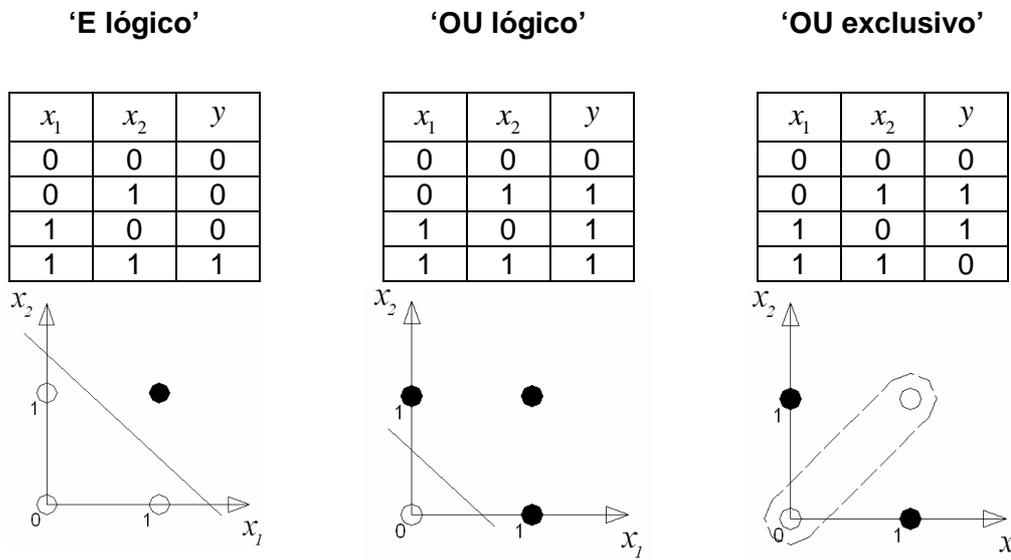


Figura 3.12 – Funções lógicas ‘E lógico’, ‘OU lógico’ e ‘OU exclusivo’

3.4.4.3. Influência do passo de adaptação

A escolha do passo de adaptação é um factor crítico no desempenho dos métodos de gradiente, na medida em que (Figura 3.13):

- se η for muito pequeno, a convergência para o mínimo é feita de forma suave e uniforme, mas lenta;
- se η for maior, a convergência para o mínimo é feita de forma mais rápida mas eventualmente mais oscilante;
- se η for excessivo, o processo pode ser instável.

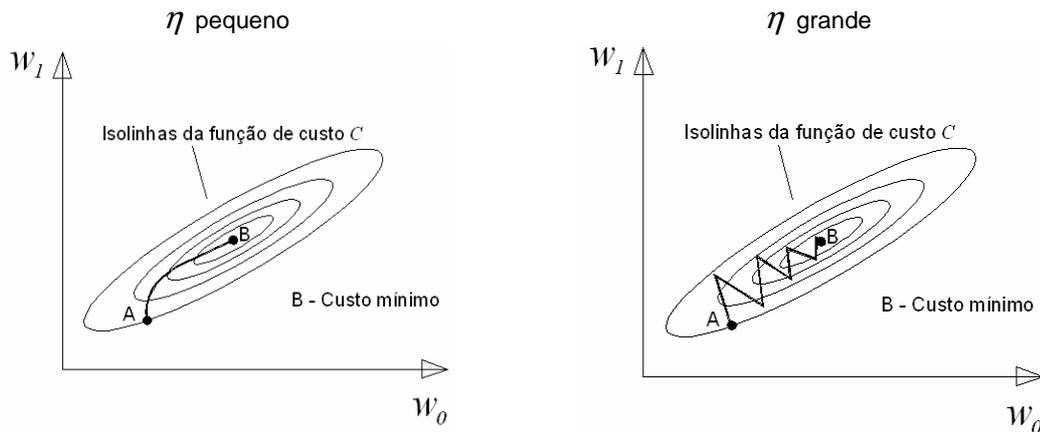


Figura 3.13 – Efeito do passo de adaptação

3.4.5. MADALINE

Com a intenção de apresentar uma solução dos problemas de separabilidade linear e otimizar a capacidade de generalização de classificadores baseados na ADALINE, Widrow e Hoff testaram a combinação múltipla de unidades simples do tipo ADALINE, tendo obtido resultados favoráveis em vários problemas testados. No entanto, não estava resolvida a generalização de uma regra de aprendizagem que permitisse o treino de unidades cujas saídas eram entradas de outras unidades, não tendo portanto uma saída desejada associada.

3.4.6. Desmotivação científica

A dificuldade em resolver problemas não linearmente separáveis como o 'OU exclusivo', apontadas em 1969 por Marvin Minsky & Seymour Paper no seu livro "Perceptrons", levou ao desencanto da comunidade científica em relação às redes neuronais artificiais.

Estes autores demonstraram matematicamente as limitações na convergência do Perceptrão, mostrando que o Perceptrão simples não podia resolver problemas não linearmente separáveis.

Para o caso específico do problema do 'OU exclusivo', mostraram que é possível uma solução, desde que se adicionassem unidades intermédias, estendendo, assim, o Perceptrão para uma rede Perceptrão Multicamada. No entanto, generalizaram – erradamente – que os sistemas com camadas intermédias apresentariam um problema bastante complexo que era o de implementar uma regra de adaptação dos pesos nas unidades que não estavam directamente ligadas às saídas da rede.

3.4.7. Renascimento

Mesmo com a desmotivação intrínseca existente nessa época, alguns cientistas continuaram o estudo no desenvolvimento de ferramentas que permitissem resolver os problemas de aprendizagem em redes multicamada.

Foi a partir do algoritmo de retropropagação do erro (também conhecido por regra delta generalizada) que se deu um novo passo nesta área.

Das personalidades que contribuíram nesta descoberta destacam-se Paul Werbos (1974), David. Parker (1985) e David E. Rumelhart, Geoffrey E. Hinton e Ronald J. Williams (1986) como as que descreveram o método de aprendizagem para implementação numa rede Perceptrão Multicamada, que foi desenvolvido pelo primeiro e generalizado pelos últimos. No entanto, foi em 1986, quando o grupo do MIT constituído por David Rumelhart e James McClelland apresentou o livro "*Parallel Distributed Processing: Explorations in the Microstructures of cognition*" que o algoritmo ficou popularizado. A publicação deste livro trouxe consigo o ressurgimento do interesse pelas redes neuronais artificiais.

A descrição do algoritmo de retropropagação, as suas características e o funcionamento das redes Perceptrão Multicamada é efectuada, com algum pormenor, nas secções seguintes.

3.5. Redes Perceptrão Multicamada

Seguidamente abordam-se as redes neuronais artificiais do tipo Perceptrão Multicamada, focando aspectos como arquitectura, funcionamento, pré-processamento de dados, aprendizagem e generalização.

3.5.1. Arquitectura

O neurónio é a unidade de processamento de uma rede Perceptrão Multicamada, sendo necessário para o desenvolvimento desta que sejam definidos os neurónios que vão formar a rede. A arquitectura é também função da forma como as unidades de processamento se interligam na estrutura da rede.

A estrutura de organização das redes Perceptrão Multicamada, ligando os neurónios por camadas, pode ser dividida em três grupos principais: uma camada de

entrada, uma ou várias camadas intermédias (ou escondidas) e uma camada de saída, conforme ilustrado na Figura 3.14.

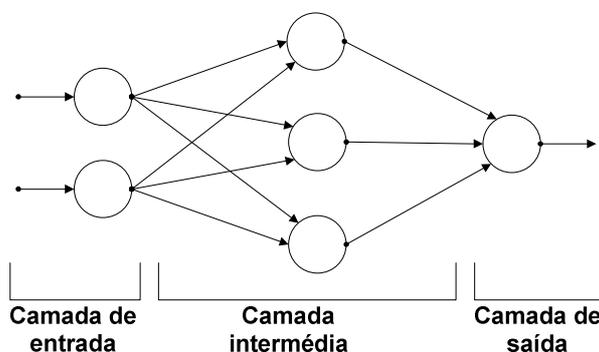


Figura 3.14 – Arquitectura de uma rede neural Perceptrão Multicamada

É na **camada de entrada** que os padrões são apresentados à rede, ou seja, é a camada que trata da distribuição da informação exterior para as camadas seguintes.

A **camada intermédia** permite a resolução de problemas com características não lineares.

Na **camada de saída** é onde o resultado final é concluído, sendo responsável pela resposta da rede.

No que diz respeito ao tipo de ligações entre as unidades de processamento, as redes Perceptrão Multicamada podem ser de dois tipos: estritamente directas ou recorrentes.

As redes neuronais **estritamente directas** são organizadas por camadas, em que as ligações são propagadas sempre numa só direcção, como mostra a Figura 3.15.

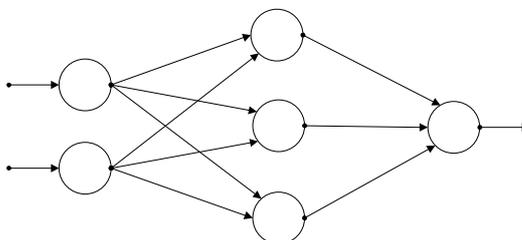


Figura 3.15 – Rede estritamente directa

Já as redes neuronais **recorrentes** podem conter ciclos, as saídas não são função exclusivamente das ligações entre os nós, mas também de uma dimensão temporal, ou seja, está-se na presença de um cálculo recursivo, que obedecerá a uma certa condição de paragem. Um exemplo de uma rede recorrente é apresentado na Figura 3.16.

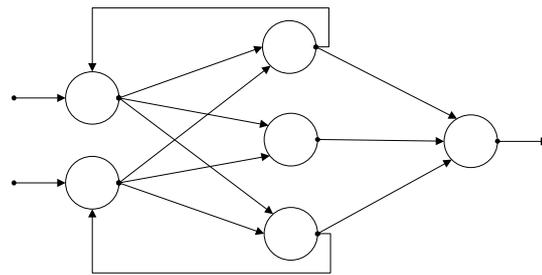


Figura 3.16 – Rede recorrente

De referir que a aplicação de redes neuronais recorrentes não faz parte do âmbito deste trabalho.

3.5.2. Nomenclatura adoptada

Com o objectivo de generalizar as designações dos elementos numa rede Perceptrão Multicamada, apresenta-se na Figura 3.17 um exemplo de uma rede com uma camada de entrada com N entradas, uma camada intermédia, l , com Q unidades de processamento e uma camada de saída, L , com M saídas. As ligações são do tipo estritamente directa e todos os neurónios de uma camada estão ligados a todos os neurónios da camada seguinte.

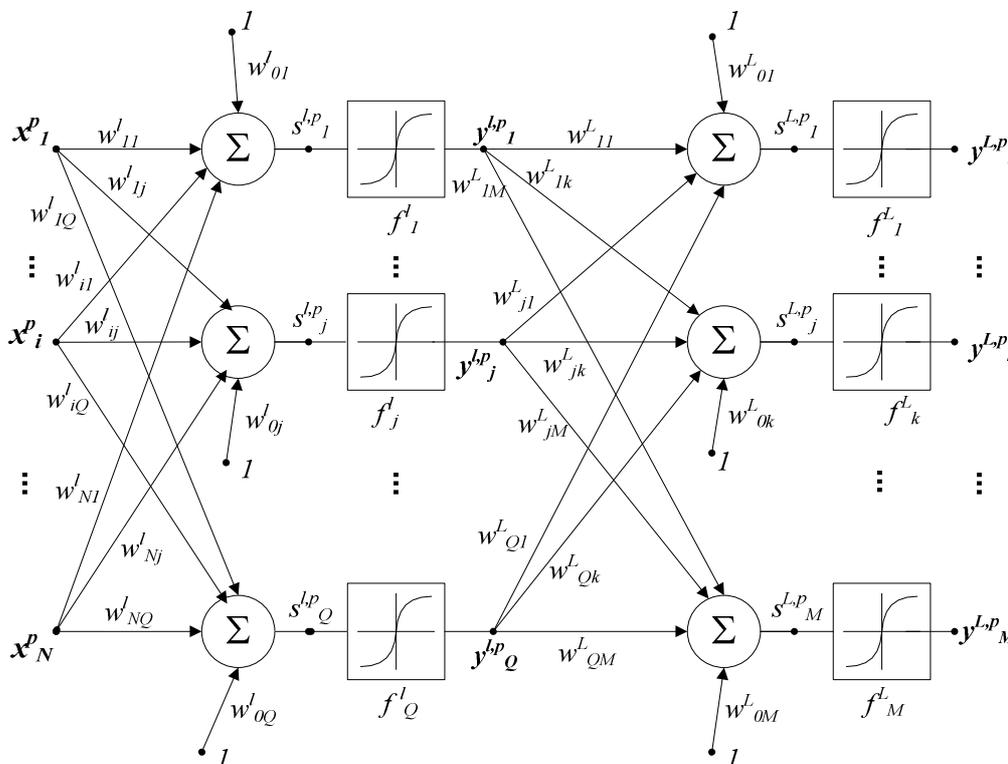


Figura 3.17 – Nomenclatura adoptada para uma rede Perceptrão Multicamada

Neste caso o conjunto de treino pode ser dado por:

$$\mathfrak{S} = \left\{ \left(x_1^1, \dots, x_i^1, \dots, x_N^1, d_1^1, \dots, d_k^1, \dots, d_M^1 \right), \dots, \left(x_1^p, \dots, x_i^p, \dots, x_N^p, d_1^p, \dots, d_k^p, \dots, d_M^p \right), \dots, \left(x_1^P, \dots, x_i^P, \dots, x_N^P, d_1^P, \dots, d_k^P, \dots, d_M^P \right) \right\}$$

No que diz respeito às nomenclaturas, tem-se que

- x_i^p – entrada da unidade i para o padrão p ;
- d_k^p – valor desejado para a saída da unidade k da camada de saída para o padrão p ;
- P – número de padrões do conjunto de treino;
- L – índice da camada de saída;
- l – índice da camada intermédia;
- N – número de entradas;
- Q – número de unidades de processamento na camada intermédia l ;
- M – número de saídas;
- w_{ij}^l – peso que liga a unidade i da camada $l-1$ à unidade j da camada l ;
- $s_j^{l,p}$ – valor da activação da unidade j da camada l para o padrão p ;
- $y_i^{l,p}$ – saída da unidade i da camada l para o padrão p .

Os valores de saída, $y_k^{l,p}$, de uma determinada camada, podem corresponder às entradas de camadas imediatamente seguintes, podendo ser determinados através de (28).

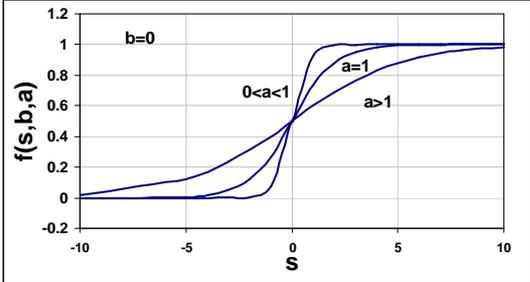
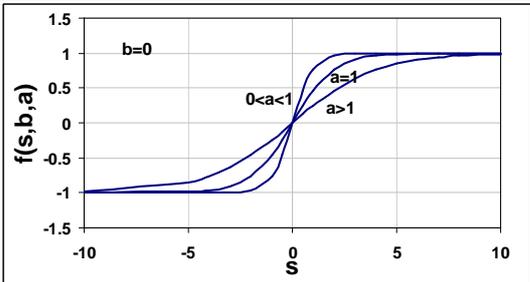
$$y_j^{l,p} = f_j^l \left(s_j^{l,p} \right) \quad (28)$$

Em redes Percepção Multicamada, uma das formas mais utilizadas no cálculo do valor de activação, $s_j^{l,p}$, é dada por (29).

$$s_j^{l,p} = \sum_{i=1}^N y_i^{l-1,p} \cdot w_{ij}^l \quad (29)$$

No Quadro 3.1 apresentam-se algumas expressões de funções de activação contínuas e diferenciáveis mais divulgadas, com as respectivas representações gráficas.

Quadro 3.1 – Exemplos de funções de activação

Tipo de função de activação	Definição da função	Representação gráfica
Sigmóide	$f(s,b,a) = \frac{1 + \tanh\left(\frac{s+b}{2 \cdot a}\right)}{2}$	
Tangente hiperbólica	$f(s,b,a) = \tanh\left(\frac{s+b}{2 \cdot a}\right)$	

3.6. Aprendizagem

Uma das propriedades mais importantes das redes neuronais artificiais é a capacidade de aprendizagem com os dados fornecidos e com isso melhorarem o seu desempenho. Isto é, elas aprendem com os exemplos (padrões) apresentados, criando uma representação própria do problema.

Ao conjunto de regras de aprendizagem denomina-se algoritmo de aprendizagem. O treino da rede consiste num processo iterativo de ajuste dos pesos, de forma a minimizar os erros.

As redes Perceção Multicamada utilizam um tipo de aprendizagem supervisionada, que consiste na apresentação à rede neuronal artificial de uma série de padrões de entrada em conjunto com as respectivas saídas desejadas. Este tipo de aprendizagem consiste na modificação dos pesos sinápticos com o intuito de reduzir a discrepância entre a saída obtida e a desejada. Os passos gerais a seguir por este algoritmo são os seguintes:

Passo 1 – Definição da arquitectura inicial da rede Percepção Multicamada.

Passo 2 – Atribuir, numa primeira instância, os pesos aleatórios em todas as ligações (preferivelmente valores pequenos).

Passo 3 – Seleccionar um conjunto de treino, o que é equivalente a definir um conjunto de entradas e respectivas saídas.

Passo 4 – Apresentar o conjunto de entrada e calcular a saída da rede através das operações usuais: soma ponderada das entradas, função de activação e transferência para as camadas seguintes até chegar à camada de saída (inicialmente são obtidas saídas aleatórias, já que os pesos das ligações são valores aleatórios).

Passo 5 – Cálculo de uma função de custo, previamente estabelecida, através do erro entre a saída desejada e a obtida. Se o custo resultante satisfaz um critério pretendido, como por exemplo, ser inferior a um determinado valor, o processo de aprendizagem é concluído, caso contrário, aplica-se o passo seguinte.

Passo 6 – Aplicar uma regra de aprendizagem a partir da qual é efectuado o ajuste dos pesos das ligações.

Passo 7 – Voltar ao passo 4.

3.6.1. Generalização

Durante a aprendizagem, as saídas da rede neuronal tendem a aproximar-se dos valores desejados apresentados no conjunto de treino. Esta capacidade por si só pode ser útil, mas na maior parte das vezes o propósito de utilizar uma rede neuronal é a de generalizar, isto é, obter valores aproximados de saídas relativamente a valores desejados que não foram apresentados no conjunto de treino.

Existem três condições, as quais são tipicamente necessárias, mas não suficientes, para uma boa generalização:

- 1) A primeira condição necessária é que as entradas da rede devem conter informação suficiente para produzir os valores desejados, podendo as entradas serem correlacionadas com as saídas desejadas.

- 2) A segunda condição necessária é que a função que se está a tentar aprender (aquela que origina as tais saídas correctas em função das entradas) deve ser, de alguma maneira, suave. Em outras palavras, uma pequena mudança nas entradas deve, ao mesmo tempo, produzir uma pequena mudança nas saídas.
- 3) A terceira condição necessária para uma boa generalização é que os exemplos do treino (padrões) sejam um subconjunto suficientemente grande e representativo da população que se pretende generalizar. A importância deste item está também relacionada com o facto de se pretender interpolar ou extrapolar.

Nos casos em que o domínio do conjunto de treino contém “descontinuidades significativas”, havendo falta de informação nesses intervalos, a extrapolação pode ser igualmente efectuada, podendo-se obter bons resultados. Da mesma forma, uma extrapolação fora do domínio de treino pode ser efectuada, no entanto a confiança na qualidade dos resultados deve ser sempre questionada.

Independentemente do número de exemplos do conjunto de treino que o sistema aprenda a reproduzir correctamente, o objectivo fundamental da aprendizagem é que a rede consiga fornecer saídas correctas para entradas não incluídas no conjunto de treino.

3.6.2. Função de custo

Para a implementação do algoritmo de aprendizagem é necessário a definição de uma função de custo C (30), directamente associada a uma medida do erro que se pretenda minimizar, que sirva para formular um critério de paragem na convergência da rede.

Aplica-se um padrão à entrada da rede, este é propagado desde a camada de entrada através das camadas seguintes até gerar as várias saídas. O valor de cada saída é, então, comparado com a saída desejada, calculando-se o valor do erro em cada uma das saídas, repetindo-se o processo até que tenham sido apresentados todos os padrões do conjunto de treino.

A função de custo pode ser dada pelo erro médio total para todos os padrões do conjunto de treino E_{Tot} , podendo ser calculada por (30),

$$C = E_{Tot} = \frac{1}{P} \sum_{p=1}^P E^p \quad (30)$$

Da expressão anterior retira-se que o erro total do sistema pode ser reduzido se o erro de cada padrão de treino, E^P , for reduzido, para qualquer dimensão finita de amostras P (Figura 3.18).

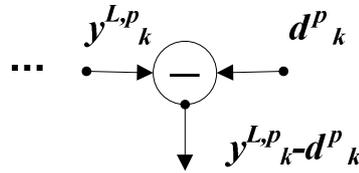


Figura 3.18 – Esquema de obtenção do erro em cada padrão

O erro em cada padrão, E^P , pode ser definido como sendo o somatório, para todas as M saídas, do erro quadrático. Esta opção penaliza os desvios grandes de forma mais gravosa que os desvios pequenos.

$$E^P = \frac{1}{2} \sum_{k=1}^M \left(y_k^{L,p} - d_k^p \right)^2 \quad (31)$$

em que

d_k^p – valor desejado da unidade k para o padrão p .

O termo $\frac{1}{2}$ foi incluído apenas por conveniência matemática.

3.6.3. Regra de aprendizagem – retropropagação do erro

Na retropropagação do erro, os erros das saídas são propagados para trás, partindo da camada de saída para os neurónios da camada intermédia que contribuem directamente para a saída. No entanto, cada neurónio da camada intermédia só recebe uma fracção do erro total, baseando-se na contribuição relativa que esse neurónio teve no erro total. Este processo é repetido, camada a camada, até que todos os neurónios da rede tenham recebido a parcela do erro que descreve a sua contribuição relativa para o erro total.

Em função do erro em cada saída de neurónio, os pesos das ligações a esse neurónio são actualizados, fazendo com que a rede convirja para um estado que permita satisfazer um critério de paragem previamente estabelecido.

Em redes Perceptrão Multicamada, o cálculo do gradiente da função de custo em ordem a um peso de uma unidade da última camada é semelhante ao caso de uma ADALINE com função de activação não linear e diferenciável (como são o caso da função sigmóide e da função tangente hiperbólica) [Kröse e Smagt, 1993].

No cálculo do gradiente da função de custo em ordem a um peso de uma unidade de uma camada intermédia a metodologia é semelhante. Uma vez que se pretende fazer uma breve dedução deste método, optou-se pela aplicação a uma rede Perceptrão Multicamada com uma única camada intermédia em que as ligações entre as camadas são “estritamente directas”, como ilustrado e em concordância com as nomenclaturas da Figura 3.17.

Como se viu, o método de retropropagação do erro consiste na propagação do erro de frente para trás, isto é, após o cálculo do erro na camada de saída, o erro é propagado para as camadas que lhe antecedem. A actualização dos pesos, de uma camada genérica, l , pode ser obtida por (32),

$$w_{ij,n+1}^l = w_{ij,n}^l + \Delta w_{ij,n}^l = w_{ij,n}^l - \eta \cdot g_{ij,n}^l \quad (32)$$

em que

- n – número da iteração;
- g_{ij}^l – gradiente da função de custo em ordem ao peso que liga a unidade i da camada $l-1$ à unidade j da camada l .

O cálculo de $g_{ij,n}^l$ é mais ou menos simples, conforme se trate de uma camada de saída ou de uma camada intermédia.

De forma a aliviar a nomenclatura, o índice n será omitido, já que o processo apresentado é para cada iteração, tendo de ser igualmente repetido nas iterações seguintes.

Começemos por determinar a variação dos pesos nas ligações que chegam à camada de saída ($l = L$). A actualização deverá ser efectuada através da equação

$$\Delta w_{jk}^L = -\eta \cdot g_{jk}^L \quad (33)$$

sendo necessária a determinação do gradiente g_{jk}^L associado à ligação entre a unidade de processamento j da camada $L-1$ e a unidade k da camada L , dado por (34),

$$g_{jk}^L = \frac{\partial E_{Tot}}{\partial w_{jk}^L} \quad (34)$$

em que $\frac{\partial E_{Tot}}{\partial w_{jk}^L}$ é o somatório para todos os padrões, P , das derivadas parciais de E^P

em ordem ao peso w_{jk}^L , ficando como em (35).

$$g_{jk}^L = \frac{\partial E_{Tot}}{\partial w_{jk}^L} = \frac{1}{P} \sum_{p=1}^P \frac{\partial E^p}{\partial w_{jk}^L} \quad (35)$$

Sem perda de generalidade, uma vez que $\frac{1}{P}$ é um valor constante para cada conjunto de amostras, no que diz respeito à actualização dos pesos, o termo pode estar indirectamente incluído no passo da adaptação η , omitindo-se $\frac{1}{P}$ no cálculo de g_{jk}^L .

$$g_{jk}^L = \frac{\partial E_{Tot}}{\partial w_{jk}^L} \propto \sum_{p=1}^P \frac{\partial E^p}{\partial w_{jk}^L} = \sum_{p=1}^P \frac{\partial E^p}{\partial y_k^{L,p}} \cdot \frac{\partial y_k^{L,p}}{\partial w_{jk}^L} = \sum_{p=1}^P \frac{\partial E^p}{\partial y_k^{L,p}} \cdot \frac{\partial y_k^{L,p}}{\partial s_k^{L,p}} \cdot \frac{\partial s_k^{L,p}}{\partial w_{jk}^L} \quad (36)$$

Assim, calculando termo a termo, obtém-se o primeiro termo a partir da derivada de (31) em ordem a $y_k^{L,p}$, resultando

$$\frac{\partial E^p}{\partial y_k^{L,p}} = \frac{\partial \left(\frac{1}{2} \sum_{k=1}^M (y_k^{L,p} - d_k^p)^2 \right)}{\partial y_k^{L,p}} = y_k^p - d_k^p \quad (37)$$

para o segundo termo, a partir de (28) obtém-se

$$\frac{\partial y_k^{L,p}}{\partial s_k^{L,p}} = \frac{\partial f_k^L(s_k^{L,p})}{\partial s_k^{L,p}} = f_k^L(s_k^{L,p}) \quad (38)$$

e, para o terceiro termo, derivando (29) em ordem a w_{jk}^L obtém-se

$$\frac{\partial s_k^{L,p}}{\partial w_{jk}^L} = \frac{\partial \left(\sum_{k=1}^M y_j^{L-1,p} \cdot w_{jk}^L \right)}{\partial w_{jk}^L} = y_j^{L-1,p} \quad (39)$$

Assim, substituindo (37), (38) e (39) em (36), resulta

$$g_{jk}^L = - \sum_{p=1}^P (d_k^p - y_k^p) \cdot f_k^L(s_k^{L,p}) \cdot y_j^{L-1,p} \quad (40)$$

De (40) e (33) obtém-se que a actualização dos pesos na camada de saída é dada por

$$\Delta w_{jk}^L = -\eta \cdot g_{jk}^L = \eta \cdot \sum_{p=1}^P (d_k^p - y_k^p) \cdot f_k^L(s_k^{L,p}) \cdot y_j^{L-1,p} \quad (41)$$

A actualização dos pesos, no caso da camada intermédia, $l = L-1$, é efectuada pela mesma expressão geral (32), no entanto a determinação do gradiente g_{ij}^l não é tão directa, podendo este ser formulado como apresentado em (42).

$$g_{ij}^{L-1} = \frac{\partial E_{Tot}}{\partial w_i^{L-1}} \approx \sum_{p=1}^P \frac{\partial E^p}{\partial w_{ij}^{L-1}} = \sum_{p=1}^P \frac{\partial E^p}{\partial y_j^{L-1,p}} \cdot \frac{\partial y_j^{L-1,p}}{\partial w_{ij}^{L-1}} \quad (42)$$

O primeiro termo não é de cálculo directo, podendo ser representado por

$$\frac{\partial E^p}{\partial y_j^{L-1,p}} = \sum_{k=1}^M \frac{\partial E^p}{\partial s_k^{L,p}} \cdot \frac{\partial s_k^{L,p}}{y_j^{L-1,p}} \quad (43)$$

Pela sua vez, o primeiro termo de (43) pode ser obtido por (44).

$$\frac{\partial E^p}{\partial s_k^{L,p}} = \frac{\partial E^p}{\partial y_k^{L,p}} \cdot \frac{\partial y_k^{L,p}}{\partial s_k^{L,p}} \quad (44)$$

Substituindo (44) em (43), fica como em (45),

$$\frac{\partial E^p}{\partial y_j^{L-1,p}} = \sum_{k=1}^M \frac{\partial E^p}{\partial y_k^{L,p}} \cdot \frac{\partial y_k^{L,p}}{\partial s_k^{L,p}} \cdot \frac{\partial s_k^{L,p}}{y_j^{L-1,p}} \quad (45)$$

o que é equivalente a

$$\frac{\partial E^p}{\partial y_j^{L-1,p}} = \sum_{k=1}^M (y_k^p - d_k^p) \cdot f_k^L(s_k^{L,p}) \cdot w_{jk}^L \quad (46)$$

Fazendo,

$$\gamma_j^{L-1,p} = \sum_{k=1}^M (y_k^p - d_k^p) \cdot f_k^L(s_k^{L,p}) \cdot w_{jk}^L \quad (47)$$

e substituindo (47) em (42), e multiplicando e dividindo por $\partial s_j^{L-1,p}$,

$$\frac{\partial E_{Tot}}{\partial w_i^{L-1}} = \sum_{p=1}^P \gamma_j^{L-1,p} \cdot \frac{\partial y_j^{L-1,p}}{\partial s_j^{L-1,p}} \cdot \frac{\partial s_j^{L-1,p}}{\partial w_{ij}^{L-1}} \quad (48)$$

ou seja,

$$\frac{\partial E_{Tot}}{\partial w_i^{L-1}} = \sum_{p=1}^P \gamma_j^{L-1,p} \cdot f_j^{L-1}(s_j^{L-1,p}) \cdot y_i^{L-2,p} \quad (49)$$

obtendo-se, finalmente

$$\Delta w_{ij}^{L-1} = -\eta \cdot \sum_{p=1}^P \gamma_j^{L-1,p} \cdot f'(s_j^{L-1,p}) \cdot y_i^{L-2,p} \quad (50)$$

De forma a manter a concordância com a nomenclatura utilizada na Figura 3.17, tem-se que $y_i^{L-2,p} = x_i^p$.

3.6.4. Critérios de paragem do treino

O critério de paragem do treino da rede está directamente ligado à qualidade do desempenho da rede, podendo acontecer uma das seguintes situações:

- 1) Se o treino for parado demasiado cedo, corre-se o risco de a rede não ter aprendido o suficiente das características do conjunto de treino.
- 2) Se o treino for parado demasiado tarde, está-se sujeito a obter um ajustamento excessivo da rede, perdendo eventualmente capacidade de generalização.

Resultante da qualidade que se pretende da rede e do tempo disponível para a aprendizagem, podem ser utilizados um ou vários dos critérios de paragem seguidamente apresentados:

- estabelecer um número máximo de iterações no treino;
- parar quando a mudança do erro entre épocas é menor que um valor previamente definido;
- aplicar a validação cruzada, método de validação da capacidade de generalização da rede neuronal.

Na validação cruzada (Figura 3.19), mesmo que o erro para o conjunto de treino continue a diminuir, se em dado momento o erro para o outro conjunto (designado de validação cruzada) começar a aumentar, então a rede está a perder capacidade de generalização, podendo estar a ajustar-se em excesso ao conjunto de treino e não ao domínio. O treino é interrompido nesse ponto de inversão do erro, garantindo-se assim uma melhor generalização.

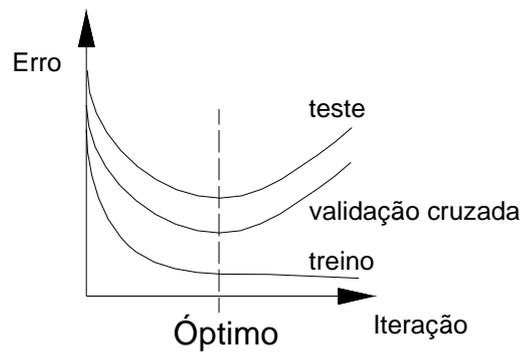


Figura 3.19 – Critério de paragem utilizando a validação cruzada

3.6.5. Técnicas de aceleração – Termo de momento

Desde a época em que Rumelhart editou o livro que deu grande popularidade ao algoritmo de retropropagação, os computadores evoluíram significativamente em termos da capacidade de processamento da informação. No entanto, ainda são considerados muito lentos para muitas aplicações analisadas, principalmente quando se utiliza apenas a formulação inicial do algoritmo de retropropagação do erro.

Em boa parte dos problemas propostos, a superfície de erro toma a forma de vales estreitos e profundos. Nestes casos, o método do gradiente provoca oscilações entre os dois lados do vale [Almeida, 1997]. Uma das formas mais simples para acelerar a optimização em situações onde a função apresenta vales estreitos, consiste na utilização do chamado termo de momento. O uso do termo de momento visa atenuar essa oscilação através da utilização, em cada iteração, de uma fracção da actualização do passo anterior, tal como indicado na equação (51),

$$\Delta w_{ij,n}^l = -\eta \cdot g_{ij,n}^l + \alpha \cdot \Delta w_{ij,n-1}^l \quad \alpha \in [0,1[\quad (51)$$

onde

- $\Delta w_{ij,n}^l$ – variação do peso que liga a unidade i da camada $l-1$ à unidade j da camada l , na iteração n ;
- $g_{ij,n}^l$ – componente do gradiente calculado na iteração n , na direcção de w_{ij}^l ;
- α – termo de momento.

O parâmetro α deve satisfazer a condição $0 \leq \alpha < 1$. O valor $\alpha = 0$ corresponde à optimização dos pesos sem termo de momento. A presença do termo $\alpha \cdot \Delta w_{ij,n-1}^l$ no cálculo de $\Delta w_{ij,n}^l$ atenua as oscilações, conferindo uma espécie de “inércia” ao processo.

Assim, tem-se que o termo de momento introduz um elemento de inércia no gradiente que aumenta os incrementos em direcções aproximadamente constantes, e penaliza (atenua) as componentes segundo direcções de oscilação.

Em geral, a utilização do termo de momento melhora muito o processo de treino da rede em termos de tempo (ver Figura 3.20). No entanto, o valor de α deve ser bem escolhido, já que para valores muito pequenos de α (em geral, $\alpha \leq 0,5$) o efeito deixa de ser sentido, e para valores muito elevados de α o balanço adquirido pode ser excessivo. É prática corrente a utilização de termos de momento compreendidos por $0,7 \leq \alpha \leq 0,95$.

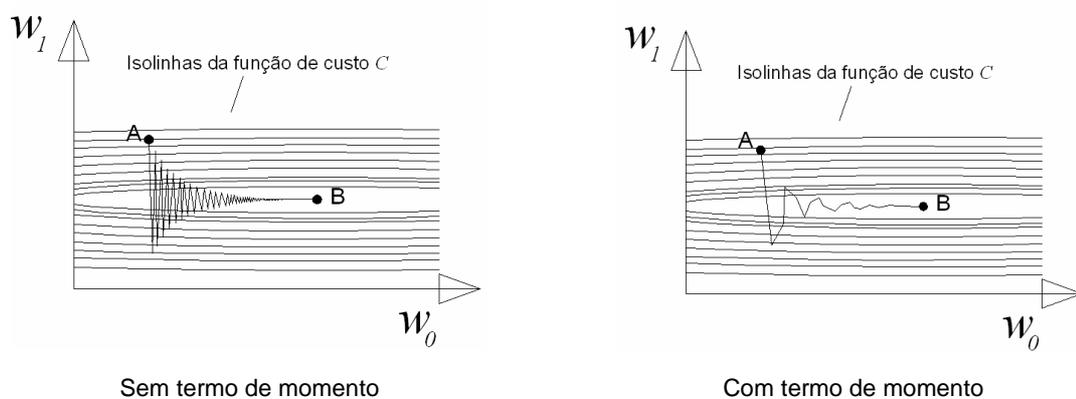


Figura 3.20 – Efeito do termo de momento

3.6.6. Pré-processamento dos dados

O pré-processamento de dados é uma tarefa que nem sempre é necessária, que em alguns casos melhora o desempenho da rede e que em outros casos é essencial para o seu funcionamento.

São várias as operações que podem ser executadas no pré-processamento, como, por exemplo, a verificação da integridade, a representação e o escalonamento dos dados [Cortez e Neves, 2000]:

- a representação dos dados é uma operação que pode consistir numa conversão de dados. Uma vez que as redes neuronais trabalham com números, os dados têm de estar apresentados numa codificação numérica. Por outro lado, uma variável pode ser representada por uma ou mais unidades de entrada ou de saída, conforme o caso. Por exemplo, em problemas de classificação de M classes é comum representar uma saída por um vector binário de dimensão M ;

- o escalonamento dos dados consiste na transformação dos dados de forma a acelerar e melhorar o processo de aprendizagem. Este escalonamento depende do tipo de dados.

Nas entradas

Algoritmos de aprendizagem do tipo gradiente descendente são bastante sensíveis ao escalonamento das variáveis de entrada. Pode ser vantajoso que a variável seja escalonada, para que o seu valor médio sobre o conjunto de treino seja próxima do zero.

O pré-processamento pode também ser realizado a partir do escalonamento, para cada uma das entradas, numa banda definida entre um limite superior e um limite inferior. Ou seja, cada entrada i é multiplicada por uma amplitude, A_i , e desfasada de B_i . A amplitude e desfasamento podem ser designados por coeficientes de normalização. Estes coeficientes são processados para cada entrada, o que significa que existe uma única amplitude e um único desfasamento em cada entrada.

Os coeficientes de normalização (52) e (53) são baseados nos valores máximo e mínimo encontrados através de cada uma das entradas, de forma a garantir que todos os exemplos de cada entrada estejam dentro dos limites superior e inferior da banda.

Os coeficientes de normalização são determinados por

$$A_i = \frac{LSB - LIB}{x_i^{\max} - x_i^{\min}} \quad (52)$$

$$B_i = LSB - A_i \times x_i^{\max} \quad (53)$$

em que

- A_i – amplitude na entrada x_i ;
- B_i – desfasamento na entrada x_i ;
- LSB – limite superior da banda (geralmente =0,9);
- LIB – limite inferior da banda (geralmente =-0,9);
- x_i^{\max} – máximo valor da entrada x_i ;
- x_i^{\min} – mínimo valor da entrada x_i .

Os coeficientes de normalização são aplicados às entradas da seguinte forma,

$$x_i^{\text{normalizado}} = A_i \times x_i + B_i \quad (54)$$

Nas saídas

Por vezes pode ser aconselhável o escalonamento das saídas. Por exemplo, quando são utilizadas mais do que uma saída e se a função de custo é sensível à escala, a diferença de escalas das variações de amplitude nas saídas pode afectar a aprendizagem da rede. Esta diferença de escalas pode fazer com que a rede dispense erroneamente maior esforço na aprendizagem da saída com maior amplitude de variações. Assim, saídas que têm igual importância devem ser escalonadas para a mesma escala, podendo ser aplicado o mesmo método de escalonamento utilizado nas entradas.

3.7. Escolha do programa de redes neuronais

Actualmente existem no mercado várias opções de programas de redes neuronais, alguns de *download* gratuito. A generalidade dos programas disponíveis permite o desenvolvimento de redes neuronais do tipo Perceptrão Multicamada, sendo a maior diferença detectada ao nível da interface (uns mais “amigáveis” que outros) e do tipo de ficheiros que utilizam (ex.: Excel, txt). De entre os programas encontrados, destacam-se os seguintes:

- BrainMaker [BrainMaker];
- Joone [Marrone, 2004];
- MATLAB Neural Net Toolbox [Neural Network Toolbox 5.0.1.];
- Neurosolutions [NeuroSolutions for Excel];
- NeuralTools [NeuralTools];
- NeuralWorks Predict [NeuralWare];
- NeuroXL [NeuroX, 2003];
- STATISTICA Neural networks [STATISTICA Neural Networks].

A escolha final do programa utilizado neste trabalho recaiu no Neurosolutions, dada a disponibilidade de utilização deste software através do Instituto Superior Técnico e devido à sua fácil aplicação num ambiente Excel.

4. APLICAÇÃO AOS RESULTADOS DA OBSERVAÇÃO DA BARRAGEM DO ALTO RABAGÃO

4.1. Introdução

Neste capítulo apresentam-se alguns desenvolvimentos na aplicação de redes neuronais no domínio das barragens de betão. Apresentam-se as aplicações das redes neuronais artificiais do tipo Perceptrão Multicamada na aprendizagem do comportamento de algumas grandezas utilizadas no controlo de segurança de barragens de betão, tendo sido escolhido como caso de estudo a barragem do Alto Rabagão. Pretende-se desta forma demonstrar a aplicabilidade deste tipo de redes neuronais a um caso real.

A escolha da barragem do Alto Rabagão como protótipo deste trabalho deveu-se, de entre outros factores, ao facto de estar disponível nesta obra um historial significativo de observações efectuadas a diversas grandezas essenciais ao controlo de segurança de uma barragem de betão.

A caracterização das principais acções como as variações do nível da albufeira a montante e a jusante e as variações da temperatura do ar, do corpo da barragem e da fundação, quando se justifique, são determinantes para a interpretação do comportamento de todas as obras de betão [Ramos, 2004]. A observação destas grandezas, conjuntamente com as grandezas que caracterizam a resposta da estrutura, tem como principal objectivo evitar que sejam atingidos estados limite de funcionalidade e segurança, procurando-se que a partir da observação sejam detectadas precocemente deteriorações cuja ocorrência e evolução não controlada possa vir a originar aqueles estados limites. Assim, de forma a acompanhar a evolução ao longo do tempo do comportamento observado nas barragens, são elaborados modelos que permitem caracterizar o comportamento normal das estruturas para as solicitações a que estão sujeitas.

De acordo com o apresentado no capítulo 3, as redes neuronais aprendem a partir de um conjunto de exemplos, que neste caso não são mais do que um conjunto de dados relativos às observações (quer em termos de acções quer em termos de respostas) num determinado intervalo temporal. Assim, desde que o conjunto de dados utilizados no treino das redes neuronais reflecta o comportamento normal da estrutura, sempre que for

apresentado à rede um novo conjunto de acções, esta poderá fornecer como resultado uma previsão da resposta estrutural a estas mesmas acções. A partir da comparação dos valores observados com os valores obtidos do modelo de redes neuronais é possível avaliar se o comportamento da barragem se mantém satisfatório ou se existe alguma alteração do comportamento que justifique um estudo mais aprofundado.

Foi desenvolvido um conjunto de modelos de redes neuronais, os quais são seguidamente apresentados. De forma a avaliar o desempenho destes modelos apresenta-se, no final deste capítulo, uma comparação entre os resultados obtidos com a utilização dos modelos de redes neuronais e os resultados obtidos com a utilização de modelos de interpretação quantitativa [Gomes, 1981].

4.2. Estado actual da aplicação de redes neuronais no controlo de segurança de barragens de betão

Durante os últimos anos tem-se verificado um crescente interesse da comunidade científica no estudo das redes neuronais do tipo Perceptrão Multicamada, basicamente com o intuito de explorar as potencialidades da aplicação desta tecnologia em diferentes áreas de investigação. Na área do controlo de segurança de barragens foram realizados alguns estudos, nos quais se propõe a utilização de modelos de redes neuronais para simular o comportamento observado de algumas das principais variáveis de controlo utilizadas na observação das obras. Todos estes estudos têm contribuído para o interesse e análise crítica do desempenho das redes neuronais.

Alguns dos trabalhos que abordam a utilização das redes neuronais no domínio das barragens foram apresentados por Hattingh [Hattingh, 1998; 2002], Carvalho [Carvalho et al., 2003], Perner [Perner et al., 2003], Gutiérrez [Gutiérrez e Romanel, 2003], Xiangi [Xianqi e Sifeng, 2004] e Vazinram [Vazinram et al., 2005].

Em 1998, Hattingh e Oosthuizen [Hattingh, 1998] apresentaram um trabalho onde aplicaram redes neuronais Perceptrão Multicamada, com uma camada intermédia (com função de activação sigmóide), na análise dos deslocamentos radiais obtidos por fios prumo. De entre os aspectos apresentados por estes autores, refere-se o facto de terem considerado numa das entradas da rede neuronal o efeito da pressão hidrostática através

de uma forma quadrática do tipo, $-\left[\left(\frac{h}{30}\right)^2 \cdot 10\right]$, em que h é a altura de água na

albufeira, e ainda os valores desta mesma grandeza nas semanas anteriores (2, 4, 12 e 24 semanas) à data da campanha em análise. O efeito da temperatura foi introduzido

através do número do mês do ano com uma casa decimal correspondente ao dia do respectivo mês (por exemplo: 1 de Janeiro = 1,1; 2 de Janeiro =1,2; 1 de Fevereiro =2,1, etc.). Em relação ao critério de paragem do treino da rede neuronal, referem os autores que obtiveram melhor desempenho utilizando como critério o erro médio de treino, mesmo quando comparado com outros critérios, nomeadamente em relação ao erro quadrático médio de treino. Porém, nem todas as redes com um determinado erro médio de treino podem ser consideradas boas, por exemplo, em algumas situações o erro médio de treino de 10% pode ser considerado satisfatório enquanto que para outras redes, com diferentes entradas, só poderão começar a ter saídas aceitáveis com erros médios de treino inferiores a 3%.

Uma das dificuldades na utilização das redes neuronais referida por estes autores é o facto dos deslocamentos observados, no caso em estudo, apresentarem uma leve tendência temporal de aumento do deslocamento radial para jusante. De referir que os autores tentaram ultrapassar esta questão recorrendo a uma análise com períodos mais reduzidos de dados, porém estes períodos não cobriam toda a gama de variação das principais solicitações.

Embora neste primeiro trabalho, publicado por Hattingh e Oosthuizen, as conclusões apresentadas indicassem que as redes neuronais seriam uma ferramenta apropriada para o controlo de segurança de barragens, mesmo com as limitações verificadas, em 2002 Hattingh apresentou um novo trabalho [Hattingh, 2002], no qual refere que as redes neuronais artificiais não são uma ferramenta apropriada para estimar o comportamento de barragens de betão. Os principais motivos por ele apresentados foram:

- as dificuldades na obtenção de redes neuronais com bom desempenho quando as grandezas observadas apresentam algum tipo de tendência ao longo do tempo;
- demasiado tempo para o treino de novas redes;
- as redes neuronais não apresentarem bom desempenho para condições extremas.

Existem alguns destes aspectos que merecem ser comentados, nomeadamente:

- o efeito da temperatura, tal como apresentado, pode não apresentar continuidade entre o fim e o início do ano;
- a utilização do erro médio como função de custo faz com que a diferença entre o valor desejado e estimado tenha sempre o mesmo peso. O erro quadrático

médio faz com que uma maior diferença de valores seja mais penalizada, podendo provocar melhores desempenhos da rede neuronal para casos extremos;

- as saídas da rede, tal como foram construídas, devem ser analisadas como valores médios, e se fossem analisadas as diferenças entre os valores da rede neuronal e os observados poderia ser despistada alguma tendência nos deslocamentos, facto que só por si já é uma mais valia na interpretação do comportamento;
- o facto de não entrarem com nenhum efeito do tempo, como entrada da rede, e havendo efectivamente uma tendência temporal na grandeza observada, é natural que a rede não apresentasse resultados satisfatórios;
- a introdução de entradas que traduzam o efeito do tempo tem de ser mais estudada, mas é provável que, tal como para as restantes entradas, a realização de análises de sensibilidade, acompanhadas de um conhecimento físico do fenómeno em estudo, sejam indispensáveis para a aceitação dos modelos.

É apresentada uma abordagem interessante e bem estruturada sobre a interpretação quantitativa e as redes neuronais do tipo Percepção Multicamada no trabalho "*Interpretation of Schlegels dam crest displacement*" [Perner et al., 2003].

Uma das desvantagens das redes neuronais referida neste último trabalho é que a influência das entradas das redes nos resultados não é facilmente definida. Uma sugestão apresentada é efectuar previamente uma análise de sensibilidade das variáveis de entrada. Foram consideradas quatro entradas da rede: o nível de água na albufeira, a fluência do betão, a temperatura média no betão e o respectivo gradiente térmico. Uma das principais conclusões destes autores é que as redes neuronais podem ser utilizadas na interpretação do comportamento das barragens e sugerem a investigação da aplicação das redes neuronais em combinação com resultados da análise estrutural e estatística.

Relativamente a este último trabalho, considera-se que a análise de sensibilidade fornece uma boa percepção da influência das entradas, mas é insuficiente se não efectuada de forma extensa, uma vez que a variação da resposta a uma dada entrada é função das restantes entradas. Assim, considera-se indispensável a realização de várias análises de sensibilidade.

4.3. Caracterização da barragem do Alto Rabagão

A barragem do Alto Rabagão está localizada no distrito de Vila Real e tem como linha de água principal o rio Rabagão, na bacia hidrográfica do Cávado (Figura 4.1).

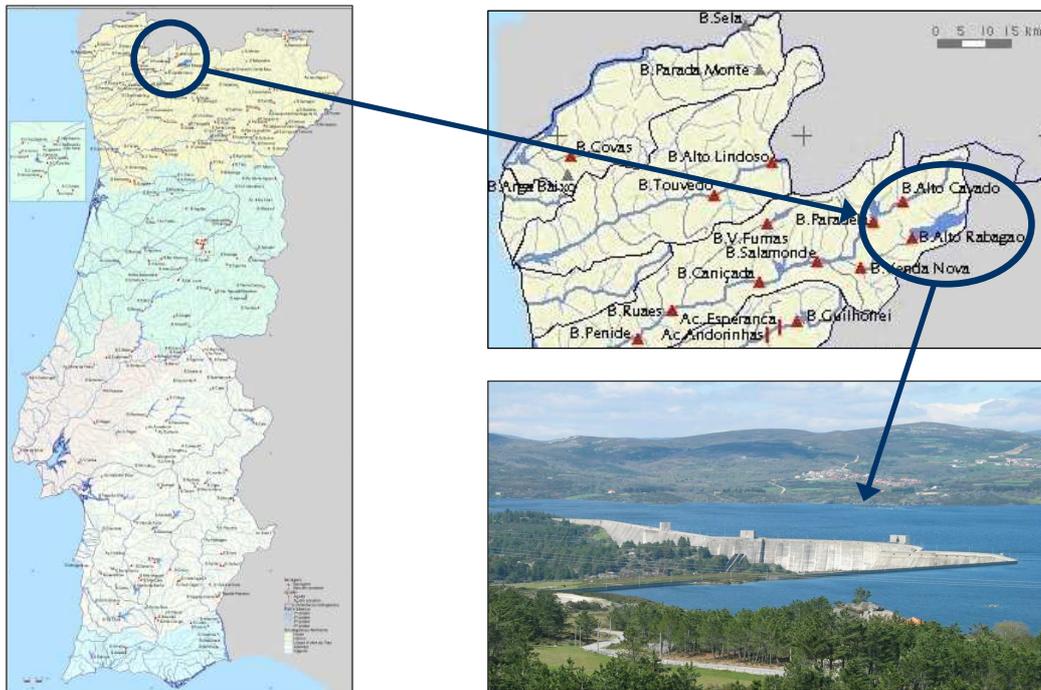


Figura 4.1 – Localização da barragem do Alto Rabagão

A barragem do Alto Rabagão é constituída por três estruturas principais, uma em abóbada e duas em gravidade (Figura 4.2). A zona central é formada pela abóbada, apoiada em dois encontros artificiais. No prolongamento de cada uma das extremidades surge um perfil em gravidade que se estende até às margens [Florentino et al., 1970; Mascarenhas, 1976].

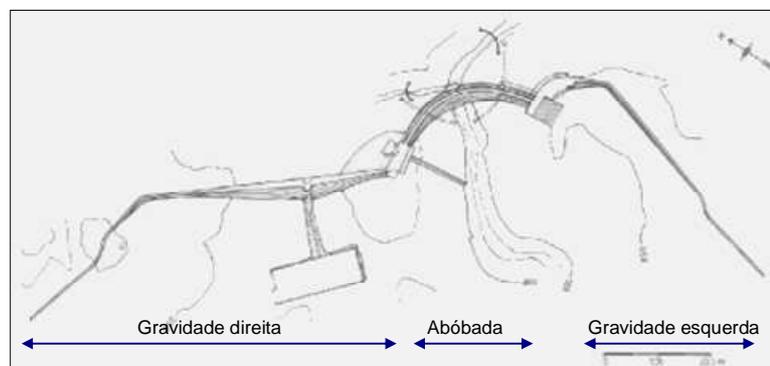


Figura 4.2 – Planta da barragem do Alto Rabagão – Trechos em abóbada e gravidade

A barragem apresenta uma altura máxima, na zona da abóbada, de 94 m, e um comprimento total do coroamento de 1970 m. A cota do nível de pleno armazenamento (NPA) é 880 m e a cota do nível mínimo de exploração (NmE) é 829 m. A espessura da abóbada é de 7 m no coroamento, sendo na fundação igual a 32 m, na margem esquerda e fundo do vale, diminuindo gradualmente ao longo da margem direita até ao valor de 24,4 m junto ao encontro direito.

Os encontros têm forma rectangular com planta com 36x56 m² na margem direita e 48x60 m² na margem esquerda, sendo a altura máxima igual a 35 m e 41 m, na margem direita e margem esquerda, respectivamente. As zonas em perfil de gravidade têm altura máxima igual a 59 m, na margem direita.

A barragem tem a maior albufeira do centro de produção Cávado-Lima, com um volume cerca de 550x10⁶ m³, no nível de pleno armazenamento.

O maciço de fundação é constituído maioritariamente por granitos, com grau de alteração variável, e muito localmente por pequenas manchas xistosas. No vale principal a fundação apresenta-se muito heterogénea, verificando-se a existência de duas zonas distintas. Na margem direita o maciço de fundação apresenta-se em bom estado, com módulos de elasticidade na ordem de grandeza da do betão, enquanto que no fundo do vale e margem esquerda a deformabilidade do maciço vai aumentando com a cota, atingindo-se valores na ordem de 1/20 do módulo de elasticidade do betão.

Antes de iniciados os trabalhos de betonagem do corpo da barragem foi efectuado o tratamento da fundação, que consistiu no habitual saneamento da superfície de inserção e em injeções na rocha.

As betonagens da obra iniciaram-se em 1961, tendo sido concluída a zona da abóbada em Agosto de 1963 e as zonas em gravidade em 1964. A injeção das juntas foi efectuada entre Outubro e Dezembro de 1963. Na zona da abóbada as injeções de consolidação da fundação decorreram entre Julho de 1961 e Setembro de 1963, sendo que a zona dos encontros foi consolidada entre Abril de 1963 e Maio de 1965. A barragem entrou em carga em 1964, tendo sido atingido o nível pleno de armazenamento em Março de 1966 [Florentino et al., 1970].

Os estudos realizados com os modelos de rede neuronais, cujos resultados são apresentados neste capítulo, referem-se ao trecho da barragem em abóbada.

4.4. Definição e exploração do sistema de observação

O sistema de observação da barragem do Alto Rabagão foi definido no Plano de Observação datado de 1961 e 1962, o qual foi implantado durante a construção da obra.

Em Outubro de 1970 o comportamento da obra, nos primeiros 5 anos de exploração, foi objecto de um relatório do LNEC, compreendendo assim o primeiro enchimento da albufeira da barragem [Florentino et al., 1970]. Neste relatório, dividido em 4 volumes, são analisados os resultados de toda a aparelhagem instalada (volumes I a III). Foi ainda realizado um estudo em modelo físico da zona em abóbada, com o objectivo de comparar os resultados obtidos com os da observação da barragem (volume IV), verificando-se ter sido essa comparação “...inteiramente satisfatória, tanto no que se refere aos deslocamentos como a tensões”. Relativamente ao comportamento da obra neste período verificou-se a existência de fenómenos iniciais de adaptação, nomeadamente a ocorrência de deslocamentos irreversíveis devidos ao primeiro enchimento. Porém, o documento refere que “...tais fenómenos podem considerar-se normais e tendem para uma estabilização”. Como conclusão o relatório registou “...o bom comportamento da obra nestes 5 anos de serviço”.

Em Maio de 1976 um novo relatório de comportamento foi elaborado pelo LNEC [Mascarenhas, 1976], onde foram analisados os resultados das grandezas seleccionadas para observação expedita. Manteve-se, neste período, o bom comportamento da obra registado até então.

Em 1993 foram publicados pelo LNEC três relatórios [Henriques e Leal, 1993; Henriques e Ribeiro, 1993; Silva e Amante, 1993]. Os dois primeiros estão relacionados com a revisão do sistema para a determinação de deslocamentos por métodos geodésicos, onde são apresentadas as alterações a introduzir no sistema de forma a melhorar a sua precisão e fiabilidade. O terceiro relatório diz respeito à inspecção à estrutura e aos sistemas de observação. Em relação à observação visual, o relatório conclui que “A observação visual da estrutura revelou não haver indícios de alteração significativa dos materiais e de comportamento anómalo das estruturas e da fundação”.

Com excepção dos sistemas de observação geodésica, que foram objecto de beneficiação, até esta data todo o sistema de observação (para além de acções de manutenção) não sofreu qualquer remodelação. Refere-se, no entanto, que em 1994 o LNEC, a pedido da CPPE, iniciou, em fase experimental, a instalação de um sistema de recolha automática de caudais e deslocamentos horizontais de fios prumo.

Em 1995 foi elaborado um documento de revisão do sistema de observação, em que foram propostas medidas que visavam o reforço da observação da fundação e a substituição de bases de alongâmetro existentes e com fiabilidade duvidosa [Silva e Portela, 1995].

O sistema de observação actual consta de um conjunto de equipamentos e dispositivos que permitem a observação e a medição de:

- temperaturas do ar;
- nível da água na albufeira;
- temperaturas no betão;
- deslocamentos horizontais com fios de prumo;
- deslocamentos horizontais por métodos geodésicos;
- deslocamentos verticais por nivelamento geométrico de precisão;
- rotações;
- movimentos de juntas;
- extensões no betão;
- tensões no betão;
- pressão da água nos poros do betão;
- teor de humidade no betão;
- deslocamentos na fundação;
- subpressões na fundação e
- caudais drenados e infiltrados.

Nas Figuras 4.3 e 4.4 são apresentados esquemas de alguns dos instrumentos do sistema de observação da barragem do Alto Rabagão, na zona da abóbada.

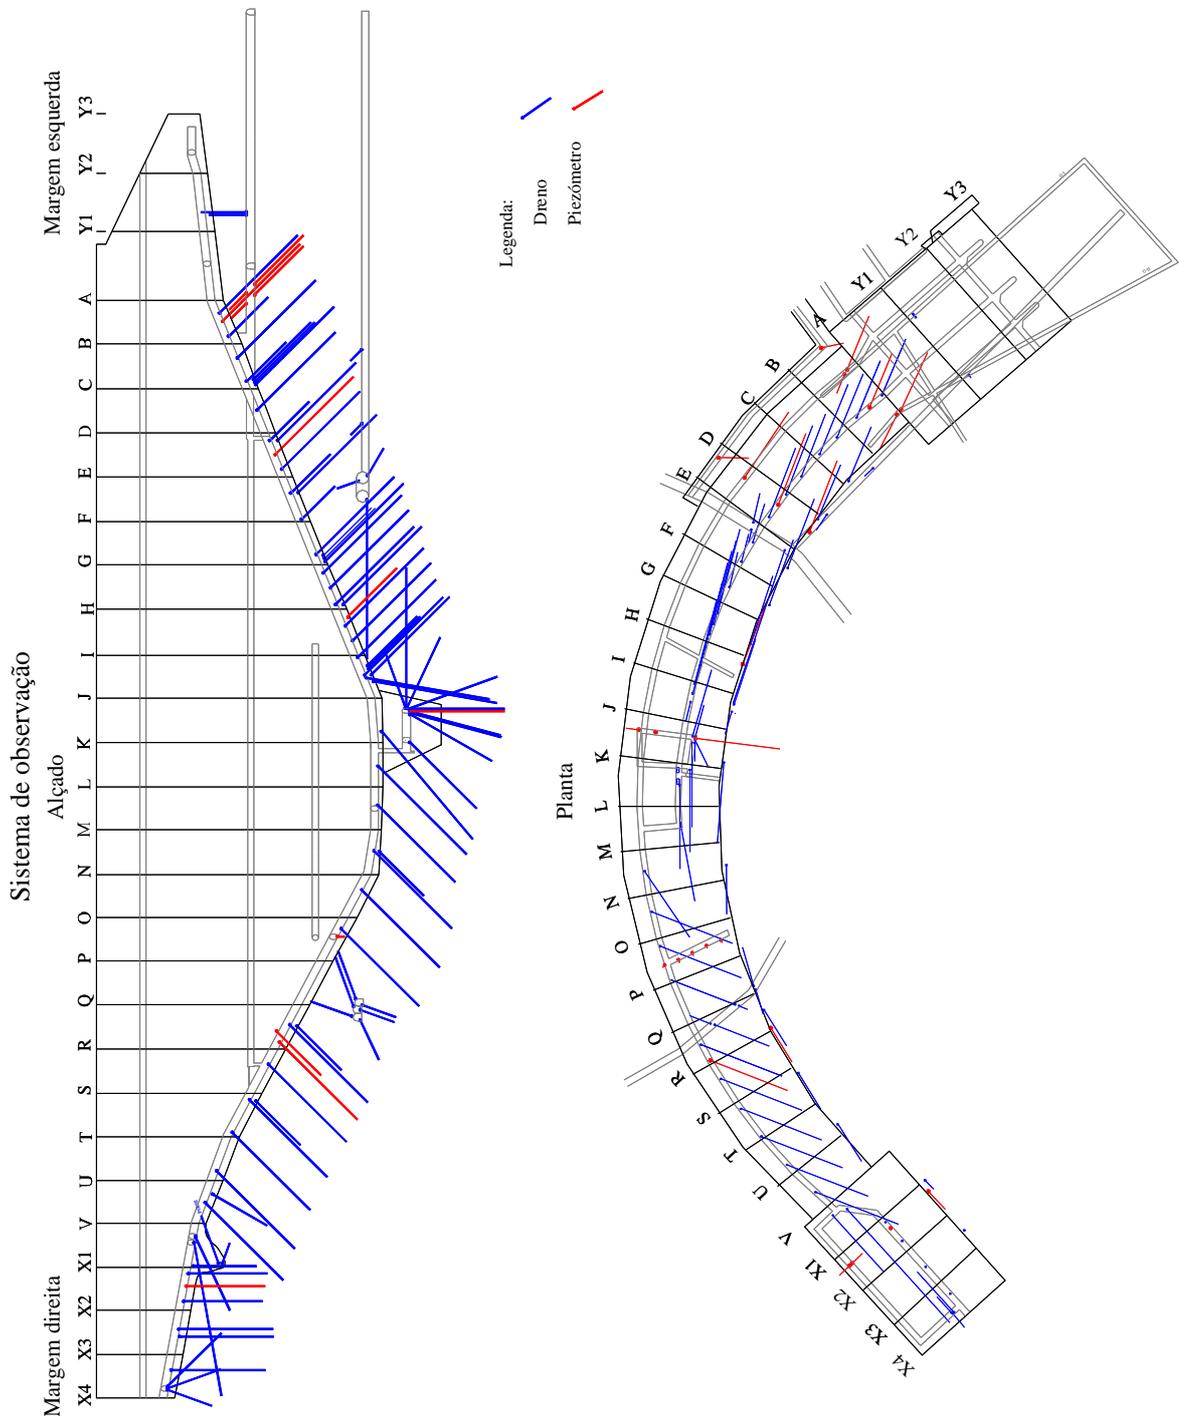


Figura 4.3 – Sistema de observação na zona da abóbada: rede de drenagem e piezométrica

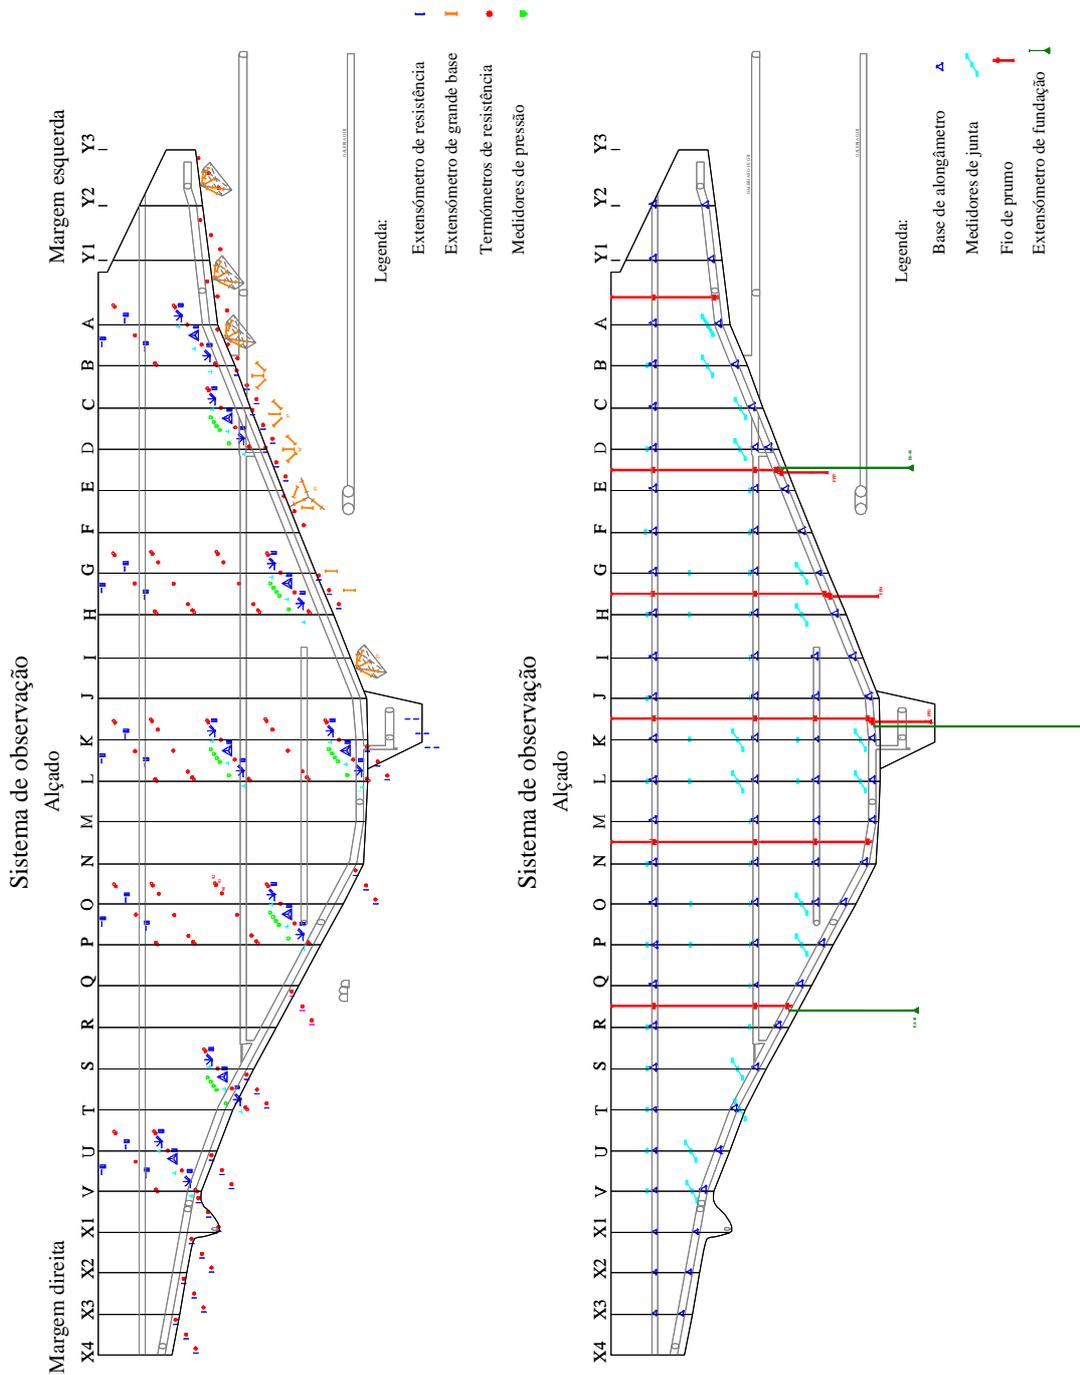


Figura 4.4 – Sistema de observação na zona da abóbada: aparelhagem eléctrica, bases de alongâmetro, fios de prumo e extensómetros de fundação

Como referido anteriormente, o sistema de observação é constituído por um conjunto de instrumentos de medida de diversas grandezas, localizados nos locais onde a medição de tais grandezas é relevante. No Quadro 4.1 apresenta-se o número total de instrumentos existentes na zona em abóbada da barragem do Alto Rabagão [Silva e Portela, 1995].

Quadro 4.1 – Número total de instrumentos existentes na zona em abóbada da barragem do Alto Rabagão [Silva e Portela, 1995]

Grandeza	Tipo de aparelho	Número de instrumentos
Deslocamentos horizontais	Fio de prumo direito (bases)	19
	Fio de prumo invertido (bases)	3
Deslocamentos na fundação	Extensómetro de fundação	3
Movimento de juntas	Bases de alongâmetro	93
	Medidor de juntas	90
Teor de humidade	Medidor de humidade	6
	Telehigrómetro	6
Deslocamentos angulares	Clinómetro (bases)	3
Pressão nos poros	Medidor de pressão Carlson	30
Extensões	Extensómetro Carlson	276
	Extensómetro de armadura	6
	Extensómetro de grande base	36
Temperaturas	Termómetro de resistência	169
Tensões	Células de Carlson	24
Subpressões	Piezómetro	28
Caudais	Dreno	67

4.5. Grandezas analisadas

Na elaboração das redes neuronais apresentadas neste capítulo foram modeladas a onda térmica média anual no betão, as subpressões, os caudais infiltrados, os deslocamentos horizontais, os deslocamentos na fundação e os movimentos de abertura e fecho de juntas.

Dado o grande número de instrumentos existentes na barragem do Alto Rabagão e os objectivos propostos no presente trabalho, foram seleccionados para estudo alguns instrumentos considerados representativos do comportamento da obra, nomeadamente as temperaturas do betão em nove pontos da barragem, o caudal de uma bica, as

subpressões num piezómetro, os deslocamentos radiais em nove bases de coordenómetro de dois fios prumo, os deslocamentos horizontais tangenciais em três bases de coordenómetro de um fio prumo, o deslocamento da fundação registado em um extensómetro de fundação e os movimentos de abertura e fecho medidos em uma base de alongâmetro. No Quadro 4.2 apresentam-se resumidamente as grandezas seleccionadas, assim como os respectivos instrumentos de medida, designações e datas das observações iniciais.

Quadro 4.2 – Instrumentos utilizados no estudo e datas das observações iniciais

Grandeza	Instrumentos	Designações dos instrumentos	Data das leituras iniciais
Temperatura no betão	Oito termómetros de resistência	162, 141, 102, 157, 133, 152, 127, 89	6-4-1979
	Um extensómetro de resistência	68-11	23-1-1986
Subpressão	Um piezómetros	PPM68	12-3-1964
Deslocamento radial	Dois fios prumo (nove bases)	FP1-791m; FP1-810,5m; FP1-831,1m; FP1-865,6m; FP1-879,25m; FP2-810,5m; FP2-831,1m; FP2-865,6m; FP2-879,25m	10-1-1964
Deslocamento tangencial	Um fio prumo (três bases)	FP3-831,2m; FP3-865,5m; FP3-879,25m	10-1-1964
Deslocamento na fundação	Um extensómetro de fundação	E6-46	24-3-1998
Abertura e fecho de juntas	Uma base de alongâmetro	BA064	25-5-1965
Caudal	Uma bica	Bica 1	30-7-1973

Na análise dos deslocamentos horizontais medidos em fios prumo, o período utilizado na aprendizagem dos modelos de redes neuronais começa em Janeiro de 1980, dado o grande número de observações disponíveis e por se considerar ser esta uma amostra representativa do comportamento desta grandeza no historial da obra.

Relativamente ao extensómetro de fundação, a base de dados de leituras é mais pequena, uma vez que a instalação deste tipo de instrumentos ocorreu apenas em 1998.

4.6. Aspectos gerais dos modelos Perceptrão Multicamada aplicados à barragem do Alto Rabagão

Um dos factores determinantes que condicionaram a selecção da ferramenta de modelação matemática a utilizar neste trabalho foi a sua disponibilidade, tendo-se optado pelo *software Neurosolutions* [NeuroDimension]. Foram implementadas redes do tipo Perceptrão Multicamada com uma camada intermédia, com funções de activação tangente hiperbólica e funções de activação lineares na camada de saída. Na Figura 4.5 pode ser observado um exemplo simplificado de uma rede com três unidades na camada de entrada, uma camada intermédia com duas unidades de processamento, funções de activação tangente hiperbólica e duas saídas com funções de activação linear.

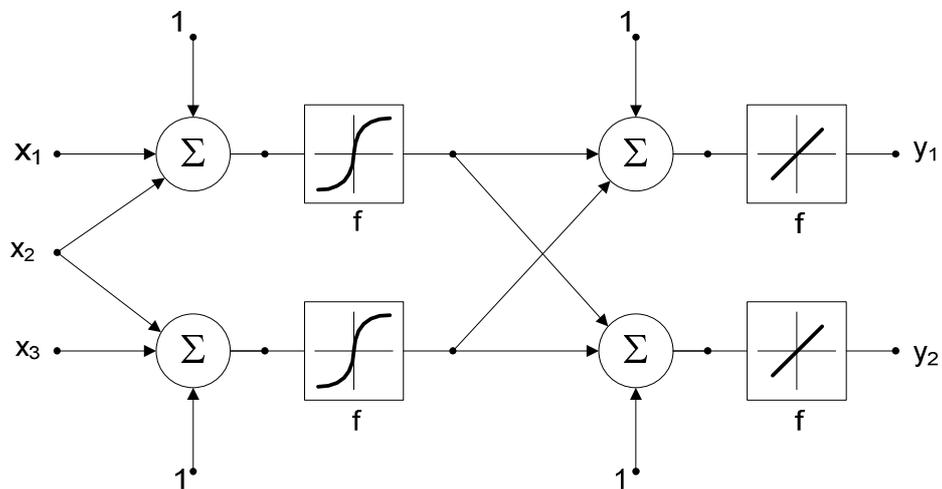


Figura 4.5 – Esquema de uma rede neuronal Perceptrão Multicamada com três entradas, com duas unidades de processamento e funções de activação tangente hiperbólica na camada intermédia e funções de activação lineares na camada de saída

4.6.1. Metodologia utilizada na aprendizagem

Para encontrar o número óptimo de unidades de processamento na camada intermédia, o treino da rede começou por ser efectuado a partir de um número pequeno de unidades de processamento, determinando-se o seu desempenho para os conjuntos de treino e de validação cruzada. Posteriormente foram incrementados elementos de processamentos, um de cada vez, efectuando-se novamente os cálculos do desempenho da nova rede para cada um dos conjuntos. Utilizou-se como critério de paragem a validação cruzada.

Uma vez que cada inicialização aleatória dos pesos pode conduzir a um mínimo local diferente, estipulou-se em cinco o número de inicializações por cada rede neuronal.

Os dados referentes ao historial das observações da obra foram separados em dois conjuntos, conforme se pode ver na Figura 4.6. O primeiro conjunto, designado por conjunto de aprendizagem no intervalo de tempo $\{t_0, t_1\}$, permite escolher o melhor modelo, isto é, seleccionar uma rede com bom desempenho. O segundo conjunto, designado por conjunto de previsão no intervalo $\{t_2, t_3\}$, é formulado com o objectivo de extrapolar os resultados do modelo obtido no primeiro conjunto, e desta forma testar o seu desempenho num contexto de previsão.

Como referido anteriormente, utilizou-se na fase de aprendizagem da rede a validação cruzada como critério para escolha da rede neuronal. Para tal foram previamente definidos, a partir de uma amostra aleatória dos dados do conjunto de aprendizagem, num período previamente estabelecido, o conjunto de treino, o conjunto de validação cruzada e o conjunto de teste, com um número de exemplos igual a 65%, 15% e 20% do conjunto de aprendizagem, respectivamente.

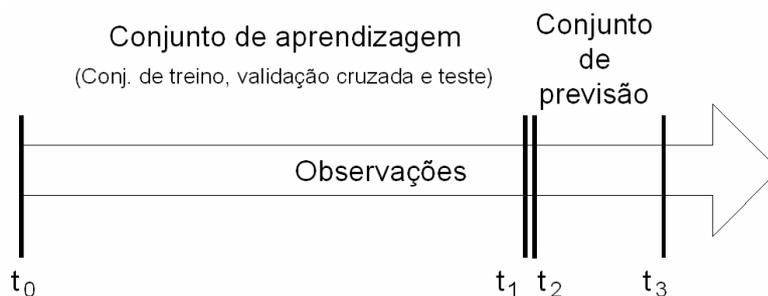


Figura 4.6 – Definição dos conjuntos de aprendizagem e de previsão

4.6.2. Normalização das entradas e saídas

Uma vez estabelecidas as entradas e as saídas, estas são normalizadas entre os valores superiores e inferiores de um intervalo definido por $[-0,9; 0,9]$.

O processo inverso de tratamento das saídas da rede neuronal, $y_k^{L,normalizado}$, para a dimensão real da grandeza física, y_k^L , é efectuado a partir de (55),

$$y_k^L = \frac{y_k^{L,normalizado} - B_k}{A_k} \quad (55)$$

sendo

$$A_k = \frac{LSB - LIB}{y_k^{L,max} - y_k^{L,min}} \quad (56)$$

$$B_k = LSB - A_k \times y_k^{L,max} \quad (57)$$

em que

- A_k – amplitude na saída y_k^L ;
- B_k – defasamento na saída y_k^L ;
- LSB – limite superior da banda (=0,9);
- LIB – limite inferior da banda (=0,9);
- $y_k^{L,max}$ – máximo valor da saída y_k^L ;
- $y_k^{L,min}$ – mínimo valor da saída y_k^L .

4.6.3. Avaliação do desempenho das RNs

Seguidamente são apresentados os critérios utilizados para avaliação do desempenho das redes neuronais:

– erro quadrático médio da rede neuronal

$$EQM^{rede} = \frac{\sum_k \sum_p (d_k^p - y_k^{L,p})^2}{P \times M} \quad (58)$$

– erro quadrático médio na saída k

$$EQM^k = \frac{\sum_p (d_k^p - y_k^{L,p})^2}{P} \quad (59)$$

– erro quadrático médio normalizado na saída k

$$EQMN^k = \frac{P \times EQM^k}{\frac{P \times \sum_p (d_k^p)^2 - \left(\sum_p d_k^p \right)^2}{N}} \quad (60)$$

– erro absoluto médio na saída k

$$EAM^k = \sum_p \frac{|d_k^p - y_k^{L,p}|}{P} \quad (61)$$

– erro absoluto mínimo na saída k

$$EAMin^k = \left| d_k^p - y_k^{L,p} \right|_{Mínimo} \quad (62)$$

– erro absoluto máximo na saída k

$$EAMax^k = \left| d_k^p - y_k^{L,p} \right|_{Máximo} \quad (63)$$

– coeficiente de correlação na saída k

$$r^k = \frac{\sum_p \left[\left(y_k^{L,p} - \overline{y_k^L} \right) \times \left(d_k^p - \overline{d_k} \right) \right]}{\sqrt{\sum_p \left(d_k^p - \overline{d_k} \right)^2} \times \sqrt{\sum_p \left(y_k^{L,p} - \overline{y_k^L} \right)^2}} \quad (64)$$

onde

- P – número de exemplos nos dados;
- M – número de elementos de saída na rede neuronal;
- $y_k^{L,p}$ – valor da rede para o exemplo p na saída k ;
- d_k^p – valor observado para o exemplo p na saída k ;
- $\overline{y_k^L}$ – média dos valores da rede na saída k ;
- $\overline{d_k}$ – média dos valores observados na saída k .

Os valores do erro quadrático médio, EQM^k , e de coeficiente de correlação na saída k , r^k , permitem verificar o ajuste da saída da rede aos valores observados.

O coeficiente de correlação na saída k está confinado ao intervalo $[-1,1]$. Quando $r=1$ significa que existe uma perfeita correlação linear positiva entre y e d , isto é, que variam na mesma proporção. Se $r=-1$, então a correlação linear negativa é perfeita, querendo dizer que y e d variam de forma oposta (quando y aumenta, d diminui na mesma quantidade). Por último, se $r=0$, então diz-se que não existe correlação entre y e d ou que a correlação é nula. Para valores acima de $r=0,8$ pode afirmar-se que o ajuste do modelo aos dados é bom.

4.7. Modelos Percepção Multicamada das acções

4.7.1. Temperatura

As variações da temperatura são acções importantes nas barragens de betão. A temperatura no interior do betão da barragem depende da temperatura do ar, da temperatura da água da albufeira, da incidência solar, da espessura do betão, entre outros factores.

Em Portugal, a evolução da temperatura do ar pode ser assimilada, em termos médios, a uma onda térmica do tipo sinusoidal com período anual. A temperatura no betão da barragem varia em função do local medido, porém a sua evolução tem também a forma de uma onda térmica anual do tipo sinusoidal. Em estruturas com uma grande inércia térmica, como é o caso da barragem do Alto Rabagão, a onda térmica diária no betão não é, em geral, significativa. As diferenças verificadas, em termos de ondas térmicas anuais no betão nos diferentes pontos, verificam-se ao nível da amplitude e da fase da onda.

Com o objectivo de estimar a evolução da temperatura em vários pontos da obra, foram implementados modelos de redes neuronais, cujas saídas são as temperaturas no betão. A obtenção dos dados foi efectuada a partir de instrumentos de resistência eléctrica embebidos no corpo da barragem, tendo sido analisadas zonas a meia espessura e a várias cotas nos blocos GH, KL e OP. A análise das temperaturas no betão foi efectuada bloco a bloco, ou seja, foi criada uma rede neuronal para a obtenção de uma estimativa da temperatura no betão por cada bloco (GH, KL e OP). Os instrumentos utilizados são apresentados no Quadro 4.3 e na Figura 4.7.

Quadro 4.3 – Identificação dos instrumentos utilizados na modelação da temperatura no betão

Bloco	Cota (m)	Designação	Tipo de instrumento
GH	867,5	162	Termómetro de resistência
	853,5	141	Termómetro de resistência
	832	102	Termómetro de resistência
KL	867,5	157	Termómetro de resistência
	854	133	Termómetro de resistência
	837	68-11	Extensómetro de resistência
OP	867,5	152	Termómetro de resistência
	853,5	127	Termómetro de resistência
	833	89	Termómetro de resistência

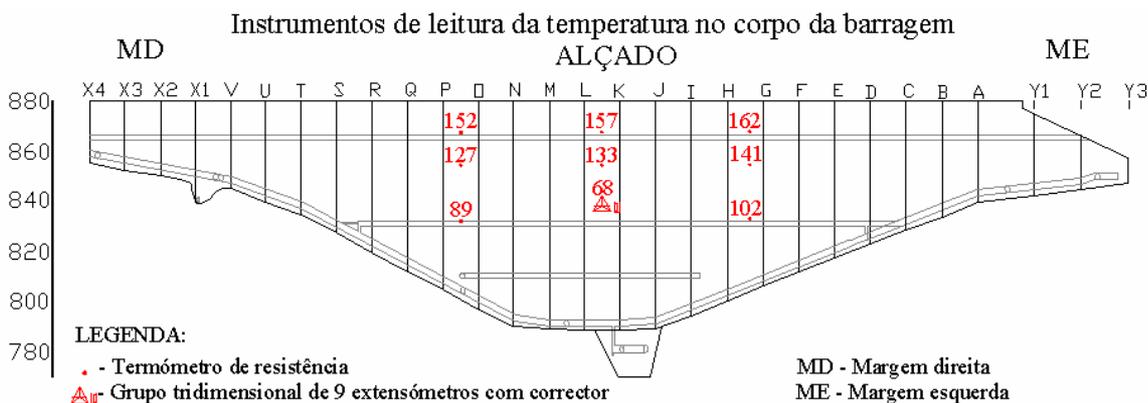


Figura 4.7 – Instrumentos de leitura da temperatura

A medição da temperatura do ar é efectuada com termómetros de máxima e mínima, registando a envolvente da temperatura diária. Assim, foram utilizadas entradas alternativas para a rede neuronal. Numa primeira abordagem considerou-se como entrada da rede neuronal o número de dias desde 1 de Janeiro do ano a que corresponde a data da observação (por exemplo: 1, 2, ..., 365). Embora se tenha obtido um bom ajuste aos valores observados, verificou-se uma descontinuidade na transição entre as estimativas dos meses de Dezembro e de Janeiro seguinte.

Considerando-se que a onda térmica anual se mantém constante, isto é, não há efeitos de aquecimento (ou arrefecimento) anual no período analisado, as saídas devem satisfazer exigências de continuidade nas temperaturas de 31 de Dezembro e 1 de Janeiro do ano seguinte. Tal pode ser conseguido garantindo-se que as entradas da rede neuronal apresentem uma periodicidade também anual e com continuidade entre 31 de Dezembro e 1 de Janeiro do ano seguinte.

Numa segunda tentativa optou-se por modelar a onda térmica anual a partir da expressão $\cos\left(\frac{2\pi \times D}{365}\right)$, onde D corresponde ao número de dias desde 1 de Janeiro do ano a que corresponde a data da observação. Neste modelo a condição de continuidade foi verificada, mas o modelo apresentava uma certa dificuldade em encontrar a correcta fase da onda térmica.

Finalmente, uma terceira opção foi a utilização simultânea dos termos $\cos\left(\frac{2\pi \times D}{365}\right)$ e $\sin\left(\frac{2\pi \times D}{365}\right)$. Constatou-se que a rede apresentava óptimos resultados, tendo-se assim adoptado redes deste tipo para a modelação das temperaturas no betão.

No Quadro 4.4 são apresentadas as entradas e as saídas das redes RN1, RN2 e RN3, que são os modelos para as temperaturas nos blocos GH, KL e OP respectivamente.

Quadro 4.4 – Entradas e saídas das RNs para modelação das temperaturas no betão

Modelo	Entradas	Saídas Temperatura no betão (°C)
RN1	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$	$TB(GH;867,5;DO)$ $TB(GH;853,5;DO)$ $TB(GH;832;DO)$
RN2	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$	$TB(KL;867,5;DO)$ $TB(KL;854;DO)$ $TB(KL;837;DO)$
RN3	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$	$TB(OP;867,5;DO)$ $TB(OP;853,5;DO)$ $TB(OP;833;DO)$

Legenda:

DO – dia da observação do exemplo de treino (dia/mês/ano);

D – número de dias após 1 de Janeiro do mesmo ano a que corresponde a data da observação DO (1,2,...,365);

$TB(X,Y,DO)$ – temperatura do betão a meia espessura no bloco X à cota Y (m) em DO (°C).

No caso particular das temperaturas no betão, utilizou-se como período de aprendizagem todo o domínio temporal existente na base de dados (Quadro 4.5), não se considerando nenhum período de previsão.

Quadro 4.5 – Período de aprendizagem nos modelos de RNs de temperaturas no betão

Modelo	Período de aprendizagem		
	Inicial	Final	Número total de observações
RN1	6-4-1979	7-9-2005	260
RN2	23-1-1986	7-9-2005	169
RN3	6-4-1979	7-9-2005	258

Como referido anteriormente em 4.6, o mesmo processo foi efectuado para cada rede neuronal na fase de aprendizagem, destacando-se que todas as redes começaram por ser treinadas com um número reduzido de elementos de processamento na camada intermédia, sendo gradualmente incrementadas até um número suficientemente elevado

que fizesse com que a rede neuronal com melhor desempenho, para o conjunto de validação cruzada, estivesse dentro desse conjunto de redes.

O período de aprendizagem na rede RN2 foi inferior aos demais por limitação nas observações do extensómetro de resistência 68-11, o qual apenas dispõe de informação a partir de 23-1-1986.

No Quadro 4.6 são apresentados os EQMs das redes neuronais com melhor desempenho para o conjunto de validação cruzada nos três modelos (RN1, RN2 e RN3).

Quadro 4.6 – Desempenho das melhores RNs obtidas para as temperaturas no betão

Modelo	Elementos de processamento na camada intermédia	EQM Conjunto de validação cruzada (°C ²)
RN1	13	0,272
RN2	14	0,328
RN3	8	0,332

Na Figura 4.8 apresentam-se os valores observados das temperaturas no betão e os valores obtidos pela RN2 (bloco KL).

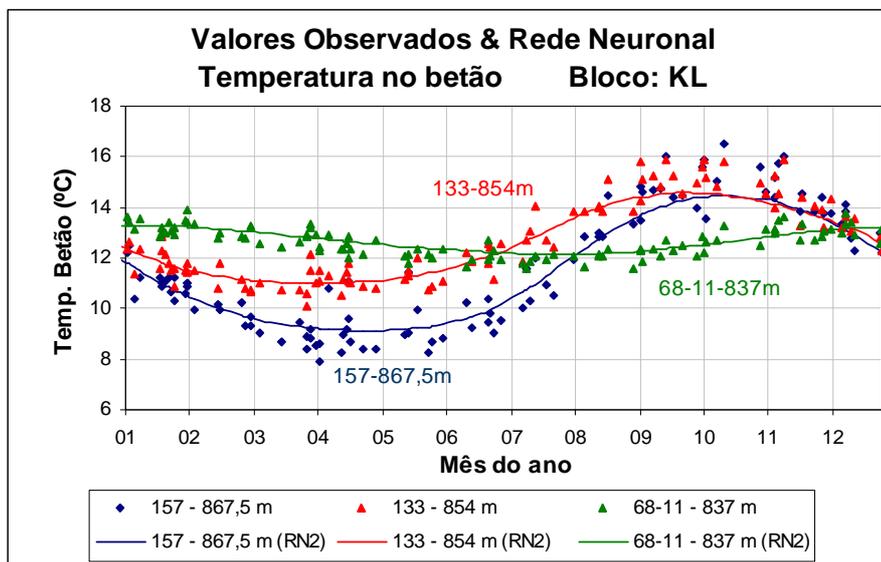


Figura 4.8 – Valores observados e da RN2 para as temperaturas no betão no bloco KL

No Quadro 4.7 apresentam-se valores indicativos do desempenho da RN2. Nas colunas correspondentes a EQM, EAM, EAMax e *r*, verifica-se que os valores destes parâmetros diminuem das observações às cotas mais elevadas para as mais baixas, sendo as amplitudes térmicas, naturalmente, menores na proximidade da base.

Em termos do EQM normalizado (EQMN) e em consequência do que foi dito anteriormente, faz sentido que aumente para as medições efectuadas a cotas cada vez mais baixas, já que o erro relativo associado à medição é maior. Deste modo, a rede neuronal apresenta melhor desempenho para as temperaturas do betão referente ao termómetro de resistência 157, já que o coeficiente de correlação é maior e o EQMN é o menor, mesmo que em termos absolutos os erros sejam superiores. Deve referir-se que resultados referentes ao desempenho das redes RN1 e RN3, embora não sejam aqui apresentados, foram igualmente satisfatórios.

Quadro 4.7– Desempenho da RN2 para as saídas de temperaturas do betão no bloco KL

Desempenho da RN2 para o bloco KL							
Saída	Conjunto	EQM (°C ²)	EQMN	EAM (°C)	EAMin (°C)	EAMax (°C)	r
157 867,5m	Treino	0,610	0,110	0,605	0,021	2,217	0,96
	Validação Cruzada	0,567	0,120	0,605	0,000	1,739	0,94
	Teste	0,703	0,126	0,700	0,048	1,936	0,94
133 854m	Treino	0,342	0,132	0,454	0,002	1,815	0,95
	Validação Cruzada	0,368	0,156	0,497	0,018	1,380	0,94
	Teste	0,390	0,159	0,492	0,019	1,883	0,93
68 - 11 837m	Treino	0,112	0,364	0,279	0,000	0,732	0,82
	Validação Cruzada	0,086	0,341	0,241	0,016	0,596	0,86
	Teste	0,220	0,735	0,391	0,005	1,256	0,61

Nas Figuras 4.9 e 4.10 são apresentados gráficos dos resultados para as redes neuronais referentes aos blocos GH (RN1) e OP (RN3), respectivamente.

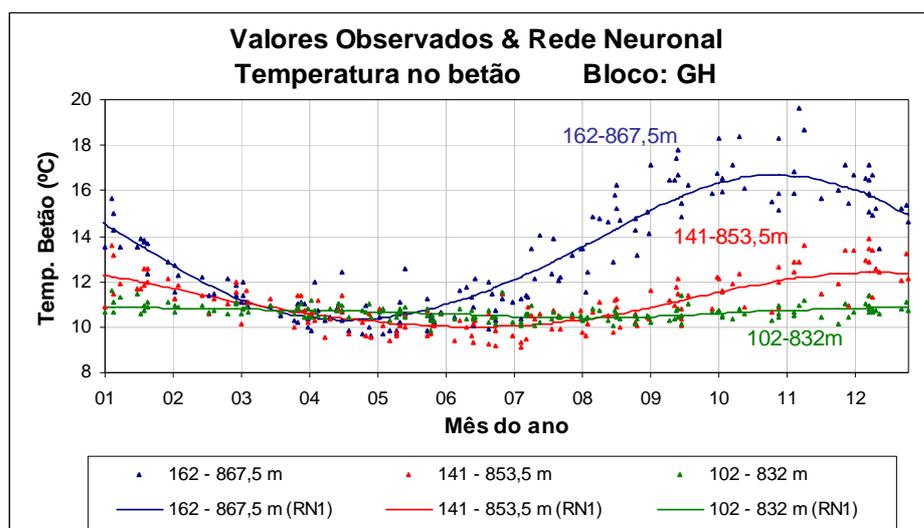


Figura 4.9 – Valores observados e da RN1 para as temperaturas no betão no bloco GH

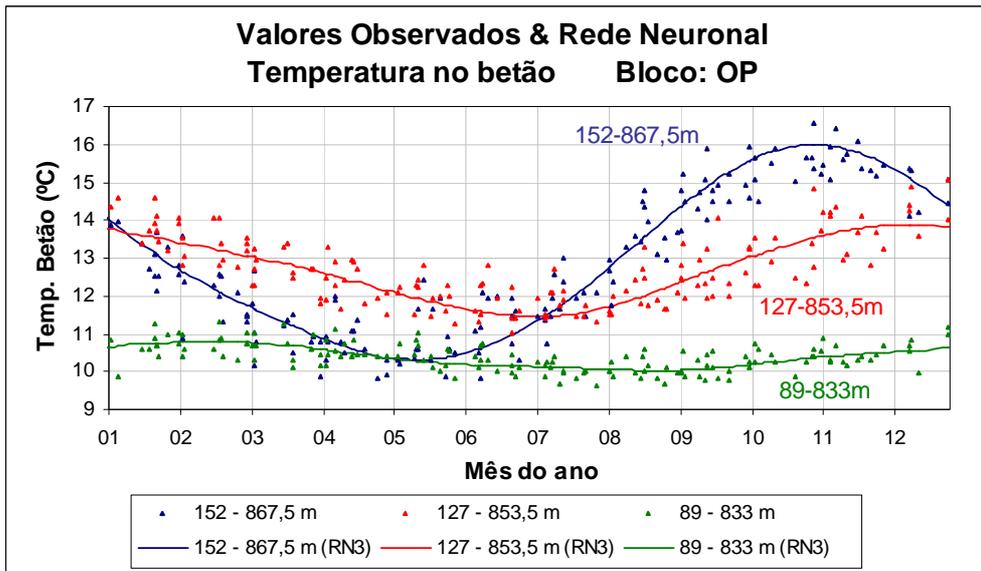


Figura 4.10 – Valores observados e da RN3 para as temperaturas no betão no bloco OP

4.7.2. Pressão hidrostática

A pressão hidrostática é uma das acções mais importantes que actuam na barragem e a sua evolução pode ser caracterizada pela variação da cota da albufeira.

Na Figura 4.11 apresenta-se a evolução da cota da albufeira da barragem do Alto Rabagão desde Janeiro de 1980 até Setembro de 2005.

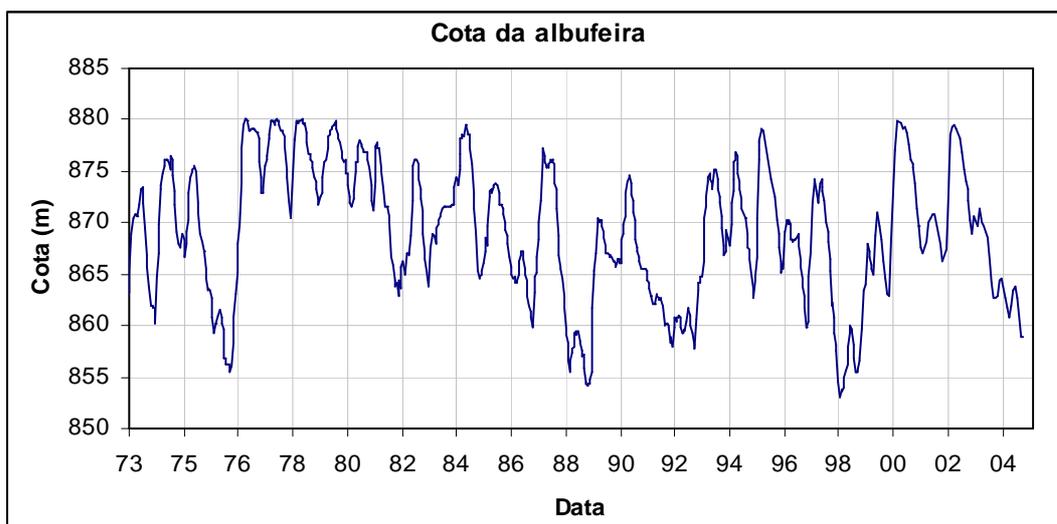


Figura 4.11 – Evolução da cota da albufeira da barragem do Alto Rabagão entre 1980 e 2005

4.7.3. Subpressões

Para a análise das subpressões escolheu-se o piezómetro PPM68, conforme indicado na Figura 4.12 e no Quadro 4.8.

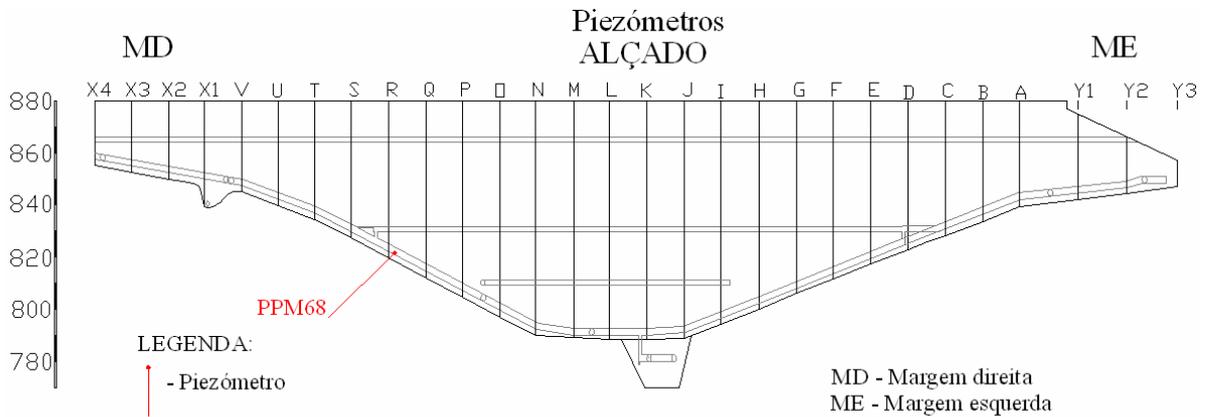


Figura 4.12 – Piezómetro utilizado nos modelos de RNs das subpressões

Quadro 4.8 – Piezómetro utilizado na modelação de subpressões

Bloco	Cota do manómetro (m)	Designação	Tipo de instrumento de leitura
QR	824,1	PPM68	Manómetro

Nos modelos de redes neuronais desenvolvidos as saídas são as subpressões observadas no piezómetro PPM68.

Para esta grandeza foram construídas duas redes neuronais. A RN1, tem como objectivo modelar apenas a dependência directa da grandeza analisada em relação à temperatura e à cota da albufeira. A RN2 tem também em conta a evolução do nível de água na albufeira nos 5 dias que antecedem a data da observação.

No Quadro 4.9 apresentam-se os parâmetros de entrada e a saída das duas redes neuronais analisadas e no Quadro 4.10 apresentam-se os períodos de aprendizagem e previsão utilizados nos modelos de RN das subpressões.

Quadro 4.9 – Entradas e saídas utilizadas nos modelos de RNs das subpressões no PPM68

Modelo	Entradas	Saídas Altura de água (m)
RN1	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$	y_{PPM68}
RN2	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$ $C(DO-1)$ $C(DO-2)$ $C(DO-3)$ $C(DO-4)$ $C(DO-5)$	

Legenda:

- DO – Dia da observação do exemplo de treino (dia/mês/ano);
 D – número de dias após 1 de Janeiro do mesmo ano a que corresponde a data da observação DO (1,2,...,365);
 $C(DO)$ – cota da albufeira no dia da observação DO (m).

Quadro 4.10 – Período de aprendizagem e previsão nos modelos de RNs de subpressões

Modelo	Período de aprendizagem			Período de previsão		
	Inicial	Final	Número total de padrões	Inicial	Final	Número total de padrões
RN1	17-12-1970	31-12-2002	714	1-1-2003	26-9-2005	35
RN2						

Conforme se pode verificar no Quadro 4.11, o desempenho obtido nas duas redes neuronais é semelhante, pelo que se optou pela RN1.

Quadro 4.11 – Desempenho dos melhores modelos de RNs de subpressões no PPM68

Modelo	Elementos de processamento na camada intermédia	EQM Conjunto de validação cruzada (m ²)
RN1	10	0,527
RN2	29	0,618

Na Figura 4.13 apresenta-se um gráfico com os valores observados no piezómetro PPM68 e os valores obtidos pela RN1. Pode-se considerar que, de uma forma geral, o modelo para estimar as subpressões no piezómetro PPM68 é apropriado.

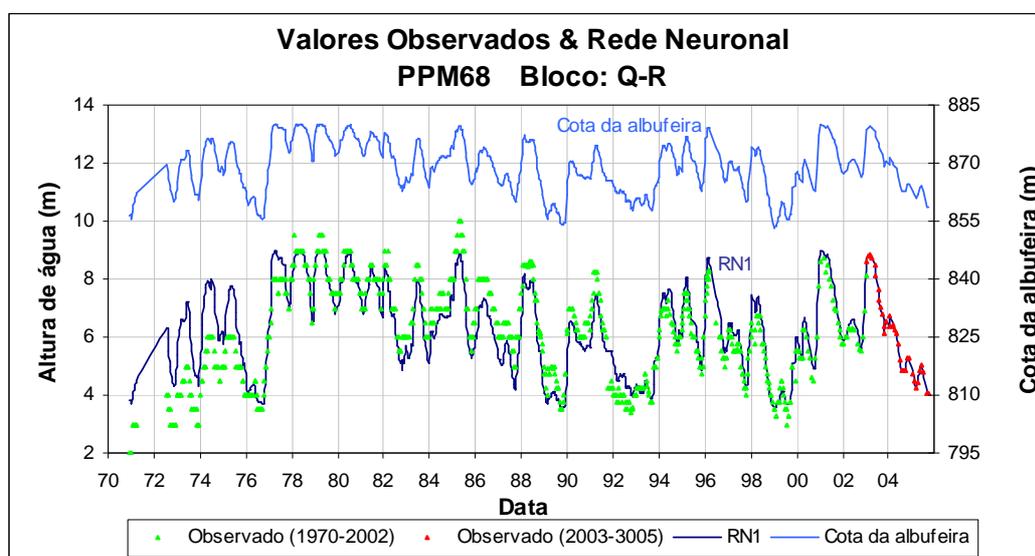


Figura 4.13 – Valores observados e do modelo de RN para as subpressões no PPM68 (período de aprendizagem e de previsão)

O Quadro 4.12 apresenta os parâmetros EQM, EQMN, EAM, EAMin, EAMax e r, os quais traduzem o bom desempenho da RN1.

Quadro 4.12 – Desempenho da RN1 para as subpressões no PPM68

Desempenho da RN1							
Saída	Conjunto	EQM (m ²)	EQMN	EAM (m)	EAMin (m)	EAMax (m)	r
y_{PPM68}^{RN1}	Treino	0,726	0,257	0,663	0,002	2,528	0,87
	Validação Cruzada	0,527	0,176	0,599	0,010	2,361	0,91
	Teste	0,604	0,217	0,606	0,000	2,698	0,89
	Previsão	0,075	0,043	0,216	0,018	0,851	0,98

4.8. Modelos Percepção Multicamada da resposta da estrutura

Seguidamente são apresentados os modelos de redes neuronais de algumas das principais grandezas observadas na barragem do Alto Rabagão, nomeadamente deslocamentos horizontais, deslocamentos na fundação, abertura e fecho de juntas e caudais.

4.8.1. Deslocamentos horizontais

Dada a importância dos deslocamentos horizontais no controlo de segurança das barragens de betão, a sua observação é efectuada com uma frequência relativamente elevada, particularmente as observações efectuadas com fios prumo (Figura 4.14). Assim, a disponibilidade destes dados é relativamente elevada.

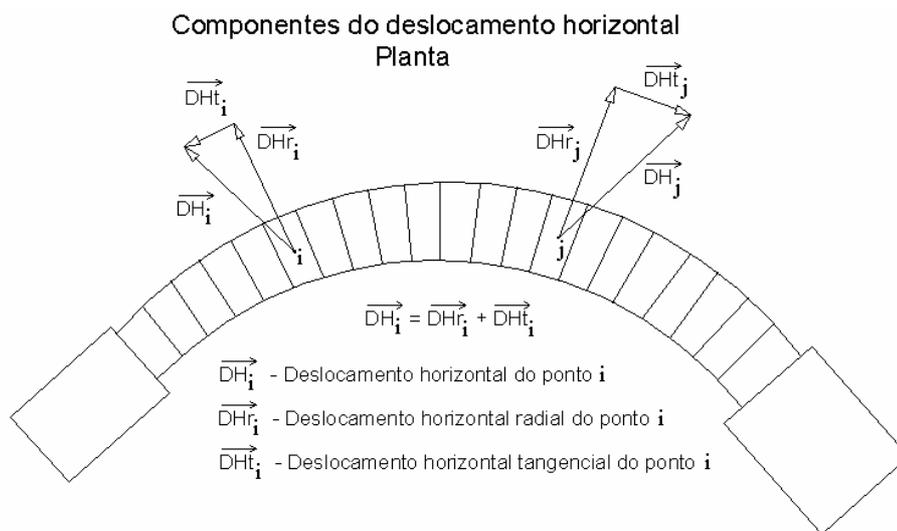


Figura 4.14 – Componentes radial e tangencial do deslocamento horizontal

No presente trabalho foram analisados 3 fios de prumos (blocos QR, MN e JK). A base de dados utilizada para a aprendizagem compreendeu as observações entre Janeiro de 1980 e Dezembro de 2002, tendo-se considerado o período de previsão entre Janeiro de 2003 e Setembro de 2005.

Os modelos de redes neuronais dos deslocamentos horizontais, assim como de outras grandezas, pode ser efectuada para um único instrumento, através das observações de uma base de coordenómetro, pode também ser efectuada considerando em simultâneo as observações de todas as bases de coordenómetro de um fio de prumo

e, ainda, agrupando informação de várias bases de coordenómetro de diferentes fios prumos.

Em geral, verifica-se que nas barragens abóbada a ordem de grandeza das componentes tangenciais é significativamente inferior às componentes radiais dos deslocamentos. Assim, a modelação em simultâneo destas duas componentes poderia conduzir a uma diminuição na qualidade do desempenho da rede. Esta perda de qualidade nos resultados deve-se ao facto das entradas e saídas serem normalizadas, tal implica que o erro relativo associado aos deslocamentos tangenciais tenha maior relevância no desempenho global da rede neuronal, pelo que se optou por modelar separadamente as componentes radiais e tangenciais dos deslocamentos horizontais.

Foram seleccionados para a análise os pontos mais significativos em termos do comportamento global da estrutura para cada uma das componentes. Deste modo foram estudados os deslocamentos radiais na zona próxima do fecho da abóbada e os deslocamentos tangenciais na zona dos rins.

4.8.1.1. Deslocamento radial

Na modelação dos deslocamentos radiais foram utilizados em simultâneo as leituras dos fios prumo FP1 e FP2. A localização relativa desses instrumentos pode ser visualizada nas Figuras 4.15 e 4.16.

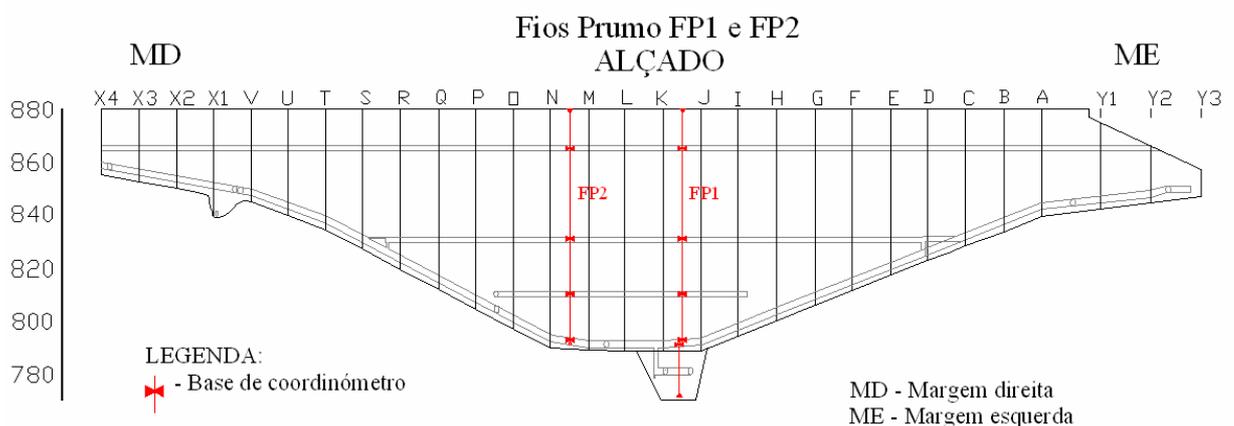


Figura 4.15 – Fios prumo utilizados nos modelos de RNs de deslocamentos radiais

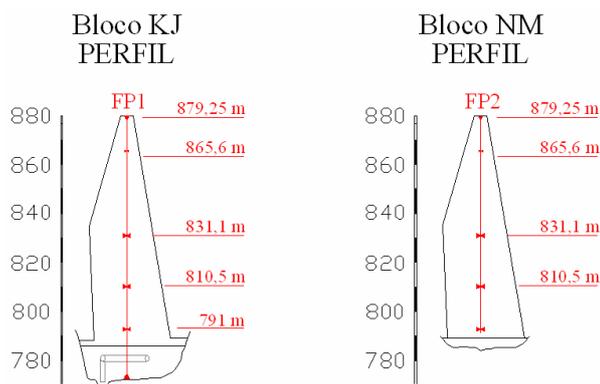


Figura 4.16 – Bases de coordenómetro dos FP1 e FP2

Treinaram-se redes do tipo Perceptrão Multicamada com uma camada intermédia (com número de unidades de processamento variável) e uma camada de saída, correspondente aos deslocamentos radiais observados nas bases indicadas no Quadro 4.13.

Quadro 4.13 – Bases de coordenómetro dos FP1 e FP2 utilizadas na modelação de deslocamentos radiais

Bloco	Cota (m)	Designação	Tipo de instrumento
KJ	791	FP1 – 791 m	Fio prumo
	810,5	FP1 – 810,5 m	
	831,1	FP1 – 831,1 m	
	865,6	FP1 – 865,6 m	
	879,25	FP1 – 879,25 m	
NM	810,5	FP2 – 810,5 m	
	831,2	FP2 – 831,1 m	
	865,6	FP2 – 865,6 m	
	879,25	FP2 – 879,25 m	

Consideraram-se para a análise destas grandezas as acções da pressão hidrostática e as variações de temperatura no betão.

Como se referiu anteriormente, a melhor forma de aproximação das temperaturas no betão foi obtida a partir da implementação das entradas com as funções seno e co-seno, tendo como argumento o número de dias desde 1 de Janeiro do ano a que corresponde a data da observação (variando entre 1 e 365). Optou-se igualmente por utilizar este tipo de entradas nas redes neuronais dos deslocamentos, RN2 e RN3. Foi ainda implementada uma outra rede neuronal, RN1, para a qual se escolheu como entradas as nove temperaturas do betão apresentadas em 4.7.1 nos modelos relativos à temperatura.

Para ter em conta o efeito da pressão hidrostática no modelo de rede neuronal considerou-se na entrada as cotas da albufeira.

Para além das três redes neuronais referidas anteriormente, foi ainda elaborado um quarto modelo, RN4, em que foram adicionadas na entrada as cotas da albufeira nos últimos 5 dias, tendo como objectivo verificar a influência desta variável na resposta final. No Quadro 4.14 apresentam-se as entradas e saídas utilizadas nas quatro redes neuronais em análise. A diferença entre a RN2 e a RN3 encontra-se apenas no tratamento dos dados. Na RN3 foram repetidos 15 vezes os máximos e os mínimos locais com o intuito de modelar melhor as respostas nas solicitações extremas.

Quadro 4.14 – Entradas e saídas utilizadas nos modelos de RNs de deslocamentos radiais nos FP1 e FP2

Modelo	Entradas	Saídas Deslocamento radial (mm)
RN1	$TB(GH;867,5;DO)$ $TB(GH;853,5;DO)$ $TB(GH;832;DO)$ $TB(KL;867,5;DO)$ $TB(KL;854;DO)$ $TB(KL;837;DO)$ $TB(OP;867,5;DO)$ $TB(OP;853,5;DO)$ $TB(OP;833;DO)$ $C(DO)$	$y_{FP1-791m}$ $y_{FP1-810,5m}$ $y_{FP1-831,1m}$
RN2	$\cos\left(\frac{2\pi \times D}{365}\right)$	$y_{FP1-865,6m}$
RN3	$\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$	$y_{FP1-879,25m}$ $y_{FP2-810,5m}$
RN4	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$ $C(DO-1)$ $C(DO-2)$ $C(DO-3)$ $C(DO-4)$ $C(DO-5)$	$y_{FP2-831,1m}$ $y_{FP2-865,6m}$ $y_{FP2-879,25m}$

Legenda:

- DO – Dia da observação do exemplo de treino (dia/mês/ano);
 $TB(X, Y, DO)$ – temperatura do betão a meia espessura no bloco X à cota Y no dia da observação DO ($^{\circ}\text{C}$);
 D – número de dias após 1 de Janeiro do mesmo ano a que corresponde a data da observação DO (1,2,...,365);
 $C(DO)$ – cota da albufera no dia da observação DO (m).

Os períodos de aprendizagem e de previsão utilizados estão apresentados no Quadro 4.15.

Quadro 4.15 – Período de aprendizagem e previsão nos modelos de RNs de deslocamentos radiais nos FP1 e FP2

Modelo	Período de aprendizagem			Período de previsão		
	Inicial	Final	Número total de padrões	Inicial	Final	Número total de padrões
RN1	1-1-1980	31-12-2002	914	1-1-2003	15-9-2005	71
RN2			914			
RN3			2294 ⁷			
RN4			914			

No Quadro 4.16 são apresentados os valores dos EQMs do conjunto de validação cruzada para cada uma das redes neuronais com melhor desempenho durante a fase de aprendizagem.

Quadro 4.16 – Desempenho dos melhores modelos de RNs de deslocamentos horizontais radiais nos FP1 e FP2

Modelo	Elementos de processamento na camada intermédia	EQM Conjunto de validação cruzada (mm^2)
RN1	22	0,818
RN2	20	0,852
RN3	25	0,871
RN4	23	0,787

Da análise dos resultados apresentados no Quadro 4.16 verifica-se que os desempenhos são semelhantes em todas as redes neuronais e que qualquer uma delas poderia ser utilizada. A RN4 é a que apresenta menor EQM, no entanto, escolheu-se a RN2 por apresentar menor número de entradas.

⁷ Corresponde aos valores observados extremos repetidos 15 vezes.

A representação gráfica dos valores observados e dos valores estimados pelo modelo adoptado, quer na fase de aprendizagem quer na de previsão, é efectuada nas Figuras 4.17 e 4.18. Os resultados apresentados correspondem às observações e aos valores estimados nas saídas com pior (FP1-791m) e melhor (FP1-879,25m) desempenho.

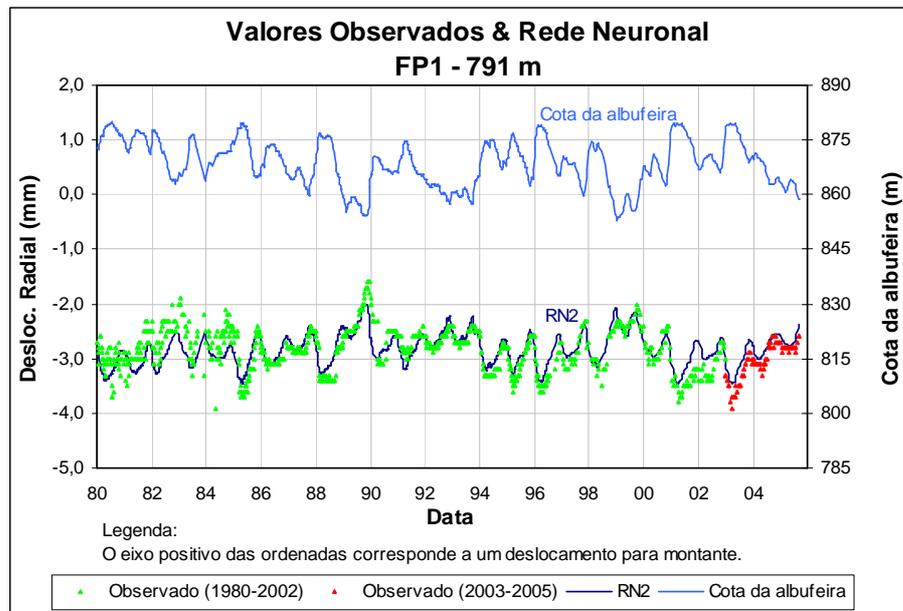


Figura 4.17 – Valores observados e do modelo de RN para os deslocamentos radiais do FP1 - 791 m (período de aprendizagem e de previsão)

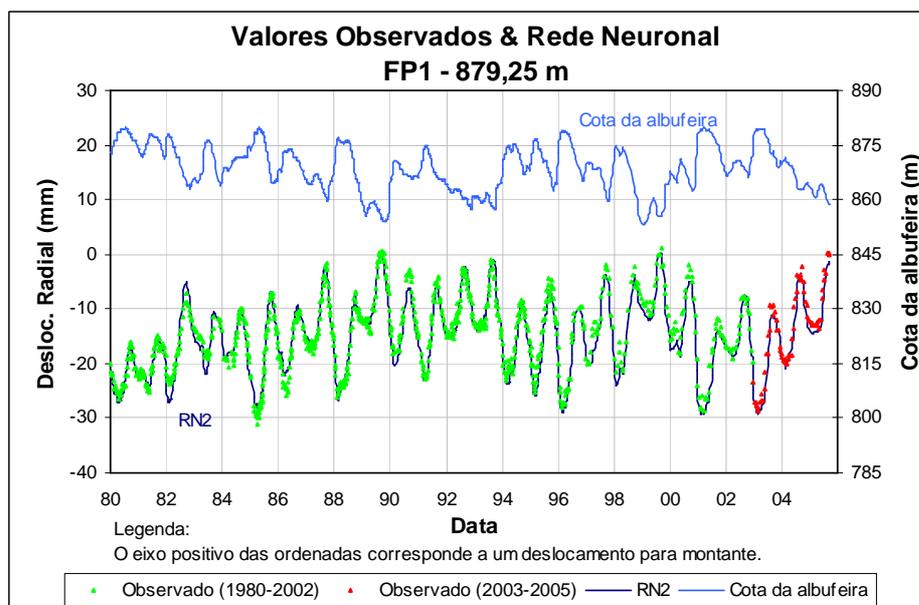


Figura 4.18 – Valores observados e do modelo de RN para os deslocamentos radiais do FP1 - 879,25 m (período de aprendizagem e de previsão)

A análise das Figuras 4.17 e 4.18 permite concluir que a rede neuronal tem maior dificuldade em estimar os valores dos deslocamentos radiais no fio prumo FP1-791m. Nesta base de coordenómetro a ordem de grandeza do erro de medida é maior em termos relativos.

No Quadro 4.17 apresentam-se os parâmetros EQM, EQMN, EAM, EAMin, EAMax e r para a RN2, os quais servem para avaliar o desempenho da rede. Verifica-se que o valor de r é da ordem de 0,80 para o FP1-791m e acima de 0,90 para o FP1-879,25m, pelo que se pode concluir que o modelo é adequado e os resultados são satisfatórios.

Quadro 4.17 – Desempenho da RN2 relativo aos deslocamentos radiais no bloco KJ às cotas 791 m e 879,25 m

Desempenho da RN2							
Saída	Conjunto	EQM (mm ²)	EQMN	EAM (mm)	EAMin (mm)	EAMax (mm)	r
$y_{RN2}^{FP1-791m}$	Treino	0,059	0,399	0,189	0,001	0,963	0,78
	Validação Cruzada	0,062	0,349	0,193	0,000	0,698	0,81
	Teste	0,060	0,387	0,184	0,001	0,831	0,79
	Previsão	0,046	0,411	0,186	0,001	0,439	0,96
$y_{RN2}^{FP1-879,25m}$	Treino	2,143	0,047	1,171	0,001	4,920	0,98
	Validação Cruzada	2,396	0,046	1,216	0,003	4,411	0,98
	Teste	2,543	0,061	1,228	0,018	5,285	0,97
	Previsão	2,574	0,044	1,274	0,029	3,627	0,99

4.8.1.2. Deslocamento tangencial

Para análise dos deslocamentos tangenciais utilizou-se o fio prumo FP3, localizado no bloco QR, onde são observadas as maiores amplitudes de deslocamentos tangenciais. A localização do FP3 é apresentada na Figura 4.19.

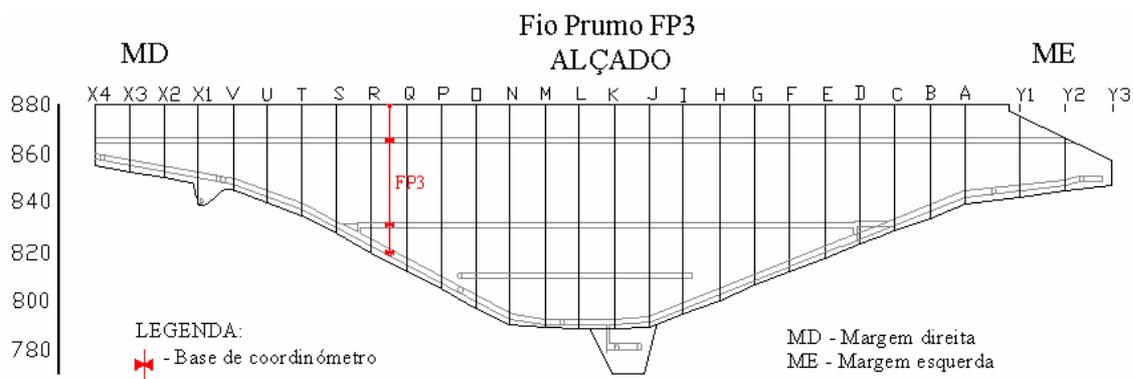


Figura 4.19 – Fio prumo utilizado nos modelos de RNs de deslocamentos tangenciais

No Quadro 4.18 apresentam-se as cotas das bases de coordenómetro no fio prumo FP3. As observações dos deslocamentos tangenciais nas três bases de coordenómetro são as saídas da rede neuronal.

Quadro 4.18 – Bases de coordenómetro utilizados para modelação de deslocamentos horizontais tangenciais do FP3

Bloco	Cota (m)	Designação	Tipo de instrumento
QR	831,2	FP3 – 831,2 m	Fio prumo
	865,5	FP3 – 865,5 m	
	879,25	FP3 – 879,25 m	

Com base nos resultados obtidos para o deslocamento radial, optou-se pela escolha de apenas uma rede com as entradas indicadas no Quadro 4.19. Os períodos de aprendizagem e previsão são apresentados no Quadro 4.20.

Quadro 4.19 – Entradas e saídas utilizados nas RNs de deslocamentos tangenciais no FP3

Modelo	Entradas	Saídas Deslocamento Tangencial (mm)
RN1	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$	$y_{FP3-831,2m}$ $y_{FP3-865,5m}$ $y_{FP3-879,25m}$

Quadro 4.20 – Período de aprendizagem e previsão nos modelos de RNs de deslocamentos tangenciais no FP3

Modelo	Período de aprendizagem			Período de previsão		
	Inicial	Final	Número total de padrões	Inicial	Final	Número total de padrões
RN1	2-1-1980	31-12-2002	917	1-1-2003	15-9-2005	71

A rede neuronal com 27 elementos de processamento na camada intermédia (Quadro 4.21) foi a que apresentou características gerais com melhor desempenho na fase de aprendizagem para o conjunto de validação cruzada.

Quadro 4.21 – Desempenho dos melhores modelos de RNs de deslocamentos tangenciais no FP3

Modelo	Elementos de processamento na camada intermédia	EQM Conjunto de validação cruzada (mm ²)
RN1	27	0,158

Na Figura 4.20 apresentam-se graficamente os resultados da rede neuronal seleccionada para o deslocamento tangencial do FP3 à cota 879,25 m, para o período completo de análise, podendo concluir-se que a rede neuronal apresenta uma boa concordância com os valores observados.

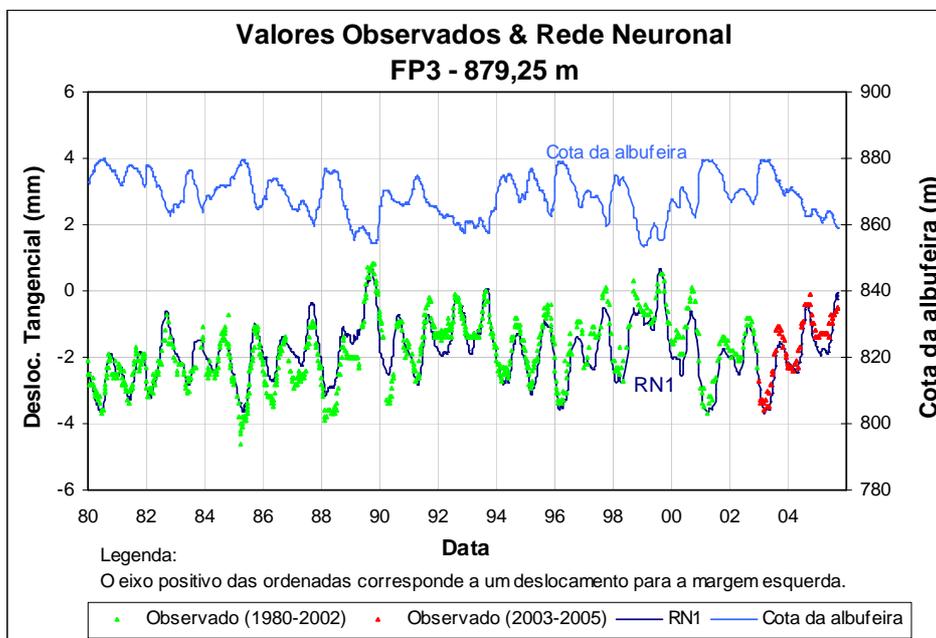


Figura 4.20 – Valores observados e do modelo de RN para os deslocamentos tangenciais do FP3 – 879,25 m (período de aprendizagem e de previsão)

No Quadro 4.22 são apresentados os parâmetros de desempenho da rede RN1 referentes às saídas dos deslocamentos tangenciais no fio prumo FP3 às cotas 879,25 m e 831,2 m (cota mais alta e mais baixa), verificando-se que o coeficiente de correlação é semelhante em ambos os casos.

Quadro 4.22 – Desempenho da RN1 nas saídas de deslocamentos tangenciais às cotas 831,2 m e 879,25 m

Desempenho da RN1							
Saída	Conjunto	EQM (mm ²)	EQMN	EAM (mm)	EAMin (mm)	EAMax (mm)	r
$y_{FP3-831,2m}^{RN1}$	Treino	0,104	0,218	0,250	0,000	1,299	0,88
	Validação Cruzada	0,118	0,214	0,272	0,001	1,155	0,89
	Teste	0,113	0,235	0,261	0,000	1,216	0,88
	Previsão	0,049	0,128	0,180	0,000	0,531	0,94
$y_{FP3-879,25m}^{RN1}$	Treino	0,188	0,192	0,350	0,000	1,221	0,90
	Validação Cruzada	0,220	0,194	0,396	0,020	1,229	0,90
	Teste	0,208	0,201	0,378	0,002	1,280	0,90
	Previsão	0,160	0,184	0,336	0,000	0,823	0,95

Da análise dos dados anteriores pode-se afirmar que para o fio prumo FP3 os valores obtidos pelas redes para os deslocamentos tangenciais mostram uma evolução adequada.

4.8.2. Deslocamento na fundação da barragem

Na barragem do Alto Rabagão existem três extensómetros de fundação localizados no trecho em abóbada. Nos modelos de redes neuronais de deslocamentos na fundação utilizou-se o extensómetro de fundação E6-46 (Quadro 4.23), cuja localização pode ser visualizada na Figura 4.21. Foi o instrumento escolhido por ser o que apresentava um maior número de observações.

Quadro 4.23 – Extensómetro de fundação utilizado nos modelos de RNs

Bloco	Cota (m)	Designação	Tipo de instrumento
ED	822,62	E6 - 46	Extensómetro de fundação

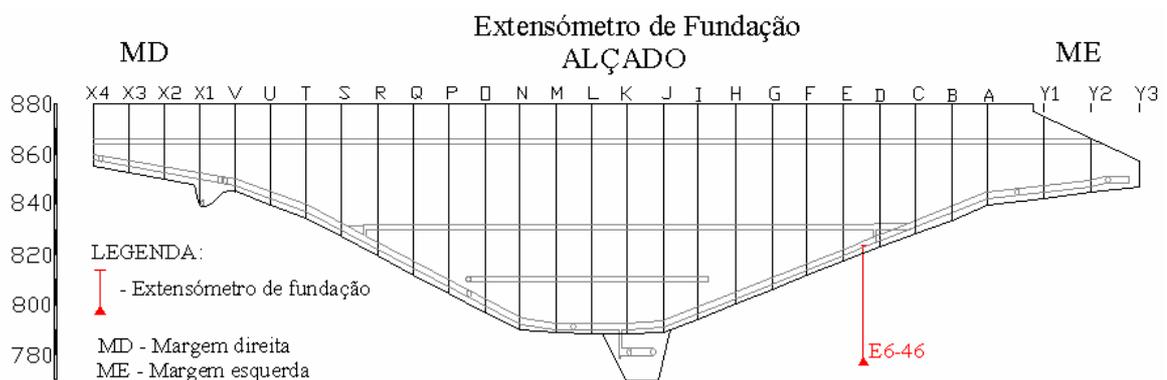


Figura 4.21 – Extensómetro de fundação utilizado nos modelos de RNs de deslocamentos na fundação no E6-46

Para modelar o comportamento desta grandeza foram construídas as redes neuronais RN1 e RN2. Na primeira, RN1, utilizaram-se como entradas a temperatura na forma de seno e de co-seno e as cotas da albufeira. Na RN2, para além das entradas da RN1, teve-se também em conta a evolução da cota da albufeira nos 5 dias que precedem a data da observação. No Quadro 4.24 apresentam-se as entradas e saídas das duas redes neuronais.

Quadro 4.24 – Entradas e saídas nos modelos de RNs dos deslocamentos na fundação no E6-46

Modelo	Entradas	Saída Deslocamento na fundação (mm)
RN1	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$	y_{E6-46}
RN2	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$ $C(DO-1)$ $C(DO-2)$ $C(DO-3)$ $C(DO-4)$ $C(DO-5)$	

As duas redes neurais têm o mesmo período de aprendizagem. Os períodos de aprendizagem e de previsão adoptados são apresentados no Quadro 4.25.

Quadro 4.25 – Período de aprendizagem e previsão nos modelos de RNs de deslocamentos na fundação no E6-46

Modelo	Período de aprendizagem			Período de previsão		
	Inicial	Final	Número total de padrões	Inicial	Final	Número total de padrões
RN1	24-03-1998	31-12-2003	201	01-01-2004	26-09-2005	46
RN2						

No Quadro 4.26 são apresentados os EQMs do conjunto de validação cruzada para cada uma das redes neurais com melhor desempenho durante a fase de aprendizagem.

Quadro 4.26 – Desempenho dos melhores modelos de RNs de deslocamentos na fundação no E6-46

Modelo	Elementos de processamento na camada intermédia	EQM Conjunto de validação cruzada (mm ²)
RN1	29	0,001
RN2	33	0,002

Da observação do Quadro 4.26 verifica-se que os desempenhos das redes RN1 e RN2 são semelhantes. Escolheu-se a RN1 por se ter verificado que para a RN2 não houve uma melhoria do desempenho resultante do acréscimo de entradas.

Através da análise da Figura 4.22 pode-se concluir que, para o conjunto de aprendizagem, a evolução dos valores fornecidos pela RN1 são próximos dos valores esperados. Para o conjunto de previsão pode-se notar que os valores observados estão sempre ligeiramente acima da curva prevista pela rede neuronal.

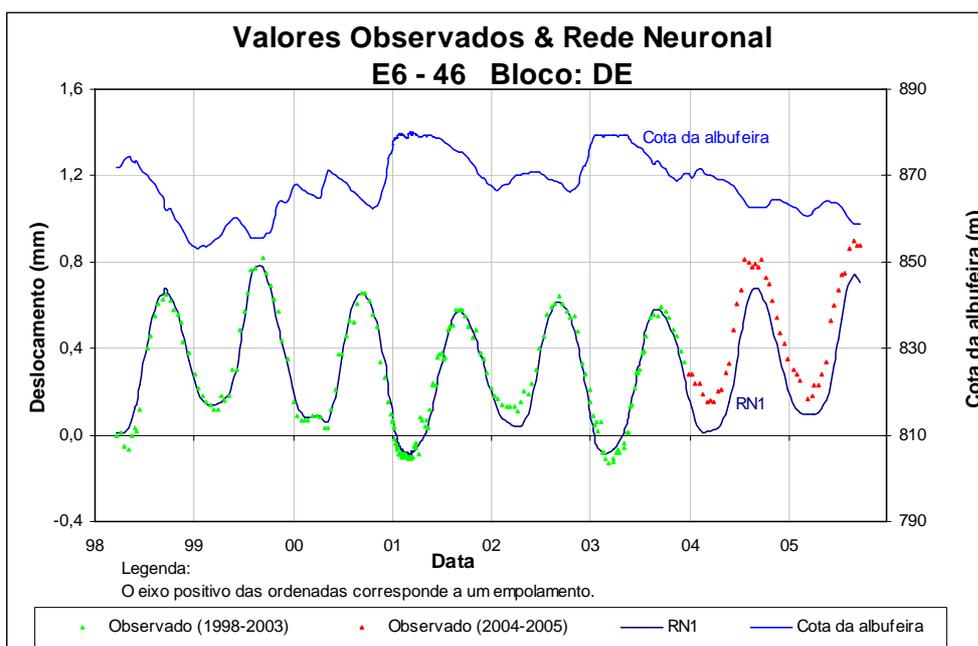


Figura 4.22 – Valores observados e da RN1 para os deslocamentos na fundação no E6-46 (período de aprendizagem e de previsão)

No Quadro 4.27 apresentam-se os parâmetros de desempenho (EQM, EQMN, EAM, EAMin, EAMax e r) para a RN1. Da análise dos resultados apresentados neste quadro verifica-se uma boa concordância entre os valores observados e os obtidos com a RN nos conjuntos de aprendizagem e de previsão, com valores de r acima de 0,95. Constata-se também que o erro EQMN aumentou consideravelmente para o conjunto de

previsão, pelo que em estudos futuros deve ser verificado se a discrepância de valores se mantém, determinando as causas, ou se a diferença se deveu apenas ao facto de o conjunto de aprendizagem ser muito pequeno e pouco representativo das acções existentes no conjunto de previsão.

Quadro 4.27 – Desempenho da RN1 para os deslocamentos na fundação no E6-46

Desempenho da RN1							
Saída	Conjunto	EQM (mm ²)	EQMN	EAM (mm)	EAMin (mm)	EAMax (mm)	r
y^{RN1}_{E6-46}	Treino	0,002	0,033	0,037	0,001	0,134	0,98
	Validação Cruzada	0,001	0,024	0,030	0,000	0,089	0,99
	Teste	0,003	0,047	0,043	0,000	0,140	0,98
	Previsão	0,028	0,446	0,162	0,073	0,290	0,98

4.8.3. Movimentos de abertura e fecho de juntas

Para a modelação do movimento de abertura e fecho de juntas foi seleccionada a base que apresentava amplitudes de movimentos mais elevada, nomeadamente a base de alongâmetro BA064 na junta Q à cota 864,2m (Quadro 4.28), no hasteal de montante da galeria GV1 (Figura 4.23).

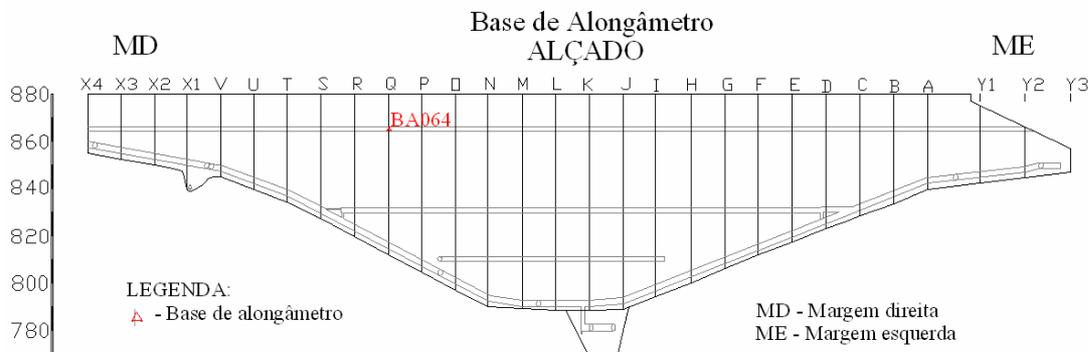


Figura 4.23 – Base de alongâmetro utilizada nos modelos de RNs de movimentos de abertura e fecho de juntas

Quadro 4.28 – Base de alongâmetro utilizada nos modelos de RNs

Junta	Cota (m)	Designação	Tipo de instrumento
Q	864,2	BA064	Base de alongâmetro

Foram construídas duas redes neuronais para a modelação do movimento de abertura e fecho na base de alongâmetro BA064. A RN1 modela apenas a influência directa da temperatura e da cota da albufera na resposta da estrutura e a RN2 considera

também a evolução da cota da albufeira nos 5 dias que antecederam a data da observação. No Quadro 4.29 apresentam-se as entradas e a saída para as duas redes.

Quadro 4.29 – Entradas e saídas utilizadas nos modelos de RNs para a abertura e fecho da junta Q na base BA064

Modelo	Entradas	Saídas Abertura e fecho (mm)
RN1	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$	$y_{BA\ 064}$
RN2	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$ $C(DO-1)$ $C(DO-2)$ $C(DO-3)$ $C(DO-4)$ $C(DO-5)$	

No Quadro 4.30 apresentam-se os períodos de aprendizagem e de previsão utilizados nos modelos de RNs de abertura e fecho da junta.

Quadro 4.30 – Período de aprendizagem e previsão nos modelos de RNs de abertura e fecho da junta Q da base BA064

Modelo	Período de aprendizagem			Período de previsão		
	Inicial	Final	Número total de padrões	Inicial	Final	Número total de padrões
RN1	1-1-1997	31-12-2003	36	1-1-2004	5-9-2005	8
RN2						

No Quadro 4.31 são apresentados os EQMs do conjunto de validação cruzada para as duas redes neuronais. O desempenho da RN1 é significativamente superior ao da RN2, facto que poderá indicar que os movimentos de abertura e fecho de juntas não têm correspondência directa com a história das cotas de água na albufeira nos últimos 5 dias.

Quadro 4.31 – Desempenho dos melhores modelos de RNs de abertura e fecho da junta Q da base BA064

Modelo	Elementos de processamento na camada intermédia	EQM Conjunto de validação cruzada (mm ²)
RN1	8	0,0004
RN2	19	0,0008

Na Figura 4.24 encontra-se a representação gráfica dos movimentos de abertura e fecho observados e obtidos com o modelo de RN1. Constata-se que a rede neuronal estima por excesso os valores do conjunto de previsão. Este desvio poderá, eventualmente, estar relacionado com o facto dos dados serem insuficientes no conjunto de aprendizagem para as cotas da albufeira mais baixas, como as existentes no período de previsão.

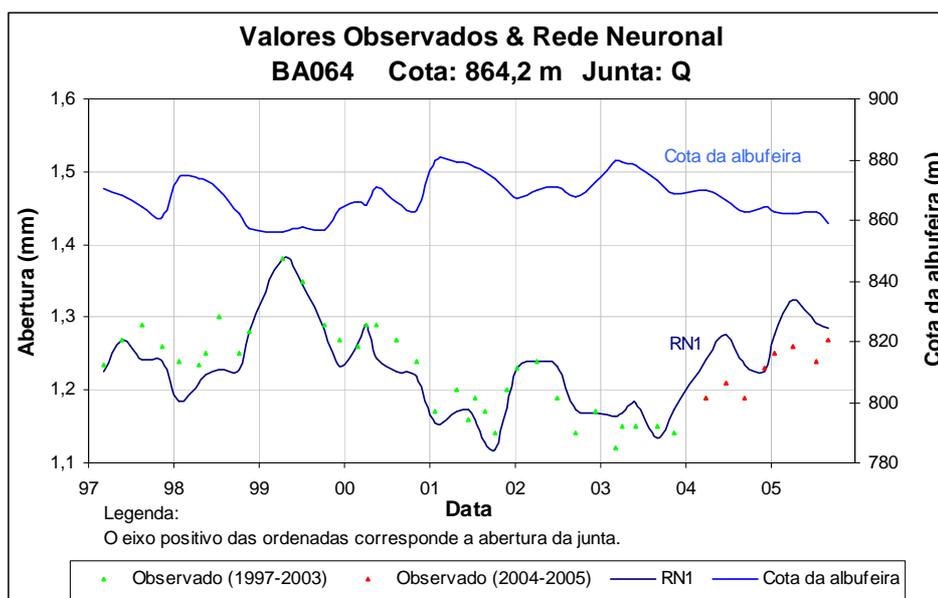


Figura 4.24 – Valores observados e do modelo RN1 adoptado para o movimento de abertura e fecho da junta Q na base BA064 (período de aprendizagem e de previsão)

No Quadro 4.32 apresentam-se os parâmetros de desempenho para a RN1. Estes resultados indicam que os valores do EQMs são da mesma ordem de grandeza, enquanto que os valores de EQMN, EAM e EAMax aumentam e r diminui para os conjuntos de teste e de previsão.

Como pode ser observado na Figura 4.24, comparativamente com o período de previsão, apenas no ano de 1999 a cota da albufeira foi tão baixa durante um período prolongado, tendo sido medidas aberturas superiores. A rede neuronal aprendeu esse comportamento e em consequência estimou valores superiores aos observados. Além

disso, a amostra contém um reduzido número de dados, que podem não ser suficientemente representativos.

Quadro 4.32 – Desempenho da RN1 para a abertura e fecho da junta Q na base BA064

Desempenho da RN1							
Saída	Conjunto	EQM (mm ²)	EQMN	EAM (mm)	EAMin (mm)	EAMax (mm)	r
$y^{RN1}_{BA\ 064}$	Treino	0,001	0,132	0,018	0,002	0,049	0,93
	Validação Cruzada	0,000	0,010	0,005	0,002	0,010	0,99
	Teste	0,002	0,472	0,036	0,011	0,063	0,85
	Previsão	0,002	2,499	0,040	0,005	0,065	0,70

4.8.4. Caudais drenados e infiltrados

A observação dos caudais drenados pode ser efectuada à saída de cada dreno ou através de bicas totalizadoras, as quais permitem medir os caudais totais por zonas características da obra, como, por exemplo, zonas das galerias, encostas e fundo do vale. Os caudais totais medidos nas galerias incluem também os caudais infiltrados no corpo da obra, pelo que o caudal na bica totalizadora é, em regra, superior à soma dos caudais medidos nos drenos que lhe são afluentes.

Para o caso de estudo, trecho em abóbada da barragem do Alto Rabagão, escolheu-se a Bica 1 localizada no fundo da galeria de drenagem GFE1, a qual colecta a água entre as juntas A e K, isto é, os caudais infiltrados nesta zona e os caudais drenados provenientes dos drenos representados na Figura 4.25 e indicados no Quadro 4.33.

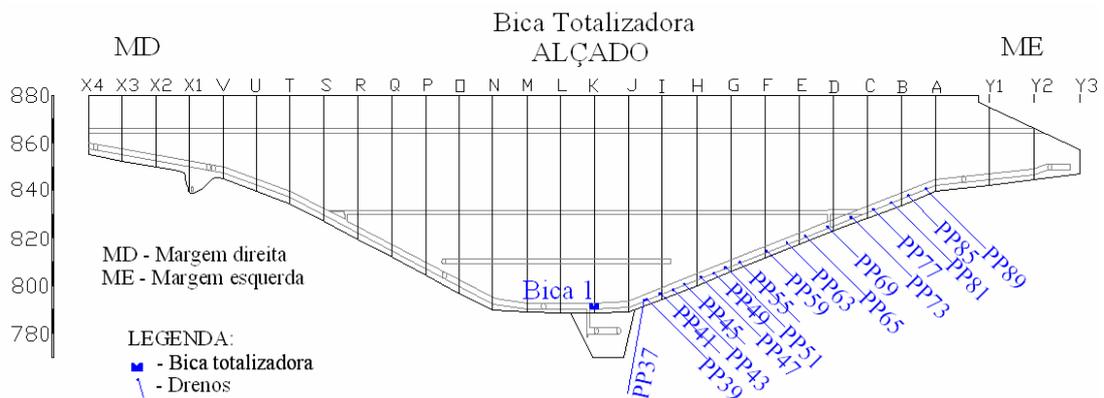


Figura 4.25 – Bica totalizadora utilizada nos modelos de RNs de caudais (e respectivos drenos afluentes)

Para a modelação dos caudais foram elaborados quatro modelos de redes neuronais (Quadro 4.34). O primeiro, um modelo simples, RN1, em que as entradas são o efeito da temperatura, através das funções seno e co-seno, e as cotas da albufeira. Os outros modelos, RN2 a RN4, tiveram em conta outros factores que podem influenciar a resposta da estrutura: a evolução dos níveis de água na albufeira nos cinco dias que precedem a observação e o efeito do tempo desde o início da análise. Na RN2 foram introduzidos cinco novas entradas que correspondem aos níveis de água na albufeira nos 5 dias anteriores à da data de análise. Na RN3 foi adicionada às entradas da RN2 uma nova entrada que corresponde ao número de dias desde o primeiro dia do período de análise. Na RN4 foram consideradas as entradas da RN1 e uma outra entrada correspondente ao número de dias desde o primeiro dia do período de análise, pretendendo-se com isto que a rede detecte alguma tendência temporal no comportamento dos caudais infiltrados.

Refira-se que apenas no modelo referente ao caudal é que foi considerada numa das entradas o efeito do tempo. Em todas as outras grandezas analisadas da barragem do Alto Rabação verificou-se que o efeito do tempo não era relevante, tendo sido o seu efeito desprezado.

Quadro 4.33 – Bica utilizada na modelação dos caudais e indicação dos drenos afluentes

Bloco	Cota (m)	Designação	Tipo de instrumento
JK	791	Bica 1	Bica totalizadora
IJ	794,8	PP37	Dreno
IJ	795,3	PP39	Dreno
IJ	797,1	PP41	Dreno
HI	799,2	PP43	Dreno
HI	801,2	PP45	Dreno
GH	803,9	PP47	Dreno
GH	805,1	PP49	Dreno
GH	806,9	PP51	Dreno
FG	810,3	PP55	Dreno
EF	814,5	PP59	Dreno
EF	817,6	PP63	Dreno
DE	821,0	PP65	Dreno
DE	824,2	PP69	Dreno
CD	827,3	PP73	Dreno
BC	830,8	PP77	Dreno
BC	834,2	PP81	Dreno
AB	837,5	PP85	Dreno
AB	841,1	PP89	Dreno

Quadro 4.34 – Entradas e saídas nos modelos de RNs de caudais na Bica 1

Modelo	Entradas	Saídas Caudal (l/min)
RN1	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$	$y_{Bica 1}$
RN2	$\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$ $C(DO-1)$ $C(DO-2)$ $C(DO-3)$ $C(DO-4)$ $C(DO-5)$	
RN3	$N(DO)$ $\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$ $C(DO-1)$ $C(DO-2)$ $C(DO-3)$ $C(DO-4)$ $C(DO-5)$	
RN4	$N(DO)$ $\cos\left(\frac{2\pi \times D}{365}\right)$ $\text{sen}\left(\frac{2\pi \times D}{365}\right)$ $C(DO)$	

Legenda:

$C(DO)$ - cota da albufeira no dia da observação DO (m);

$N(DO)$ - número de dias desde 1ª observação até a dia da observação DO .

Como indicado no Quadro 4.35, o período de aprendizagem e de previsão em todas as redes neuronais é o mesmo.

Quadro 4.35 – Período de aprendizagem e previsão nos modelos de RNs de caudais na Bica 1

Modelo	Período de aprendizagem			Período de previsão		
	Inicial	Final	Número total de padrões	Inicial	Final	Número total de padrões
RN1	30-7-1973	31-12-2002	880	1-1-2003	26-9-2005	35
RN2						
RN3						
RN4						

Os resultados do processo de aprendizagem são apresentados no Quadro 4.36 através dos valores dos EQMs do conjunto de validação cruzada para cada uma das redes neuronais com melhor desempenho.

Quadro 4.36 – Desempenho dos melhores modelos de RNs de caudais na Bica 1

Modelo	Elementos de processamento na camada intermédia	EQM Conjunto de validação cruzada ((l/min) ²)
RN1	21	1,129
RN2	16	1,040
RN3	33	0,107
RN4	30	0,185

Da análise do Quadro 4.36 observa-se que as redes RN3 e RN4 são as que apresentam melhor desempenho, pelo que a consideração do efeito do tempo na rede neuronal é aparentemente relevante. Embora a RN3 apresente um desempenho ligeiramente melhor que a RN4, adoptou-se a RN4 por ter menos entradas.

Da análise da Figura 4.26 verifica-se que os valores observados no período inicial são sistematicamente superiores aos obtidos com o modelo RN1, enquanto que os valores observados a partir de 1986 são sensivelmente inferiores. Assim, adicionou-se às entradas do modelo RN1 um parâmetro para simular este efeito temporal, construindo-se o modelo RN4.

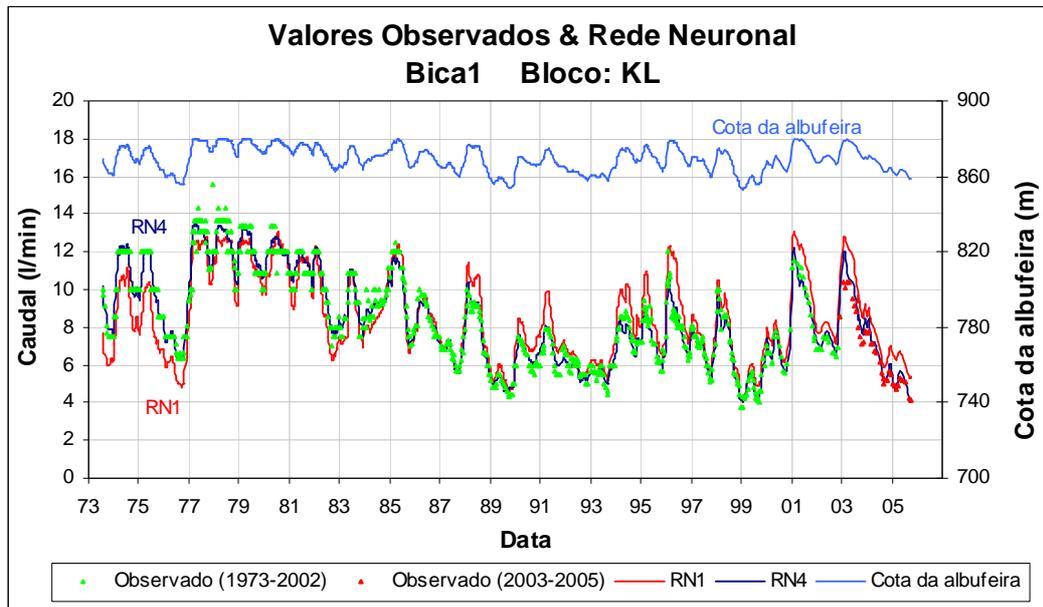


Figura 4.26 – Valores observados e dos modelos RN1 e RN4 para os caudais da Bica 1 (Período de aprendizagem e de previsão)

O novo parâmetro de entrada na RN4, através da introdução do número de dias desde a primeira observação, conduziu à obtenção de melhores resultados (ver Figuras 4.26 e 4.27 e Quadro 4.37).

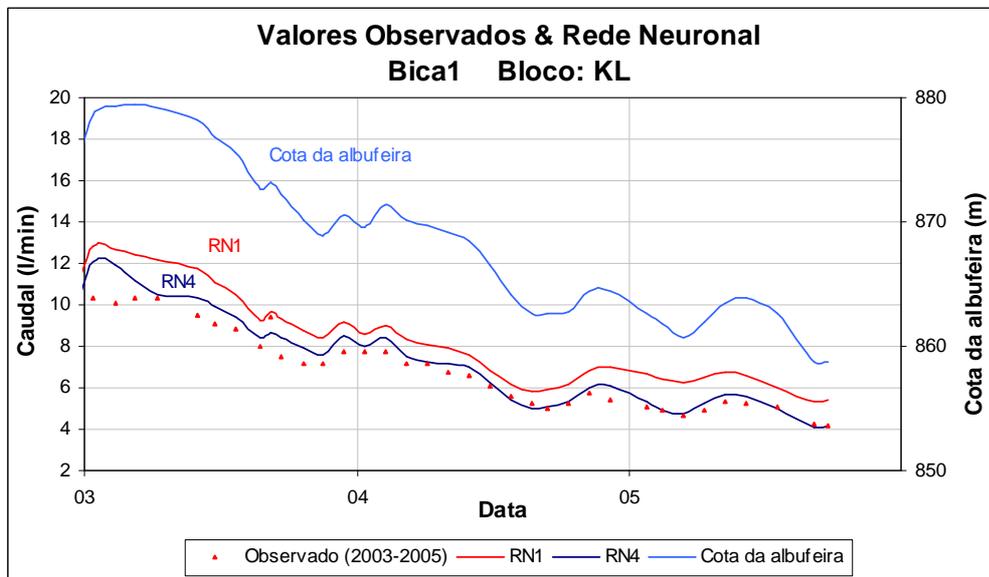


Figura 4.27 – Valores observados e dos modelos RN1 e RN4 para os caudais da Bica 1 (Período de previsão)

Na Figura 4.28 é apresentada a evolução dos resíduos ao longo do tempo, para o modelo RN1.

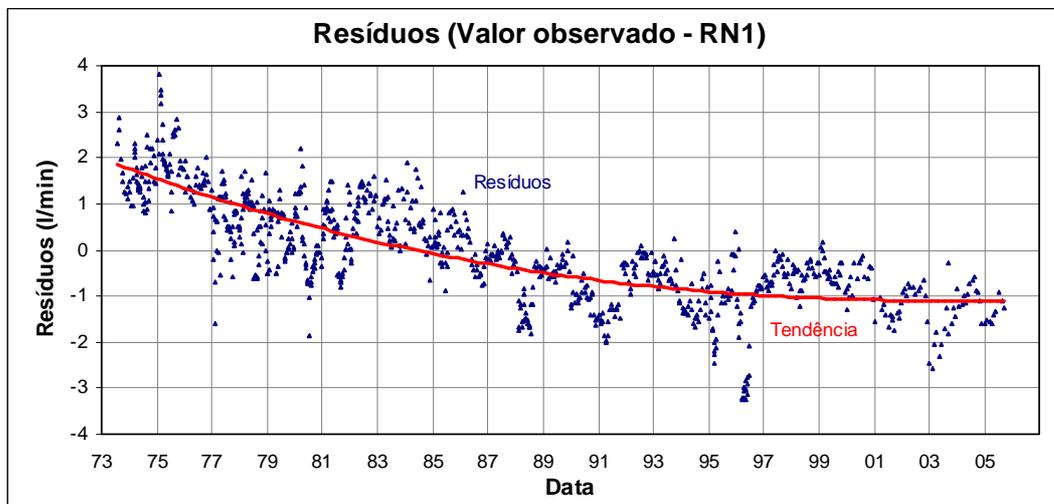


Figura 4.28 – Evolução dos resíduos ao longo do tempo relativos ao modelo RN1

No Quadro 4.37 apresentam-se os parâmetros de desempenho das redes RN1 e RN4. Na rede RN1 o coeficiente de correlação do conjunto de treino é menor do que o do conjunto de previsão. Tal poderá justificar-se pelo facto do período utilizado para aprendizagem ser relativamente extenso quando comparado com o período utilizado para previsão, sendo, portanto, o efeito temporal mais perceptível no período de aprendizagem.

Quadro 4.37 – Desempenho das RN1 e RN4 para os caudais da Bica 1

Desempenho das RN1 e RN4							
Saída	Conjunto	EQM ((l/min) ²)	EQMN	EAM (l/min)	EAMin (l/min)	EAMax (l/min)	r
$y_{Bica\ 1}^{RN1}$	Treino	1,281	0,183	0,901	0,002	4,959	0,90
	Validação Cruzada	1,129	0,188	0,866	0,000	2,872	0,90
	Teste	1,200	0,184	0,877	0,003	3,489	0,91
	Previsão	2,121	0,590	1,362	0,279	2,578	0,98
$y_{Bica\ 1}^{RN4}$	Treino	0,223	0,034	0,330	0,000	4,243	0,98
	Validação Cruzada	0,185	0,026	0,331	0,006	1,868	0,99
	Teste	0,190	0,029	0,335	0,001	1,456	0,99
	Previsão	0,391	0,109	0,465	0,004	1,848	0,98

4.9. Comparação entre modelos de redes neuronais e de interpretação quantitativa

De forma a avaliar o desempenho dos modelos de redes neuronais desenvolvidos, comparam-se os resultados obtidos com os resultados de modelos de interpretação quantitativa (IQ). Os modelos de IQ foram construídos com o mesmo período de aprendizagem utilizado nos modelos de redes neuronais.

Nos modelos de interpretação quantitativa adoptou-se para representar o efeito do nível de água na albufeira o termo, h^4 (h representa a altura de água em relação à base em metros), e para o efeito da temperatura as funções $\sin\left(\frac{2\pi \times D}{365}\right)$ e $\cos\left(\frac{2\pi \times D}{365}\right)$ (D é o número de dias desde 1 de Janeiro do ano a que corresponde a data da observação). Em relação ao efeito do tempo, apenas significativo no comportamento dos caudais da Bica 1, considerou-se a função $\ln\left(1 + \frac{t}{a}\right)$, em que t corresponde ao número de dias entre a campanha e o início da análise, enquanto que a corresponde ao número de dias entre as datas do 1º enchimento e do início da análise.

Utilizaram-se como parâmetros de comparação do desempenho dos modelos o erro absoluto médio, EAM, o erro absoluto máximo, EAMax, e o coeficiente de correlação, r .

4.9.1. Subpressões

A comparação entre os modelos de interpretação quantitativa e as redes neuronais foi efectuada com o intuito de avaliar o desempenho relativo de cada um dos modelos relativamente aos valores observados. A equação do modelo de interpretação quantitativa obtida para a subpressão observada no piezómetro PPM68m foi

$$y_{PPM68m}^{IQ}(h, D) = 7,876 \times 10^{-8} \cdot h^4 + 8,170 \times 10^{-2} \cdot \cos\left(\frac{2\pi \times D}{365}\right) + \\ -2,272 \times 10^{-2} \cdot \sin\left(\frac{2\pi \times D}{365}\right) + 1,0828$$

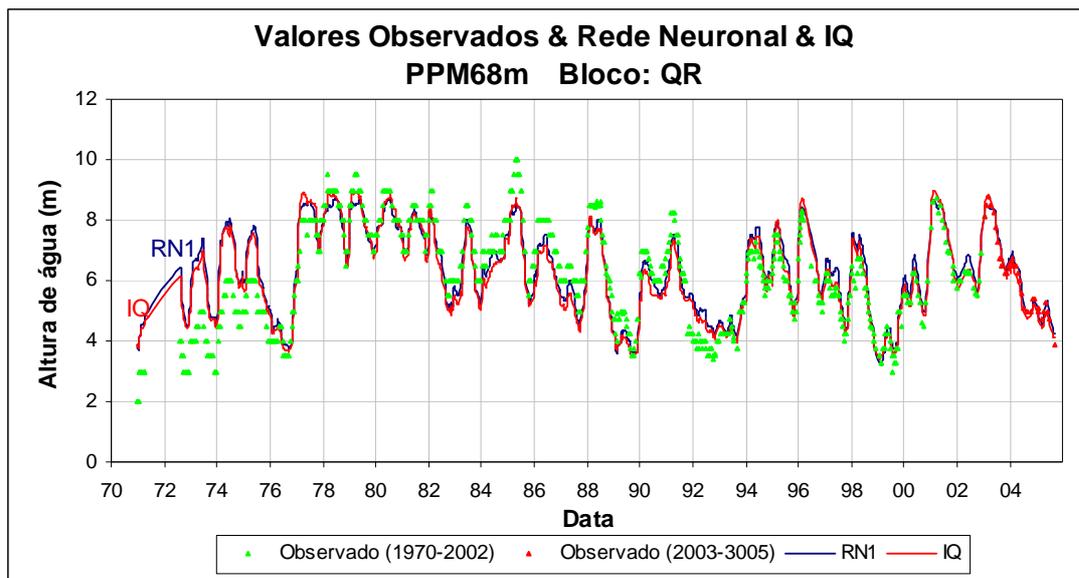


Figura 4.29 – Comparação entre os valores observados e dos modelos RN1 e de IQ adoptados para as subpressões no PPM68m (período de aprendizagem e de previsão)

Da Figura 4.29 e do Quadro 4.38 constata-se uma boa aproximação dos dois modelos, particularmente no período após 1994, sendo o modelo de redes neurais ligeiramente mais preciso.

Quadro 4.38 – Desempenho da interpretação quantitativa e da rede neuronal para as subpressões no PPM68m

Saída	Período de aprendizagem			Período de previsão		
	EAMax (m)	EAM (m)	r	EAMax (m)	EAM (m)	r
$y_{PPM68m}^{IQ}(h, D)$	2,440	0,633	0,88	0,709	0,243	0,98
y_{PPM68}^{RN1}	2,528	0,618	0,88	0,851	0,216	0,98

4.9.2. Deslocamentos horizontais

4.9.2.1. Deslocamento radial

As expressões obtidas com os modelos de interpretação quantitativa para representar os deslocamentos radiais da base de coordenómetro do FP1 às cotas 791 m e 879,25 m foram, respectivamente,

$$y_{FP1-791m}^{IQ}(h, D) = -1,262 \times 10^{-7} \cdot h^4 + 8,126 \times 10^{-2} \cdot \cos\left(\frac{2\pi \times D}{365}\right) +$$

$$-1,423 \cdot \text{sen}\left(\frac{2\pi \times D}{365}\right) - 2,0038$$

$$y_{FP1-879,25m}^{IQ}(h, D) = -2,636 \times 10^{-5} \cdot h^4 - 2,007 \cdot \cos\left(\frac{2\pi \times D}{365}\right) +$$

$$-4,628 \cdot \text{sen}\left(\frac{2\pi \times D}{365}\right) + 2,2500$$

Nas Figuras 4.30 e 4.31 representam-se as comparações dos resultados obtidos com os modelos RN2 e IQ para as bases de coordenómetro à cota 791 m e 879,25 m, respectivamente. Embora em ambos os modelos se tenha verificado dificuldade de aproximação aos valores extremos, particularmente para a base de coordenómetro à cota 791 m, os resultados obtidos com o modelo de redes neuronais foram ligeiramente melhores.

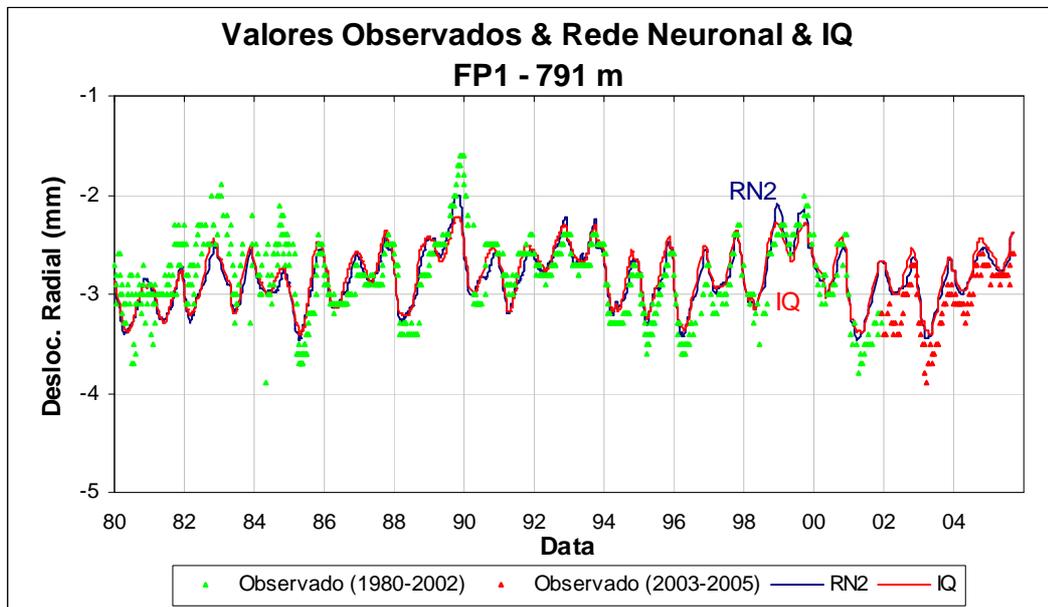


Figura 4.30 – Comparação entre os valores observados e dos modelos RN2 e de IQ para o deslocamento radial no FP1 – 791 m (período de aprendizagem e de previsão)

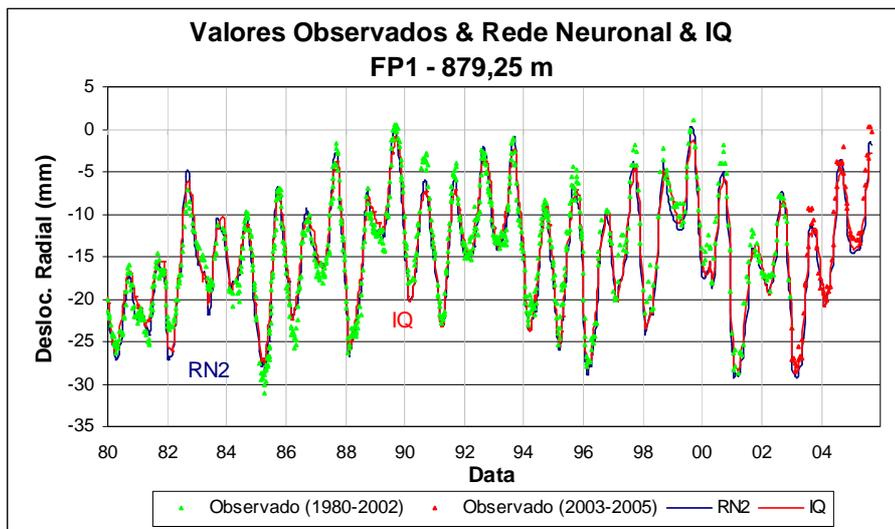


Figura 4.31 – Comparação entre os valores observados e dos modelos RN2 e de IQ para o deslocamento radial no FP1 – 879,25 m (período de aprendizagem e de previsão)

O Quadro 4.39, onde se apresentam os parâmetros EAM, EAMax e r, confirma o melhor desempenho das redes neurais.

Quadro 4.39 – Desempenho da interpretação quantitativa e da rede neuronal para o deslocamento radial no FP1

Saída	Período de aprendizagem			Período de previsão		
	EAMax (mm)	EAM (mm)	r	EAMax (mm)	EAM (mm)	r
$y_{FP1-791m}^{IQ}(h, D)$	1,013	0,204	0,76	0,536	0,233	0,95
$y_{FP1-791m}^{RN2}$	0,963	0,190	0,78	0,439	0,186	0,96
$y_{FP1-879,25m}^{IQ}(h, D)$	5,547	1,434	0,97	4,342	1,352	0,98
$y_{FP1-879,25m}^{RN2}$	5,285	1,256	0,98	3,627	1,274	0,99

4.9.2.2. Deslocamento tangencial

A equação obtida no modelo da interpretação quantitativa para o deslocamento tangencial na base de coordenómetro do FP3 à cota 879,25 m foi

$$y_{FP3-879,25m}^{IQ}(h, D) = -3,864 \times 10^{-8} \cdot h^4 - 1,336 \cdot \cos\left(\frac{2\pi \times D}{365}\right) + 5,224 \cdot \sin\left(\frac{2\pi \times D}{365}\right) + 0,6346$$

Na Figura 4.32 e no Quadro 4.40 apresenta-se uma comparação entre os resultados obtidos com os modelos de redes neuronais e o modelo de interpretação quantitativa para a base de coordenómetro à cota 879,25 m do FP3 e permitem constatar a semelhança de resultados dos dois modelos.

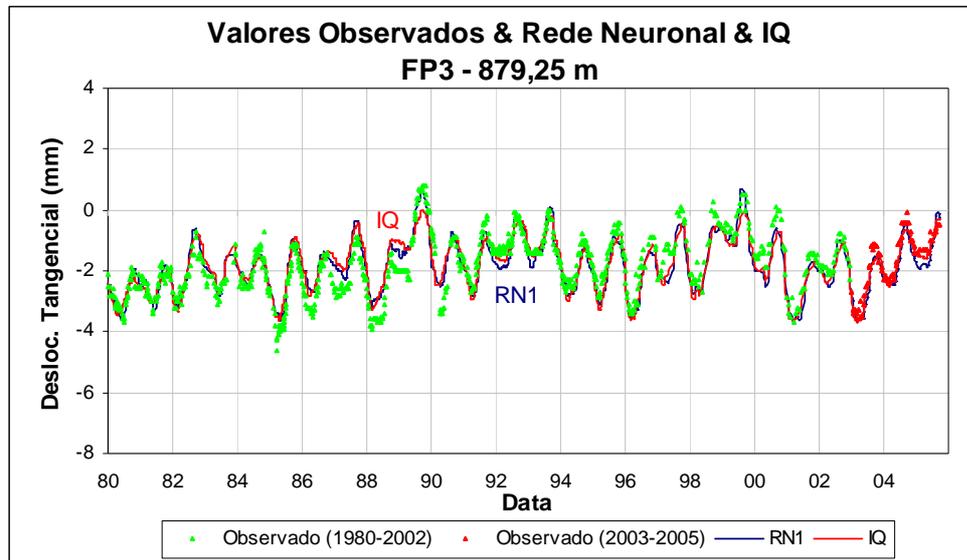


Figura 4.32 – Comparação entre os valores observados e dos modelos RN1 e de IQ para o deslocamento tangencial no FP3 – 879,25 m (período de aprendizagem e de previsão)

Quadro 4.40 – Desempenho da interpretação quantitativa e da rede neuronal para o deslocamento tangencial no FP3 – 879,25 m

Saída	Período de aprendizagem			Período de previsão		
	EAMax (mm)	EAM (mm)	r	EAMax (mm)	EAM (mm)	r
$y_{FP3-879,25m}^{IQ}(h, D)$	1,289	0,401	0,88	0,733	0,235	0,97
$y_{FP3-879,25m}^{RN1}$	1,280	0,363	0,90	0,823	0,336	0,95

4.9.3. Deslocamento na fundação da barragem

O modelo de interpretação quantitativa dos deslocamentos da fundação observados no extensómetro de fundação E6-46 apresenta a equação

$$y_{E6-46}^{IQ}(h, D) = -2,748 \times 10^{-9} \cdot h^4 - 1,024 \times 10^{-1} \cdot \cos\left(\frac{2\pi \times D}{365}\right) +$$

$$-2,962 \times 10^{-1} \cdot \text{sen}\left(\frac{2\pi \times D}{365}\right) + 0,4754$$

A representação gráfica dos valores obtidos pela interpretação quantitativa e pela rede neuronal adoptada consta na Figura 4.33.

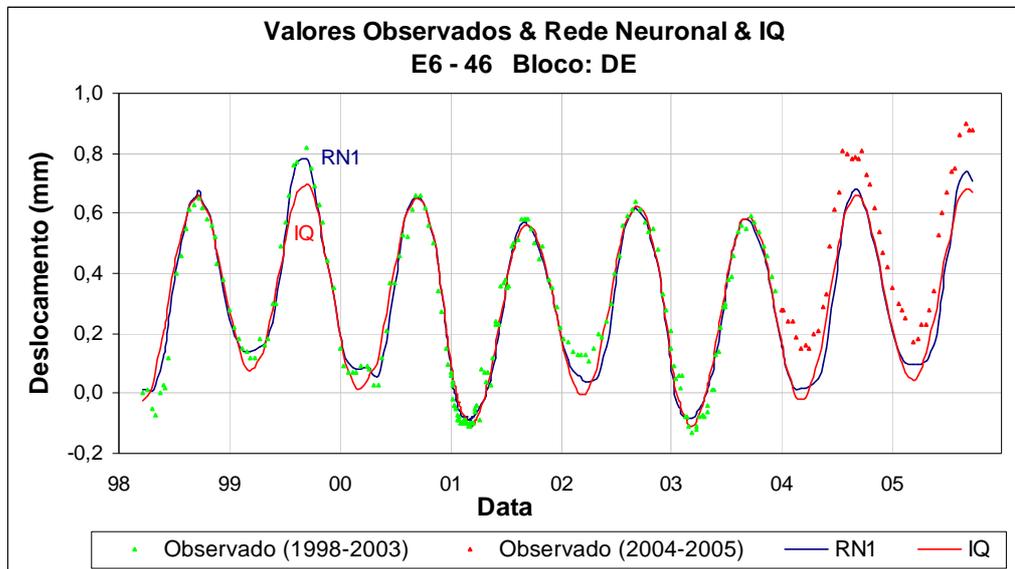


Figura 4.33 – Comparação entre os valores observados e dos modelos RN1 e de IQ para os deslocamentos no E6 – 46 (período de aprendizagem e de previsão)

Verifica-se que nos dois modelos a correlação com os valores observados é muito boa, particularmente no período de aprendizagem (Quadro 4.41). No período de previsão os resultados para ambos os modelos já são menos satisfatórios, o que poderá estar relacionado com o reduzido período de observação, provavelmente ainda insuficiente para cobrir todos os níveis de solicitação.

Quadro 4.41 – Desempenho da interpretação quantitativa e da rede neuronal para os deslocamentos na fundação no E6-46

Saída	Período de aprendizagem			Período de previsão		
	EAMax (mm)	EAM (mm)	r	EAMax (mm)	EAM (mm)	r
$y_{E6-46}^{IQ}(h, D)$	0,241	0,088	0,98	0,300	0,206	0,99
y_{E6-46}^{RN1}	0,140	0,038	0,98	0,290	0,162	0,98

4.9.4. Movimentos de abertura e fecho de juntas

A equação obtida com o modelo de interpretação quantitativa para os movimentos de abertura e fecho da junta Q à cota 864,2 m foi

$$y_{BA\ 064}^{IQ}(h, D) = -3,127 \times 10^{-9} \cdot h^4 - 2,39 \times 10^{-2} \cdot \cos\left(\frac{2\pi \times D}{365}\right) - 0,384 \times 10^{-1} \cdot \text{sen}\left(\frac{2\pi \times D}{365}\right) + 1,4324$$

A Figura 4.34 permite observar a insuficiência de dados disponíveis, o que poderá estar na origem do facto de as aproximações não serem tão boas como as verificadas nas grandezas anteriores.

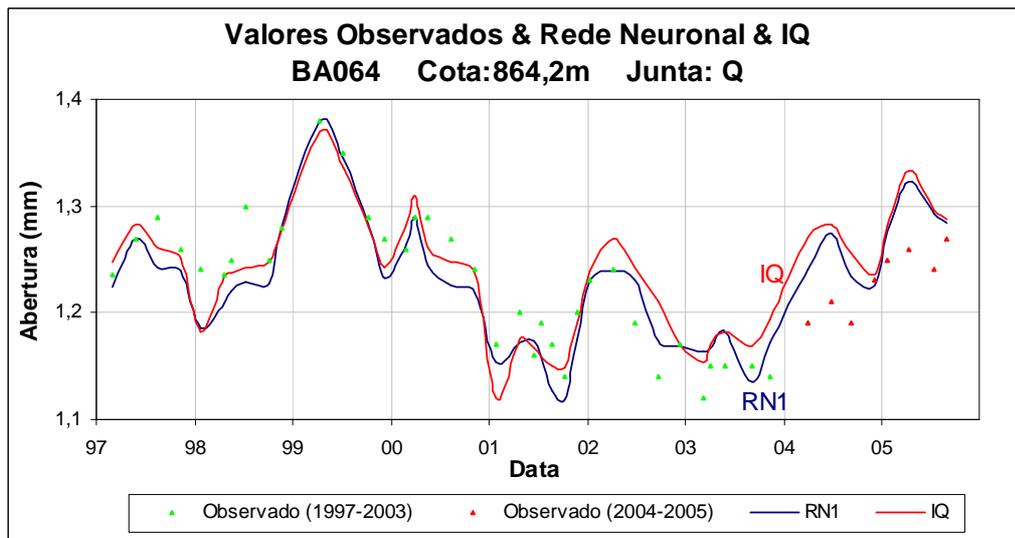


Figura 4.34 – Comparação entre os valores observados e dos modelos RN1 e de IQ adoptados para os movimentos de abertura e fecho da junta Q na BA064 (período de aprendizagem e de previsão)

Quadro 4.42 – Desempenho da interpretação quantitativa e da rede neuronal para os movimentos de abertura e fecho da junta Q na BA064

Saída	Período de aprendizagem			Período de previsão		
	EAMax (mm)	EAM (mm)	r	EAMax (mm)	EAM (mm)	r
$y_{BA\ 064}^{IQ}(h, D)$	0,070	0,023	0,89	0,080	0,050	0,65
$y_{BA\ 064}^{RN1}$	0,063	0,024	0,90	0,065	0,040	0,70

Constata-se que os erros são significativos para ambos os modelos (Quadro 4.42 e Figura 4.34). Os coeficientes de correlação apresentam valores maiores na fase de aprendizagem do que na fase de previsão. No entanto, como referido anteriormente, a amostra contém um pequeno número de dados, o qual pode não ser suficientemente representativa para a grandeza em análise.

4.9.5. Caudais drenados e infiltrados

Embora apenas em circunstâncias específicas a interpretação quantitativa de grandezas como os caudais seja aceitável, recorreu-se a este tipo de modelos para comparar os resultados obtidos com o modelo de redes neuronais. Para a Bica 1 o modelo de interpretação quantitativa vem definido pela expressão

$$y_{Bica1}^{IQ}(h, D) = 1,038 \times 10^{-7} \cdot h^4 + 9,822 \times 10^{-3} \cdot \cos\left(\frac{2\pi \times D}{365}\right) + 0,2275 \cdot \text{sen}\left(\frac{2\pi \times D}{365}\right) - 2,599 \cdot \ln\left(1 + \frac{t}{3414}\right) + 3,927$$

Como pode ser verificado na Figura 4.35 e no Quadro 4.43, o modelo de rede neuronal RN4 apresenta um desempenho ligeiramente melhor que a IQ no período de aprendizagem e pior no período de previsão.

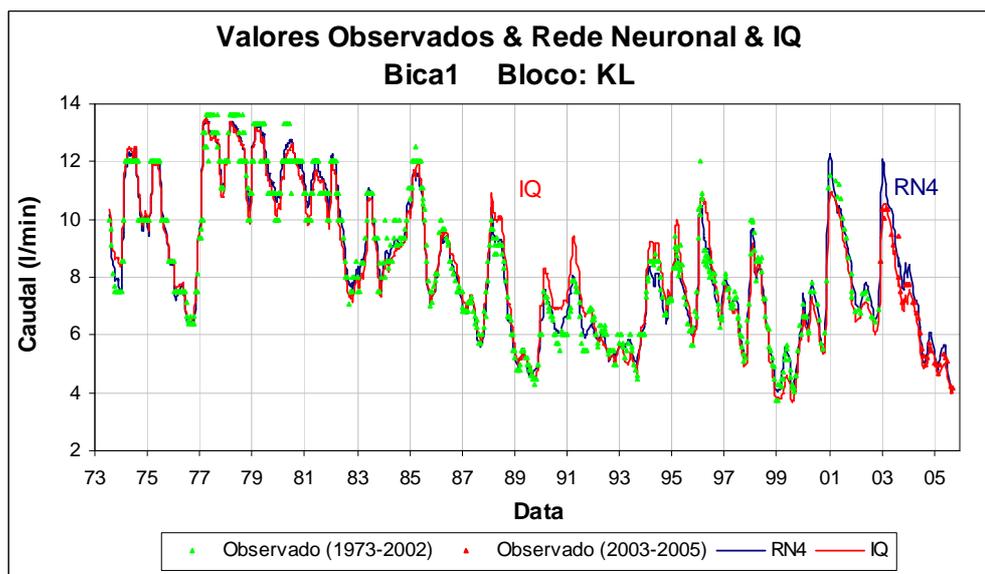


Figura 4.35 – Comparação entre os valores observados e dos modelos RN4 e de IQ adoptados para os caudais da Bica 1 (período de aprendizagem e de previsão)

Quadro 4.43 – Desempenho da interpretação quantitativa e da rede neuronal para os caudais da Bica 1

Saída	Período de aprendizagem			Período de previsão		
	EAMax (l/min)	EAM (l/min)	r	EAMax (l/min)	EAM (l/min)	r
$y_{Bica1}^{IQ}(h, D, t)$	4,510	0,479	0,97	1,485	0,262	0,99
y_{Bica1}^{RN4}	4,242	0,331	0,98	1,848	0,465	0,98

4.10. Análise de sensibilidade dos modelos de redes neuronais

Os modelos de interpretação quantitativa têm características particulares, baseando-se na separação de efeitos, o que é vantajoso para quantificar qual o contributo que uma determinada acção tem na resposta da estrutura. Por outro lado, na interpretação quantitativa são seleccionadas funções com base num conhecimento físico do comportamento da estrutura, por exemplo, é habitual atribuir uma função polinomial do tipo h^4 para traduzir o efeito que a variação da cota da albufera tem nos deslocamentos horizontais de barragens abóbada.

Por sua vez, as redes neuronais identificam elas próprias a influência que cada uma das entradas tem na resposta, tirando partido do processamento em paralelo da interacção conjunta das entradas, se ela existir. O efeito que cada uma das entradas tem na saída da rede neuronal também pode ser obtido através de uma análise de sensibilidade, isto é, percorrendo toda a gama de valores de uma das entradas e fixando as restantes.

Para o problema em estudo foi efectuada uma análise de sensibilidade relativamente ao deslocamento radial da base de coordenómetro do fio prumo FP1 à cota 879,25 m.

4.10.1. Análise do deslocamento horizontal radial do fio prumo FP1 à cota 879,25m

4.10.1.1. Efeito térmico

No modelo de interpretação quantitativa da grandeza em análise, a parcela do efeito térmico é dada por

$$y_{FP1-879,25m}^{IQ}(D) = -2,007 \cdot \cos\left(\frac{2\pi \times D}{365}\right) - 4,628 \cdot \text{sen}\left(\frac{2\pi \times D}{365}\right)$$

pelo que a resposta referente a este efeito é uma sinusóide com uma amplitude e uma fase bem definidas.

No que diz respeito à rede neuronal, a análise de sensibilidade em relação ao efeito térmico realizou-se fixando a entrada referente à cota da albufeira com um valor previamente estabelecido, percorrendo todo o domínio da entrada referente ao efeito térmico. Este processo foi repetido várias vezes para diferentes cotas da albufeira. Desta forma, em relação ao modelo de rede neuronal adoptada em 4.8.1.1 (RN2), percorreu-se todo o domínio da variação da temperatura, tendo sido fixada a cota da albufeira em 875 m. O processo foi repetido para as cotas da albufeira 870 m, 860 m e 855 m, tendo-se verificado que a contribuição do efeito térmico na resposta da estrutura, em termos de deslocamentos radiais, era, neste caso, praticamente independente da cota da albufeira.

Na Figura 4.36 apresenta-se uma comparação dos modelos de rede neuronais e de interpretação quantitativa referente ao efeito da temperatura nos deslocamentos radiais. Foi subtraída a cada resposta a respectiva média para que estivessem centradas em relação ao zero das ordenadas.

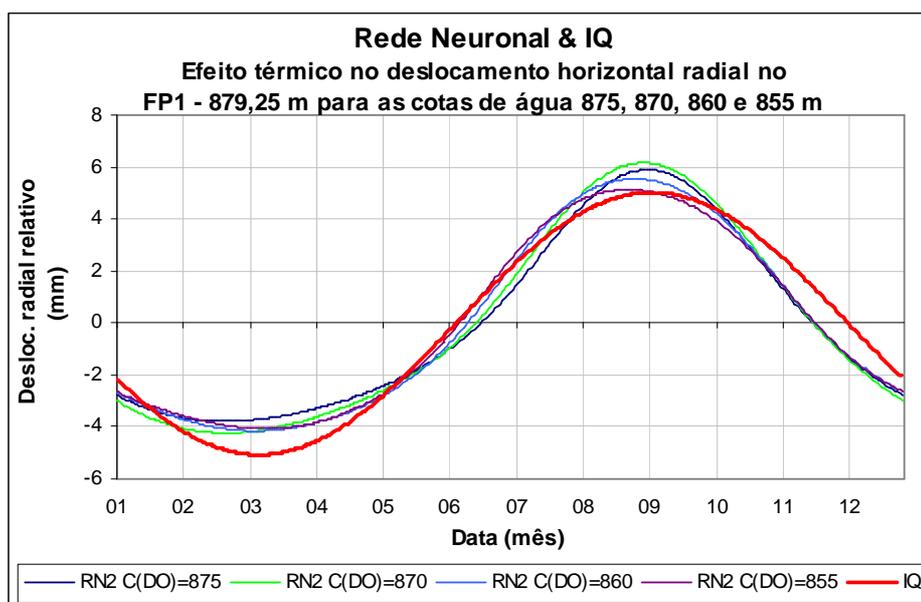


Figura 4.36 – Comparação dos modelos de IQ e RN referente ao efeito da temperatura na resposta para as cotas de água 875 m, 870 m, 860 m e 855 m

Da observação da Figura 4.36 verifica-se que os efeitos são semelhantes. No entanto, constata-se que na rede neuronal a resposta devido à onda térmica tem uma abertura de onda mais reduzida na época quente do que na fria. Esta flexibilidade é uma vantagem que os modelos de redes neuronais possuem relativamente aos modelos de IQ.

4.10.1.2. Efeito da cota da albufeira

No modelo de interpretação quantitativa a parcela da resposta referente ao efeito da cota da albufeira é dada por

$$y_{FP1-879,25m}^{IQ}(h) = -2,636 \times 10^{-5} \cdot h^4$$

Na rede neuronal a contribuição que a entrada referente à cota da albufeira tem na resposta obteve-se fixando a entrada relativa ao efeito térmico e percorrendo todo o domínio da cota da albufeira. Este processo foi efectuado para os dias do ano $D = \{20, 100, 180, 260\}$, tendo-se verificado que a resposta era praticamente independente de D .

De forma a serem comparáveis, as respostas nos dois modelos foram transladados para a média. Como pode ser observado na Figura 4.37 os dois modelos apresentam evolução semelhante.

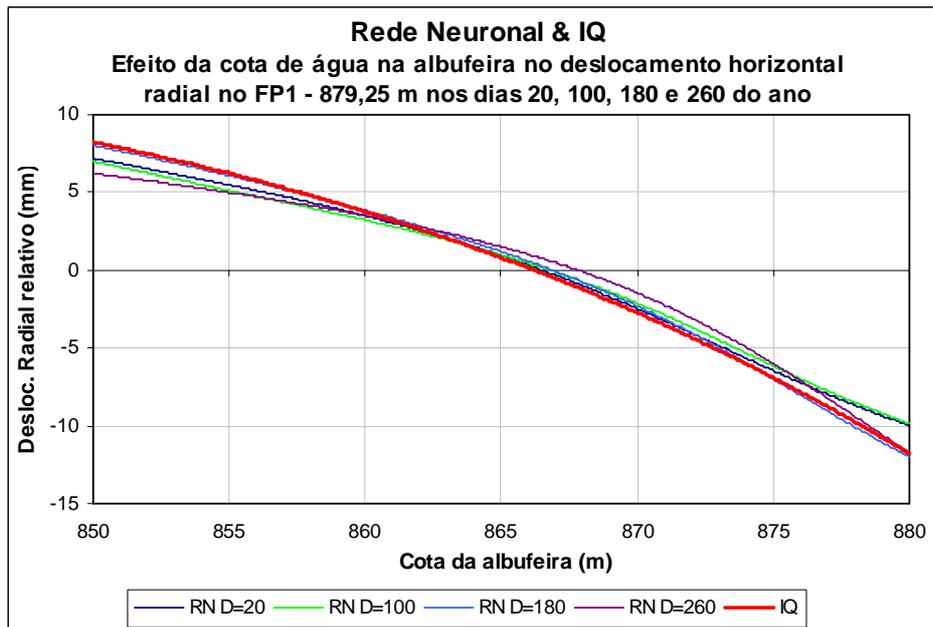


Figura 4.37 – Comparação dos modelos de IQ e RN2 referente ao efeito da cota da albufeira na resposta nos dias 20, 100, 180 e 260 do ano

Assim, pode-se considerar que a RN2 foi capaz de identificar adequadamente os efeitos que a variação de temperatura e da cota da albufeira têm nos deslocamentos.

No entanto, em redes neuronais com um maior número de entradas, esta análise poderá ser mais difícil, sendo possível ocorrer situações em que a resposta final da rede neuronal seja muito boa mas a análise para cada uma das entradas individualmente não corresponda a uma interpretação física correcta. Assim, considera-se desejável que as formulações de redes neuronais sejam sempre acompanhadas da realização de uma análise de sensibilidade para auxiliar na interpretação dos resultados obtidos.

5. CONSIDERAÇÕES FINAIS

5.1. Síntese do trabalho realizado

O controlo de segurança de barragens de betão é suportado pela observação das obras e baseia-se em modelos de comportamento. Neste trabalho foram desenvolvidos modelos de redes neuronais, em particular as do tipo Perceptrão Multicamada, para analisar algumas das principais grandezas que são sistematicamente observadas neste tipo de obras.

No capítulo 2 realizou-se uma breve descrição dos principais aspectos relacionados com o controlo de segurança de barragens de betão, tais como a observação de grandezas, a análise do seu comportamento, os erros associados aos métodos/instrumentos de medida e a elaboração de modelos e métodos de previsão do comportamento das estruturas. Abordou-se com maior profundidade o método de interpretação quantitativa, explicando-se o seu funcionamento e os princípios que tem por base.

Uma vez que se trata de uma área ainda pouco divulgada na engenharia civil, reservou-se o capítulo 3 para a apresentação de alguns conceitos gerais das redes neuronais artificiais, particularizando a explicação para redes neuronais do tipo Perceptrão Multicamada, uma vez que o caso de estudo teve por base a aplicação deste tipo de redes numa barragem. Nesse capítulo foram introduzidas algumas noções relativas às redes neuronais biológicas, seguindo-se a descrição do funcionamento básico de um neurónio artificial e a apresentação de uma perspectiva histórica das redes neuronais artificiais, abordando-se as evoluções mais significativas nesta matéria. Desenvolveram-se conceitos referentes às redes Perceptrão Multicamada, introduzindo-se a nomenclatura adoptada e conceitos fundamentais, tais como a arquitectura, a retropropagação do erro, os critérios de paragem do treino, algumas técnicas de aceleração do treino e o pré-processamento dos dados.

Após a introdução dos conceitos necessários para a concretização dos objectivos propostos nos capítulos 2 e 3, desenvolveram-se, no capítulo 4, os modelos de redes neuronais Perceptrão Multicamada para a análise de algumas grandezas observadas na barragem do Alto Rabagão, escolhida como caso de estudo. No decorrer do capítulo fez-se uma descrição sucinta das características da obra e das metodologias gerais

adoptadas para a implementação das redes Perceptrão Multicamada. Caracterizaram-se ainda as principais acções, tendo-se optado por modelar as variações de temperatura no betão e as subpressões através de redes neuronais Perceptrão Multicamada. Seguidamente modelaram-se várias grandezas, considerando-se para entrada das redes neuronais as principais acções e para a saída das redes as grandezas em análise. Após a fase de aprendizagem da rede neuronal foram realizadas comparações entre os valores previstos pelos modelos e os valores observados, efectuando-se depois gráficos temporais das grandezas analisadas.

Avaliou-se, ainda, o desempenho das redes neuronais relativamente aos modelos de interpretação quantitativa, os quais foram desenvolvidos para as mesmas grandezas, tendo-se constatado que, de uma forma geral, as redes neuronais do tipo Perceptrão Multicamada apresentam um desempenho, em termos de erros e para os casos de estudo, muito semelhante aos modelos de interpretação quantitativa.

Finalmente, realizaram-se análises de sensibilidade para o caso dos deslocamentos radiais de uma base de um fio prumo, de forma a visualizar o efeito que cada uma das entradas das redes neuronais desenvolvidas tem na resposta do modelo. Os resultados foram comparados com os obtidos com a separação de efeitos nos modelos de interpretação quantitativa.

5.2. Discussão dos resultados obtidos

Este trabalho teve como principal objectivo investigar a aplicação de redes neuronais no contexto do controlo de segurança das barragens de betão. Os resultados obtidos permitem concluir que a utilização deste tipo de modelos conduz a resultados satisfatórios e, desta forma, deve ser considerada como uma ferramenta complementar, ou alternativa, aos métodos tradicionalmente utilizados pelos especialistas desta matéria.

Como resultado da experiência adquirida no decorrer do trabalho, verificou-se que a criação de redes neuronais do tipo Perceptrão Multicamada deve ser o mais simples possível, de forma a obter uma melhor capacidade de generalização, quer em termos do número de elementos de processamento na camada intermédia, quer nas entradas, devendo ser consideradas apenas as entradas que têm influência significativa na saída da rede neuronal, isto é, deve-se reduzir ao mínimo a informação que não é relevante e que pode ser um factor de distúrbio na aprendizagem da rede neuronal.

Verificou-se que a utilização da validação cruzada como critério de paragem é apropriada na obtenção de uma rede neuronal com boa capacidade de generalização.

No entanto, é aconselhável ter um domínio de aprendizagem suficientemente grande para que a validação cruzada também seja um conjunto representativo.

A aplicação de redes neuronais do tipo Perceptrão Multicamada a problemas que apresentam fenómenos com uma evolução ao longo do tempo deve ser efectuada com alguma cautela. Quando uma das entradas corresponde a uma parcela temporal, por exemplo, “o número de dias desde o início da análise”, cada exemplo é único e corresponde a uma variável que é monótona crescente, e por isso qualquer extrapolação deve ser efectuada para períodos de tempo curtos, com risco de perda de qualidade nos resultados.

Considera-se aconselhável efectuar análises de sensibilidade para cada uma das entradas da rede neuronal, uma de cada vez, fixando os valores para as restantes entradas. Os resultados destas análises devem ser confrontadas com outros modelos e com o conhecimento de especialistas em engenharia de barragens.

Uma das vantagens da utilização de redes neuronais do tipo Perceptrão Multicamada é que, ao contrário da interpretação quantitativa, não é necessário formular hipóteses simplificadoras como, por exemplo, a consideração de comportamentos lineares para os materiais e para a estrutura e, ainda, a sobreposição dos efeitos (por exemplo, da pressão hidrostática e da temperatura). Desta forma, pode-se considerar que os modelos de redes neuronais são mais flexíveis.

De uma forma geral, considera-se que os objectivos propostos foram cumpridos, uma vez que no decorrer deste trabalho foram analisadas algumas das potencialidades e das limitações das redes neuronais do tipo Perceptrão Multicamada, quer através de uma apresentação teórica do funcionamento deste tipo de modelos, quer da sua aplicação na análise de algumas das grandezas que são observadas na barragem do Alto Rabagão.

5.3. Desenvolvimentos futuros

De forma a continuar a aferir a aplicabilidade e o desempenho das redes neuronais Perceptrão Multicamada na análise das principais grandezas observadas no âmbito do controlo de segurança de barragens de betão, este estudo deve prosseguir, não apenas no caso da barragem do Alto Rabagão, mas também de outras barragens de betão. Uma vez sistematizadas metodologias baseadas em redes neuronais na análise das medições provenientes dos instrumentos da recolha manual, prevê-se alargar a sua aplicação para

a análise das grandezas medidas através dos sistemas de recolha automática, contribuindo assim, para o controlo de segurança em tempo real.

Os estudos futuros deverão explorar ainda as possibilidades das redes neuronais na interligação espacial dos valores observados das diversas grandezas em diferentes pontos das estruturas.

Um caso onde a utilização de modelos de redes neuronais poderá ser particularmente importante é na análise do comportamento hidromecânico da fundação de barragens de betão. Considera-se que deverão ser efectuados estudos onde, para além de outros factores, sejam considerados parâmetros como a permeabilidade dos maciços rochosos e o estado de tensão induzido pela estrutura.

A utilização integrada de diferentes tipos de modelos nas actividades de apoio à observação e controlo de segurança de barragens de betão tem permitido um conhecimento mais aprofundado do desempenho das obras e a detecção precoce de comportamentos particulares e/ou anómalos. Nesta perspectiva afigura-se como muito interessante a possibilidade de usar em conjunto modelos estruturais e de redes neuronais na interpretação do comportamento observado das obras.

REFERÊNCIAS BIBLIOGRÁFICAS

- Almeida, L. B. (1997). "*Multilayer perceptrons*", Handbook of neural computation, Section C.1.2, Oxford.
- Bauchspiess, A., (2004). "*Redes neuronais artificiais, Lógica Fuzzy e Sistemas Neuro Fuzzy*". Consultado em 30 de Agosto de 2006, em Universidade de Brasília: <http://www.ene.unb.br/~adolfo/ISI/isi.pdf>
- Batista, A. L. (1998). "Análise do comportamento ao longo do tempo de barragens Abóbada", Tese de doutoramento, IST, Lisboa.
- Berberan, A. L. (1995). "Identificação de observações contaminadas em modelos lineares heterogéneos", Tese de especialidade, LNEC; Lisboa
- Bharath, R.; Drosen J. (1994). "*Neural network computing*", s.l..
- "*BrainMaker*" (s.d). Consultado em 30 de Agosto de 2006, em Califórnia Scientific: <http://www.calsci.com/BrainIndex.html>
- Carvalho, F. (1989). "*Engenharia de sistemas de controlo. Contribuição para o desenvolvimento das suas aplicações na investigação em domínios da engenharia civil*", Programa de investigação. Memória n.º 742, LNEC, Lisboa.
- Carvalho, J. V.; Gutiérrez, J. L. C.; Romanel, C., (2003). "*A neural network approach for seepage control in earth dams*", Proceedings of the Seventh International Conference on the Application of Artificial Intelligence to Civil and Structural Engineering.
- Castro, A. T. (1998). "Métodos de Retroanálise na interpretação do comportamento de barragens de betão" – Tese de doutoramento, IST, Lisboa.
- Caudill, M.; Butler, C. (1992). "*Understanding Neural Networks*", Vol. 1, A Bradford Book, The MIT Press, Cambridge, Massachusetts, London.
- Cortez, P.; Neves, J. (2000). "*Redes neuronais artificiais*", Departamento de informática, Escola de Engenharia Universidade do Minho, Braga.
- Draper; Smith (1996). "*Applied Regression Analysis*", United States of America.

-
- Eykhoff (1974). “*System identification. Parameter and state estimation*”, John Wiley & Sons, New York.
- Farinha, M. L. (2000). “*Extensões e tensões observadas em barragens de betão*”, Tese de mestrado, IST, Lisboa.
- Farinha, M. L. B.; Castro, A. T.; Pina, c. A. B. (2004). “*Definição e exploração de sistemas de recolha automática de dados da observação de barragens de betão*”, Relatório 175/04-NO, LNEC, Lisboa.
- Florentino, C. A.; Soares, M. C.; Pinto, J. F. (1970). “*Observação da Barragem do Alto Rabagão*” Relatório Final, Volume I a IV, LNEC, Lisboa.
- Franklin, S.(2000). “*Mentes Artificiais*”, Lisboa.
- Gomes, A. F. S. (1981). “Automatização das actividades de observação de barragens e análise quantitativa de resultados” – Tese de especialista, LNEC, Lisboa.
- Gomes, A. F. S. (1986). “A observação no controlo de segurança das barragens de betão portuguesas”, Relatório 302/86 – NO, LNEC, Lisboa.
- Gomes, A. F. S.; Ramos, J. M.; Martins, R. B. (1993). “*Criação de um Núcleo de Controlo de Segurança de Barragens no Laboratório de Engenharia de Angola*”, Relatório 59/93 – NF/NO/NHE, LNEC, Lisboa.
- Gomes, J. M. N. P. (2005). “Análise experimental de cenários de rotura em fundações de barragens de betão”, Tese de Doutoramento, LNEC, Lisboa.
- Gutiérrez, J. L. C.; Romanel, C., (2003). “Aplicação de redes neuronais na previsão de vazão através da fundação da ombreira esquerda da Barragem Corumbá-I”, XXV Seminário Nacional de Grandes Barragens, Salvador, Brasil.
- Hattingh, L. C.; Oosthuizen, C., (1998). “*surveillance of Gariep dam using neural networks*”, Dam Safety, Volume: 2, Rotterdam.
- Hattingh, L. C. (2002). “A critical review of use of neural network prediction model in the surveillance of a large dam”, 3rd International conference on Dam Engineering, Singapore.
- Henriques, M. J.; Leal, J. C. (1993). “*Análise do Sistema para a Determinação de Deslocamentos por Métodos Geodésicos*”, Relatório 84/93 - NMG/DB, LNEC, Lisboa.

Henriques, M. J.; Ribeiro, H. C. (1993). “Barragem do Alto Rabagão. Revisão do Sistema para a Determinação de Deslocamentos por Métodos Geodésicos”, Relatório 192/93 - NMG/DB, LNEC, Lisboa.

INAG, (2001). “Curso de exploração e segurança de barragens”, Instituto da água, Lisboa.

Kröse, B.; Smagt, P. (1993). “An Introduction to Neural Networks”, University of Amsterdam, Faculty of Mathematics & Computer Science, Amsterdam.

Lima, C. F. (2002). “Elementos da teoria de erros”. Consultado em 30 de Agosto de 2006, em Universidade do Minho:
<http://www2.fisica.uminho.pt/Topicos%20de%20Fisica/Elementos%20de%20teoria%20de%20erros.htm>

Lima, J. N. (2005). “O GPS na observação geodésica de barragens”. Relatório 157/05 – NGA/DBB, LNEC, Lisboa.

Marrone P. (2004). “Joone”. Consultado em 30 de Agosto de 2006, em Java Object Oriented Neural Engine: <http://www.jooneworld.com>

Mascarenhas, A. (1976) “Observação da barragem do Alto Rabagão”, Proc.43/1/853, Laboratório Nacional de Engenharia Civil, Lisboa.

Minsky, M.; Paper S. (1969). “Perceptrons”, MIT Press.

“NeuralTools” (s.d.). Consultado em 30 de Agosto de 2006, em Palisade Europe: <http://www.palisade-europe.com/trials.asp>

“NeuralWare” (s.d.). Consultado em 30 de Agosto de 2006, em NeuralWare: <http://www.neuralware.com/index.jsp>

“Neural Network Toolbox 5.0.1.” (s.d.). Consultado em 30 de Agosto de 2006, em The MathWorks: <http://www.mathworks.com/products/neuralnet>

“NeuroDimension” (s.d.). Consultado em 30 de Agosto de 2006, em NeuroDimension Incorporated: <http://www.nd.com/>

“NeuroSolutions for Excel” (s.d.). Consultado em 30 de Agosto de 2006, em

NeuroDimension Incorporated: <http://www.neurosolutions.com>

“NeuroX” (2003). Consultado em 30 de Agosto de 2006, em Neural Network Software Add-ins for Microsoft excel: <http://www.neuroxl.com>

NOIB (1993). “Normas de observação e inspecção de barragens” Portaria nº. 847/93 de 10 de Setembro, Lisboa.

Oliveira, S. B. (2000). “Modelos para análise do comportamento de barragens de betão considerando a fissuração e os efeitos do tempo. Formulações de dano”, Tese de doutoramento, FEUP, Porto.

Patterson, D. W. (1996). “Artificial neural networks: theory and applications”, Singapore.

Pedro, J. O. (1987). “A engenharia de barragens de betão em Portugal. Estruturas mais importantes e alguns estudos”. Conferência Ibero-Americana sobre Aproveitamentos hidráulicos, LNEC, Lisboa.

Pedro, J. O. (2001). “Segurança e funcionalidade das barragens” Memória N.º 824, LNEC, Lisboa.

Perner, F.; Koehler, W.; Oberhuber, P., (2003). “Interpretation of Schlegeis dam crest displacement”, 6th ICOLD Benchmark Workshop on Numerical Analysis of Dams. Salzburg.

Pinho, J. L. S. (1989), “Contribuição para o estudo da deformabilidade do betão de barragens”, Tese para obtenção do grau de Especialista, LNEC, Lisboa.

Pinho, A. J. F. (1996), “Estudo sobre a aplicação de redes neuronais à detecção de contornos de imagens”, Tese de doutoramento, IST, Lisboa.

Portela, E. T. A. (1999). “Novas metodologias de apoio ao controlo de segurança de barragens de betão: Uma abordagem através de sistemas periciais”, Tese de doutoramento, IST, Lisboa.

Ramos, J. M. (2004). “Observação do comportamento estrutural de barragens de betão, aspectos práticos” LNEC, Lisboa.

RSB (1990) “Regulamento de Segurança de Barragens” Decreto-lei N° 11/90 de 6 de Janeiro, Diário da Republica, Lisboa.

-
- Russell, J. S.; Norvig, P., (1995) "*Artificial intelligence a modern approach*", pp. 563-597, London.
- Silva, H. S.; Amante, J. A. (1993). "Barragem do Alto Rabagão. Inspecção à Estrutura e aos Sistemas de Observação", Relatório 215/93 - NO/DBB, LNEC, Lisboa
- Silva, H. S.; Portela, E. T. (1995). "*Revisão do sistema de observação da Barragem do Alto Rabagão*" Relatório 353/95-NO, LNEC, Lisboa.
- Silveira, A. F. (1961). "*As variações de temperatura nas barragens*", Memória Nº 177, LNEC, Lisboa.
- "*STATISTICA Neural Networks*" (s.d). Consultado em 30 de Agosto de 2006, em StatSoft: http://www.statsoft.com/products/stat_nn.html
- Swiss Committee on Dams (2003). "Methods of analysis for the prediction and the verification of dam behaviour", 21º Congresso do ICOLD, Montreal.
- Topping, B.H.V.; Bahreininejad, A. (1997). "*Neural computing for structural mechanis*", s.l..
- Turban, E.; Aronson, J.E. (2001). "*Decision support systems and intelligent systems*", pp. 550-646, s.l..
- Varlet, H. (1996). "*Barrages-Réservoirs*". Eyrolles, Paris.
- Vazinram, F.; Safi, M.; Rasti, R. (2005). "*Artificial neural networks for concrete dam monitoring*", Paper Nº: 030-S6, 73rd Annual Meeting of ICOLD, Iran.
- Veltrop, J. A. (1988) – Section 3 in "*Development of Dam Engineering in United States*", Nova Iorque, Pergamon Press.
- Xianqi, L.; Sifeng, L. (2004). "Use artificial neural network and genetic algorithms for prediction of stresses and deformations in rock-fill dam", New Developments in Dam Engineering, London.

BIBLIOGRAFIA

- "*Artificial Neural Network from Wikipedia*" (2001). Consultado em 30 de Agosto de 2006:
http://en.wikipedia.org/wiki/Artificial_neural_network
- Almeida, L. B. (s.d.). "*Luís Borges de Almeida*". Consultado em 30 de Agosto de 2006, em Instituto de telecomunicações: <http://www.lx.it.pt/~lbalmeida/>
- Abdulmit, A. (2002). "*Seepage through an earthfill dam - foundation system and piezometric level variation downstream of the dam*", 7th International Benchmark Workshop on Numerical Analysis of Dams, ICOLD, Romania. Consultado em 30 de Agosto de 2006, em Integrity assessment of large concrete dams: <http://nw-ialad.uibk.ac.at/Wp3/Tg4/Se3/Files/Synthesis-C.pdf>
- Cardoso, J. F. S. (2001). "*Predição da qualidade na indústria de fundição injectada*", Tese de Doutoramento, 2001, Porto. Consultado em 30 de Agosto de 2006, em Faculdade de Engenharia da Universidade do Porto: <http://paginas.fe.up.pt/~jcard/publicacoes/tese.pdf>
- Cortez, P. (s.d.). "*Paulo Cortez WWW Page*". Consultado em 30 de Agosto de 2006, em Departamento de Sistemas de Informação da Escola de Engenharia da Universidade do Minho: <http://piano.dsi.uminho.pt/~pcortez/>
- Fairbairn, E. M. R.; Goulart E.; Coutinho, A. L. G. A.; Ebecken, N. F. F.; Guedes, Q. M.; Viana, D. M. (s.d.). "*Durability Assessment of an Arch Dam using Inverse Analysis with Neural Networks and High Performance Computing*". Consultado em 30 de Agosto de 2006, em Universidade Federal do Rio de Janeiro: <http://209.85.129.104/search?q=cache:O4Oe5VklCtsJ:www.coc.ufrj.br>
- Fedele, R.; Maier, G.; Miller, B. (2006). "*Health Assessment of Concrete Dams by Overall Inverse Analyses and Neural Networks*", International Journal of Fracture. Consultado em 30 de Agosto de 2006, em IngentaConnect: <http://www.ingentaconnect.com/content/klu/frac/2006/00000137/F0040001/00006582>

-
- Fedele, R.; Maier, G.; Miller, B. (s.d). "*Mechanical characterization of dam concrete by in situ tests and neural networks*". Consultado em 30 de Agosto de 2006, em Integrity assessment of large concrete dams: <http://nw-ialad.uibk.ac.at/Wp3/Tg3/Se2/Ss3>
- Gomes, M. P. (1999). "*Reconhecimento de dígitos impressos com redes neuronais*", Tese de mestrado, IST, Lisboa.
- Gurney, K. (s.d.). "*Neural Nets: Dr K Gurney*". Consultado em 30 de Agosto de 2006, em Department of Psychology, University of Sheffield: <http://www.shef.ac.uk/psychology/gurney/notes/contents.html>
- Lagoa, J. M., (2000). "*Representação matricial de redes neuronais*", Tese de mestrado, IST, Lisboa.
- "*Machine Learning Neural Networks Group*" (2003). Consultado em 30 de Agosto de 2006, em Department of Systems and Computer Science, University of Florence: <http://www-dsi.ing.unifi.it/neural/w3-sites.html>
- Nunes, L.M. (1996). "Inicialização e construção de perceptrões multi-camada e redes locais", Tese de mestrado, IST, Lisboa.
- Pinho, A. J. F. (1996). "Estudo sobre a aplicação de redes neuronais à detecção de contornos de imagens", Tese de doutoramento, IST, Lisboa.
- Ribeiro B. (1997). "*Redes Neuronais*". Consultado em 30 de Agosto de 2006, em Mestrado em Engenharia Informática, Universidade de Coimbra: <http://pascal.iseg.utl.pt/~sie/Aula06/Rneuro.html>
- "*ScienceDirect Top 25 Hottest Articles*" (s.d.). Consultado em 30 de Agosto de 2006: http://top25.sciencedirect.com/?journal_id=08936080
- Smith, L. (1996). "*An Introduction to Neural Networks*". Consultado em 30 de Agosto de 2006, em Department of Computing and Mathematics, University of Stirling: <http://www.cs.stir.ac.uk/~lss/NNIntro/InvSlides.html>
- "*Sociedade Brasileira de Redes Neuronais*" (s.d.). Consultado em 30 de Agosto de 2006: <http://www.sbrn.org.br/>

Technical University of Civil Engineering of Bucharest. (2003). "*Seepage through an earthfill dam – foundation system and piezometric level variation downstream of the dam*", 7th Benchmark workshop on numerical analysis of dams, Romania. Consultado em 30 de Agosto de 2006, em Romanian National Committee on Large Dams: <http://www.rocold.ro/themec.htm>

