

4 METODOLOGIA

4.1 Introdução

Neste capítulo descreve-se as características principais da barragem de Funil e das instrumentações de vazões analisadas neste trabalho. Trata-se ainda, da metodologia adotada para utilização das técnicas empregadas neste trabalho.

4.2 Barragem de Funil

A barragem de Funil (Figura 4.1), situada próxima da cidade de Resende no Estado do Rio de Janeiro, é uma barragem do tipo abóbada de dupla curvatura com altura máxima de 85 m e comprimento máximo de 385 m. A casca tem uma espessura de 12 m na base e 3,6 m no topo. O volume total de concreto é de 286.000 m³. A capacidade de produção de energia é de 216 MW.



Figura 4.1 Arranjo geral da barragem Funil do tipo abóbada de dupla curvatura.

O sistema de medição monitora as seguintes grandezas:

- a) Temperatura é medida no interior da casca, do soco e do encosto. A figura 4.3 mostra o quadro de controle dos extensômetros e dos termômetros;
- b) Deformações são medidas utilizando extensômetros;
- c) Três drenos captam água. O dreno “D191” (figura 4.4) capta a água drenada da fundação da barragem. O dreno “D192” (figura 4.5) capta a água drenada da margem direita. O dreno “D193” (figura 4.6) capta a água drenada da margem esquerda;
- d) Deslocamentos das juntas de dilatação;
- e) Piezômetros medem a pressão hidrostática;
- f) Deslocamentos horizontais, tangenciais e radiais são medidos em ambas as margens com cordinômetros;
- g) Deslocamento vertical da barragem.

As medições das grandezas são feitas ao longo de galerias no interior da barragem (Figura 4.2).

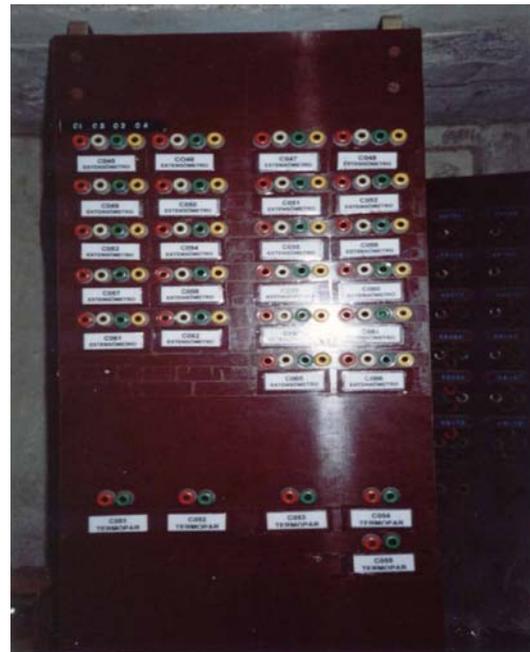


Figura 4.2 Galeria no soco da barragem de Funil.

Figura 4.3 Quadro de controle dos extensômetros e do termômetro.



Figura 4.4 Dreno "D191".



Figura 4.5 Dreno "D192".



Figura 4.6 Dreno "D193".

As medidas de vazão ao longo da barragem e sob a barragem são importantes indicadores do bom funcionamento da barragem durante o período de operação. Caso algum problema ocorra no comportamento geotécnico da barragem, os valores anormais serão captados pelo sistema de aquisição de dados de vazões. Então a geração de modelos de previsão, que forneçam valores futuros

das medidas de vazão, é uma ferramenta importante para o sistema de segurança da barragem.

4.3 Análise e preparação dos dados

Os dados considerados são as séries temporais das leituras de vazão dos drenos “D191”, “D192”, “D193”, o nível do reservatório e a temperatura. As séries foram amostradas a partir de 02/09/1985 a 25/02/2002, totalizando 737 amostras.

O grau de correlação existente entre as séries temporais de vazão dos drenos “D191”, “D192” e “D193” e a série das cotas do nível d’água do reservatório e a série das leituras de temperatura foi analisado. Determinou-se nesta análise que o coeficiente de correlação entre as medidas de vazão do dreno “D191” e as cotas do nível d’água é de 58%, entre as medidas de vazão do dreno “D192” e as cotas do nível d’água é de 65% e entre as medidas de vazão do dreno “D193” e as cotas do nível d’água é de 63%. Constatou-se ainda, nesta análise que o coeficiente de correlação entre as medidas de vazão do dreno “D191” e as medidas de temperatura é de -30%, entre as medidas de vazão do dreno “D192” e as medidas de temperatura é de -15% e entre as medidas de vazão do dreno “D193” e as medidas de temperatura é de -4%. As correlações encontradas para a série da cota do nível d’água justificam a inclusão desta série como variável explicativa em alguns modelos de previsão por redes neurais temporais. Apesar das correlações baixas encontradas para a série de temperatura, esta foi também considerada como variável explicativa, com o intuito de analisar se o grau de correlação é realmente um mecanismo eficiente de seleção de variáveis de entrada para a rede neural temporal.

O grau de correlação existente entre as séries temporais de vazão dos drenos “D191”, “D192” e “D193” foi analisado. Nesta análise observou-se que o coeficiente de correlação entre as medidas de vazão do dreno “D191” e as medidas de vazão do dreno “D192” é de 53%, entre as medidas de vazão do dreno “D191” e as medidas de vazão do dreno “D193” é de 57% e entre as medidas de vazão do dreno “D192” e as medidas de vazão do dreno “D193” é de 83%. Apesar de somente a correlação entre os drenos “D192” e “D193” ser alta, todas as

medidas de vazões serão consideradas como variáveis explicativas, pelo mesmo motivo apresentado para a consideração da temperatura como variável explicativa.

As séries passaram por uma etapa de pré-processamento de dados para completar dados faltantes e substituir leituras aberrantes por valores obtidos por interpolação utilizando *splines cúbicas*. A normalização dos valores entre 0 e 1 torna a etapa de treinamento das redes mais eficiente.

4.4 Análises realizadas

Serão realizadas duas análises. A primeira considera as séries com intervalo de tempo constante, ou seja, o tempo decorrido entre duas amostras será sempre o mesmo. Enquanto que na segunda análise as séries apresentam intervalo de tempo variável, ou seja, o intervalo de tempo entre as amostras é diferente ao longo das séries.

Na análise com intervalo de tempo constante, as séries foram alteradas, com a inclusão de novos dados, para ficarem com intervalo de tempo igual. Nesta etapa, as séries apresentam frequência semanal. Estas séries são compostas por 455 amostras, das 737 amostras originais. A redução do conjunto original de amostras ocorre devido o intervalo de tempo entre a amostra na data 16/05/1994 e a amostra sucessiva (26/09/94) ser muito grande. Inviabilizando a utilização das *splines* cúbicas para inclusão destes novos dados, já que os erros da interpolação seriam elevados. Então as séries utilizadas para a análise com intervalo de tempo constante possuem apenas 455 amostras, compreendidas entre as datas 09/09/1985 e 16/05/1994.

Na análise com intervalo de tempo variável, a data da amostra foi considerada como variável explicativa. Para considerar o aspecto temporal das séries utiliza-se uma função seno para representar a data, indicada na equação (4.1). Nesta análise, foram consideradas todas as 737 amostras.

$$entrada = \text{sen}\left(\frac{2\pi(data - data_origem)}{365}\right) \quad (4.1)$$

4.5 Técnicas empregadas

As técnicas de redes neurais temporais, método estatístico de Box & Jenkins (1970) e métodos geoestatísticos são empregados na previsão da vazão dos drenos subterrâneos “D191”, “D192” e “D193”.

Os tipos de redes utilizadas foram:

- RNT com arquitetura *feedforward* associada a técnica de janelamento;
- RNT recorrente Elman.
- RNT FIR
- RNT Jordan

No treinamento das RNT's com arquitetura *feedforward* associada à técnica de janelamento, recorrente Elman e Jordan foi utilizado o algoritmo de regularização bayseana associado ao método leave-one-out. Enquanto que na RNA FIR, o algoritmo de treinamento utilizado é o de retropropagação temporal associado ao método de validação cruzada. No treinamento das redes neurais temporais foram considerados os seguintes parâmetros.

Taxa de aprendizado (η)	0,001
Termo de momento (constante)	0,50
Gradiente mínimo	1E-12

A função de ativação utilizada na camada oculta foi a função de ativação logística não linear e na camada de saída foi a função linear.

No processo de modelagem, com a finalidade de evitar erros mínimos locais, as RNT's com arquitetura *feedforward* associada à técnica de janelamento, recorrente Elman e Jordan tiveram seus programas reinicializados aleatoriamente 100 vezes para cada caso analisado, adotando-se como melhor topologia aquela que tivesse os valores de erros mais próximos das médias dos erros obtidas. Enquanto que na RNT FIR, os programas foram reinicializados aleatoriamente apenas 5 vezes. Este número menor de reinicializações ocorre devido o tempo de processamento do programa para a RNT FIR ser extremamente longo. Em todas as redes, tomou-se o cuidado de não considerar as previsões com erros acima de um valor considerado alto pelo analista do problema. Este cuidado evita que a média seja alterada por estas previsões ruins.

Métodos geoestatísticos baseados em variogramas são chamados normalmente de krigagem e, dentre estes, o mais usualmente empregado é o método da krigagem ordinária. A krigagem ordinária foi escolhida para estimar a

previsão, devido às séries analisadas serem estacionárias, característica necessária para utilização deste método.

Para a análise com intervalo de tempo constante foi utilizado o método de Box & Jenkins (1970), as quatro redes neurais temporais e a krigagem ordinária. Nesta etapa, considerou-se uma única série histórica para geração do modelo, ou seja, a previsão da vazão do dreno era realizada considerando como variável explicativa somente a sua própria série histórica. Este critério foi adotado para poder utilizar o método univariado de Box & Jenkins. A análise foi feita considerando apenas o conjunto de aprendizado com 455 amostras.

Na análise com intervalo de tempo variável foram utilizadas as quatro redes neurais temporais e a krigagem ordinária. Os modelos testados para as redes neurais temporais podem utilizar como variáveis explicativas: a data, o nível do reservatório à montante, a temperatura e as séries históricas de vazões dos drenos. Já a krigagem ordinária utilizou somente a vazão do dreno como variável explicativa. No treinamento com o algoritmo de regularização bayseana e de retropropagação temporal foram utilizados dois subconjuntos denominados, aprendizado (588 amostras) e teste (148 amostras). Na krigagem ordinária foram utilizados dois subconjuntos denominados, aprendizado (587 amostras) e teste (150 amostras).

4.6 Métricas Adotadas

As métricas de comparação usadas correspondem ao erro percentual médio absoluto (MAPE); raiz do erro médio quadrático (RMSE), que penaliza mais os erros maiores; e o coeficiente U de Theil, que avalia o desempenho da previsão em relação à previsão ingênua ou trivial. Previsão ingênua ou trivial significa que a estimativa do valor futuro é igual ao valor atual.

O coeficiente U de Theil analisa a qualidade de uma previsão através dos seguintes valores:

- $U > 1$, significa que o erro do modelo é maior do que da previsão ingênua;
- $U < 1$, significa que o erro do modelo é menor que da previsão ingênua.

O coeficiente U de Theil menor do que 1 já indica uma previsão melhor que a previsão ingênua; quanto mais próximo o mesmo for de zero, melhor será o resultado da previsão.

$$MAPE = \frac{1}{N} \sum_{j=1}^N \left| \frac{alvo_j - pred_j}{alvo_j} \right| * 100 \quad (4.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (alvo_j - pred_j)^2} \quad (4.3)$$

$$UTHEIL = \frac{\sqrt{\sum_{j=1}^N (alvo_j - pred_j)^2}}{\sqrt{\sum_{j=1}^N (alvo_j - alvo_{j-1})^2}} \quad (4.4)$$

onde $alvo_j$ são os valores reais desejados na previsão, $pred_j$ representa os valores obtidos pela rede neural.