

## **5 CASOS ESTUDADOS**

### **5.1. Previsão da vazão na fundação da ombreira esquerda**

#### **5.1.1. Introdução**

As vazões através de um aterro de solo compactado são, em geral, muito pequenas, sendo os maiores valores de fluxo normalmente observados pela fundação. Algum tempo após a formação do reservatório da barragem Corumbá I, medições sistemáticas permitiram determinar a vazão máxima pelo sistema de drenagem global, com qualquer acréscimo significativo em relação a esse valor podendo indicar uma anomalia que necessitaria ter suas causas investigadas. Da necessidade de garantir a segurança e o normal funcionamento da barragem Corumbá I, acrescido do fato que o maciço de fundação junto à ombreira esquerda tem características peculiares, surgiu o interesse de modelar e prever em um horizonte o comportamento da vazão sob a fundação da barragem.

A série temporal da vazão total que percola através da fundação na região da ombreira esquerda foi obtida considerando-se a soma das vazões medida nos drenos nº3 e nº4, localizados nas surgências d'água à jusante, descritas no capítulo 3, procurando-se obter uma estimativa total da vazão junto à ombreira esquerda.

#### **5.1.2. Análise e preparação dos dados**

Uma das primeiras análises dos dados da instrumentação de Corumbá I consistiu na avaliação do grau de correlação existente entre a série temporal da vazão total nos drenos nº3 e nº4 e as séries das cotas do nível d'água do reservatório e as leituras de carga de pressão no piezômetro PZ15, instalado na

fundação de solo residual (Figura 3.5). Determinou-se nesta análise preliminar que o coeficiente de correlação entre as medidas de vazão e as cotas do nível d'água é de 90% e entre as medidas de vazão e da carga de pressão no piezômetro PZ15 é de 72%, justificando-se a inclusão destas duas séries como variáveis explicativas (cota do nível d'água e carga de pressão) em alguns modelos de previsão por redes neurais artificiais.

As leituras disponíveis de vazão nos drenos, das cotas do nível d'água do reservatório e das cargas de pressão na fundação de solo residual foram geralmente feitas com frequência quinzenal ( $\Delta t = 15$  dias) entre as datas de 13/08/1997 a 30/11/2002. Em algumas ocasiões, no entanto, as leituras não foram realizadas, sendo esses valores faltantes estimados neste trabalho através de interpolação com “spline” cúbica construída com as leituras mais próximas disponíveis.

As séries históricas de vazão, nível do reservatório e leituras piezométricas consideradas no período operacional da barragem contam com 130 observações no período de análise, e foram subdivididas em dois conjuntos denominados de treinamento (formado por 104 padrões, ou 80% do total das medidas disponíveis) entre as datas de 13/08/1997 a 05/11/2001, e conjunto de validação (contendo os outros 26 padrões, ou 20% restante) entre as datas de 20/11/2001 a 30/11/2002. No decorrer desta pesquisa alguns dados adicionais da instrumentação, entre os períodos de 30/11/2002 a 15/03/2003, tornaram-se também disponíveis, o que viabilizou a formação de um conjunto de teste com os 7 novos padrões. No apêndice A, as tabelas A.1 e A.3 mostram em detalhe as séries temporais das variáveis envolvidas na modelagem da vazão.

### **5.1.3.**

#### **Previsão da vazão pelo modelo de Box & Jenkins**

Para previsão de vazão pelo modelo de Box & Jenkins utilizou-se o programa E-views v 4.0 (2001). A condição de estacionariedade da série de vazão para o conjunto de modelagem, correspondente ao conjunto de treinamento das RNA, foi comprovada pelo teste da raiz unitária (Dickey & Fuller, 1979) enquanto que o exame do comportamento das funções de autocorrelação simples e

autocorrelação parcial indicaram que a seqüência histórica de valores pode ser adequadamente modelada através de um modelo auto-regressivo linear AR(1). Na seleção do modelo apropriado de Box & Jenkins procurou-se capturar toda a estrutura de dependência serial presente na seqüência de dados, de tal modo que os erros não apresentassem nenhuma dependência em relação ao tempo (ruído branco). A análise detalhada do processo de modelagem é apresentada no item B.1 do apêndice B.

A tabela 5.1 mostra o desempenho da modelagem através das métricas estatísticas mencionadas no capítulo 4, para o conjunto de modelagem e as previsões efetuadas para os conjuntos de validação e teste, enquanto que a figura 5.1 ilustra graficamente os resultados para cada um desses conjuntos. Nesta e nas demais previsões, intervalos de confiança com probabilidade de 95% foram construídos, isto é, admitindo-se a hipótese de que provavelmente 95% dos valores previstos estejam no interior dessa faixa.

Embora o modelo AR(1) tenha passado os testes estatísticos, o coeficiente U de Theil na tabela 5.1 resultou maior do que 1 para os conjuntos de validação e teste, indicando que as previsões assim obtidas são menos precisas do que uma estimativa trivial ou ingênua. Esta deficiência da modelagem poderia ser superada, repetindo-se, por exemplo, o processo de ajuste do modelo com a exclusão dos valores mais irregulares (*outliers*) da série. Uma boa modelagem depende não só da quantidade de valores considerados na seqüência como também de uma correta identificação daqueles que mais contribuem no processo estocástico que produz a série temporal.

Modelagem			Validação			Teste		
MAPE (%)	RMSE l/min	U	MAPE (%)	RMSE l/min	U	MAPE (%)	RMSE l/min	U
35,440	40,863	0,950	10,867	34,210	1,022	19,429	56,858	1,131

Tabela 5.1 Desempenho do modelo AR(1) para os conjuntos de modelagem, validação e teste.

#### 5.1.4. Análise da vazão por redes neurais

Na modelagem das séries temporais da vazão por RNA, foram consideradas redes multicamadas com uma camada escondida, sendo empregada em todos os casos a técnica de ‘janelamento’ temporal com algoritmo de retropropagação do erro na fase de aprendizagem e o critério de parada baseado na técnica de validação cruzada (Haykin, 1999).

#### Seleção de variáveis.

A tabela 5.2 descreve as séries de variáveis consideradas na previsão das vazões através da fundação da barragem.

Sigla	Descrição
Vz	Vazão nos drenos 3 e 4 (total) através da fundação da ombreira esquerda, (l/min.)
NA	Cota do nível do reservatório acima do nível do mar (m).
Pz15	Carga de pressão no piezômetro PZ15 instalado na fundação da ombreira esquerda (m). Ver (Fig. 3.5).

Tabela 5.2 Siglas adotadas para as variáveis consideradas na modelagem da vazão.

Todas as variáveis envolvidas neste estágio foram normalizadas entre 0 e 1, como normalmente feito em aplicações de redes neurais para melhorar o desempenho durante o treinamento.

#### Configuração da rede

A grande dificuldade na aplicação de redes neurais tem sido a indisponibilidade de um processo padronizado para determinação da melhor topologia de rede neural para determinado problema. A seleção das variáveis explicativas é normalmente feita com base no conhecimento do analista sobre as causas prováveis do fenômeno, complementado por estudos de correlação como o executado no item 5.1.2.

O treinamento da rede neural foi feito com o algoritmo de retropropagação do erro, que incorpora o método do gradiente descendente, com a adição, neste caso, de um termo constante denominado termo de momento para acelerar o processo iterativo, com taxa adaptativa de aprendizado. Tanto nos neurônios da camada escondida quanto da camada de saída foi adotada a função de ativação logística não linear (equação 4.8).

O software utilizado foi o MatLab 6.1. (2001) com a consideração dos seguintes parâmetros para a fase de treinamento de todas as redes neurais artificiais mencionadas neste capítulo.

Taxa de aprendizado ( $\eta$ )	0,01
Acréscimo da taxa de aprendizado	1,05
Decréscimo da taxa de aprendizado	0,70
Termo de momento (constante)	0,90
Gradiente mínimo	1E-06

Foram testados 10 modelos de redes neurais, cada um admitindo 5 topologias com 2, 3, 5, 8 e 10 neurônios na camada escondida, totalizando 50 configurações com padrões de entrada listados na tabela 5.3. Nos quatro primeiros modelos (RNA I, RNA II, RNA III, RNA IV) as redes foram construídas apenas com os valores históricos da vazão, enquanto que nos demais modelos foram incluídas como entradas adicionais as variáveis causais correspondentes à leitura do nível do reservatório e valores da carga de pressão no piezômetro PZ15.

No processo de modelagem, para obtenção das menores estimativas de erro na rede neural, o programa foi reinicializado randomicamente 10 vezes para cada caso analisado, adotando-se como melhor topologia aquela apresentando os menores erros.

Rede Neural	Entradas ( $\Delta t =$ intervalo de 15 dias)
RNA I	$Vz_{t-\Delta t}$
RNA II	$Vz_{t-\Delta t}, Vz_{t-24\Delta t}, Vz_{t-25\Delta t}, Vz_{t-26\Delta t}$
RNA III	$Vz_{t-\Delta t}, Vz_{t-2\Delta t}$
RNA IV	$Vz_{t-\Delta t}, Vz_{t-23\Delta t}, Vz_{t-24\Delta t}, Vz_{t-25\Delta t}$
RNA V	$Vz_{t-\Delta t}, NA_{t-\Delta t}$
RNA VI	$Vz_{t-\Delta t}, Vz_{t-24\Delta t}, Vz_{t-25\Delta t}, Vz_{t-26\Delta t}, NA_{t-\Delta t}, NA_{t-24\Delta t}, NA_{t-25\Delta t}, NA_{t-26\Delta t}$
RNA VII	$Vz_{t-\Delta t}, Vz_{t-24\Delta t}, Vz_{t-25\Delta t}, Vz_{t-26\Delta t}, Vz_{t-31\Delta t}, NA_{t-\Delta t}, NA_{t-24\Delta t}, NA_{t-25\Delta t}, NA_{t-26\Delta t}, NA_{t-31\Delta t}$
RNA VIII	$Vz_{t-\Delta t}, Vz_{t-24\Delta t}, NA_{t-\Delta t}, NA_{t-24\Delta t}$
RNA IX	$Vz_{t-\Delta t}, Pz15_{t-\Delta t}$
RNA X	$Vz_{t-\Delta t}, Vz_{t-16\Delta t}, Vz_{t-17\Delta t}, Vz_{t-18\Delta t}, Vz_{t-19\Delta t}, Pz15_{t-\Delta t}, Pz15_{t-16\Delta t}, Pz15_{t-17\Delta t}, Pz15_{t-18\Delta t}, Pz15_{t-19\Delta t}$

Tabela 5.3 Padrões de entrada considerados nos modelos de redes neurais.

No apêndice C, as tabelas C.1 a C.10 mostram o desempenho de cada modelo, com as topologias marcadas em negrito indicando as melhores redes de cada modelo. A tabela 5.4 apresenta um resumo dessas melhores topologias, onde os valores a/b/c listados na coluna ‘topologia’ correspondem ao número de padrões na camada de entrada, número de neurônios na camada escondida e na camada de saída, respectivamente. A abreviação ‘univ’ significa que a variável dependente está sendo explicada através da própria série histórica, enquanto a abreviação ‘mult’ indica que o modelo considera a hipótese de outras variáveis causais para explicar o comportamento de vazão.

No processo de seleção da melhor configuração de rede neural foram avaliados os erros obtidos nas fases de treinamento e de validação, conferindo-se maior peso e importância aos erros obtidos nos conjuntos de validação e teste, onde a capacidade de generalização da rede é examinada. Observa-se que em quase todos os casos listados na tabela 5.4 o coeficiente U de Theil é menor do que 1, evidenciando que as previsões obtidas através das RNA têm melhor desempenho do que uma previsão ingênua.

Rede Neural	Topologia	Treinamento			Validação		
		MAPE (%)	RMSE (l/min)	U	MAPE (%)	RMSE (l/min)	U
<b>RNA I</b>	<b>1/3/1 univ</b>	<b>27,266</b>	<b>41,440</b>	<b>0,963</b>	<b>8,859</b>	<b>27,756</b>	<b>0,829</b>
RNA II	4/3/1 univ	55,490	44,774	1,041	7,098	29,039	0,839
RNA III	2/2/1 univ	38,579	39,082	0,905	9,381	33,133	0,993
RNA IV	4/3/1 univ	44,590	38,672	0,904	7,277	30,114	0,871
RNA V	2/8/1 mult	25,721	34,313	0,800	9,731	30,638	0,915
RNA VI	8/3/1 mult	41,462	40,481	0,938	10,190	30,897	0,893
RNA VII	10/10/1mult	20,075	28,013	0,631	8,573	27,508	0,804
RNA VIII	4/10/1 mult	33,537	35,453	0,833	10,302	30,377	0,855
RNA IX	2/5/1 mult	31,304	36,558	0,851	9,041	32,405	0,966
RNA X	10/10/1mult	33,990	33,846	0,810	8,854	34,773	0,991

Tabela 5.4 Resumo das melhores topologias de cada modelo de RNA considerado.

Em relação aos resultados da tabela 5.4, pode-se observar que as topologias RNA VII e RNA I apresentaram os desempenhos superiores, com melhores resultados para a RNA VII nas fases de treinamento e validação e para a RNA I na fase final de teste e generalização do modelo (comparar tabelas 5.5 e 5.6).

Outro conceito importante, que auxilia na escolha da rede neural para o problema, é o da parcimônia, i.e. seleciona-se a rede neural que possa representar a série temporal através de uma configuração que envolva a menor quantidade de parâmetros (pesos sinápticos). Com base nos resultados da tabelas 5.4, 5.5, 5.6 e no conceito da parcimônia, a rede RNA I foi então selecionada para dar continuidade às análises, apresentando topologia baseada em apenas um valor atrasado da própria série de vazão e três neurônios na camada escondida.

É ainda importante deixar claro que em todos os casos estudados neste capítulo não houve re-treinamento das redes neurais, usando-se o conjunto de validação para simular o comportamento do conjunto de teste, procurando-se manter as comparações com os modelos autoregressivos em igualdade de condições.

Treinamento			Validação			Teste		
MAPE (%)	RMSE l/min	U	MAPE (%)	RMSE l/min	U	MAPE (%)	RMSE l/min	U
27,266	41,440	0,963	8,859	27,756	0,829	19,597	57,644	1,146

Tabela 5.5 Desempenho da rede neural RNA I na previsão da vazão.

Treinamento			Validação			Teste		
MAPE (%)	RMSE l/min	U	MAPE (%)	RMSE l/min	U	MAPE (%)	RMSE l/min	U
20,075	28,013	0,631	8,573	27,508	0,804	23,256	68,700	1,366

Tabela 5.6 Desempenho da rede neural RNA VII na previsão da vazão.

Por outro lado, da análise dos resultados obtidos pelo modelos auto-regressivo AR(1) e rede neural artificial RNA I (tabelas 5.1 e 5.5) pode-se afirmar que ambos apresentam desempenhos similares, com resultados ligeiramente melhores para a rede neural nas fases de treinamento e validação. Observe-se também que o valor do coeficiente U de Theil é levemente superior a 1 para a simulação do conjunto de teste, tanto para o modelo AR(1) quanto para a RNA I.

As figuras 5.1 e 5.3 apresentam graficamente o desempenho dos modelos AR(1) e RNA I, respectivamente, para as três etapas de análise: modelagem (treinamento), validação e teste. Nas figuras 5.2 e 5.4 são mostrados os erros relativos das previsões destes modelos em relação aos dados amostrais da série temporal. No caso de RNA, as estimativas são consideradas pontuais, não tendo portanto sido construídos intervalos de confiança como aqueles apresentados na figura 5.1 para o modelo autoregressivo.

Adicionalmente, para uma comparação adicional dos resultados obtidos com as redes neurais, as previsões obtidas pela RNA I (julgada a melhor topologia) e RNA VII (considerada a segunda melhor topologia) foram também apresentadas as previsões da série temporal obtidas com a RNA VII (figura 5.5) e respectivos erros relativos (figura 5.6) para as fases de treinamento, validação e teste.

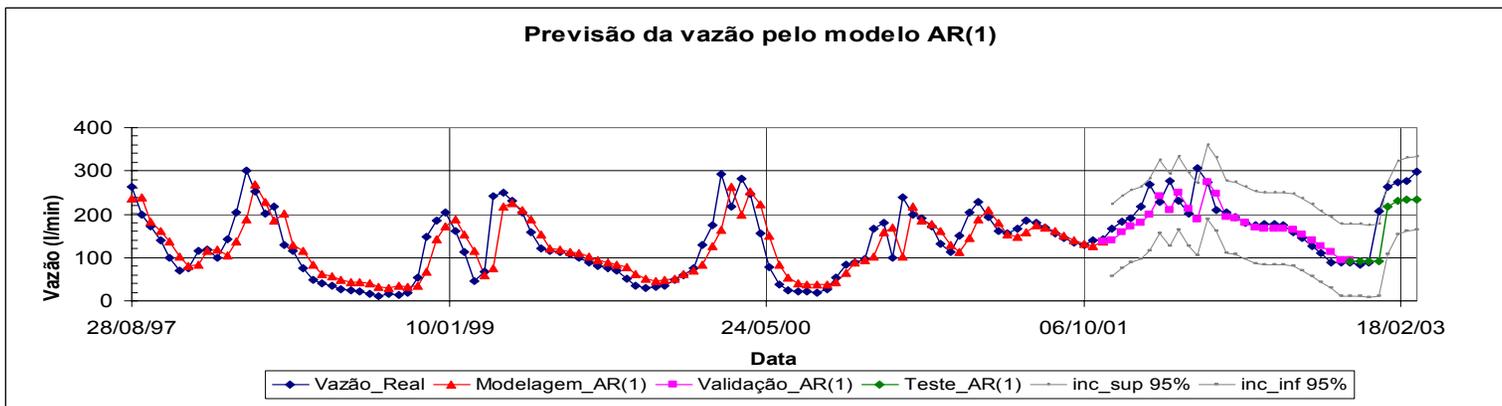


Figura 5.1 Modelagem e previsão da vazão com o modelo AR(1) para os conjuntos de modelagem, validação e teste.

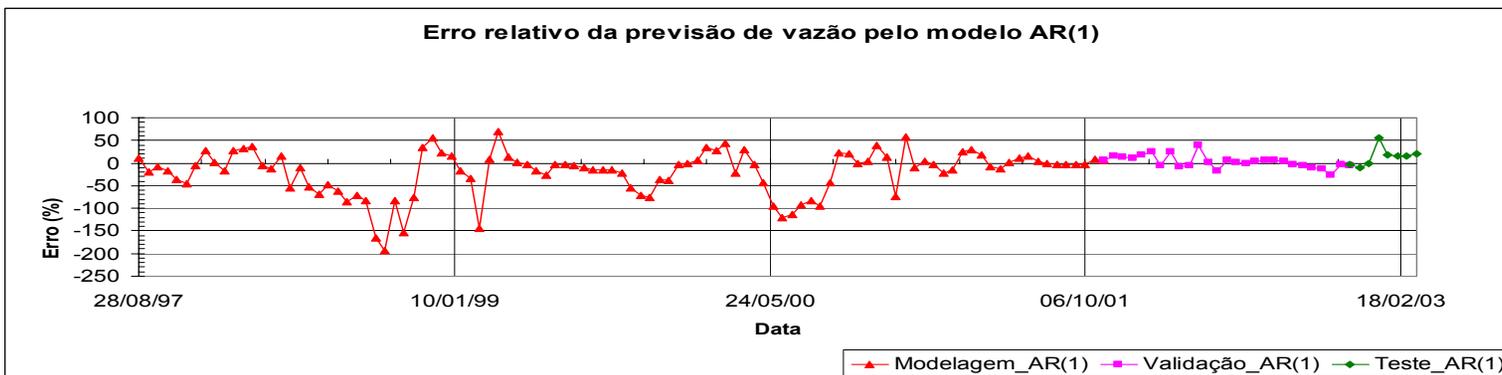


Figura 5.2 Erro relativo da vazão com o modelo AR(1) para os conjuntos de modelagem, validação e teste.

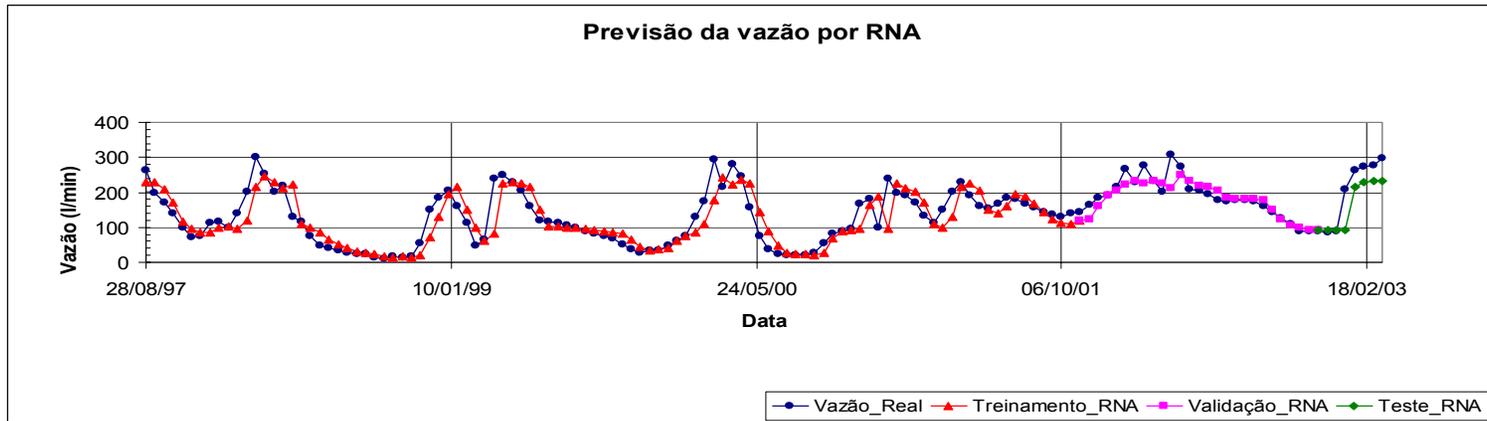


Figura 5.3 Modelagem e previsão da vazão com a rede neural RNA I para os conjuntos de treinamento, validação e teste.



Figura 5.4 Erro relativo da vazão com a rede neural RNA I para os conjuntos de treinamento, validação e teste.

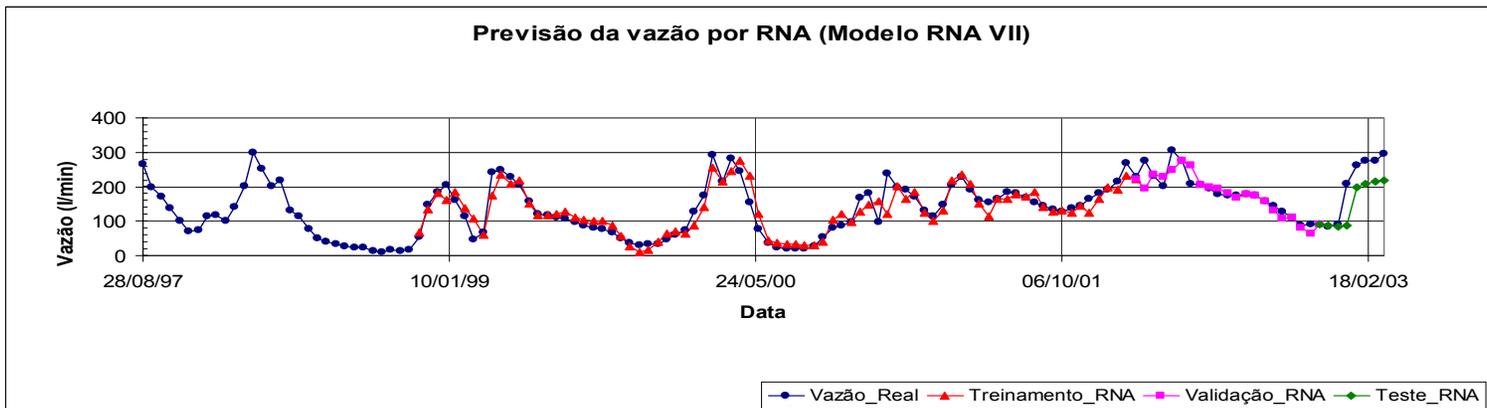


Figura 5.5 Modelagem e previsão da vazão com a rede neural RNA VII para os conjuntos de treinamento, validação e teste.

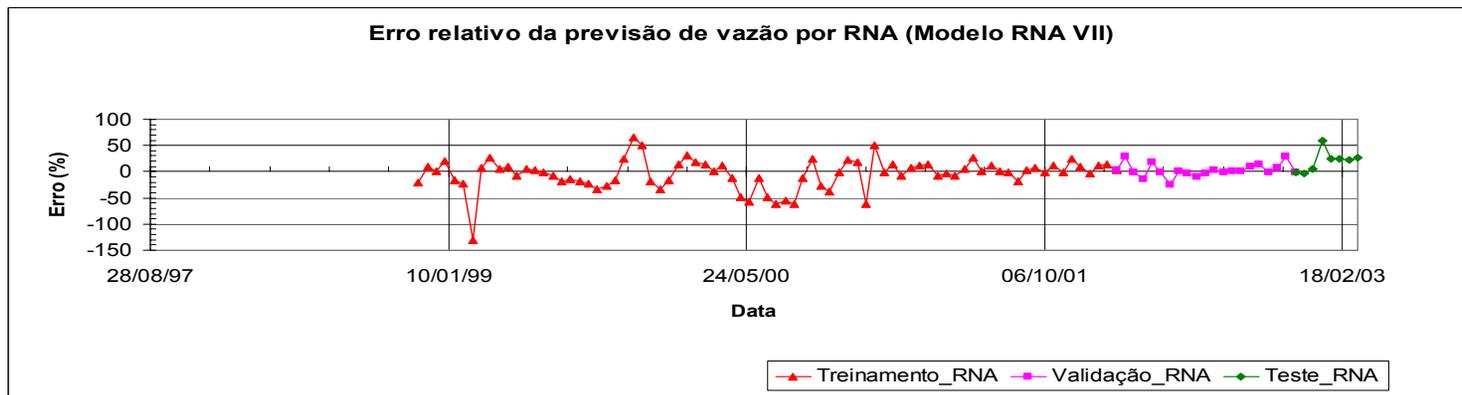


Figura 5.6 Erro relativo da vazão com a rede neural RNA VII para os conjuntos de treinamento, validação e teste.

Previsão das cargas de pressão nos piezômetros instalados no núcleo da barragem e na fundação de solo residual.

### **5.1.5. Introdução**

As medidas das cargas de pressão nos núcleos de barragens de enrocamento, nos períodos construtivos e de operação, são importantes para verificação da eficiência da drenagem nas camadas de transição e na influência na estabilidade de taludes da barragem. Na fundação, as cargas de pressão são também medidas para determinação das condições de fluxo e para monitorar o desempenho dos dispositivos de impermeabilização e/ou drenagem.

O comportamento das cargas de pressão na barragem Corumbá I foi também estudado através de redes neurais e modelos de Box & Jenkins considerando as séries históricas de valores medidos em três piezômetros pneumáticos no núcleo da barragem escolhidos arbitrariamente (PZ8, PZ9 e PZ10) e o já descrito piezômetro PZ15 localizado na fundação da ombreira esquerda (figura 3.5).

### **5.1.6. Análise e preparação dos dados**

De maneira análoga à empregada para previsão das vazões, as séries históricas dos piezômetros foram completadas e uniformizadas para uma frequência quinzenal constante e, tendo em vista a aplicação de redes neurais, foram também normalizadas para o intervalo 0 e 1.

A tabela 5.7 descreve as variáveis consideradas na previsão das cargas de pressão enquanto que os valores associados a cada um dos piezômetros e as estatísticas básicas das séries temporais são apresentados no apêndice A, tabelas A.2 e A.4.

Sigla	Descrição
Pz8, Pz9, Pz10	Carga de pressão nos piezômetros PZ8, PZ9, PZ10 instalados no núcleo da barragem, na região da seção principal (m).
Pz15	Carga de pressão no piezômetro PZ15 instalado na fundação da ombreira esquerda (m).
NA	Cota do nível do reservatório acima do nível do mar (m).

Tabela 5.7 Siglas adotadas na modelagem das cargas de pressão dos piezômetros PZ8, PZ9, PZ10, PZ15.

Para todos os casos apresentados neste trabalho, as variáveis explicativas foram identificadas através de uma análise de correlação linear. No caso da modelagem por redes neurais, a inclusão de variáveis causais foi também verificada pela correlação linear existente entre as medidas nos piezômetros e as cotas do nível d'água no reservatório, conforme mostra a matriz de correlação apresentada na tabela 5.8.

	NA	PZ7	PZ8	PZ9	PZ10	PZ11	PZ12	PZ13	PZ14	PZ15
NA	1,00	0,71	0,68	0,56	0,61	0,40	0,79	0,69	0,47	0,75
PZ7	0,71	1,00	0,95	0,37	0,86	0,57	0,88	0,49	0,36	
PZ8	0,68	0,95	1,00	0,30	0,83	0,47	0,86	0,37	0,30	
PZ9	0,56	0,37	0,30	1,00	0,18	0,29	0,31	0,70	0,21	
PZ10	0,61	0,86	0,83	0,18	1,00	0,75	0,89	0,48	0,60	
PZ11	0,40	0,57	0,47	0,29	0,75	1,00	0,63	0,56	0,58	
PZ12	0,79	0,88	0,86	0,31	0,89	0,63	1,00	0,63	0,55	
PZ13	0,69	0,49	0,37	0,70	0,48	0,56	0,63	1,00	0,58	
PZ14	0,47	0,36	0,30	0,21	0,60	0,58	0,55	0,58	1,00	
PZ15	0,75									1,00

Tabela 5.8 Matriz de correlação linear entre as leituras dos piezômetros e as cotas do nível d'água do reservatório.

### 5.1.7. Análise das cargas de pressão pelo modelo de Box & Jenkins

As séries históricas dos piezômetros pneumáticos estudados têm comportamento estacionário, não se necessitando de transformações das séries originais via diferenciações.

Na avaliação das funções de autocorrelação simples e parcial das séries de cada piezômetro observou-se que estas respondem a um processo auto-regressivo, variando simplesmente a ordem da dependência serial em cada caso. Para os piezômetros PZ8 e PZ15, as funções mostraram que as séries temporais podem ser explicados por um modelo auto-regressivo AR(2), enquanto que as cargas de pressão nos piezômetros PZ9 e PZ10 seguem um processo AR(1). No item B.2 do apêndice B, apresenta-se, em detalhe, a modelagem do piezômetro PZ8; demais análises para os piezômetros PZ9, PZ10 e PZ15 foram desenvolvidas de acordo com a mesma sistemática.

A tabela 5.9 lista as equações polinomiais resultantes da simulação do comportamento de cada piezômetro através de modelos auto-regressivos, onde os sub-índices indicam as datas atrasadas dos valores de carga de pressão em relação à data t.

Piezômetro	Modelo	Equação polinomial
PZ8	AR(2)	$Pz8_t = 5,790 + 1,317*Pz8_{t-\Delta t} - 0,418*Pz8_{t-2\Delta t}$
PZ9	AR(1)	$Pz9_t = 2,742 + 0,907*Pz9_{t-\Delta t}$
PZ10	AR(1)	$Pz10_t = 5,378 + 0,865*Pz10_{t-\Delta t}$
PZ15	AR(2)	$Pz15_t = 2,577 + 1,635*Pz15_{t-\Delta t} - 0,746*Pz15_{t-2\Delta t}$

Tabela 5.9 Equações polinomiais para representação do comportamento das leituras piezométricas nos modelos de Box & Jenkins.

A tabela 5.10 mostra o resultado do desempenho das previsões para cada piezômetro estudado em termos dos erros cometidos nas três etapas do processo auto-regressivo: modelagem, validação e teste.

PZ	Modelo	Padrões*	Conjunto	MAPE (%)	RMSE(m)	U de Theil
PZ 8	AR(2)	Pz8 <sub>t-Δt</sub> Pz8 <sub>t-2Δt</sub>	Modelagem	0,927	0,628	0,688
			Validação	1,319	1,078	0,830
			Teste	0,116	0,105	0,352
PZ 9	AR(1)	Pz9 <sub>t-Δt</sub>	Modelagem	1,832	0,912	0,976
			Validação	1,044	0,371	1,207
			Teste	0,756	0,216	1,858
PZ 10	AR(1)	Pz10 <sub>t-Δt</sub>	Modelagem	2,454	1,333	0,940
			Validação	0,754	0,328	1,752
			Teste	0,583	0,277	0,933
PZ 15	AR(2)	Pz15 <sub>t-Δt</sub> Pz15 <sub>t-2Δt</sub>	Modelagem	2,266	0,764	0,632
			Validação	1,037	0,358	0,611
			Teste	1,461	0,344	1,282

\* Variáveis explicativas correspondentes a valores atrasados da própria série.

Tabela 5.10 Desempenho dos modelos autoregressivos de Box & Jenkins para previsão da carga de pressão nos piezômetros PZ8, PZ9, PZ10, e PZ15.

Dos resultados na tabela 5.10, podemos concluir que, em todos os casos, foram obtidos bons resultados, com os erros cometidos nas três fases de estudo considerados baixos, não chegando a superar, em nenhum momento, os limites de 2,5%, na métrica MAPE, ou 1,50 metros de coluna d'água, na métrica RMSE. Para os piezômetros PZ8 e PZ10, os coeficientes U de Theil foram inferiores à unidade nos conjuntos de teste, resultando, portanto, em melhor desempenho do que a previsão trivial, o que não acontece em relação aos piezômetros PZ9 e PZ15. Este fato, todavia, não representa em si uma deficiência grave do modelo.

As figuras 5.7 a 5.14 apresentam os trechos da série ajustada (referente ao conjunto de modelagem) e das séries previstas englobando os conjuntos de validação e teste, bem como os erros relativos correspondentes. Em todos os casos estudados pelos métodos de Box & Jenkins foram também considerados intervalos de confiança superior (inc\_sup) e inferior (inc\_inf) com probabilidade de 95%.

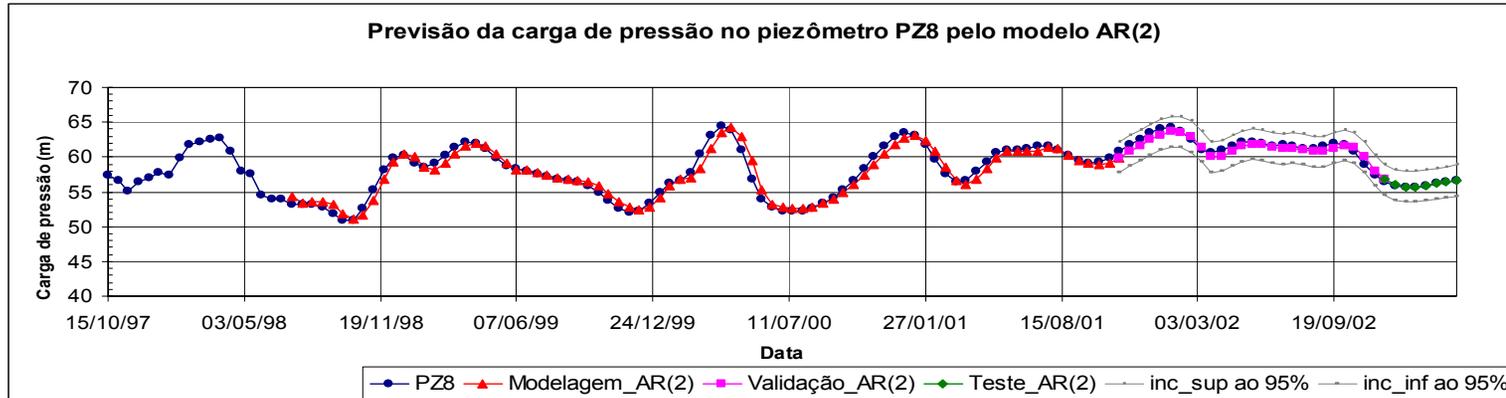


Figura 5.7 Modelagem e previsão do piezômetro PZ8 com o modelo AR(2) para os conjuntos de modelagem, validação e teste.

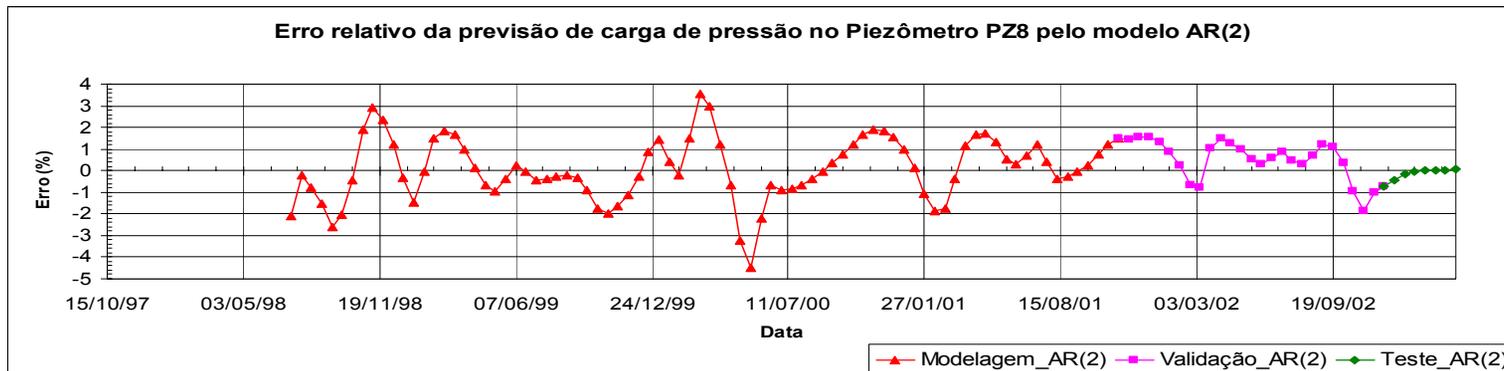


Figura 5.8 Erro relativo da carga de pressão no piezômetro PZ8 com o modelo AR(2) para os conjuntos de modelagem, validação e teste.

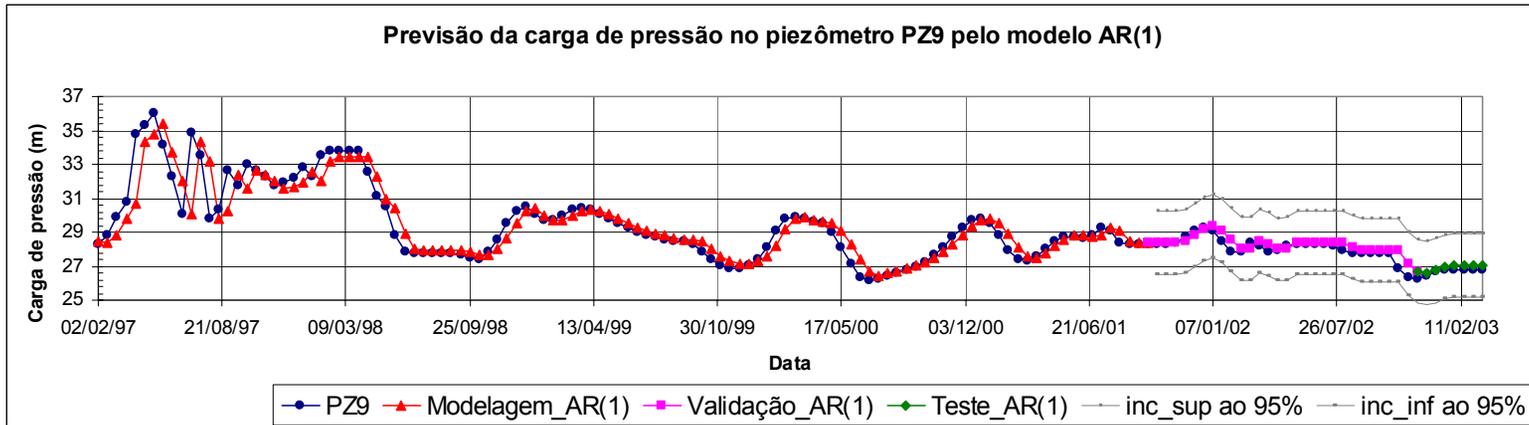


Figura 5.9 Modelagem e previsão do piezômetro PZ9 com o modelo AR(1) para os conjuntos de modelagem, validação e teste.

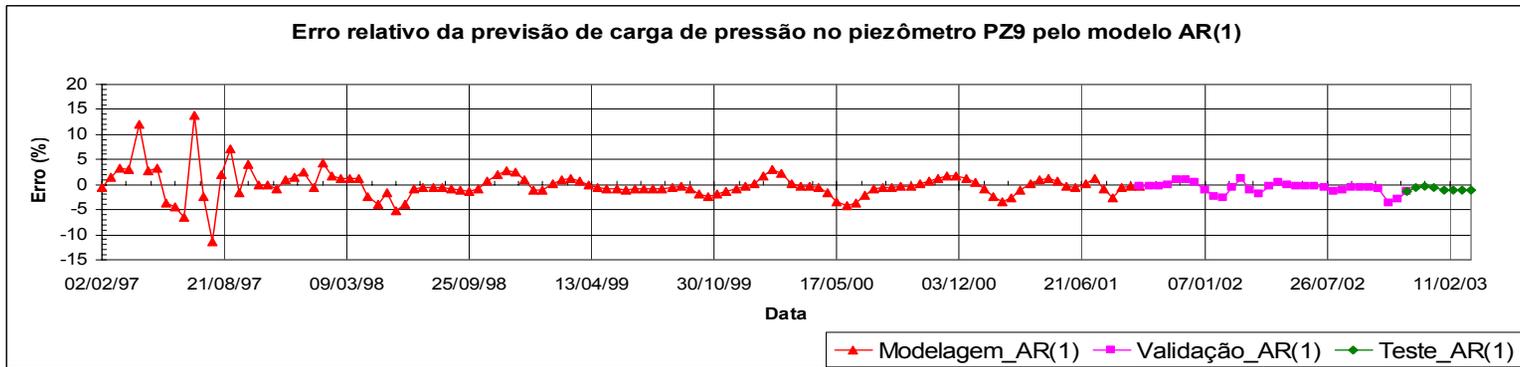


Figura 5.10 Erro relativo da carga de pressão no piezômetro PZ9 com o modelo AR(1) para os conjuntos de modelagem, validação e teste.

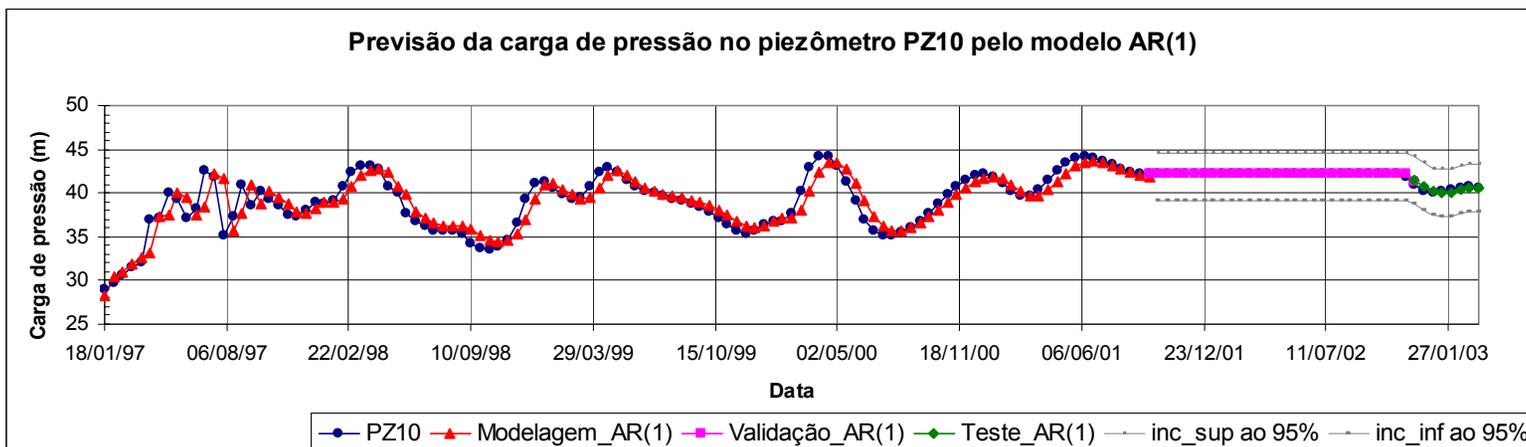


Figura 5.11 Modelagem e previsão do piezômetro PZ10 com o modelo AR(1) para os conjuntos de modelagem, validação e teste..

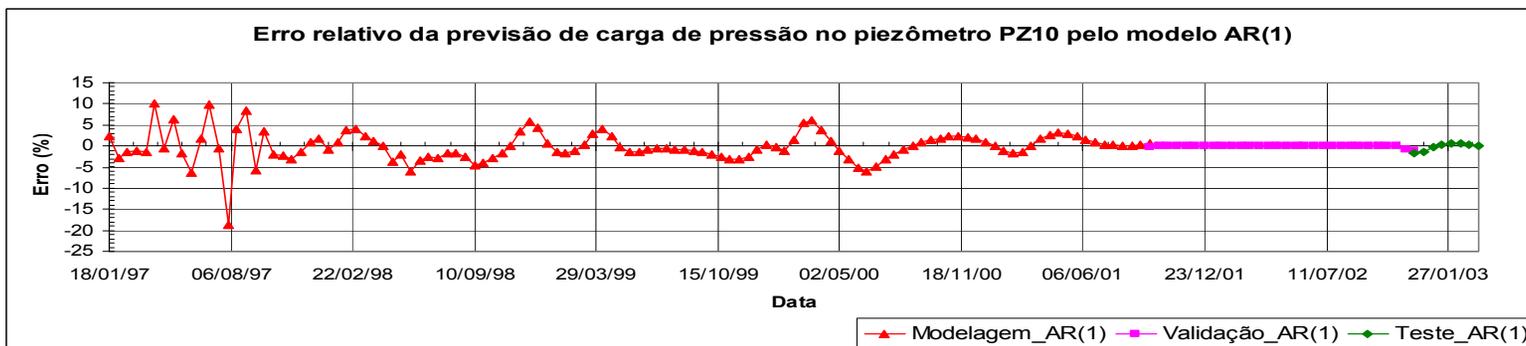


Figura 5.12 Erro relativo da carga de pressão no piezômetro PZ10 com o modelo AR(1) para os conjuntos de modelagem, validação e teste..

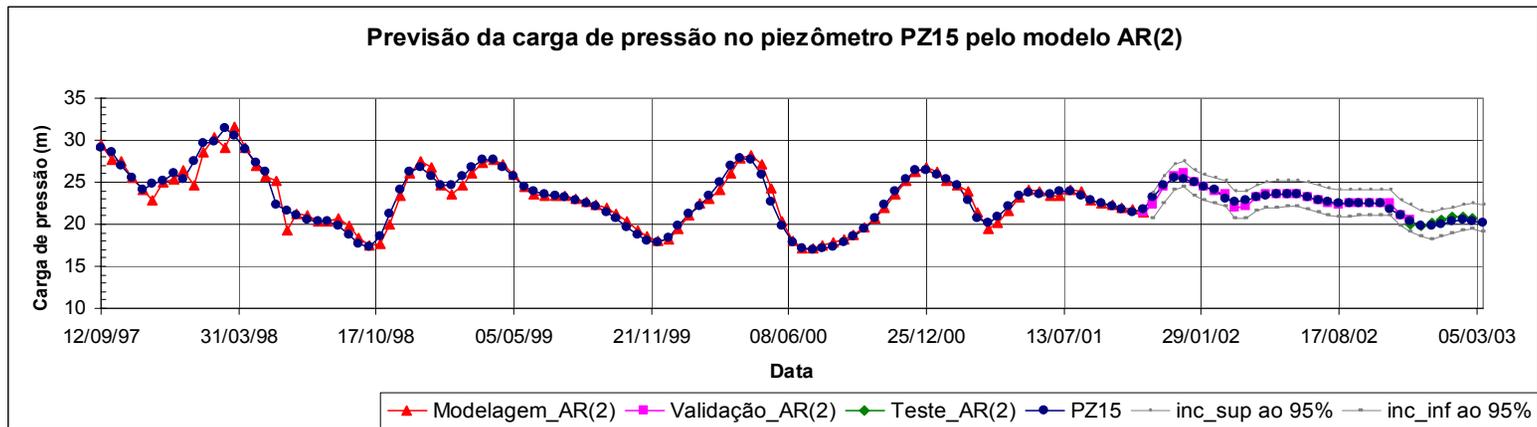


Figura 5.13 Modelagem e previsão do piezômetro PZ15 com o modelo AR(2) para os conjuntos de modelagem, validação e teste

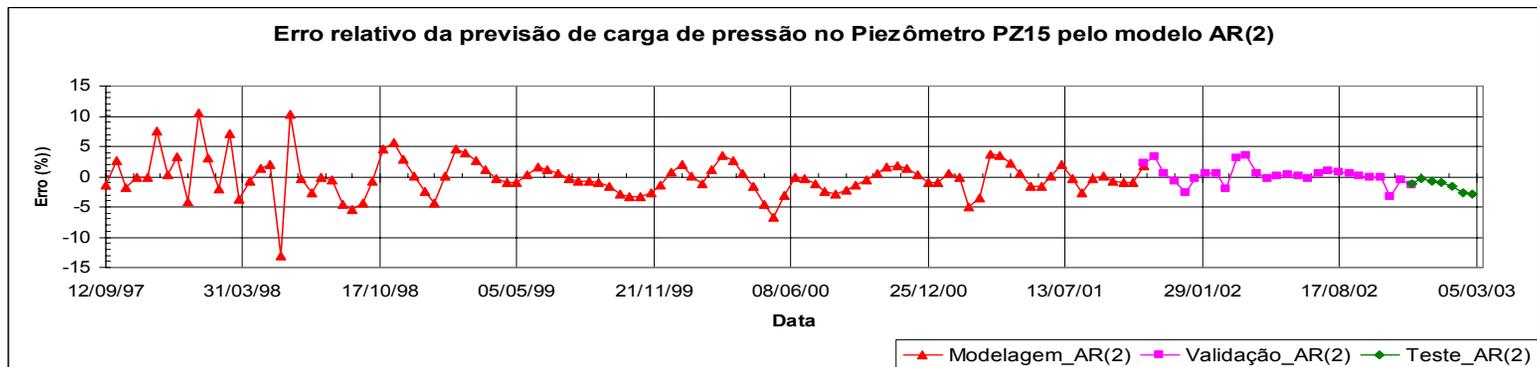


Figura 5.14 Erro relativo da carga de pressão no piezômetro PZ15 com o modelo AR(2) para os conjuntos de modelagem, validação e teste.

### 5.1.8. Análise das cargas de pressão por redes neurais

Na modelagem das cargas de pressão por redes neurais foi adotada a mesma metodologia da aplicação de RNA nas estimativas de vazão, variando-se, naturalmente, a escolha das variáveis explicativas e os modelos de redes neurais testados. Em alguns dos modelos considerou-se a flutuação do nível do reservatório como variável explicativa, com o propósito de tentar capturar possíveis correlações não lineares e assim tentar melhorar as previsões anteriormente obtidas pelos modelos lineares de Box & Jenkins. No entanto, a modelagem por redes neurais artificiais confirmou que as melhores configurações de RNA para previsão de um horizonte das cargas de pressão foram aquelas cujos padrões de entrada são valores atrasados da própria série modelada.

As séries históricas consideradas nas análises de previsão são as mesmas identificadas na tabela 5.7. O apêndice D mostra, detalhadamente, os resultados dos desempenhos em cada uma das topologias testadas em função dos erros de treinamento e de validação. A tabela 5.11 apresenta as melhores topologias obtidas para cada um dos piezômetros estudados, enquanto que as figuras 5.15 a 5.22 mostram, para estes piezômetros, o comportamento das estimativas com os erros relativos correspondentes.

PZ	Modelo	Padrões *	Conjunto	MAPE (%)	RMSE(m)	U de Theil
PZ 8	RNA8 IV	Pz8 <sub>t-Δt</sub> Pz8 <sub>t-2Δt</sub>	Treinamento	1,325	1,181	0,909
			Validação	0,626	0,552	0,661
			Teste	0,641	0,367	1,232
PZ 9	RNA9 IV	Pz9 <sub>t-Δt</sub> Pz9 <sub>t-2Δt</sub>	Treinamento	1,567	0,800	0,853
			Validação	0,668	0,260	0,845
			Teste	0,138	0,047	0,408
PZ 10	RNA10 I	Pz10 <sub>t-Δt</sub>	Treinamento	2,582	1,346	0,946
			Validação	0,075	0,110	0,586
			Teste	0,699	0,329	1,109
PZ 15	RNA15 IV	Pz15 <sub>t-Δt</sub> Pz15 <sub>t-2Δt</sub>	Treinamento	2,236	0,766	0,636
			Validação	1,013	0,345	0,589
			Teste	0,953	0,208	0,775
* Variáveis explicativas correspondentes a valores atrasados da própria série.						

Tabela 5.11 Desempenho das melhores topologias de redes neurais para previsão da carga de pressão nos piezômetros PZ8, PZ9, PZ10 e PZ15.

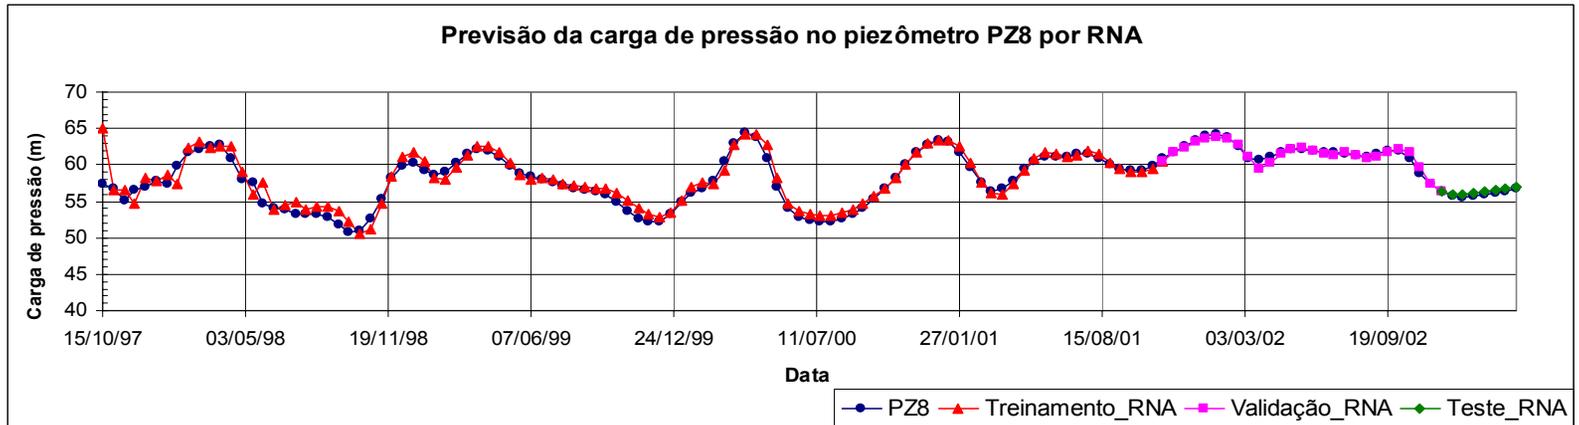


Figura 5.15 Modelagem e previsão das cargas de pressão no piezômetro PZ8 com a rede neural RNA8 IV.

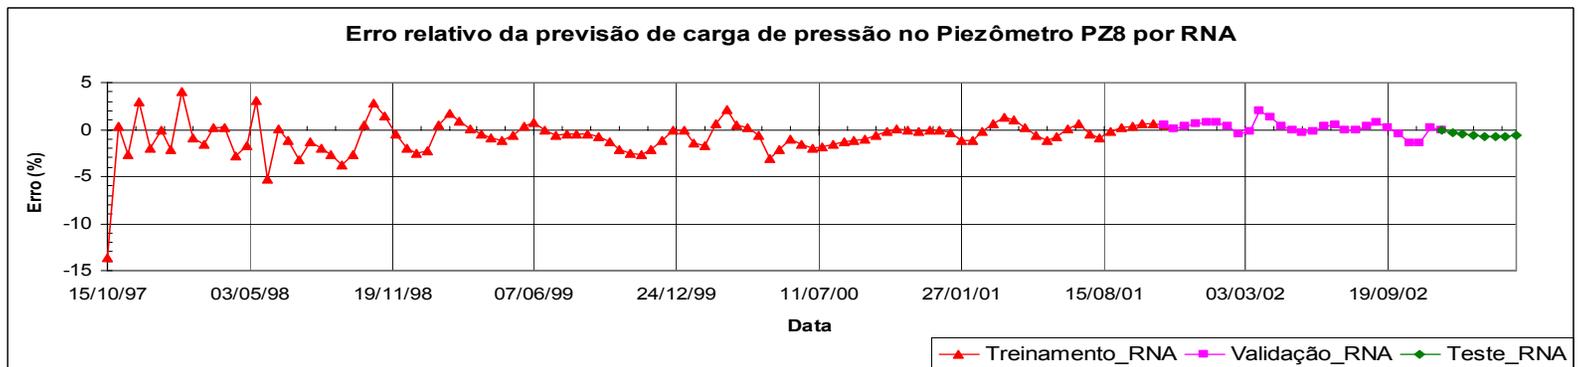


Figura 5.16 Erro relativo da carga de pressão no piezômetro PZ8 com a rede neural RNA8 IV.

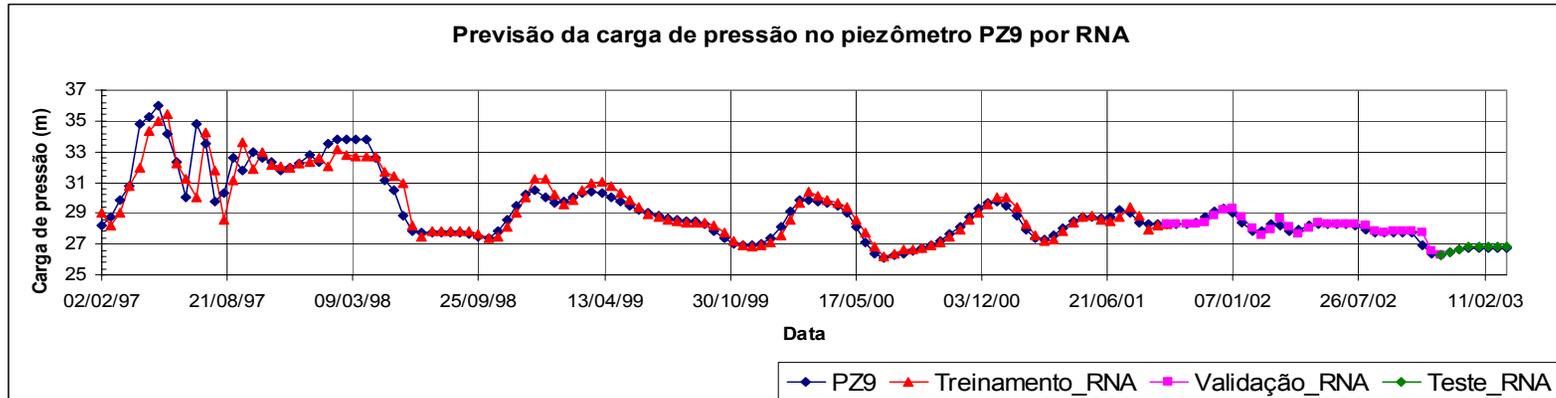


Figura 5.17 Modelagem e previsão das cargas de pressão no piezômetro PZ9 com a rede neural RNA9 IV.

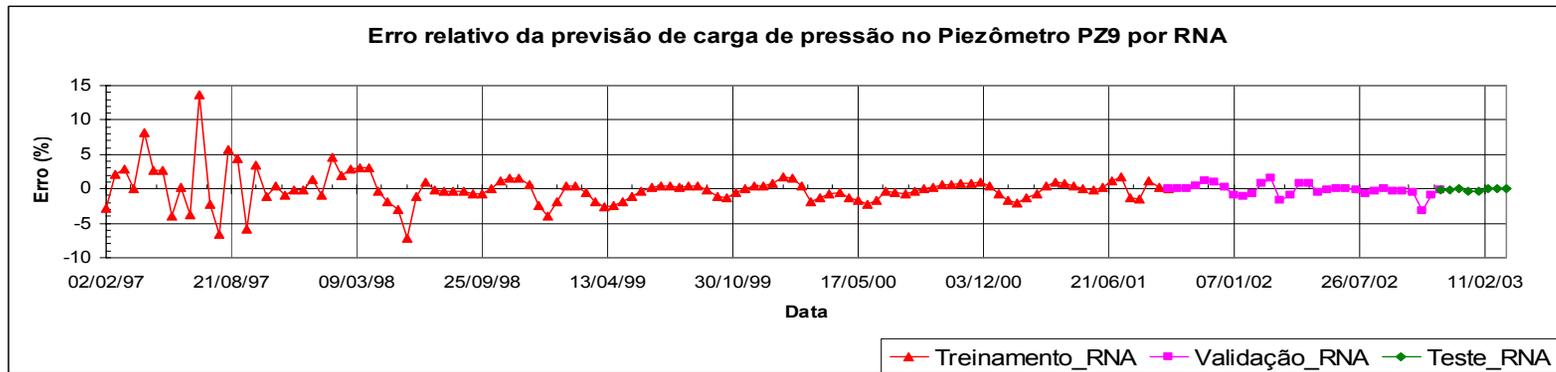


Figura 5.18 Erro relativo da carga de pressão no piezômetro PZ9 com a rede neural RNA9 IV.

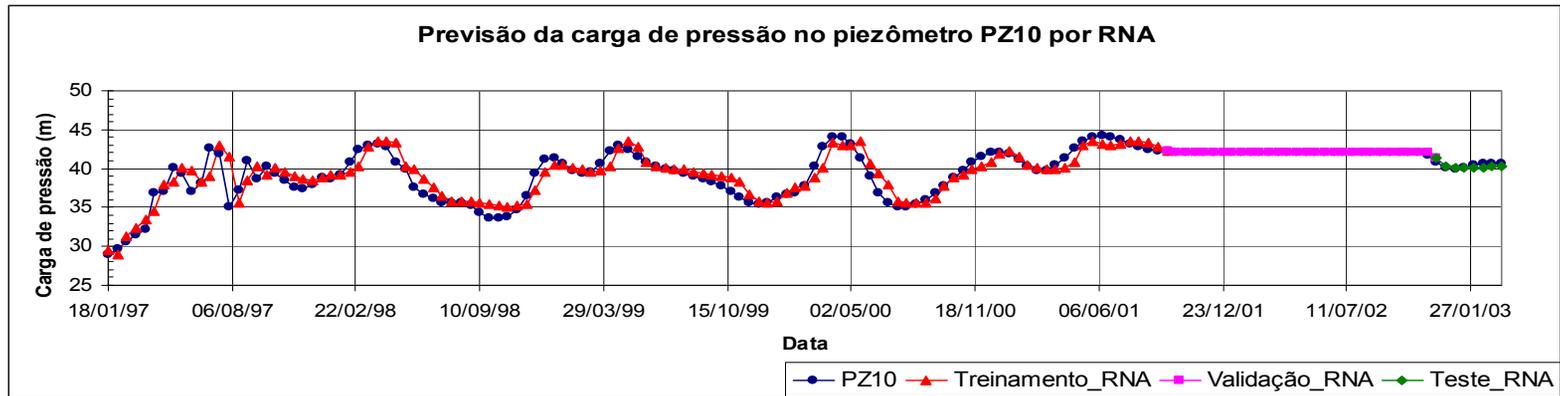


Figura 5.19 Modelagem e previsão das cargas de pressão no piezômetro PZ10 com a rede neural RNA10 I.

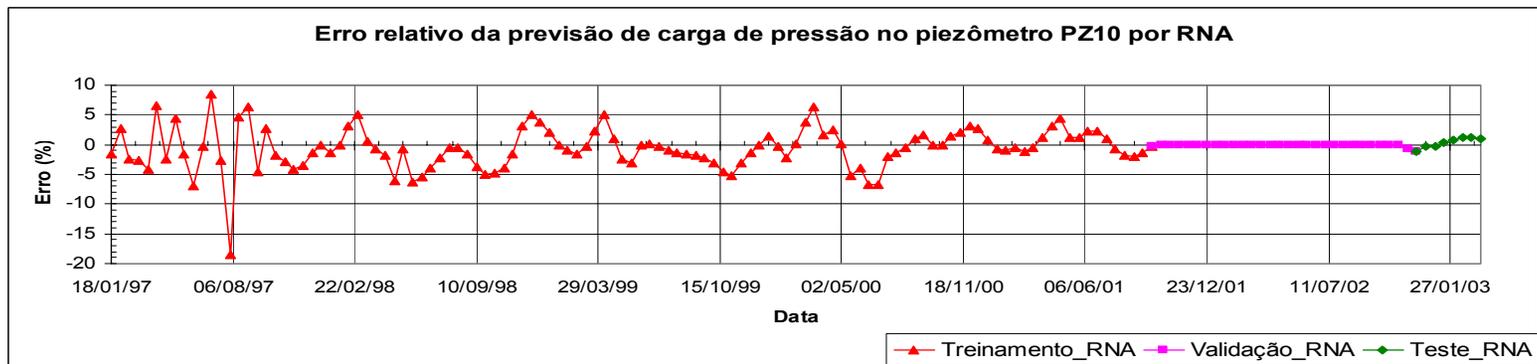


Figura 5.20 Erro relativo da carga de pressão no piezômetro PZ10 com a rede neural RNA10 I.

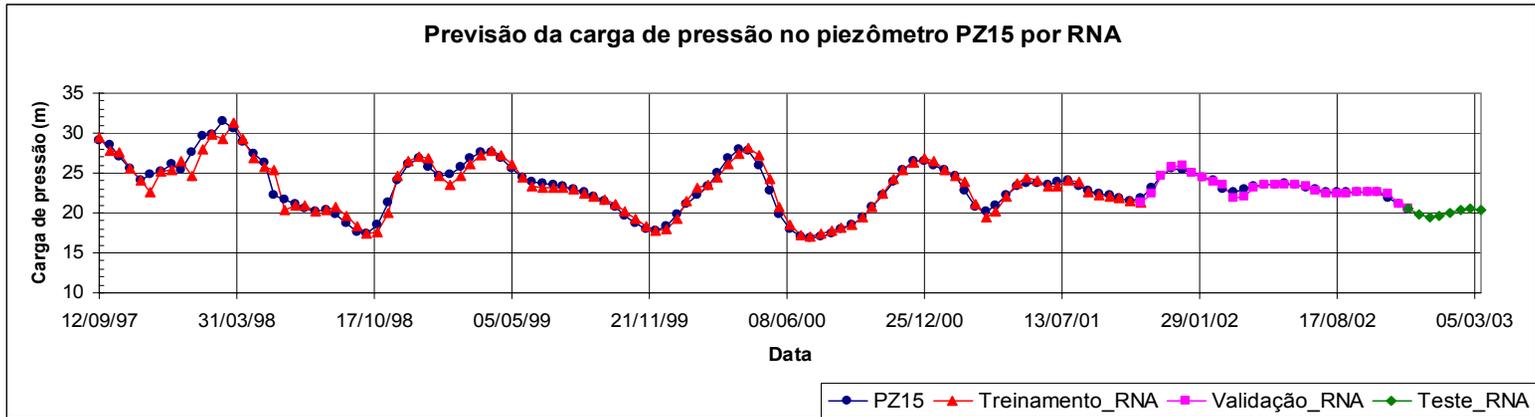


Figura 5.21 Modelagem e previsão das cargas de pressão no piezômetro PZ15 com a rede neural RNA15 IV.

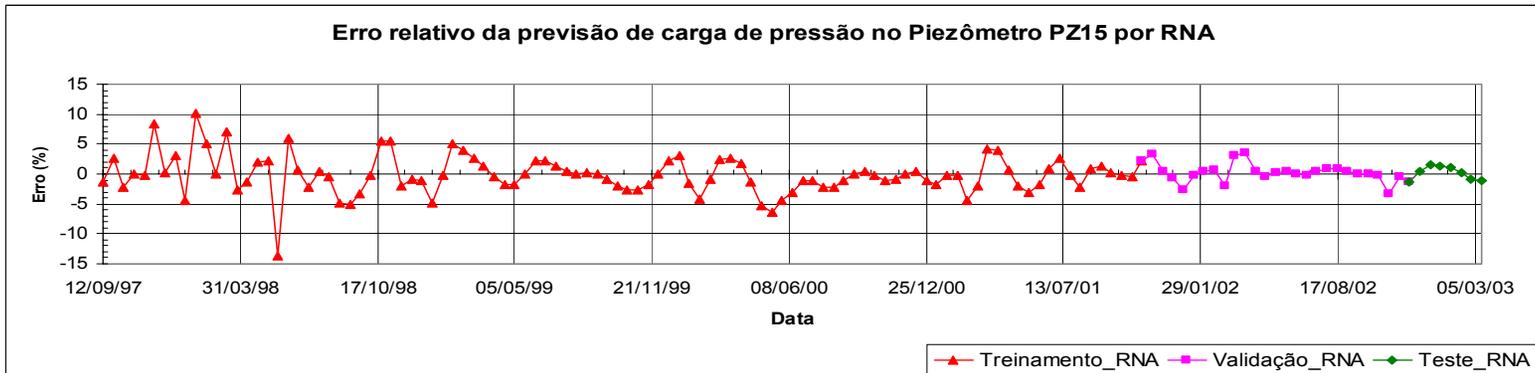


Figura 5.22 Erro relativo da carga de pressão no piezômetro PZ15 com a rede neural RNA15 IV.

## **5.2.**

### **Previsão das cargas de pressão em um piezômetro admitido danificado**

Neste terceiro exemplo supôs-se que determinado piezômetro cessasse de funcionar, procurando-se estimar a provável evolução no tempo de suas leituras em função de variáveis causais como a cota do reservatório e as cargas de pressão medidas em outros piezômetros situados nas vizinhanças. É importante ressaltar que nesta aplicação, as previsões efetuadas no tempo  $t$  são feitas com base em leituras de outras variáveis efetuadas também no tempo  $t$  e anteriores, i.e. sem um horizonte de previsão.

Para pesquisar as potencialidades das RNA em tratar deste problema, foram feitas quatro modelagens independentes, considerando-se, em cada caso, os piezômetros PZ7, PZ8, PZ9 e PZ10 como danificados. No apêndice E mostram-se em detalhes as variáveis explicativas definidas para cada um dos modelos propostos, que também incorporam as cargas de pressão nos piezômetros PZ11, PZ12, PZ13, e PZ14, instalados no núcleo central da barragem, na região da seção principal, conforme figura 3.5. No apêndice A, a tabela A.3 apresenta os valores das flutuações no tempo da cota do reservatório e das cargas de pressão, em metros de coluna d'água, para cada um dos piezômetros estudados.

A modelagem do problema só foi feita por redes neurais porque os modelos de Box & Jenkins usados nesta dissertação correspondem a análises univariados.

#### **5.2.1.**

##### **Análise das cargas de pressão por redes neurais**

A metodologia para seleção da melhor topologia de rede neural é a mesma empregada nos exemplos anteriores, já suficientemente comentada. O apêndice E apresenta as diversas topologias de RNA testadas, com seus respectivos erros de modelagem.

A tabela 5.12 resume as características das melhores topologias de redes neurais obtidas para cada um dos piezômetros considerados danificados.

Previsão do PZ “danificado”	Modelo	Topologia	Conjunto	MAPE (%)	RMSE (m)
PZ 7	RNA7_d IV	8/15/1 mult	Treinamento	1,479	1,224
			Validação	1,063	0,963
			Teste	1,204	0,909
PZ 8	RNA8_d I	16/15/1 mult	Treinamento	1,135	0,858
			Validação	0,807	0,678
			Teste	1,626	1,082
PZ 9	RNA9_d III	3/5/1 mult	Treinamento	3,385	1,419
			Validação	2,293	0,823
			Teste	3,650	0,986
PZ 10	RNA10_d IV	10/15/1 mult	Treinamento	2,188	1,151
			Validação	0,497	0,303
			Teste	1,454	0,622

Tabela 5.12 Desempenho das melhores topologias de redes neurais para previsão das cargas de pressão nos piezômetros “danificados” PZ7, PZ8, PZ9 e PZ10.

Como se observa dos resultados da tabela, os erros medidos são em geral baixos, menores do que 3,5%, na métrica MAPE, e menores do que 3,65 metros de coluna d’água, na métrica RMSE. Na simulação dos resultados para o piezômetro danificado, é importante frisar que os demais piezômetros são admitidos funcionarem normalmente.

A tabela 5.13 descreve as variáveis que influenciam o comportamento dos piezômetros danificados para as melhores topologias acima referidos.

Modelo	Entradas
RNA7_d IV	$NA_t, NA_{t-\Delta t}, Pz8_t, Pz8_{t-\Delta t}, Pz10_t, Pz10_{t-\Delta t}, Pz12_t, Pz12_{t-\Delta t}$
RNA8_d I	$NA_t, NA_{t-\Delta t}, Pz7_t, Pz7_{t-\Delta t}, Pz9_t, Pz9_{t-\Delta t}, Pz10_t, Pz10_{t-\Delta t}, Pz11_t, Pz11_{t-\Delta t}, Pz12_t, Pz12_{t-\Delta t}, Pz13_t, Pz13_{t-\Delta t}, Pz14_t, Pz14_{t-\Delta t}$
RNA9_d III	$Pz13_t, Pz13_{t-\Delta t}, Pz13_{t-2\Delta t}$
RNA10_d IV	$NA_t, NA_{t-\Delta t}, Pz7_t, Pz7_{t-\Delta t}, Pz8_t, Pz8_{t-\Delta t}, Pz11_t, Pz11_{t-\Delta t}, Pz12_t, Pz12_{t-\Delta t}$

Tabela 5.13 Variáveis explicativas para os melhores modelos neurais dentre as testadas para previsão das cargas de pressão nos piezômetros “danificados” PZ7, PZ8, PZ9 e PZ10.

As figuras 5.23 a 5.30 mostram graficamente o desempenho das redes neurais nas etapas de treinamento, validação e teste para cada um dos piezômetros estudados (PZ7, PZ8, PZ9, PZ10) com os erros relativos das estimativas em relação aos dados amostrais.

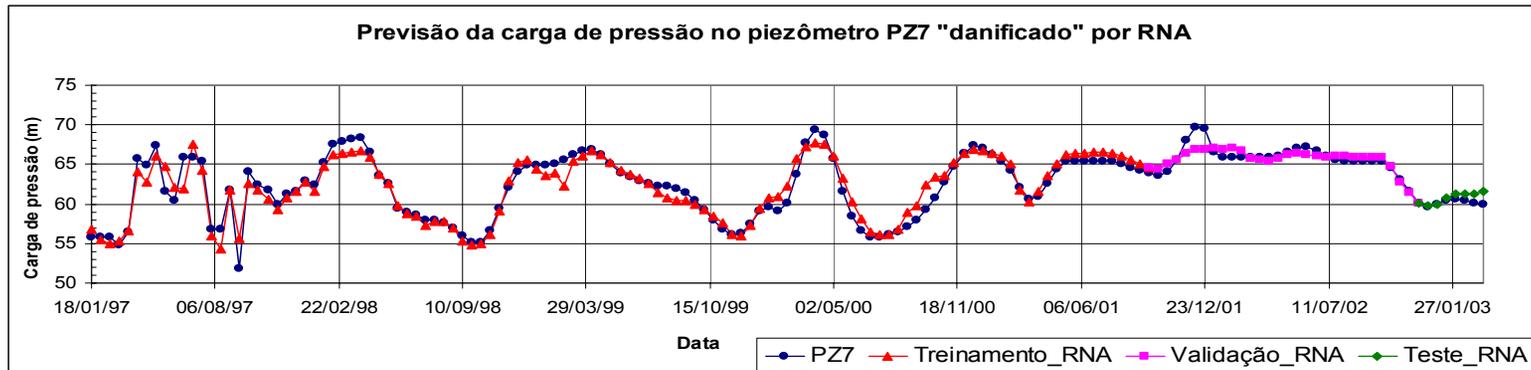


Figura 5.23 Modelagem da carga de pressão no piezômetro danificado PZ7, para os conjuntos de treinamento, validação e teste.

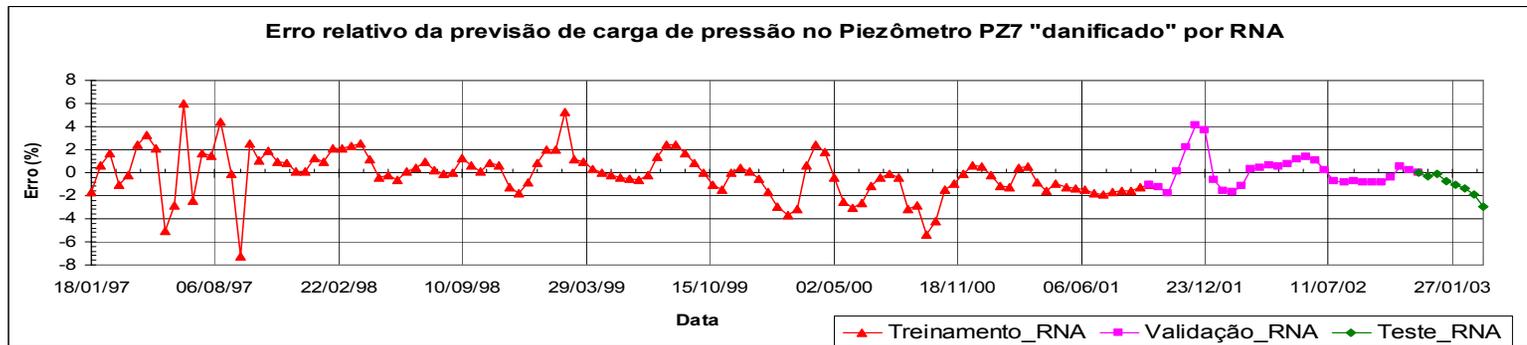


Figura 5.24 Erro relativo da carga de pressão no piezômetro danificado PZ7, para os conjuntos de treinamento, validação e teste.

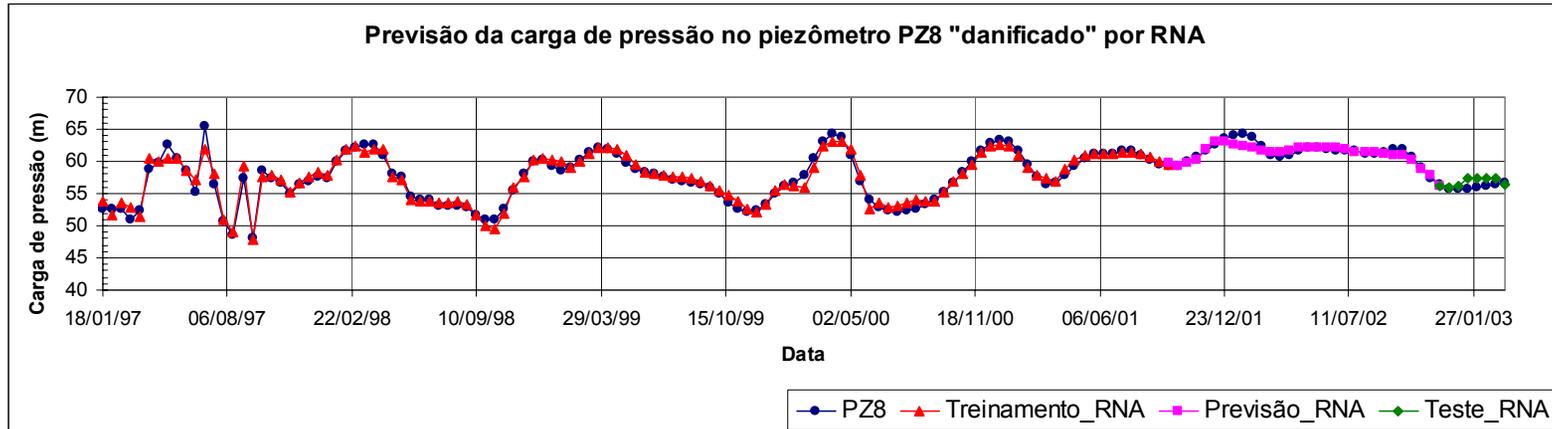


Figura 5.25 Modelagem da carga de pressão no piezômetro danificado PZ8, para os conjuntos de treinamento, validação e teste.

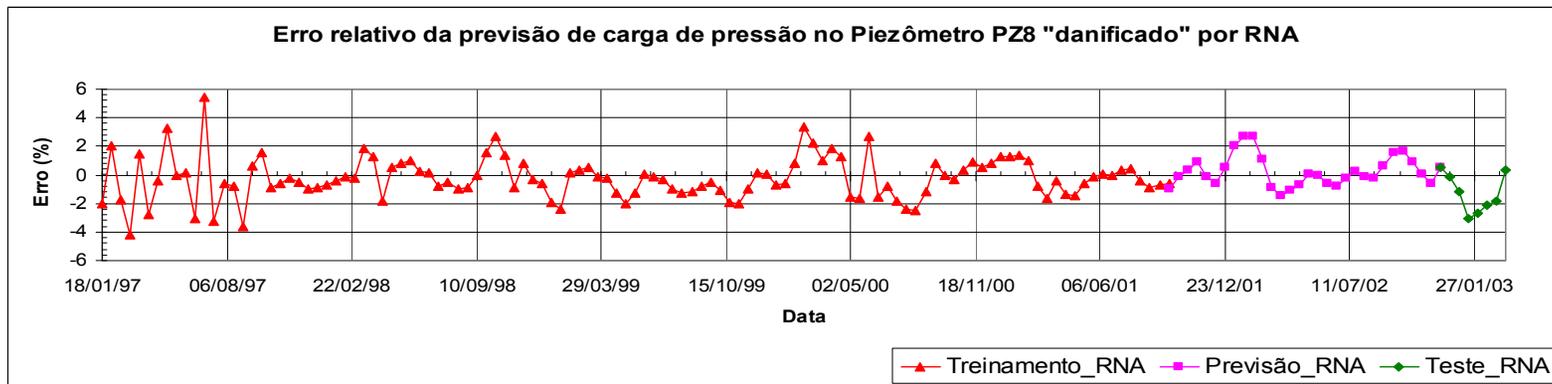


Figura 5.26 Erro relativo da carga de pressão no piezômetro danificado PZ8, para os conjuntos de treinamento, validação e teste.

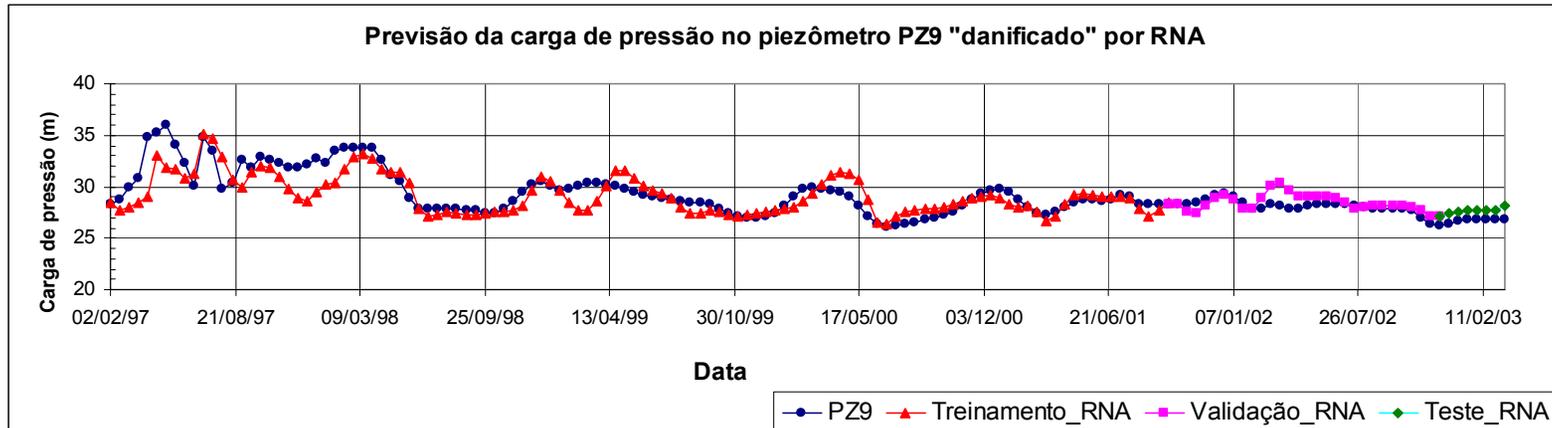


Figura 5.27 Modelagem da carga de pressão no piezômetro danificado PZ9, para os conjuntos de treinamento, validação e teste.

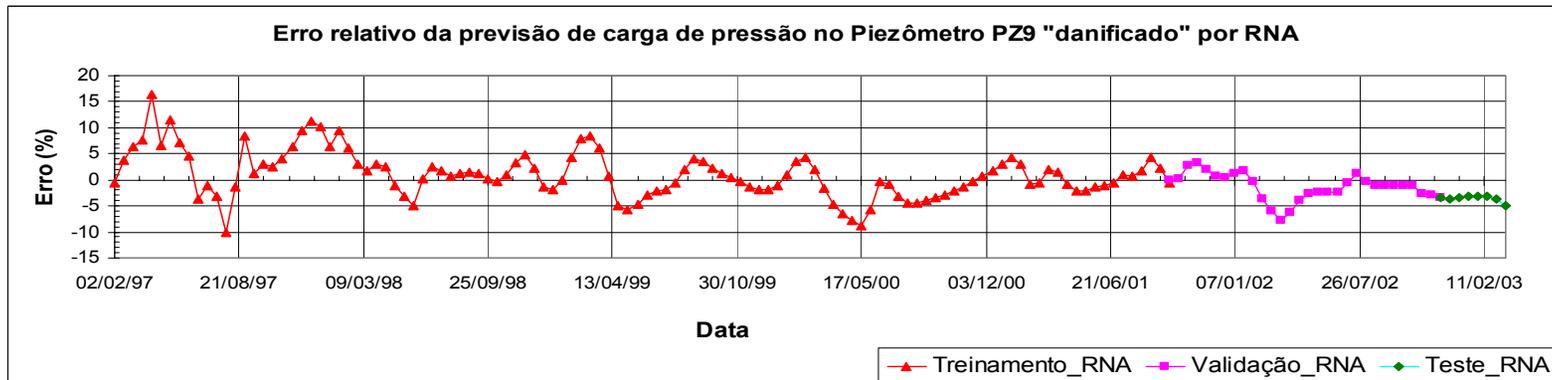


Figura 5.28 Erro relativo da carga de pressão no piezômetro danificado PZ9, para os conjuntos de treinamento, validação e teste.

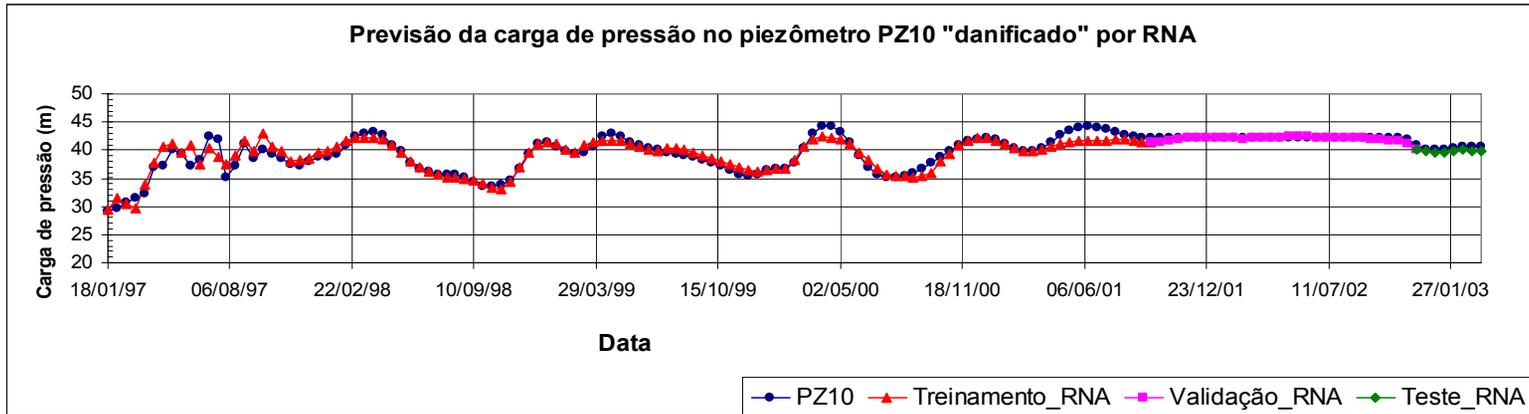


Figura 5.29 Modelagem da carga de pressão no piezômetro danificado PZ10, para os conjuntos de treinamento, validação e teste.

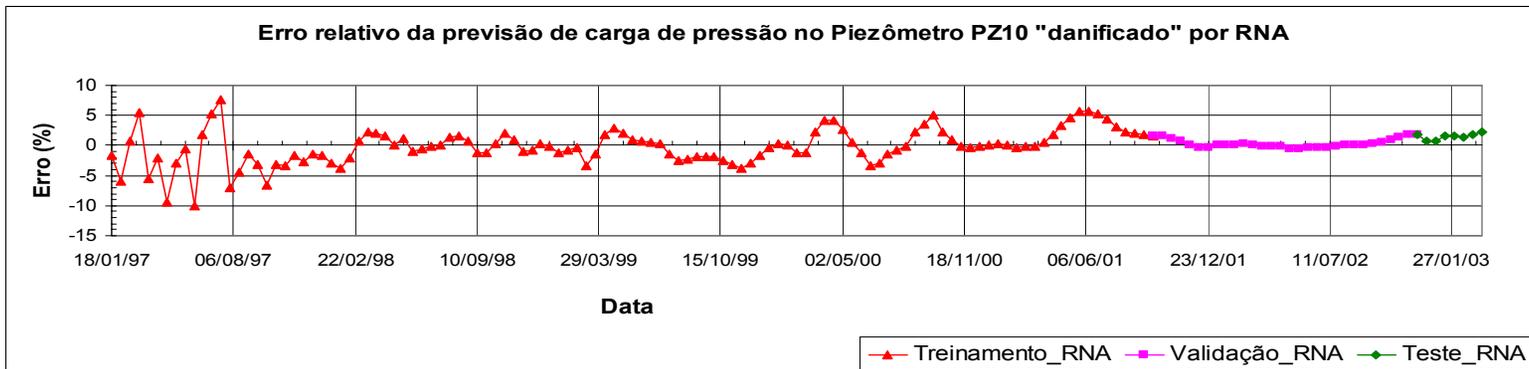


Figura 5.30 Erro relativo da carga de pressão no piezômetro danificado PZ10, para os conjuntos de treinamento, validação e teste.