

## 5

### Inteligência Computacional

Hoje, a modelagem computacional permite aprimorar os métodos de projeto, fazendo com que se tenham resultados mais próximos da realidade. Este estudo paramétrico apresenta o comportamento de uma coluna estaiada e protendida com um sistema de travamento no centro do comprimento da coluna principal utilizando tubos de aço perpendiculares.

Este estudo foi aprimorado com o uso de inteligência computacional para a obtenção de cargas críticas da coluna minimizando a necessidade de uma enorme quantidade de análises não-lineares com o método dos elementos finitos [31].

O primeiro objetivo deste capítulo é apresentar o projeto de experimentos, essencial para a elaboração do conjunto representativo para satisfazer todas as possíveis variáveis da coluna estaiada e protendida. Como item desta etapa apresentam-se os resultados de teste da rede neural com treinamento bayesiano para previsão de cargas críticas a partir de comparações com resultados obtidos por uma análise com o método dos elementos finitos utilizando o programa ANSYS [17].

#### 5.1 Projeto de Experimentos

O projeto de experimentos visa encontrar o número suficiente de informações com o menor número possível de ensaios buscando otimizar a quantidade de ensaios necessários para cobrir todas as variáveis possíveis. Para isso, é necessário seguir algumas sugestões para obter um melhor planejamento:

- reconhecer, estabelecer e delimitar claramente o problema;
- identificar os possíveis fatores que podem afetar o problema em estudo;
- verificar quais fatores que poderão ser mantidos fixos e, portanto, não terão os seus efeitos avaliados no estudo experimental;

- identificar, para cada fator, o intervalo de variação e os níveis que entrarão no estudo;
- escolher um projeto de experimentos adequado, isto é, saber como combinar os níveis dos fatores de forma a resolver o problema proposto com o menor número de casos;
- escolher quais variáveis medem adequadamente o resultado (a qualidade, o desempenho, etc.) do processo para o planejamento de como será a análise dos dados do experimento.

Através de um arranjo ortogonal obtém-se a seqüência e a quantidade dos experimentos a serem realizados. Este tipo de arranjo engloba a combinação das variáveis e seus níveis adotados. Para criar a tabela de dados identificam-se as principais variáveis que influenciam no sistema estrutural, Figura 5.1:

- Diâmetro externo da coluna principal ( $De_c$ );
- Espessura da parede da coluna principal ( $t_c$ );
- Comprimento da coluna principal ( $L_c$ );
- Pontos de aplicação do sistema de protensão ( $Pp_c$ );
- Imperfeição inicial da coluna principal ( $I_c$ );
- Diâmetro externo do tubo dos braços ( $De_b$ );
- Espessura da parede do tubo dos braços ( $t_b$ );
- Comprimento dos braços ( $L_b$ );
- Diâmetro dos estais ( $D_s$ );
- Intensidade de protensão ( $P_s$ );
- Número de braços por sistema de protensão.

Separando os parâmetros mais importantes para a análise [19] as seguintes variáveis foram investigadas:

- Rigidez da coluna principal em termos do raio de giração ( $r_c$ ) calculado pelo diâmetro externo ( $De_c$ ) e pela espessura da parede do tubo da coluna principal ( $t_c$ );
- Comprimento da coluna principal ( $L_c$ );
- Comprimento dos braços ( $L_b$ );
- Área dos estais ( $A_s$ );

- Intensidade de protensão ( $P_s$ ).

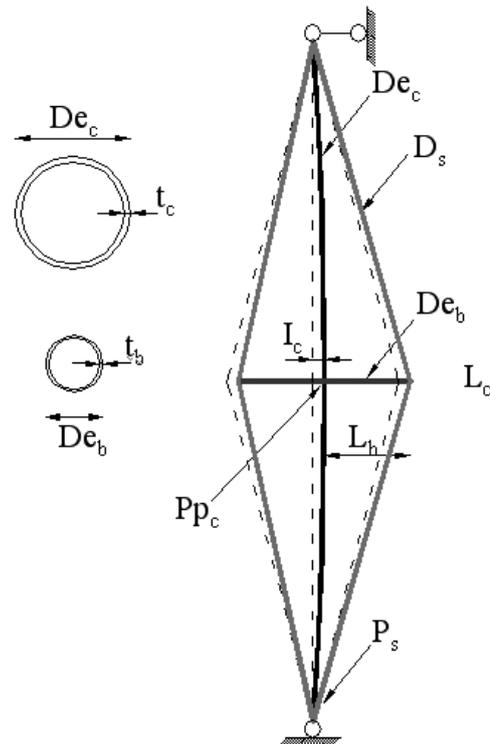


Figura 5.1. Variáveis da coluna de aço estaiada para os dados de entrada.

Para cada variável, os seguintes níveis foram estudados:

Níveis	Fatores				
	$r_c$	$L_c$ (m)	$L_b$ (m)	$A_s$ (mm <sup>2</sup> )	$P_s$ (e)
1	30,462	12	0,6	16,18	0
2	57,026	20	0,9	34,669	15
3	75,767	30	1,2	126,68	30
4					45
5					60
6					75

Tabela 5.1. Nível de variação para cada fator investigado.

Para o presente estudo utilizou-se um software que faz a combinação das variáveis e seus respectivos níveis. O Design Expert [20] é um programa voltado para projeto de experimento e de fácil manuseio. Com ele pode-se gerar experimentos rapidamente, analisar os dados e visualizar graficamente os resultados obtidos.

Vários métodos são indicados para representar o espaço do projeto de experimentos como “Latin Square”, Taguchi e outros. A presente investigação adotou o método fatorial “D-Optimal” por ser o método que permitia o uso de diferentes níveis para cada variável. Este método, “D-Optimal”, faz uma

otimização quadrática do arranjo fatorial completo minimizando a quantidade dos experimentos necessária para englobar todo o conjunto.

O processo para gerar a tabela com os experimentos necessários é mostrado na sequência das figuras a seguir. Na Figura 5.2 foi escolhido o método de arranjo fatorial e a quantidade de variáveis a serem utilizadas.

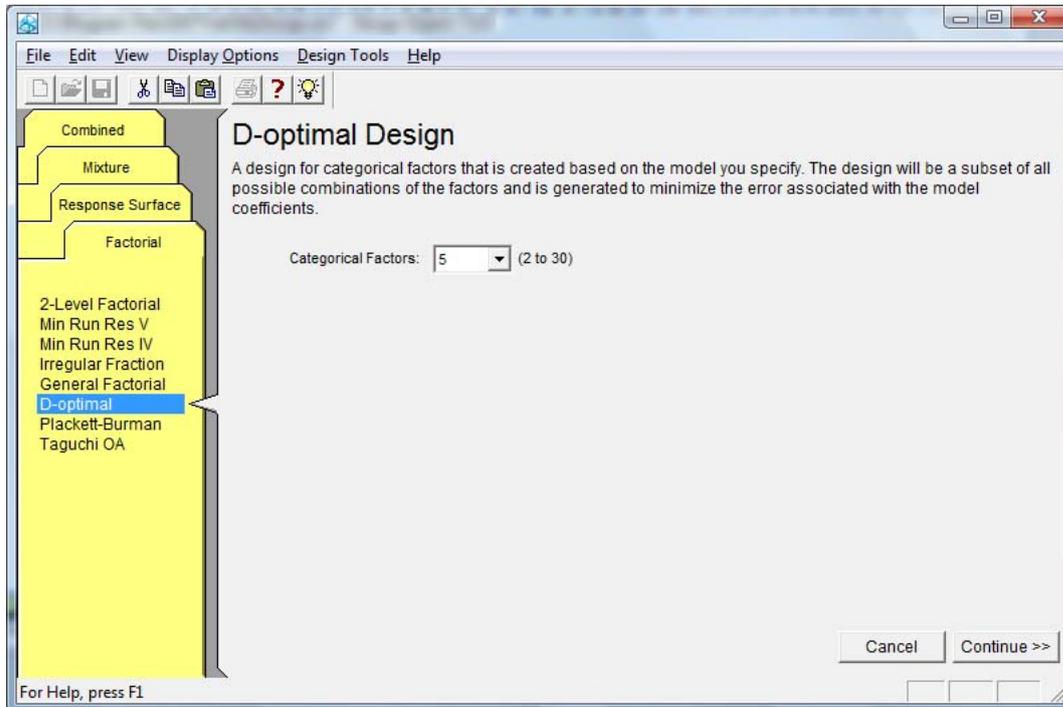


Figura 5.2 Método D-Optimun e a quantidade de variáveis.

Com o fim desta etapa são inseridas as variáveis, uma a uma, com seus níveis e respectivos valores. Como já mencionado, para este método não é necessário que as variáveis tenham a mesma quantidade de níveis, como poderá ser observado na Figura 5.3 e na Figura 5.4, respectivamente. Ao final do processo o programa gera uma tabela (Figura 5.5) com o arranjo das análises a serem realizadas usando o programa ANSYS [17], para determinação das cargas críticas.

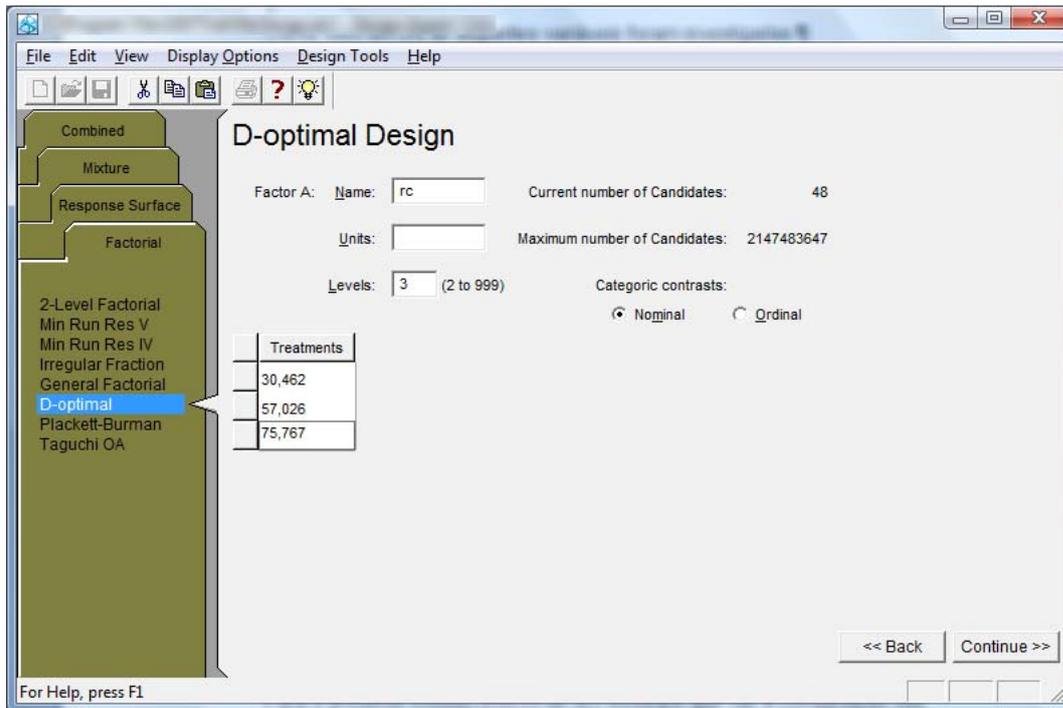


Figura 5.3 Variável raio de giração com seus níveis e respectivos valores

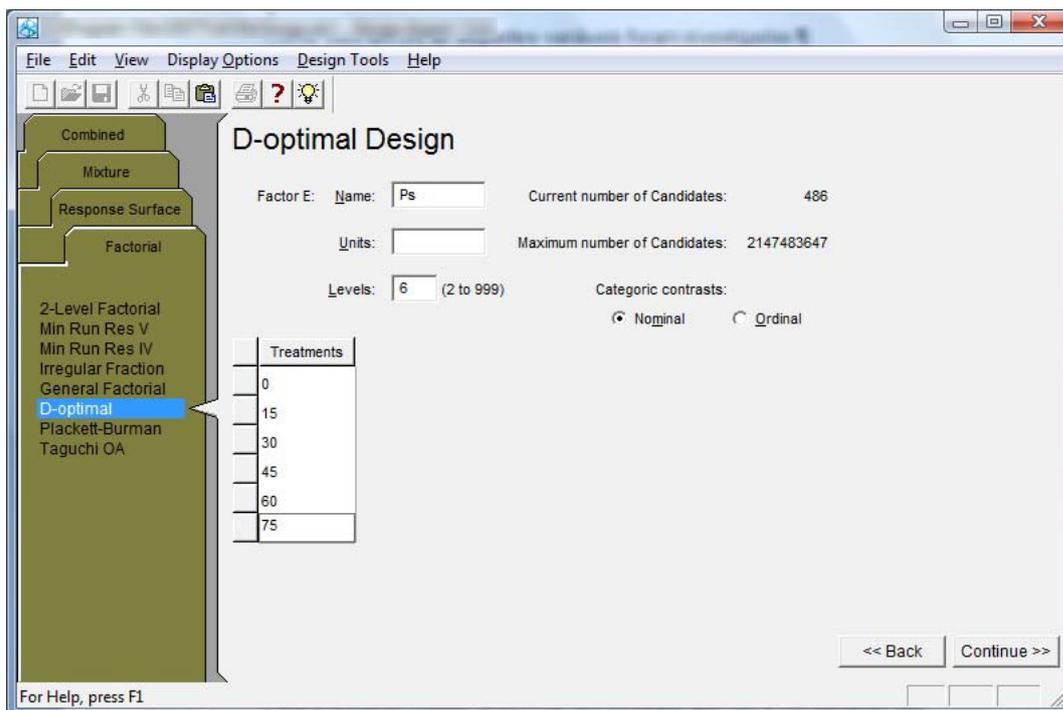


Figura 5.4 Variável nível de protensão com seus níveis e respectivos valores

Std	Run	Block	Factor 1 A:rc	Factor 2 B:Lc	Factor 3 C:Lb	Factor 4 D:As	Factor 5 E:Ps	Response 1 Pcr
75	1	Block 1	30,462	20	0,9	16,18	30	
35	2	Block 1	57,026	20	0,9	126,68	15	
63	3	Block 1	30,462	20	0,6	126,68	75	
28	4	Block 1	75,767	20	0,9	126,68	0	
4	5	Block 1	30,462	30	0,9	126,68	60	
81	6	Block 1	75,767	12	1,2	16,18	0	
33	7	Block 1	57,026	20	0,9	126,68	30	
7	8	Block 1	30,462	20	1,2	126,68	60	
48	9	Block 1	75,767	12	0,6	34,669	45	
68	10	Block 1	57,026	20	1,2	34,669	15	
45	11	Block 1	57,026	30	0,6	126,68	0	
70	12	Block 1	30,462	20	0,9	34,669	0	
56	13	Block 1	30,462	20	1,2	16,18	60	
30	14	Block 1	75,767	20	0,9	126,68	45	
80	15	Block 1	57,026	12	0,9	16,18	0	
55	16	Block 1	30,462	20	0,6	16,18	60	
72	17	Block 1	57,026	20	0,6	34,669	45	

Figura 5.5 Tabela com o arranjo das análises pelo Design Expert.

A Tabela 5.2 apresenta os dados da análise paramétrica gerada com o programa Design-Expert [20] e suas cargas críticas associadas. Essas cargas foram determinadas pela análise não-linear de elementos finitos utilizando o programa ANSYS [17] e mais tarde, usada para treinar e testar a Rede Neural Bayesiana. A tabela completa encontra-se no apêndice referente a este capítulo.

	Entradas					Saídas	
	$r_c$ (mm)	$L_c$ (m)	$L_b$ (m)	$A_s$ (mm <sup>2</sup> )	$P_s$ (%)	$P_{cr}$ (N)	$P_{cr}^*$ (N)
1	75,767	12	1,2	34,669	75	409367	0,337
2	30,462	30	0,6	34,669	75	6407,61	0,019
3	75,767	20	0,6	126,68	0	114594	0,094
4	30,462	20	1,2	16,18	30	23378,7	0,071
5	75,767	30	1,2	126,68	0	86188,7	0,071
6	30,462	20	0,6	16,18	45	10198,4	0,031
7	30,462	12	0,6	16,18	60	31950,3	0,097
8	30,462	12	1,2	16,18	0	47192,9	0,143
9	30,462	12	1,2	126,68	30	82013,6	0,249
10	75,767	12	0,6	16,18	45	450324	0,371
11	57,026	20	1,2	16,18	0	45339,7	0,063
...	...	...	...	...	...	...	...
78	30,462	20	0,9	16,18	15	15971,3	0,049

Tabela 5.2. Dados de entrada e saída.

A penúltima coluna da tabela contém as cargas críticas obtidas com o auxílio do programa ANSYS [17] e usadas como saída de dados da Rede Neural. Essa carga crítica foi usada em casos onde a estratégia de normalização dos dados de saída foi efetuada em termos dos valores máximos e mínimos da coluna  $P_{cr}$ . Uma segunda estratégia de normalização baseou-se na divisão da carga crítica,  $P_{cr}$ , pela carga de plastificação (área da coluna vezes tensão de escoamento do aço da coluna – 380MPa), conforme Equação (5.1). Esta normalização está representada na última coluna da Tabela 5.2. Esta estratégia de normalização foi usada também como uma alternativa para os dados de saída da Rede Neural.[19].

$$P_{cr}^* = \frac{P_{cr}}{\pi D_e t_c f_y} \quad (5.1)$$

## 5.2

### Análise Paramétrica com Uso de Redes Neurais Bayesianas

De acordo com os objetivos supracitados, serão estudados os casos de rigidez da coluna principal em termos do raio de giração ( $r_c$ ), o comprimento da coluna principal ( $L_c$ ), o comprimento dos braços ( $L_b$ ), o diâmetro dos estais ( $D_s$ ) e o nível de protensão ( $P_s$ ). O motivo pelo qual são realizados os diferentes níveis de protensão é porque se procura o valor da protensão ótima que fará com que a estrutura obtenha a maior carga crítica. A busca pela protensão ótima é realizada tanto para cada tipo de imperfeição inicial quanto para a variação de rigidez longitudinal dos estais.

Com o intuito de obter resultados de uma forma inteligente, sem a utilização de uma análise numérica baseada no programa Ansys [17], decidiu-se utilizar o algoritmo baseado no treinamento Bayesiano devido a sua capacidade de superar problemas de convergência utilizando poucos dados de treinamento (problema de mínimos locais), onde os coeficientes de regulação são selecionados a partir dos dados de treinamento sem a necessidade da separação de dados para a validação cruzada, o que reduz o erro do problema durante a modificação dos parâmetros para ajustar os ruídos existentes.

Basicamente, as Redes Neurais Bayesianas consistem na utilização do mecanismo de inferência Bayesiana no cálculo dos parâmetros (pesos) do modelo neural, no qual se calcula uma função de densidade de probabilidade

(densidade a posteriori) sobre todos os possíveis vetores de parâmetros que a rede neural pode possuir.

O objetivo da aproximação Bayesiana é obter a distribuição prevista  $p(t^{(N+1)} | x^{(N+1)}, D)$  para prever a saída  $t^{(N+1)}$  quando uma nova entrada  $x^{(N+1)}$ , que não pertence às observações é apresentada, utilizando um modelo de regressão modal (que possui nas saídas da rede neural valores reais), com uma distribuição que possua uma forma exponencial, como por exemplo, a distribuição gaussiana.

### 5.2.1

#### Aprendizado Bayesiano

O objetivo da aproximação Bayesiana é obter a distribuição prevista  $p(t^{(N+1)} | x^{(N+1)}, D)$  para prever a saída  $t^{(N+1)}$  quando uma nova entrada  $x^{(N+1)}$ , que não pertence às observações é apresentada. As observações (dados de treinamento) do processo a ser modelado são representadas pelo conjunto dado pela equação (5.2 de “N” dados de treinamento.

A distribuição prevista é calculada pela Equação (5.3):

$$D = \{(x^{(1)}, t^{(1)}), (x^{(2)}, t^{(2)}), \dots, (x^{(N)}, t^{(N)})\} \quad (5.2)$$

$$p(t^{(N+1)} | x^{(N+1)}, D) = \int p(t^{(N+1)} | x^{(N+1)}, w) p(w | D) dw \quad (5.3)$$

Onde:  $w = [w_1, w_2, \dots, w_w]$  são os parâmetros da rede neural (pesos e bias). O cálculo de  $p(t^{(N+1)} | x^{(N+1)}, D)$  é raramente obtido analiticamente devido a dimensão do vetor dos parâmetros, utilizando-se assim métodos baseados em aproximações ou técnicas computacionais. Neste trabalho, utilizou-se o método de aproximação gaussiana.

### 5.2.2

#### Método da Aproximação Gaussiana

A densidade de probabilidade a posteriori dos parâmetros pode ser obtida pelo teorema de Bayes:

$$p(w | D) = \frac{p(D | w)p(w)}{p(D)} \quad (5.4)$$

onde o denominador é o fator de normalização expresso por:

$$p(D) = \int p(D | w)p(w)dw \quad (5.5)$$

$p(w)$  é a densidade a priori dos parâmetros baseada na distribuição gaussiana

$$p(w) = \frac{1}{Z_w(\alpha)} \exp(-\alpha E_w) \quad (5.6)$$

$\alpha$  é um hiper-parâmetro que controla o ruído dos parâmetros e a expressão para  $E_w$  pode ser sugerida no sentido de aplicar uma técnica de ajuste dos parâmetros, favorecendo parâmetros pequenos

$$E_w = \frac{1}{2} \|w\|^2 = \frac{1}{2} \sum_{i=1}^w w_i^2 \quad (5.7)$$

e  $Z_w(\alpha)$  é o fator de normalização.

$$Z_w(\alpha) = \left(\frac{2\pi}{\alpha}\right)^{\frac{w}{2}} \quad (5.8)$$

A dedução da função de verossimilhança  $p(D|w)$  depende do modelo neural utilizado. Neste trabalho, como se está utilizando o modelo regression (que possui nas saídas da rede neural valores reais), geralmente é utilizada uma distribuição que possua uma forma exponencial, como por exemplo, a distribuição gaussiana.

$$p(D | w) = \frac{1}{Z_D(\beta)} \exp(-\beta E_D) \quad (5.9)$$

onde  $E_D$  é uma função de erro

$$E_D = \frac{1}{2} \sum_{i=1}^N [t^i - y(x^i; w)]^2 \quad (5.10)$$

e o fator de normalização  $Z_D(\beta)$

$$Z_D(\beta) = \left( \frac{2\pi}{\beta} \right)^{\frac{N}{2}} \quad (5.11)$$

onde  $\beta$  é outro hiper-parâmetro que controla o ruído da saída da rede.

Finalmente a distribuição a posteriori  $p(w|D)$  é apresentada por:

$$p(w|D) = \frac{1}{Z_S} \exp(-\beta E_D - \alpha E_w) = \frac{1}{Z_S} \exp(-S(w)) \quad (5.12)$$

onde o fator de normalização  $Z_S$  é expresso por:

$$Z_S(\alpha, \beta) = \int \exp(\beta E_D + \alpha E_w) dw \quad (5.13)$$

### 5.2.3

#### Previsão da Carga de Flambagem da Coluna de Aço Estaiada e Protendida

Uma ferramenta do programa MATLAB [22] foi usada para o treinamento das Redes Neurais Bayesianas. A topologia padrão para todas as configurações das redes foi elaborada com cinco entradas, uma camada escondida de processadores e uma saída. As seguintes configurações da Rede Neural foram testadas com as duas estratégias de normalização para os dados de saída citados acima. Todos os dados de entrada foram normalizados pelo método de máximo e mínimo.

- 78 dados “reais” de entrada, onde 70% foram usados para treinamento, 20% para validação, e 10% para teste, com 3, 4 e 5 processadores na camada escondida (**primeira configuração**).
- 78 dados “reais” de entrada e 78 dados ruidosos, onde 70% foram usadas para treinamento, 20% para validação e 10% para teste,

com 3, 4, 5 e 10 processadores na camada escondida (**segunda configuração**).

- 78 dados “reais” de entrada e 156 dados ruidosos, onde 70% foram usadas para treinamento, 20% para validação e 10% para teste, com 3, 4, 5 e 10 processadores na camada escondida (**terceira configuração**).

Apesar do algoritmo de treinamento Bayesiano poder lidar com uma base de dados pequena, dados ruidosos foram gerados a fim de melhorar ainda mais o seu desempenho. O processo de geração dos dados ruidosos baseia-se na aplicação de um centésimo do valor gerado pela função randômica do MATLAB [22] (randn). A função “randn” gera uma matriz quadrada de ordem “n” de números randômicos onde seus elementos são normalmente distribuídos com média igual a zero, variância igual a um e desvio padrão igual a um.

### 5.3 Resultados Obtidos Com as Redes Neurais

As tabelas seguintes representam os resultados obtidos com as várias configurações das Redes Neurais Bayesianas. Os resultados são calculados em termos dos erros MAP e RMS (MAPE - Mean Absolute Percentage Error; RMSE - Root Mean Square Error).

As Equações (5.14) e (5.15) definem como os termos MAPE e RMSE são calculados.

$$MAPE = \frac{\sum_{k=1}^N \left| \frac{a_k - y_k}{a_k} \right|}{N} \times 100\% \quad (5.14)$$

$$RMSE = \sqrt{\frac{\sum_{k=1}^N \left| \frac{a_k - y_k}{a_k} \right|^2}{N}} \quad (5.15)$$

onde:

- N é o número de previsões;
- $a_k$  é a saída desejada para a previsão índice “k”;
- $y_k$  é a saída prevista para a previsão índice “k”.

As Tabela 5.3 e Tabela 5.4 representam a configuração sem a utilização de dados ruidosos. Os números apresentados na primeira coluna significam a configuração que foi usada na rede neural, conforme apresentado no item 3.2.3 deste capítulo, onde 78 é a quantidade total de dados reais, 54 é quantidade de dados para treinamento (70%), 16 para validação (20%) e 8 (10%) para o teste da rede neural. O mesmo aplica-se para todas as tabelas (Tabela 5.5 a Tabela 5.8), onde o primeiro número é a soma dos dados reais com os dados ruidosos (por exemplo: 78 dados reais + 78 dados ruídos = 156 dados totais de entrada).

Configuração	Processadores	1ª Normalização (Pcr)			
		Validação		Teste	
		MAPE	RMSE	MAPE	RMSE
78x54x16x8	3	3,02%	3,89%	17,46%	24,24%
	4	2,38%	<b>3,54%</b>	73,30%	108,13%
	5	<b>1,42%</b>	5,63%	<b>8,58%</b>	<b>8,99%</b>

Tabela 5.3 Análise sem dados ruidosos – 1a Estratégia de normalização

Configuração	Processadores	2ª Normalização (Pcr*)			
		Validação		Teste	
		MAPE	RMSE	MAPE	RMSE
78x54x16x8	3	7,76%	15,17%	62,10%	121,87%
	4	6,32%	16,51%	<b>48,11%</b>	<b>62,91%</b>
	5	<b>1,94%</b>	<b>6,01%</b>	50,09%	86,84%

Tabela 5.4 Análise sem dados ruidosos – 2a Estratégia de normalização

Ruído nos dados de entrada		1ª Normalização			
Configuração	Processadores	Validação		Teste	
		MAPE	RMSE	MAPE	RMSE
156x109x31x16	3	3,53%	4,85%	5,24%	6,50%
	4	<b>2,61%</b>	6,88%	1,14%	1,74%
	5	3,21%	<b>4,71%</b>	2,72%	3,99%
	10	3,39%	15,97%	<b>0,48%</b>	<b>0,61%</b>
234x164x47x23	3	3,65%	5,11%	3,55%	4,47%
	4	3,75%	7,20%	3,05%	6,32%
	5	1,48%	1,81%	1,19%	1,73%
	10	<b>0,34%</b>	<b>0,49%</b>	<b>0,21%</b>	<b>0,30%</b>

Tabela 5.5 Análise 1 - ruídos nos dados de entrada e 1a estratégia de normalização

Ruído nos dados de entrada e saída		1ª Normalização			
		Validação		Teste	
Configuração	Processadores	MAPE	RMSE	MAPE	RMSE
156x109x31x16	3	2,48%	3,47%	2,87%	4,21%
	4	2,78%	3,99%	2,36%	3,31%
	5	1,71%	2,39%	1,58%	2,15%
	10	<b>0,48%</b>	<b>1,05%</b>	<b>0,22%</b>	<b>0,37%</b>
234x164x47x23	3	2,65%	4,15%	2,72%	4,23%
	4	1,99%	3,06%	2,28%	3,00%
	5	2,22%	3,13%	1,69%	2,35%
	10	<b>0,43%</b>	<b>0,66%</b>	<b>0,35%</b>	<b>0,47%</b>

Tabela 5.6 Análise 2 - ruídos nos dados de entrada e saída e 1ª estratégia de normalização.

Ruído nos dados de entrada		2ª Normalização (Pcr*)			
		Validação		Teste	
Configuração	Processadores	MAPE	RMSE	MAPE	RMSE
156x109x31x16	3	12,34%	20,70%	14,41%	19,04%
	4	9,54%	<b>18,63%</b>	4,24%	7,17%
	5	<b>5,89%</b>	21,70%	6,17%	8,56%
	10	19,19%	62,91%	<b>1,05%</b>	<b>1,78%</b>
234x164x47x23	3	18,88%	36,07%	16,46%	24,60%
	4	11,96%	39,41%	5,15%	7,41%
	5	9,01%	15,15%	6,59%	12,18%
	10	<b>1,23%</b>	<b>2,06%</b>	<b>1,11%</b>	<b>1,77%</b>

Tabela 5.7 Análise 3 - ruídos nos dados de entrada e 2ª estratégia de normalização.

Ruído nos dados de entrada e saída		2ª Normalização (Pcr*)			
		Validação		Teste	
Configuração	Processadores	MAPE	RMSE	MAPE	RMSE
156x109x31x16	3	12,52%	<b>19,38%</b>	10,54%	16,49%
	4	<b>11,59%</b>	20,36%	10,47%	<b>13,12%</b>
	5	19,06%	60,02%	<b>9,68%</b>	13,70%
	10	18,77%	37,91%	12,32%	15,47%
234x164x47x23	3	20,11%	45,60%	<b>8,88%</b>	<b>12,85%</b>
	4	15,34%	27,90%	11,89%	22,91%
	5	<b>11,79%</b>	<b>19,56%</b>	11,71%	21,50%
	10	13,82%	20,52%	10,52%	17,56%

Tabela 5.8 Análise 4 - ruídos nos dados de entrada e saída e 2ª Estratégia de normalização.

Observa-se que a configuração topológica que apresentou o melhor resultado foi a que contém ruído nos dados de entrada e de saída normalizado pelos máximos e mínimos (primeira estratégia de normalização). Os resultados mais expressivos para o conjunto de teste estão apresentados nos gráficos a seguir.

A Figura 5.6 e a Figura 5.7 descrevem o menor valor para os erros MAP e RMS de teste para as configurações de redes apresentadas no item 0 deste capítulo e pela Tabela 5.5 até a Tabela 5.8. É evidente pelos gráficos que o melhor comportamento da rede neural foi obtido pela segunda configuração, onde se tem ruído nos dados de entrada e saída com a primeira estratégia de normalização (máximo e mínimo) para a rede com 78 dados reais e 78 dados ruidosos, totalizando 156 dados, sendo 70% desses dados para treinamento, 20% para validação e 10% para teste, com 10 neurônios na camada escondida.

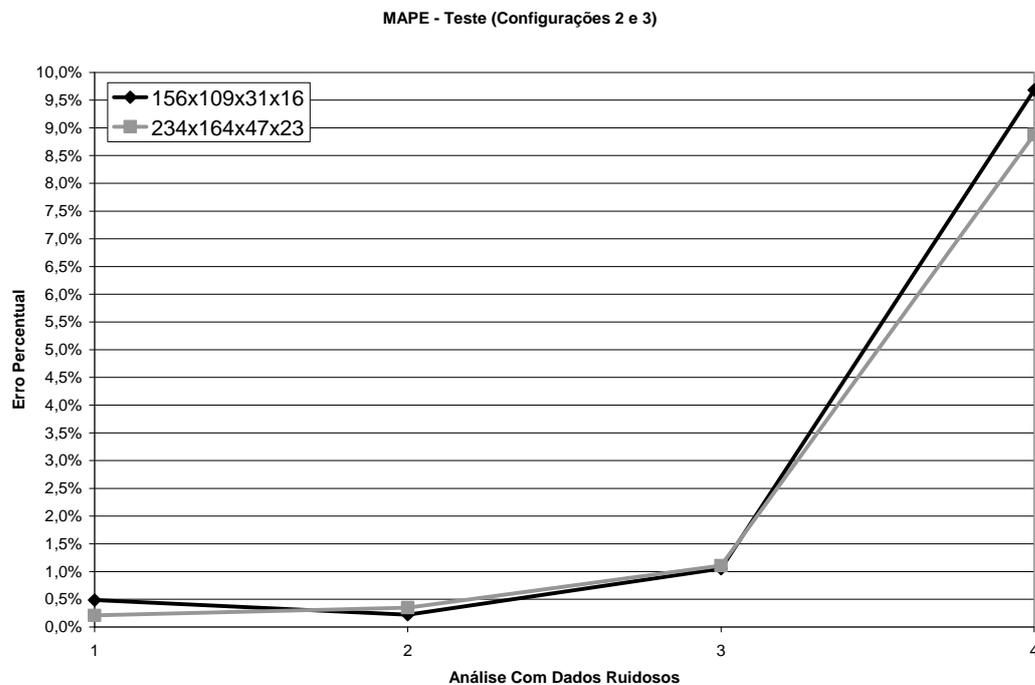


Figura 5.6 Menor valor de erro MAP da validação para cada análise.

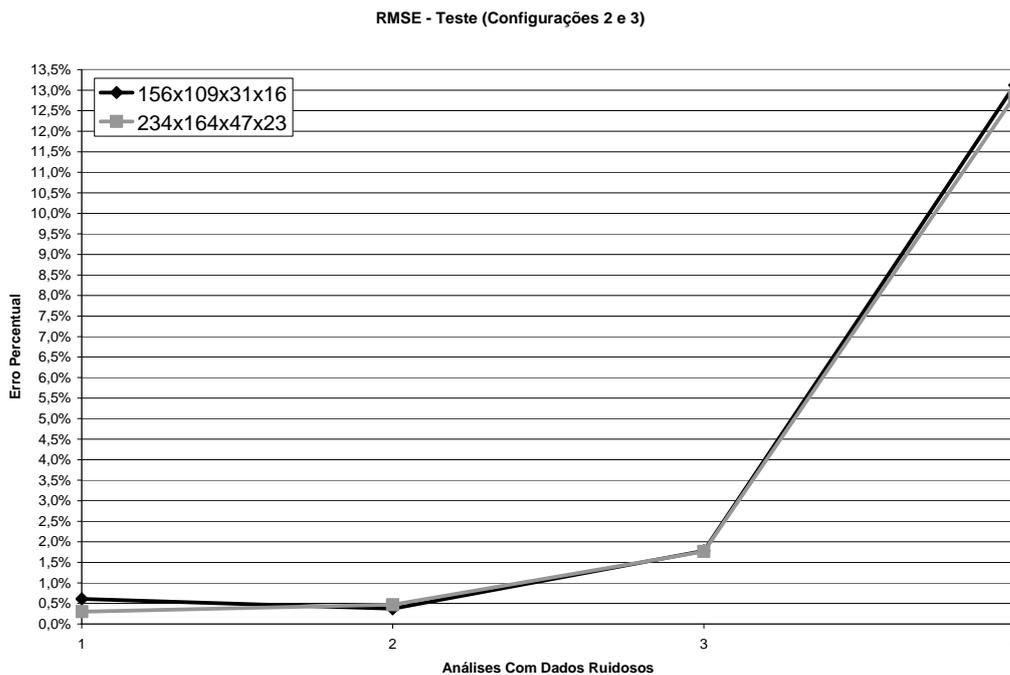


Figura 5.7 Menor valor de erro RMS da validação para cada análise.

Os gráficos da Figura 5.8, Figura 5.9 e Figura 5.10 descrevem o treinamento, a validação e o teste para a segunda configuração que foi a que melhor se comportou (156x109x31x16) com 10 neurônios na camada escondida.

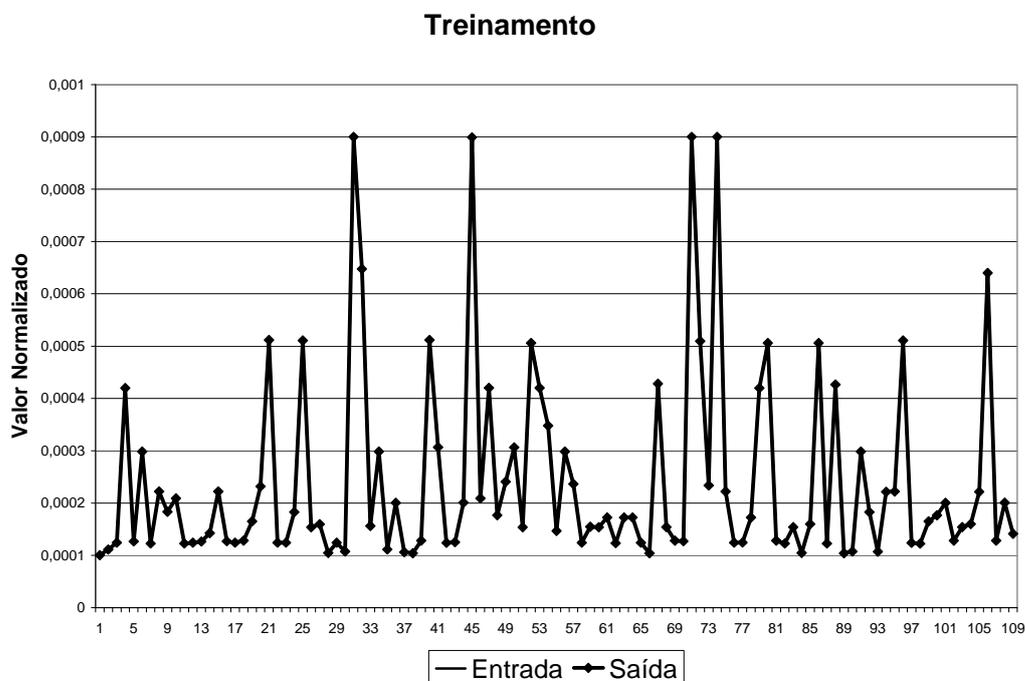


Figura 5.8 Treinamento para a segunda configuração com dez neurônios na camada escondida.

O desempenho da rede é também ilustrado na Figura 5.11 para a segunda configuração onde se tem ruído nos dados de entrada e saída com a primeira estratégia de normalização. Os resultados indicam que o melhor desempenho foi obtido com a rede com 78 dados reais e 78 dados ruidosos, onde 109 dados (70%) foram usados para treinamento da rede, 31 dados (20%) foram usados para validação e 16 dados (10%) foram usados para o teste final da rede neural.

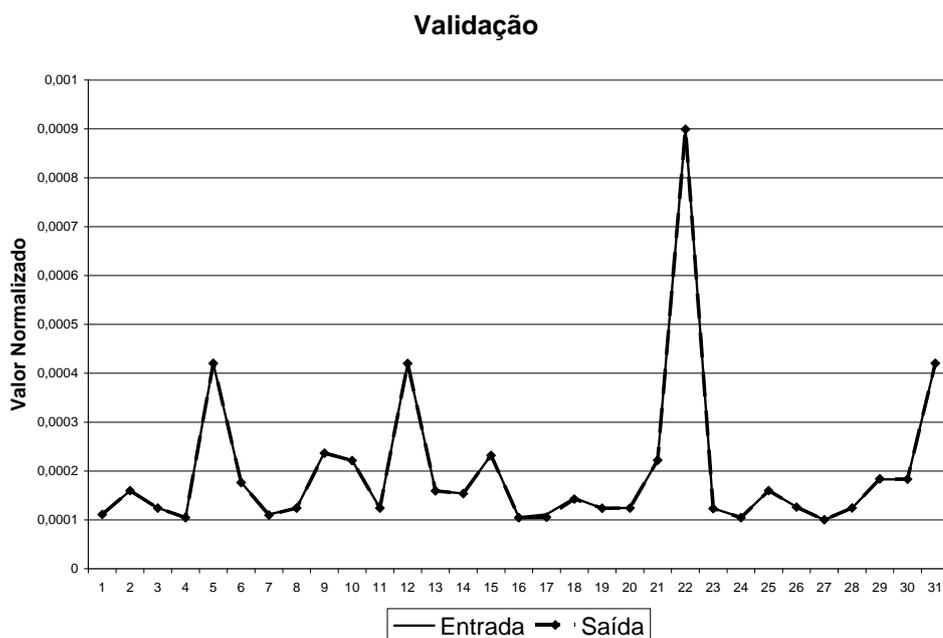


Figura 5.9 Teste para a segunda configuração com dez neurônios na camada escondida.

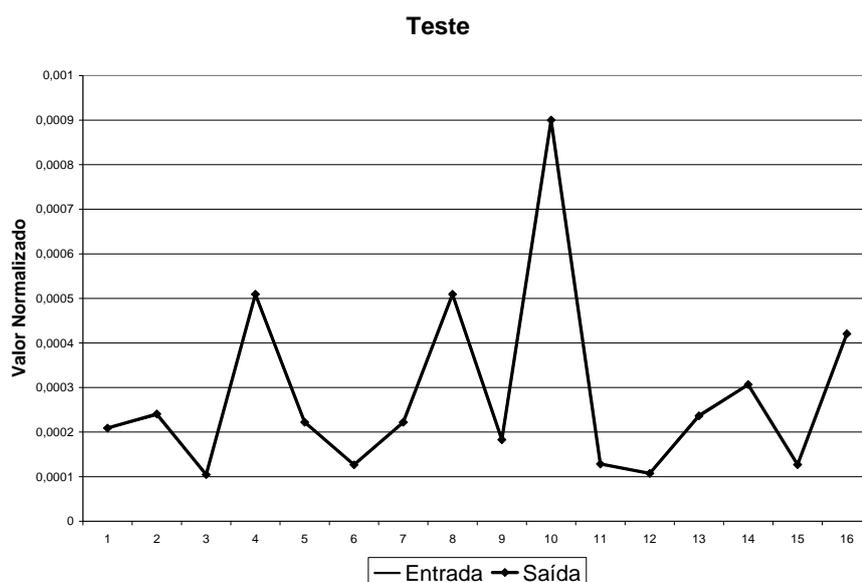


Figura 5.10 Validação para a segunda configuração com dez neurônios na camada escondida.

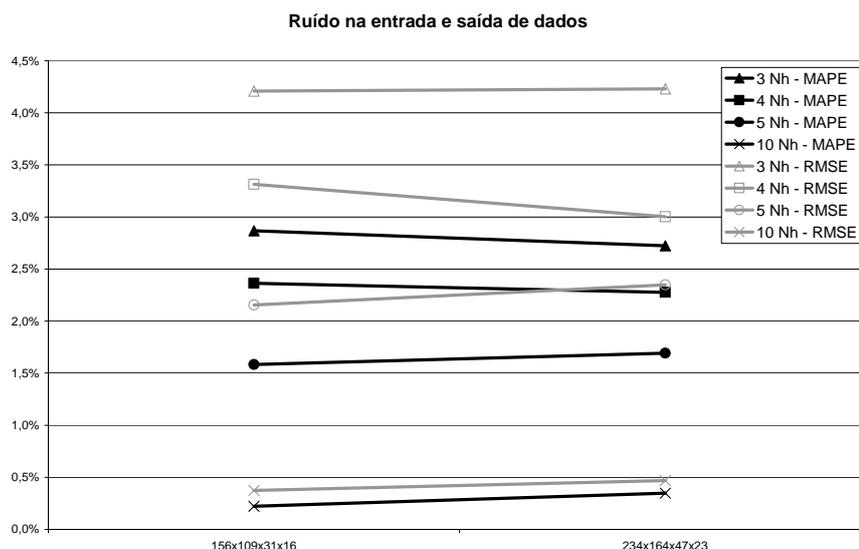


Figura 5.11 Erro geral para a segunda configuração com ruído na entrada e na saída, onde Nh é o número de neurônios na camada escondida.

As redes neurais bayesianas foram de suma importância para a ampliação da análise paramétrica de colunas de aço protendidas e estaiadas. Com o aumento dos dados reais conseguiu-se encontrar a melhor configuração topológica para a rede neural, apresentando um erro abaixo da expectativa, somente com a utilização de dados ruidosos. Com isto, conclui-se que há uma necessidade de um banco de dados ainda maior para que haja uma boa generalização da rede neural sem a necessidade de utilização de dados ruidosos. A rede neural com 78 dados reais não apresentou uma boa generalização devido à pouca quantidade de padrões utilizados, apesar de se ter obtido um erro próximo a 9% na média para o teste dos resultados para cinco neurônios na camada escondida. Quando se trabalhou com menos neurônios os erros foram além da expectativa. Ao serem apresentados à rede os dados ruidosos, observou-se uma grande melhoria nos resultados esperados, sendo que o excesso destes já não se mostrou eficaz. Desta forma, adotou-se a topologia com o dobro dos dados reais sendo que 78 dados são ruidosos e com dez neurônios na camada escondida. Os presentes resultados mostraram que a rede neural com treinamento bayesiano é uma técnica computacional eficaz para a ampliação das análises paramétricas das colunas de aço estaiadas e protendidas, tornando a criação de novos dados mais rápidos e mais simples de serem realizados, diminuindo o tempo de simulações que nem sempre convergem com facilidade.