



**AUTARQUIA ASSOCIADA À UNIVERSIDADE  
DE SÃO PAULO**

**MODELAGEM DO COMPORTAMENTO SEPARATIVO DE  
ULTRACENTRÍFUGAS VIA REDE NEURAL**

**SYLVANA CAVEDON PRESTI MIGLIAVACCA**

**Tese apresentada como parte dos  
requisitos para obtenção do Grau de  
Doutor em Ciências na Área de  
Tecnologia Nuclear - Materiais.**

**Orientador:  
Dr. Cláudio Rodrigues**

**São Paulo  
1999**

**INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES**

**Autarquia associada à Universidade de São Paulo**

**MODELAGEM DO COMPORTAMENTO  
SEPARATIVO DE ULTRACENTRÍFUGAS VIA  
REDE NEURAL**

**SYLVANA CAVEDON PRESTI MIGLIAVACCA**

Tese apresentada como parte dos requisitos  
para obtenção do grau de Doutor em Ciências  
na Área de Tecnologia Nuclear - Materiais

Orientador:  
Dr. Cláudio Rodrigues

**São Paulo**

**1999**



Dedico este trabalho aos meus filhos,  
Paulo, Gabriela e Leonardo,  
que representam o futuro.

## AGRADECIMENTOS

Quero expressar minha gratidão, como uma forma de homenagem póstuma, ao Prof. Dr. Ivo Jordan, responsável pela minha formação técnica na área de Separação Isotópica.

Agradeço ao Dr. Claudio Rodrigues, meu orientador, pela prestimosa orientação e encorajamento na elaboração desta tese.

Ao LSCP, Laboratório de Simulação e Controle de Processos do Departamento de Engenharia Química da Escola Politécnica da Universidade de São Paulo, na pessoa do Dr. Claudio Augusto Oller do Nascimento, pela concessão de uso do programa NEURO14 e pelas valiosas sugestões e auxílio durante o desenvolvimento deste trabalho.

Ao IPEN, Instituto de Pesquisas Energéticas e Nucleares, e ao CTMSP, Centro Tecnológico da Marinha em São Paulo pela oportunidade de realizar este estudo.

Aos MsC. Fernando da Costa Magalhães e MsC. José Henrique Buchmann, meus chefes, pela autorização a mim concedida para o desenvolvimento desta tese.

Aos colegas do IPEN e do CTMSP-II que, direta ou indiretamente colaboraram para a realização dos ensaios separativos e no levantamento de dados para a elaboração deste trabalho, de modo especial, a Mônica de Carvalho Vasconcelos, que possibilitou minha maior dedicação a este trabalho.

Ao meu colega e marido Elder Migliavacca pelo apoio pessoal e profissional, incentivo, paciência e auxílio na revisão dos manuscritos.

Finalmente agradeço à minha família pelo permanente apoio e compreensão, de modo especial aos meus pais, Lourdes e Vinício, com quem sempre pude contar, em todas as fases de minha vida.

# MODELAGEM DO COMPORTAMENTO SEPARATIVO DE ULTRACENTRÍFUGAS VIA REDE NEURAL

Sylvana Cavedon Presti Migliavacca

## RESUMO

A modelagem numérica de uma ultracentrífuga para enriquecimento de urânio, considerando seus componentes internos atuantes na geração da contracorrente é um problema complexo. O escoamento interno do gás e a distribuição da sua concentração no rotor podem ser descritas pela solução analítica ou numérica das equações que governam o processo. No entanto, esses modelos fenomenológicos não conseguem representar uma centrífuga real com todos seus dispositivos internos. O presente trabalho utiliza a técnica de redes neurais, advinda do desenvolvimento da inteligência artificial, para a modelagem do processo de separação dos isótopos do urânio por ultracentrifugação. Uma rede neural tem a capacidade de “aprender” as não-linearidades do processo a ela apresentado na fase de treinamento. Isto faz desta técnica uma ferramenta muito interessante na modelagem de processos químicos e físicos onde a não-linearidade é muito acentuada. O objetivo dos modelos propostos é o cálculo dos parâmetros separativos, de particular interesse o poder de separação  $\delta U$ , e dos parâmetros operacionais das centrífugas em estudo. São analisados cinco diferentes casos: dois, utilizando os dados experimentais de Zippe, de interesse acadêmico, e três, com dados experimentais das ultracentrífugas nacionais, com crescente grau de complexidade. Os modelos obtidos foram verificados frente a ensaios de confirmação e apresentaram concordância de 1% a 10%, dependendo da complexidade do modelo proposto. Os modelos definidos permitem, desta forma, prever os parâmetros separativos e operacionais das ultracentrífugas estudadas, de maneira extremamente rápida. Isto permite a análise completa do processo em estudo, incluindo a otimização numérica de um tipo de centrífuga e a utilização desses modelos para os cálculos de cascatas de separação.

# NEURAL NETWORKS FOR MODELING THE SEPARATIVE PARAMETERS OF A GAS CENTRIFUGE

Sylvana Cavedon Presti Migliavacca

## ABSTRACT

The prediction by a mathematical model of the separation of uranium isotopes using a gas centrifuge process is a hard task. The gas motion and the concentration profile can be described by analytical or numerical solutions of the governing equations. However, due to the complexity of the internal geometry of the centrifuges, these calculations can not be performed for actual centrifuges. This work uses neural networks, a modeling technique originated from the artificial intelligence field, to simulate the uranium isotope separation process by ultracentrifugation. A neural network has the ability to “learn” the non-linearities of a process presented in the learning process. So, neural networks are an alternative for modeling complex problems that show too many difficulties to be solved by phenomenological models. The main objective of the models is to calculate the separative parameters of the gas centrifuge, especially the separative power  $\delta U$ , and its operational conditions. Five different cases are studied: two of them using Zippe’s experimental data and three using our own experimental data, in increasing complexity levels. The calculated models are checked against experimental results, showing an agreement between 1% and 10%, depending on the complexity of the model. With these models the prevision of the separative and operational parameters of a centrifuge may be calculated in an extremely fast way. This allows a complete analysis of the process, including the optimization of the centrifuge and the use of these models for cascades calculations.

## SUMÁRIO

	<b>Página</b>
<b>1 INTRODUÇÃO</b> .....	1
<b>2 DESCRIÇÃO DO PROCESSO</b> .....	4
2.1 Conceitos básicos da teoria da separação isotópica .....	4
2.2 Descrição da centrífuga a gás .....	7
2.3 Notação .....	12
2.4 Referências .....	13
<b>3 REDE NEURAL</b> .....	15
3.1 Introdução à simulação via rede neural .....	15
3.2 Aplicação em centrífugas .....	20
3.3 Notação .....	23
3.4 Referências .....	25
<b>4 MODELAGEM DOS RESULTADOS EXPERIMENTAIS DE ZIPPE</b> .....	29
4.1 Os ensaios de separação isotópica de ZIPPE .....	30
4.2 Estudo do CASO 1 .....	38
4.3 Otimização da centrífuga do CASO 1 .....	42
4.4 Estudo do CASO 2 .....	45
4.5 Conclusão .....	53
4.6 Notação .....	54
4.7 Apêndices .....	55
4.8 Referências .....	62

<b>5</b>	<b>APLICAÇÃO AOS DADOS OBTIDOS NO ENSAIO SEPARATIVO DE UMA CENTRÍFUGA</b> .....	<b>63</b>
5.1	Treinamento e testes da rede neural .....	64
5.2	Comparação entre os dados experimentais e os calculados .....	66
5.3	Otimização da centrífuga .....	70
5.4	Conclusão .....	72
5.5	Notação .....	73
5.6	Apêndices .....	74
5.7	Referências .....	78
<b>6</b>	<b>APLICAÇÃO AOS DADOS OBTIDOS NO ENSAIO SEPARATIVO DE UMA CENTRÍFUGA EM CONDIÇÕES ASSIMÉTRICAS</b> .....	<b>79</b>
6.1	Treinamento e testes da rede neural .....	84
6.2	Comparação entre os dados experimentais e os calculados .....	88
6.3	Otimização das condições de operação da centrífuga .....	100
	6.3.1 Caso simétrico .....	100
	6.3.2 Corte otimizado .....	104
6.4	Análise de sensibilidade .....	110
6.5	Conclusão .....	116
6.6	Notação .....	117
6.7	Apêndices .....	119
6.8	Referências .....	127
<b>7</b>	<b>MODELAGEM DE CENTRÍFUGAS COM DIFERENTES CONFIGURAÇÕES INTERNAS</b> .....	<b>128</b>
7.1	Dados experimentais .....	129
7.2	Estrutura das redes neurais .....	143
7.3	Treinamento da rede neural para o cálculo do poder de separação $\delta U$ .....	147
7.4	Treinamento da rede neural para o cálculo da pressão de rejeito $p_w$ .....	157
7.5	Ensaio de verificação .....	162
7.6	Mapeamento da solução e otimização .....	168

7.7	Análise de sensibilidade .....	174
7.8	Conclusão .....	176
7.9	Notação .....	178
7.10	Apêndices .....	180
7.11	Referências .....	251
<b>8</b>	<b>CONCLUSÕES</b> .....	<b>252</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	<b>256</b>

## 1 INTRODUÇÃO

O enriquecimento ou separação isotópica do urânio, uma das etapas do ciclo do combustível nuclear, é a operação através da qual se tem em vista aumentar o teor do isótopo  $^{235}\text{U}$  acima de sua composição isotópica natural no elemento urânio ou em um dos seus compostos. Na natureza existem três isótopos do urânio de número atômico 92 e números de massa 234, 235 e 238, no entanto, como a proporção do isótopo 234 é muito pequena (0.00055%), nos processos de enriquecimento, o urânio natural é sempre considerado como sendo uma mistura binária formada apenas pelos componentes U-235 e U-238, na proporção de 0.711% e 99.289% em massa, respectivamente.

O fato de no enriquecimento isotópico do urânio aumentar-se o teor do isótopo  $^{235}\text{U}$ , provém da condição de ser este o isótopo fissil do urânio, que sofre a fissão de seu núcleo quando bombardeado por neutrons. Nesse processo de ruptura do núcleo e conseqüente condução a uma reação em cadeia, produz-se uma grande quantidade de energia, que liberada de forma controlada, é aproveitada nas centrais nucleares para a geração de energia elétrica. O urânio enriquecido, utilizado como combustível nessas centrais, apresenta um teor de  $^{235}\text{U}$  compreendido entre 2 e 4%. . Conhecido por urânio levemente enriquecido (“low enriched uranium”, LEU), esse combustível se destina aos reatores de água pressurizada (“pressurized water reactors”, PWR) e aos reatores de água fervente (“boiling water reactor”, BWR). Esse urânio enriquecido é também usado nos reatores heterogêneos de grafite-água fervente, de elevada potência do tipo RBMK instalados em centrais nucleares soviéticas, como a de Chernobyl, assim como nos reatores ingleses avançados resfriados a gás (“advanced gas cooled reactors”, AGR). Além do combustível nuclear considerado, é também produzido o urânio altamente enriquecido (“high enriched uranium”, HEU) com teores de  $^{235}\text{U}$  iguais ou superiores a 90%, muito utilizado como combustível nos primeiros reatores de pesquisa ou de ensaios de materiais, nos quais são desejados elevados fluxos de neutrons, e nos reatores de potência compactos,

que apresentam uma elevada densidade de potência elétrica. Esse urânio altamente enriquecido é também empregado nos artefatos nucleares, além de constituir o combustível de reatores do tipo “breeders”.

A produção industrial do urânio levemente enriquecido representa o principal objetivo da realização do enriquecimento isotópico do urânio em larga escala. Como geralmente o enriquecimento obtido em um único elemento de separação é muito pequeno, utilizam-se as cascatas de separação isotópica, que são sistemas nos quais se realiza , repetidas vezes, através do arranjo em série e em paralelo dos elementos de separação, o enriquecimento isotópico do urânio, para obter-se um produto com o teor desejado de  $^{235}\text{U}$ .

O Brasil, por meio da Marinha, no atual CTMSP, Centro Tecnológico da Marinha em São Paulo, e do IPEN, Instituto de Pesquisas Energéticas e Nucleares, optou por desenvolver o processo da ultracentrifugação gasosa como meio de obtenção de combustível nuclear com teor de urânio  $^{235}\text{U}$  suficiente para o uso no programa de propulsão nuclear. A ultracentrifugação e a difusão gasosa são os dois processos utilizados em usinas comerciais, no entanto, o primeiro apresenta menores custos de produção, alta modularidade e flexibilidade de produção. O fato da ultracentrifugação possibilitar atingir altos teores de enriquecimento, aliado a uma agressiva estratégia comercial, estabeleceu a mesma como uma tecnologia classificada como secreta. As bases teóricas do processo são encontradas em literatura aberta, mas os requisitos mais sensíveis ao desenvolvimento tecnológico, bem como o estágio de desenvolvimento de um dado grupo ou país são fielmente resguardados. Por esse motivo relevante, a tecnologia para o enriquecimento do urânio por ultracentrifugação foi totalmente desenvolvida no Brasil e deve também ser preservada.

O desenvolvimento de um modelo, ou geração, de ultracentrífugas passa pelas seguintes etapas:

- desenvolvimento eletromecânico, que visa obter uma centrífuga operacional e confiável;

- otimização dos parâmetros separativos, que tem por objetivo maximizar a capacidade de separação de uma centrífuga através da otimização das variáveis internas e das condições de operação;
- preparação para operação em cascata, que visa aprofundar o conhecimento da centrífuga otimizada, acertar parâmetros externos para operação de centrífugas em conjunto e definir um modelo numérico representativo da centrífuga para o projeto da cascata.

O presente trabalho tem por objetivo principal avaliar a aplicação de uma nova técnica de modelagem de processos denominada redes neurais, advinda do desenvolvimento da inteligência artificial. Essa técnica será utilizada na modelagem dos parâmetros separativos das ultracentrífugas construídas pelo Centro Tecnológico da Marinha no Brasil. Tal decisão se solidificou devido à aplicação, com sucesso, de redes neurais na modelagem de processos altamente não-lineares, caso específico da modelagem de ultracentrífugas no enriquecimento de urânio.

Os modelos fenomenológicos encontrados na literatura aberta são de grande valia para a compreensão do processo em questão, no entanto, tornam-se incipientes na previsão do desempenho separativo de ultracentrífugas. Por outro lado, o sucesso da aplicação da técnica de redes neurais na modelagem de um processo depende fortemente do conhecimento desse processo e da disponibilidade de um bom conjunto de dados. Daí que a obtenção de modelos numéricos que representem as características separativas das ultracentrífugas permite orientar e agilizar o processo de otimização desse equipamento. Centrífugas otimizadas representam menor custo de instalação e de operação das usinas de enriquecimento, uma vez que será necessário menor número de máquinas para cumprir uma dada tarefa de separação. Nesse sentido, a técnica de modelagem por redes neurais configura uma eficiente ferramenta na modelagem de ultracentrífugas com diferentes características de montagem, permitindo assim sua otimização. O mesmo vale para as etapas posteriores à montagem das ultracentrífugas, onde a técnica de redes neurais pode fornecer modelos numéricos representativos da ultracentrífuga desenvolvida, com resultados muito próximos da máquina em operação real.

## 2 DESCRIÇÃO DO PROCESSO

### 2.1 Conceitos Básicos da Teoria da Separação Isotópica

A separação dos isótopos do urânio, assim como a separação de outros isótopos estáveis, independentemente do processo utilizado, pode ser representada por uma teoria completamente geral que se aplica a qualquer mistura isotópica binária. Uma vez que as propriedades físicas e químicas dos isótopos são muito próximas, a separação realizada em uma única vez é, de modo geral, muito pequena. Por isso se faz necessária a ligação em série de vários dispositivos de separação com o objetivo de multiplicar a separação obtida. Esse conjunto é chamado de cascata de separação de isótopos. A teoria da separação dos isótopos do urânio assim realizada está descrita em detalhes nas obras de COHEN [2.1] e BENEDICT *et al.* [2.2] e na obra nacional de JORDAN [2.3].

O menor elemento de uma usina de enriquecimento é chamado unidade ou elemento de separação. No caso da separação do urânio pela centrífuga a gás, uma unidade de separação é representada por uma centrífuga. Um grupo de unidades de separação ligadas em paralelo define um estágio. No estágio todas as unidades de separação são alimentadas com material de mesma composição isotópica e produzem individualmente frações enriquecidas, ou produtos, e frações empobrecidas, ou rejeitos, com composições iguais entre si. A ligação em série de um grupo de estágios forma então uma cascata de separação isotópica.

O elemento de separação simples recebe um fluxo de alimentação  $F$  da mistura isotópica binária de composição  $x_F$  do isótopo desejado ( $^{235}\text{U}$ ) e fornece duas correntes, uma, a do produto, parcialmente enriquecida no isótopo desejado com fluxo  $P$  e

composição  $x_P$  e outra parcialmente empobrecida no isótopo desejado, denominada rejeito, de fluxo  $W$  e composição  $x_W$ . A razão de abundância, definida pela relação entre as composições do componente desejado e a do outro componente  $R=x/(1-x)$  é denotada por  $R_F$  para a corrente da alimentação,  $R_P$  para a corrente do produto e  $R_W$  para a do rejeito. A seguir são definidos os principais parâmetros de separação:

$$\text{fator de enriquecimento: } \beta = \frac{R_P}{R_F} = \frac{x_P(1-x_F)}{x_F(1-x_P)} \quad (2.1)$$

$$\text{fator de empobrecimento: } \gamma = \frac{R_F}{R_W} = \frac{x_F(1-x_W)}{x_W(1-x_F)} \quad (2.2)$$

$$\text{fator de separação: } \alpha = \frac{R_P}{R_W} = \frac{x_P(1-x_W)}{x_W(1-x_P)} = \beta \times \gamma \quad (2.3)$$

Chamamos de processo simétrico o processo no qual os fatores de enriquecimento e de empobrecimento são iguais,  $\beta=\gamma$  e portanto,  $\alpha=\beta^2$ , onde os parâmetros são denotados por um \*.

Outra propriedade fundamental da unidade de separação é o corte  $\theta$ . Essa propriedade é definida como sendo a relação entre o fluxo da corrente enriquecida e o fluxo da alimentação:

$$\theta = \frac{P}{F} = \frac{P}{P+W} \quad (2.4)$$

ou, em termos das composições, quando se considera o balanço material do isótopo desejado:

$$\theta = \frac{x_F - x_W}{x_P - x_W} \quad (2.5)$$

A unidade de separação é descrita pelos parâmetros separativos  $\alpha$  ou  $\beta$  e pelas variáveis de fluxo  $F$  e  $\theta$  (ou  $P$  e  $W$ ). No entanto, nenhuma dessas variáveis representa individualmente o desempenho da unidade de separação. Assim é interessante definir uma propriedade que englobe as grandezas separativas e de fluxo e que ao mesmo tempo esteja relacionada ao trabalho separativo útil produzido pela unidade. Essa propriedade, chamada poder ou capacidade de separação, foi definida por DIRAC, apresentada num manuscrito em 1941 não publicado, mas citado por COHEN [2.1], mediante a introdução do conceito do fluxo de valor, considerando que a unidade de separação produz uma variação no valor de uma quantidade de material separado. Sendo o fluxo de valor uma função  $U$ , a produção de valor resultante da separação de isótopos por um elemento de separação é dada pela variação da função  $U$ . O fluxo de valor  $U$  é dado pelo produto do fluxo de material e uma função de valor  $V(x)$ . Então no elemento de separação vamos ter os fluxos de valor  $U_F = FV(x_F)$ ,  $U_P = PV(x_P)$  e  $U_W = WV(x_W)$  para as correntes de alimentação, produto e rejeito, respectivamente. A variação do valor produzida pelo elemento de separação é então o poder de separação  $\delta U$ , o qual é dado pelo balanço dos fluxos de valor, a saber:

$$\delta U = PV(x_P) + WV(x_W) - FV(x_F) \quad (2.6)$$

A função de valor  $V(x)$  é uma função somente da composição  $x$  e é adimensional, definida pela equação:

$$V(x) = (2x - 1) \ln \left( \frac{x}{1-x} \right) \quad (2.7)$$

Esta função é simétrica em  $x=0.5$ , onde ela assume valor zero. É positiva para os demais valores de composição e aumenta tendendo ao infinito quando  $x$  se aproxima de 0 e de 1. A função  $V(x)$  permite que o aumento de valor  $\delta U$  efetuado pela unidade de separação seja independente da concentração isotópica do material processado.

## 2.2 Descrição da Centrífuga a Gás

A centrífuga a contracorrente, esquematizada na Figura 2.1, consiste de um cilindro vertical relativamente longo e de parede fina, girando ao redor de seu eixo em altas velocidades dentro de um recipiente em vácuo. O gás, a saber uma mistura isotópica binária contendo  $^{235}\text{UF}_6$  e  $^{238}\text{UF}_6$ , no interior desse cilindro, denominado rotor, está sujeito à ação de uma aceleração centrífuga milhares de vezes maior que a aceleração da gravidade. Assim se estabelece uma distribuição de pressões, manifestada na forma de um gradiente radial de pressão, crescente no sentido do eixo para a parede do rotor. Essa distribuição de pressão é diferente para os diferentes isótopos, uma vez que a ação do campo centrífugo depende da massa. Resulta então uma separação parcial da mistura de isótopos presente no interior do rotor. Induzindo um fluxo de contracorrente vertical obtém-se uma multiplicação do efeito elementar da separação radial. Assim a diferença entre a composição do topo e do fundo do rotor da centrífuga se torna maior que a diferença no sentido radial para uma dada posição axial.




FIGURA 2.1: Esquema de uma centrífuga a contracorrente (extraída de BENEDICT [2.2])

A contracorrente interna, representada pelas setas verticais na Figura 2.1, pode ser gerada por meios mecânicos, mediante a interação do gás em rotação com obstáculos estacionários, presentes no interior do rotor, e por meios térmicos, através do controle das temperaturas das tampas do rotor ou da temperatura ao longo da parede do rotor. Nesse sentido, existem quatro mecanismos elementares para a geração da contracorrente, que são os seguintes:

1. *o acionamento pelo coletor ou placa defletora fixa*, no qual a criação da contracorrente é provocada pela interação do coletor ou de um disco estacionário com o gás de processo em movimento de rotação. Esse mecanismo, que representa o meio mais comum para gerar a contracorrente interna; na Figura 2.1 é estabelecido pelo coletor inferior.
2. *o acionamento térmico na parede do rotor*, que é determinado por uma distribuição de temperatura não uniforme ao longo do comprimento da parede do rotor, ou seja, por um gradiente de temperatura axial. Nesse caso, para manter a circulação axial no mesmo sentido da produzida pelo coletor, é necessário que, na Figura 2.1, a temperatura seja decrescente da extremidade inferior para a extremidade superior do rotor.
3. *o acionamento térmico das tampas do rotor*, que resulta quando há remoção de calor de uma das tampas e introdução de calor na outra tampa. No esquema da Figura 2.1, esse escoamento ocorre no mesmo sentido da circulação interna provocada pelo coletor inferior no caso em que a tampa inferior é aquecida e a superior é resfriada.
4. *o acionamento pela alimentação*, no qual a circulação do gás no interior do rotor é induzida pela injeção do fluxo da alimentação no rotor. Nesse caso, o escoamento interno provém de uma fonte (o ponto de alimentação do rotor) e de dois sumidouros representados pela remoção do gás em ambas as extremidades do rotor.

Na prática, esses quatro tipos de mecanismos elementares responsáveis pela geração da contracorrente agem simultaneamente. Nesse caso, os perfis de circulação interna provenientes de cada um desses mecanismos podem ser analisados separadamente, quando são admitidas hipóteses simplificadoras. Por outro lado, a análise separativa, que visa calcular os parâmetros separativos da centrífuga, não permite a linearização da equação

que descreve o equilíbrio entre os dois componentes, a saber a equação da difusão-convecção. Para essa análise é necessário recorrer à equação que descreve o fluxo total no interior do rotor, resultante dos diversos mecanismos de acionamento.

As equações nas quais se baseia a teoria da centrífuga a contracorrente para a separação isotópica do urânio, são as seguintes:

#### **Equações de conservação do gás como um todo**

1. Massa: equação da continuidade do gás
2. Quantidade de movimento radial
3. Quantidade de movimento angular
4. Quantidade de movimento axial
5. Energia

#### **Equação termodinâmica de estado**

6. Equação do gás ideal

#### **Equação de conservação da mistura gasosa**

7. Massa: equação da continuidade do isótopo desejado

Face a essas equações, a análise teórica da centrífuga pode ser dividida em duas partes: a análise gás-dinâmica e a análise separativa. A análise gás-dinâmica trata o gás de processo como um fluido de um único componente e tem em vista a resolução simultânea das seis primeiras equações acima, buscando obter os valores das seis variáveis: componentes de velocidade axial, radial e azimutal e pressão, densidade e temperatura do gás. A análise separativa considera o gás de processo como uma mistura isotópica de dois componentes e tem por objetivo resolver a sétima equação do sistema considerado. Desse modo, com o auxílio dos perfis de velocidade obtidos na análise gás-dinâmica, é possível determinar as concentrações de produto e rejeito, dadas as condições de operação da centrífuga.

A análise gás-dinâmica não pode ser realizada sem a definição de hipóteses simplificadoras. A primeira dessas simplificações, empregada em algumas soluções analíticas, é admitir que os desvios das componentes da velocidade e das variáveis de estado dos respectivos valores de equilíbrio são suficientemente pequenos, de modo que podem ser tratados como perturbações do escoamento primário de rotação de corpo rígido. Nessas condições é possível linearizar as equações de conservação em torno dos valores de equilíbrio, de modo que as equações resultantes contenham apenas as perturbações, que são de primeira ordem. A segunda simplificação introduzida é considerar que apenas as regiões próximas às fronteiras sólidas contêm gás de densidade significativa. Nesse sentido, o gás aderente às tampas escoam essencialmente na direção radial, formando as camadas limites conhecidas por camadas de Ekman. O gás mantido adjacente à parede do rotor pela força centrífuga se desloca axialmente e também constitui uma camada limite, denominada por camada de Stewartson. Dependendo do mecanismo de acionamento da contracorrente podem existir diversos tipos de camadas de Stewartson. Apesar do grande número de trabalhos publicados, desde o início da década de 1960, acerca da resolução das equações gás-dinâmicas da centrífuga, é possível classificar os métodos usados na resolução em (i) o método da expansão em auto-funções, (ii) o método das camadas limites e (iii) os métodos numéricos. Uma boa revisão dos estudos sobre o escoamento no interior de centrífugas foi feita por RÄTZ [2.4]. Segundo RÄTZ os métodos que apresentaram melhores resultados se encontram no primeiro e no terceiro grupo. Atualmente é possível estabelecer soluções numéricas mais completas (KAI [2.5]), no entanto, a descrição das condições de contorno, que representam os dispositivos internos responsáveis pela geração da contracorrente, ainda passam por simplificações. Em qualquer caso, a resolução das equações gás-dinâmicas só pode ser efetuada admitindo hipóteses simplificadoras para as equações ou para as condições de contorno.

A análise separativa da centrífuga a contracorrente foi estabelecida primeiramente por COHEN [2.1] na década de 1940 através da solução da equação da difusão e convecção, utilizando o método desenvolvido por FURRY, JONES e ONSAGER [2.6] para a coluna de difusão térmica. Essa solução tornou-se clássica, sendo denominada então de equação de Cohen-Onsager. Nesse tratamento o fluxo interno é considerado constante ao longo do rotor e deve ser admitido um perfil radial para o escoamento da

contracorrente. Esta teoria foi posteriormente apresentada por diversos autores, tais como AVERY e DAVIS [2.7], OLANDER [2.8], BENEDICT et al. [2.2] SOUBBARAMAYER [2.9], VON HALLE [2.10], JORDAN e BUCHMANN [2.11]. No entanto, trabalhos da gás-dinâmica publicados a partir do final da década de 1960 comprovaram que a hipótese da contracorrente constante ao longo da parede do rotor não é verdadeira. Diversos trabalhos na área da separação isotópica foram publicados nesse sentido, como por exemplo OLANDER [2.12] e MIGLIAVACCA [2.13]. Esses trabalhos, no entanto, correspondem ainda a uma análise unidimensional. Diversos trabalhos realizaram análise bidimensional do escoamento interno e do campo de concentrações da centrífuga. Já na década de 70, SOUBBARAMAYER e LAHARGUE [2.14] e [2.9] procederam à solução numérica bidimensional do escoamento e da separação de centrífugas através do programa CENTAURE. NAKAYAMA & TORI [2.15] também apresentaram um modelo numérico bidimensional. Porém nessa época os recursos computacionais eram mais fracos e esses programas consumiam um considerável tempo de CPU. Trabalhos mais recentes foram apresentados por MAKIHARA & ITO [2.16], descrevendo uma solução analítica bidimensional para centrífugas com alimentação e retiradas de gás pelas tampas. KAI [2.5] apresenta uma revisão de seu estudo da separação isotópica realizado dentro de um projeto da POWER REACTOR AND NUCLEAR FUEL DEVELOPMENT CORP. (PNC), mostrando as dificuldades envolvidas na avaliação do desempenho separativo de centrífugas e apresenta os resultados do modelo numérico bidimensional desenvolvido. Portanto, a análise separativa necessita sempre da análise anterior da gás-dinâmica para definição do escoamento interno, como já foi mencionado. A solução do escoamento interno da centrífuga é um problema extremamente complexo, cuja solução requer o uso de simplificações ou linearizações, o que freqüentemente leva a soluções distantes da realidade. Esse aspecto do problema é muito propriamente descrito por KAI [2.5].

## 2.3 Notação

- F - fluxo de alimentação da unidade de separação
- P - fluxo de retirada do produto da unidade de separação
- $R_F$  - razão de abundância da alimentação
- $R_P$  - razão de abundância do produto
- $R_W$  - razão de abundância do rejeito
- U - fluxo de valor
- $V(x)$  - função de valor (Eq. 2.7)
- W - fluxo de retirada do rejeito da unidade de separação
- $x_F$  - composição da corrente de alimentação da unidade de separação
- $x_P$  - composição da corrente de produto da unidade de separação
- $x_W$  - composição da corrente de rejeito da unidade de separação

### letras gregas

- $\alpha$  - fator de separação da unidade de separação (Eq. 2.3)
- $\beta$  - fator de enriquecimento da unidade de separação (Eq. 2.1)
- $\delta U$  - poder ou capacidade de separação da unidade de separação (Eq. 2.6)
- $\gamma$  - fator de empobrecimento da unidade de separação (Eq. 2.2)
- $\theta$  - corte (Eq. 2.4 ou 2.5)

### símbolo

- \* - notação para variáveis correspondentes ao processo de separação simétrico

## 2.4 Referências

- [2.1] COHEN, K. *The Theory of Isotope Separation as Applied to the Large Scale Production of U<sup>235</sup>*. New York, NY: McGraw-Hill, 1951.
- [2.2] BENEDICT, M.; PIGFORD, T.H.; LEVI, H.W. *Nuclear Chemical Engineering*. 2.ed., New York, NY: McGraw-Hill, 1981.
- [2.3] JORDAN, I. *Separação dos isótopos de urânio pelo processo da centrifugação em fase gasosa*. São Paulo, SP: Instituto de Pesquisas Energéticas e Nucleares, 1980. (IPEN-Inf-3).
- [2.4] RÄTZ, E. Uranium isotope separation in the gas centrifuge. Rhode Saint Genese: Von Karman Institute For Fluid Dynamics, Jul. 1978 (Pres. at VKI Lecture series entitled: Aerodynamic Separation of Gases and Isotopes, May, 29 – Jun., 2, 1978).
- [2.5] KAI, T. Theoretical research on gas-centrifugal separation for uranium enrichment. *J. Nucl. Sci. Technol.*, v.26, n.1, p.157-160, 1989.
- [2.6] FURRY, W.H.; JONES, R.C.; ONSAGER, L. On the theory of isotope separation by thermal diffusion. *Phys. Rev.*, v.55, p.1083-1095, 1939.
- [2.7] AVERY, D.G.; DAVIS, E. *Uranium Enrichment by Gas Centrifuges*. London: Mills and Boon, 1973.
- [2.8] OLANDER, D.R. Technical basis of the gas centrifuge. *Adv. Nucl. Sci. Tech.*, v.6, p.105-174, 1972.
- [2.9] SOUBBARAMAYER. Centrifugation. In: VILLANI, S., (ed.) *Uranium Enrichment*. Berlin: Springer Verlag, 1979. p.183- 243.
- [2.10] VON HALLE, E. Procedure for the calculation of a the separative performance of a countercurrent gas centrifuge. In: WORKSHOP ON GASES IN STRONG

ROTATION, Aug. 24-27, 1981. Oxford. **Proceedings...** USDOE, 1981. (K/OA-5013).

- [2.11] JORDAN,I.; BUCHMANN,J.H. *Teoria de separação isotópica na centrífuga a contracorrente e cálculo dos parâmetros de separação*. São Paulo, SP: Instituto de Pesquisas Energéticas e Nucleares, Jul. 1983. (IPEN-Pub. C-5).
- [2.12] OLANDER,D.R. The theory of uranium enrichment by the gas centrifuge. *Prog. Nucl. Energy*, v.8, p.1-33, 1981.
- [2.13] MIGLIAVACCA,S.C.P. *Cálculo dos parâmetros de separação de uma centrífuga a contracorrente com variação axial do fluxo interno*. São Paulo, SP, 1991. Dissertação (Mestrado) - Instituto de Pesquisas Energéticas e Nucleares.
- [2.14] LAHARGUE,J.P. & SOUBBARAMAYER A numerical model for the investigation of the flow and isotope concentration field in an ultracentrifuge. *Comp. Meth. in Appl. Mech. and Eng.*, v.15, n.2, p.259-273, 1978.
- [2.15] NAKAYAMA,W. & TORII,T. Numerical analysis of separative power of isotope centrifuges (I). *J. Nucl. Sci. Technol.*, v.11, n.11, p.495-504, 1974.
- [2.16] MAKIHARA,H. & ITO,T. Separation characteristics of gas centrifuges - Approximate analyses of separation performance. *J. Nucl. Sci. Technol.*, v.25, n.8, p.649-666, 1988.

### **3 REDE NEURAL**

#### **3.1 Introdução à Simulação Via Rede Neural**

A técnica de redes neurais é uma das áreas de inteligência artificial que mais se desenvolveu nos últimos anos. Na engenharia química só recentemente essa técnica começou a ser utilizada, notadamente em detecção e diagnóstico de falhas de processos químicos (HOSKINS et al. [3.1] e [3.2], VENKATASUBRAMANIAN et al. [3.3], WATANABE et al. [3.4]) e em modelagem e controle de processos químicos (BHAT et al. [3.5], BHAT & McAVOY [3.6], UNGAR et al. [3.7], PSICHOGIOS & UNGAR [3.8], SU & McAVOY [3.9], CHAN & NASCIMENTO [3.10]).


Na tecnologia nuclear essa técnica começou a ser mais amplamente explorada em 1989 (YIFTAH [3.11]) e tem sido largamente utilizada em física de alta energia (DENBY [3.12], CUTTS [3.13] e PETERSON [3.14]) e em usinas nucleares (UHRIG [3.15], [3.16] e [3.17] e TANABE [3.18] e ERYÜREK et.al. [3.19] e [3.20]). Nesse último campo vale a pena citar as possíveis aplicações de redes neurais:

- (a) diagnóstico de condições anormais específicas;
- (b) detecção de mudanças no modo de operação;
- (c) validação de sinal de instrumentos;
- (d) monitoração da checagem de válvulas;
- (e) monitoração total da planta usando redes neurais auto-associativas;

- (f) modelagem termodinâmica da planta;
- (g) emulação dos cálculos da recarga do núcleo;
- (h) análise de vibrações da planta;
- (i) estimativa do nível de potência durante um transiente de desligamento da planta e em condições normais de operação;
- (j) monitoração do nível de potência e das temperaturas da “perna quente”, da “perna fria” e da saída do núcleo do reator.

A potencialidade do uso de redes neurais na simulação de processos químicos e nucleares, e de modo particular, na separação isotópica, é grande devido à forte não-linearidade observada nesses casos. Desta forma, contornam-se as dificuldades inerentes à obtenção de um modelo fenomenológico representativo do processo como expostas anteriormente. O sucesso de uma modelagem e controle de processo via rede neural, no entanto, depende fortemente do conhecimento das principais variáveis do processo, além de se ter uma base de dados de boa qualidade, ou seja, que contenha todas as informações importantes do processo, dentro do domínio desejado.

Existem duas estruturas principais de redes neurais: (i) rede de múltiplas camadas, cuja informação segue uma única direção ("*multilayer feedforward network*"), esquematizada na Figura 3.1, utilizadas para modelagem de sistemas em estado estacionário, e (ii) rede recursiva ("*recurrent network*"), para previsão de parâmetros, e portanto mais apropriada para modelos dinâmicos.



**FIGURA 3.1:** Esquema de uma rede neural de três camadas

Em geral, uma rede é formada por neurônios (representados por círculos), e por canais que transferem a informação entre os neurônios, denominados interconectores. Os retângulos representam neurônios onde as entradas da rede são armazenadas. Cada neurônio calcula primeiramente a soma ponderada de todos os sinais da camada anterior (Eq.3.1), e então gera uma saída através de uma função, geralmente definida pela Eq.3.2.

$$S_r = \sum_{u=1}^n W_{u,r} x_u + W_{n+1,r} \quad (3.1)$$

$$f(S_r) = \frac{1}{1 + e^{-S_r}} \quad (3.2)$$

As redes neurais mais comumente utilizadas para modelagem de processos são compostas por três camadas: a camada de entrada de dados, a camada oculta ("*hidden layer*") e a camada de saída. A camada de entrada possui  $n_i+1$  neurônios, onde  $n_i$  é o número de variáveis de entrada, e não efetua nenhum processamento. A fim de diminuir as

dificuldades de convergência, todos os dados do conjunto de aprendizagem são normalizados entre zero e um. Além dos dados de entrada, a rede também é alimentada com um valor de referência ("*bias*"). O número de neurônios da camada oculta é definido pelo usuário, e, segundo POLLARD et al. [3.21] a precisão dos resultados finais é relativamente insensível à quantidade de neurônios, acima de um valor mínimo necessário. A camada de saída é constituída por um número de neurônios igual ao número de variáveis de saída ou respostas.

O sistema "aprende" alterando os valores dos pesos ( $W_{u,v}$ ) de forma a minimizar o quadrado das diferenças ( $E$ ) entre os valores experimentais e os calculados pela rede, definido por

$$E = \sum_{m=1}^r \sum_{k=1}^{no} (y_k^{(m)} - O_k^{(m)})^2 \quad (3.3)$$

onde  $y_k$  é proveniente do conjunto de dados experimentais para o treinamento da rede e  $O_k$  é o valor correspondente obtido na camada de saída calculado pela expressão

$$O_k = f(S_k) \quad (3.4)$$

Atualmente, o algoritmo mais utilizado para determinar o conjunto de pesos no aprendizado da rede é o de retro-propagação ("*backpropagation*"). Esse algoritmo é uma derivação do algoritmo de otimização do gradiente descendente (RUMELHART & McCLELLAND [3.22]), que busca a minimização do resíduo quadrático  $E$ , dado pela Eq. 3.3, com respeito aos pesos  $W_{u,v}$ . Assim o gradiente  $\partial E / \partial W_{u,v}$  é calculado indicando a direção a ser seguida no processo de minimização de  $E$ .

Enquanto o método do gradiente descendente utiliza todos os dados do conjunto de aprendizado para determinar uma variação nos valores de  $W_{u,v}$ , o algoritmo de retro-propagação usa apenas um sub-conjunto de dados de entrada e saída. Primeiramente são ajustados os pesos entre a camada oculta e a camada de saída  $W2_{j,k}$ , segundo a expressão:

$$\Delta W2_{j,k}^{(m)} = \eta \cdot f'(S_k) (y_k^{(m)} - O_k^{(m)}) O_j^{(m)} \quad (3.5)$$

e depois são ajustados os pesos entre a camada de entrada e a camada oculta  $W1_{i,j}$ , segundo:

$$\Delta W1_{i,j}^{(m)} = \eta \cdot f'(S_j) \left\{ \left[ \sum_{k=1}^{no} f'(S_k) (y_k^{(m)} - O_k^{(m)}) W2_{j,k}^{(m-1)} \right] x_i^{(m-1)} \right\} \quad (3.6)$$

Os pesos são reavaliados a cada apresentação dos dados experimentais.

O fator  $\eta$  representa uma aceleração no processo de convergência. Podem ser adotados valores fixos ( $\eta=1$  não interfere no processo numérico) ou variáveis. No caso de se adotar um fator de aceleração  $\eta$  variável, ocorre uma mudança dinâmica deste fator de acordo com o desempenho da função resíduo  $E$ . Se o resíduo diminui após um certo número de apresentações, ocorre um aumento do fator  $\eta$ . Se o resíduo aumenta uma única vez, o fator  $\eta$  é diminuído. O número de apresentações consecutivas, o percentual de aumento ou diminuição do fator  $\eta$  e seus limites são parâmetros escolhidos de forma arbitrária no processo de treinamento de uma rede neural.

### 3.2 Aplicação em centrifugas

As variáveis tratadas são divididas em variáveis de entrada e variáveis de saída, ou respostas. De modo geral, as seguintes variáveis são consideradas variáveis de entrada:

- as condições de operação de processo, definidas pelo fluxo de alimentação  $F$  e o corte  $\theta$ , ou os fluxos de retirada do produto e do rejeito e por uma das pressões de retirada, normalmente a da linha do produto  $p_p$ ;
- a configuração de montagem da centrífuga, expressa por características como o raio de coleta do produto  $r_p$ , o raio de coleta do rejeito  $r_w$ , o diâmetro do furo central do disco girante  $D_I$ , a posição axial da alimentação, em termos do comprimento da seção de enriquecimento  $Z_E$ ,

As respostas primárias obtidas são:

- as pressões nas linhas de alimentação  $p_F$  e de retirada do rejeito  $p_w$ ;
- as razões de abundância das correntes enriquecida  $R_p$  e empobrecida  $R_w$ ;

Com esses dados são então calculados os parâmetros separativos a serem analisados, a saber os fatores de enriquecimento  $\beta$ , de empobrecimento  $\gamma$  e de separação  $\alpha$  e o poder de separação  $\delta U$ .

Especificamente, o trabalho constará da análise dos seguintes casos:

1. aplicação da técnica aos dados experimentais de ZIPPE [3.23], os últimos dados experimentais divulgados em literatura aberta, através do estudo de dois casos:

( a) caso 1: onde diversas configurações de montagem são testadas, sendo então definidas as variáveis de entrada:

- as diversas características de montagem,
- o fluxo de alimentação,

e as variáveis de saída:

- o fator de separação  $\alpha$ ,
- o poder de separação  $\delta U$ ,
- a potência consumida;

(b) caso2: onde uma das configurações do caso 1 é mais estudada, possibilitando a análise mais detalhada das respostas separativas, sendo as variáveis de entrada:

- fluxo de alimentação,
- velocidade periférica

e as variáveis de saída:

- o fator de separação  $\alpha$ ,
- o poder de separação  $\delta U$ ,
- a potência consumida.

2. modelagem dos parâmetros de uma dada centrífuga com uma dada configuração, operando próximo ao processo simétrico, tendo como variáveis de entrada:

- $Q_p$  : vazão de retirada do produto,
- $Q_w$  : vazão de retirada do rejeito,
- $p_p$  : pressão na linha de retirada do produto;

e como variáveis de saída as seguintes respostas:

- $p_F$  : pressão na linha de alimentação,
- $p_w$  : pressão na linha de retirada do rejeito,
- $R_p$  : razão de abundância do produto (enriquecido),
- $R_w$  : razão de abundância de rejeito (empobrecido);

lembrando que a razão de abundância molar da alimentação é sempre considerada a do urânio natural, a saber  $R_F=0.725\%$ , uma vez que a separação obtida independe da concentração do material processado.

3. modelagem de uma centrífuga operando em condições de processo assimétrico, com as variáveis de entrada:

- $F$  : fluxo de alimentação,
- $\theta$  : corte,
- $p_P$  : pressão na linha de retirada do produto;

e as variáveis de saída:

- $p_F$  : pressão na linha de alimentação,
- $p_W$  : pressão na linha de retirada do rejeito,
- $\delta U$  : poder de separação.

4. modelagem de um tipo de centrífugas, para o processo de separação simétrico, tendo como variáveis de entrada:

- $F$  : fluxo de alimentação,
- $p_P$  : pressão na linha de retirada do produto,
- $r_P$  : raio de coleta do coletor do produto,
- $r_W$  : raio de coleta do coletor do rejeito,
- $D_I$  : diâmetro do furo central do disco girante,
- $Z_E$  : comprimento da seção de enriquecimento,

e como variáveis de saída as seguintes respostas:

- $\delta U$  : poder de separação,
- $p_W$  : pressão na linha de retirada do rejeito.

O programa para treinamento e simulação via rede neural foi desenvolvido pelo Laboratório de Simulação e Controle de Processos do Departamento de Engenharia

Química da Escola Politécnica da USP em linguagem FORTRAN. Utiliza uma rede neural de três camadas, onde a informação segue em um único sentido (“feedforward neural network”), e realiza o treinamento pelo algoritmo de retro-propagação.

Para cada caso será realizado o treinamento de uma rede específica, com arquitetura a ser definida. Os modelos assim obtidos serão avaliados através da análise dos resíduos. Sempre que possível, será efetuada uma otimização do modelo, buscando o conjunto de variáveis de entrada que maximize a capacidade de separação da centrífuga. As técnicas a serem utilizadas nessas análises são apresentadas por BOX et. al. [3.24], DRAPER & SMITH [3.25] e HIMMELBLAU [3.26]. Especificamente a otimização numérica será baseada em BEVERIDGE & SCHECHTER [3.27], utilizando rotinas de cálculo descritas por KAHANER et. al. [3.28].

### 3.3 Notação

$D_I$	-	diâmetro do furo interno do disco girante da centrífuga
$E$	-	desvio (ou erro) quadrático (Eq. 3.3)
$F$	-	fluxo de alimentação da centrífuga
$f(S_v)$	-	função de ativação (Eq. 3.2)
$n_h$	-	número de neurônios na camada oculta
$n_i$	-	número de neurônios na camada de entrada = número de variáveis de entrada do modelo
$n_o$	-	número de neurônios na camada de saída = número de variáveis de saída (ou respostas) do modelo
No. Sets	-	número de apresentações dos dados de treinamento à rede neural
$O_k$	-	saída calculada pelo neurônio $k$ na camada de saída (Eq. 3.4)
$p_F$	-	pressão na linha de alimentação da centrífuga
$p_P$	-	pressão na linha de retirada do produto da centrífuga
$p_W$	-	pressão na linha de retirada do rejeito da centrífuga
$Q_P$	-	fluxo de retirada do produto da centrífuga

$Q_w$	-	fluxo de retirada do rejeito da centrífuga
$r$	-	número de dados experimentais no conjunto de treinamento
RMST	-	somatório de erros do “learning set”
RMSTT	-	somatório de erros do “test set”
$R_F$	-	razão de abundância da corrente de alimentação da centrífuga
$R_P$	-	razão de abundância da corrente de produto da centrífuga
$R_W$	-	razão de abundância da corrente de rejeito da centrífuga
$r_P$	-	raio de coleta do produto da centrífuga
$r_W$	-	raio de coleta do rejeito da centrífuga
$S_v$	-	soma ponderada de entradas no neurônio (Eq. 3.1)
$W_{u,v}$	-	conjunto de pesos internos da rede neural (notação genérica)
$W1_{i,j}$	-	conjunto de pesos entre a camada de entrada e a camada oculta
$W2_{j,k}$	-	conjunto de pesos entre a camada oculta e a camada de saída
$x_k$	-	variável de entrada k
$y_k$	-	variável de saída experimental k
$Z_E$	-	comprimento da seção de enriquecimento

### letras gregas

$\alpha$	-	fator de separação da centrífuga
$\beta$	-	fator de enriquecimento da centrífuga
$\delta U$	-	poder ou capacidade de separação da centrífuga
$\gamma$	-	fator de empobrecimento da centrífuga
$\eta$	-	fator de aceleração de convergência no treinamento de redes neurais
$\theta$	-	corte da centrífuga

### símbolo

*	-	notação para variáveis correspondentes ao processo de separação simétrico
---	---	---

### 3.4 Referências

- [3.1] HOSKINS,J.C.; HIMMELBLAU,D.M. Artificial neural network models of knowledge representation in chemical engineering. *Comput. Chem. Eng.*, v.12, n.9/19, p.881-890, 1988.
- [3.2] HOSKINS,J.C.; HIMMELBLAU,D.M. Fault detection and diagnosis using artificial neural networks, In: MAVROVOUNIOTS,M.L. (ed.) *Artificial Intelligence in Process Engineering*. New York, NY: Academic Press, 1990, p.123-160.
- [3.3] VENKATASUBRAMANIAM,V.; VAIDYANATHAN,R.; YAMAMOTO,Y. Process fault detection and diagnosis using neural networks – I: Steady state process. *Comput. Chem. Eng.*, v.14, n.7, p.699-712, 1990.
- [3.4] WATANABE,K.; MATSUDA,I.; KUBOTA,M.; HIMMELBLAU,D.M. Incipient fault diagnosis of chemical processes via artificial neural networks. *AIChE Journal*, v.35, n.11, p.1803-1812, 1989.
- [3.5] BHAT,N.V.; MINDERMAN Jr,P.A.; McAVOY,T.; WANG,N.S. Modeling chemical process systems via neural computation. *IEEE Control Systems Magazine*, v.4, p.24-30, 1990.
- [3.6] BHAT,N.; McAVOY,T. Use of neural nets for dynamic modeling and control of chemical process systems. *Comput. Chem. Eng.*, v.14, n.4/5, p.573-583, 1990.
- [3.7] UNGAR,L.H.; POWEL,B.A.; KAMENS,S.N. Adaptive networks for fault diagnosis and process control. *Comput. Chem. Eng.*, v.14, n.4/5, p.572-651,1990.
- [3.8] PSICHOGIOS,D.C.; UNGAR,L.H. Direct and indirect model based control using artificial neural networks. *Ind. Eng. Chem. Res.*, v.30, p.2564-2573, 1991.

- [3.9] SU,H.T.; McAVOY,T.; WERBOS,P. Long-term predictions of chemical processes using recurrent neural networks: A parallel training approach. *Ind. Eng. Chem. Res.*, v.31, p.1338-1352, 1992.
- [3.10] CHAN,W.M.; NASCIMENTO,C.A.O. Use of neural networks for modeling of olefin polymerization in high pressure tubular reactors. *J. Appl. Polymer Sci.*, v.53, p.1277-1289, 1994.
- [3.11] YIFTAH,S. Neural networks - Potential application in the nuclear industry: Preliminary comments and reflections. In: ISRAEL NUCLEAR SOCIETY ANNUAL MEETING, 1989. Yavne. **Proceedings**...., Mar. 13, 1989. Beer-Sheva. p.56-62. (INIS-mf-11503).
- [3.12] DENBY,B. Tutorial on neural network applications in high energy physics: A 1992 perspective. In: INTERNATIONAL WORKSHOP ON SOFTWARE ENGINEERING, ARTIFICIAL INTELLIGENCE (AI) AND NEURAL NETS FOR HIGH ENERGY AND NUCLEAR PHYSICS, 2., 13-18 Jan. 1992, L'Agelonde (France). **Proceedings**... (CONF-920172-7).
- [3.13] CUTTS,D.; HOFTUN,J.S.; NESIC,D.; SOMBORGER,A.; JONHSON,C.R.; ZELLER,R.T. Applications of neural networks in high energy physics. In: CONFERENCE ON COMPUTING IN HIGH ENERGY PHYSICS, Apr. 1990, Santa Fe, NM. **Proceedings**...[sl.:sn] 1990. (CONF-9004190-AIP).
- [3.14] PETERSON,C. Neural networks and high energy physics. In: PERRET-GALLIX,D.; WOJCIK,W. (eds.). *New computing techniques in physics research*. Paris: Institut National de Physique Nucleaire et de Physique des Particules (IN2P3), 1990. p.465-480. (ISBN 2-222-04514-2).
- [3.15] UHRIG,R.E. Application of neural networks to the operation of nuclear power plants. In: JSME/ASME JOINT INTERNATIONAL CONFERENCE ON NUCLEAR ENGINEERING, 4-7 Nov. 1991, Tokyo. **Proceedings**... Tokyo: Japan Society of Mechanical Engineers, 1991. v.2, p.365-369.

- [3.16] UHRIG,R.E. Neural networks and their potential application in nuclear power plants. In: NASER,J.A. *Expert Systems Applications for Electric Power Industry*. New York, NY, Hemisphere, 1991. p.1435-1446. (CONF-8900634).
- [3.17] UHRIG,R.E. Neural networks and their potential applications to nuclear power plants. In: INTERNATIONAL CONFERENCE ON FRONTIERS IN INNOVATIVE COMPUTING FOR THE NUCLEAR INDUSTRY, Jackson, WY, 15-18 Sep., 1991. **Proceedings...** Washington, DC: USDOE, 1991. (CONF-9109110-16).
- [3.18] TANABE,A.; YAMAMOTO,T.; SHINFUKU,K.; NAKAMAE,T. Neural network application to the survey of enrichment and local power. In: INTERNATIONAL CONFERENCE ON STRUCTURAL MECHANICS IN REACTOR TECHNOLOGY, 11. 1991, **Proceedings...** Tokyo: Atomic Energy Society of Japan, 1991. p.127-132.
- [3.19] ERYÜREK,E.; TÜRCKAN,E. Neural networks for sensor validation and plant-wide monitoring., Netherlands Energy Research Foundation (ECN), Aug., 1991. Petten. (ECN-RX-91-089).
- [3.20] ERYÜREK,E.; UPADHYAYA,B.R.; KAVAKLIOGLU,K. Hybrid digital processing and neural networks applications in PWRs. Tennessee Univ., Dept. of Nuclear Engineering Knoxville, 1991. Knoxville, TN. (CONF-9109110-10).
- [3.21] POLLARD,J.F.; BROUSSARD,M.R.; GARRISON,D.B.; SAN,K.Y. Process identification using neural networks. *Comput. Chem. Eng.*, v.16, n.4, p.253-270, 1992.
- [3.22] RUMELHART,D.; McCLELLAND,J. Parallel distributed processing explorations in the microstructure of cognition. Cambridge, Mass.: MIT, v.1, cap.8, 1986.
- [3.23] ZIPPE,G. *The development of short bowl ultra-centrifuges*. Charlottesville, VI: University of Virginia, research Laboratories for the Engineering Science, 1960. (ORO-315).

- [3.24] BOX,G.E.P.; HUNTER,W.G; HUNTER,J.S. *Statistics for Experimenters: An Introduction to Design, Data Analysis and Model Building*. New York, NY: Wiley, 1978.
- [3.25] DRAPER,N.R.; SMITH,H. *Applied Regression Analysis*. 2. ed. New York, NY: Wiley, 1981.
- [3.26] HIMMELBLAU,D.M. *Process Analysis by Statistical Methods*. New York, NY: Wiley, 1970.
- [3.27] BEVERIDGE,G.S.G.; SCHECHTER,R.S. *Optimization: Theory and Practice*. Tokyo: McGraw-Hill Kogakusha,, 1970.
- [3.28] KAHANER,D.; MOLER,C.; NASH,S. *Numerical Methods and Software*. New Jersey, NJ: Prentice-Hall, 1989.

## **4 MODELAGEM DOS RESULTADOS EXPERIMENTAIS DE ZIPPE**

O processo do enriquecimento do urânio pela centrífuga a gás teve, no período da 2ª Guerra Mundial, um grande interesse por parte das potências. Nessa época então teve início intensa pesquisa, tanto no campo teórico como no campo experimental. Uma visão histórica do desenvolvimento do processo nessa época é apresentada por JORDAN [4.1].

As bases da teoria da separação pelo processo da centrifugação foram estabelecidas pelos Estados Unidos da América por COHEN e colaboradores, e pela Alemanha por MARTIN e KUHN. Paralelamente foram construídas centrífugas a gás sob a coordenação de BEAMS nos Estados Unidos e por GROTH na Alemanha. Na extinta União Soviética, no período de 1946 a 1954, um grupo de cientistas soviéticos e alemães, sob a coordenação de STEENBECK, SCHEFFEL e ZIPPE também se dedicou ao desenvolvimento de centrífugas a gás para o enriquecimento do urânio. Mais tarde em 1954 ZIPPE, ainda na ex-URSS, desenvolveu uma centrífuga curta, baseada num princípio de construção totalmente diferente das anteriores. Essa centrífuga apresentou resultados excelentes, tanto do ponto de vista mecânico como com relação a seu desempenho separativo, que se tornou a precursora das centrífugas modernas. No período de 1958 a 1960 ZIPPE [4.2] reproduziu na Universidade de Virgínia (USA), sob a supervisão de BEAMS, o trabalho desenvolvido na União Soviética com as centrífugas curtas.

Este trabalho ainda pôde ser integralmente divulgado, apresentando todos os detalhes construtivos e operacionais das centrífugas bem como os resultados experimentais obtidos nos ensaios para enriquecimento de urânio. Em meados de 1960 a Comissão Norte-Americana de Energia Atômica proibiu a divulgação de qualquer informação técnica ou


operacional relativa às centrífugas desenvolvidas nos Estados Unidos. Alguns meses mais tarde a Alemanha e a Holanda tomaram decisão semelhante. Com isso, a partir do final de 1960 não se conhece nenhuma publicação aberta sobre os aspectos tecnológicos desse processo.

#### **4.1 Os ensaios de separação isotópica de ZIPPE**

O presente trabalho utiliza os dados obtidos por ZIPPE [4.2] em sua pesquisa na Universidade de Virgínia, para a modelagem via redes neurais do comportamento separativo das centrífugas então desenvolvidas.

A centrífuga utilizada está representada esquematicamente na Figura 4.1. O rotor gira dentro de um recipiente mantido em vácuo, denominado carcaça, ao redor de seu eixo sobre um mancal de agulha. Na extremidade superior existe um sistema de mancal magnético para garantir a centralização do rotor sem contatos mecânicos entre as partes estacionárias e as rotativas. Um sistema de três tubos para a introdução e extração do gás de processo passa por uma abertura e atinge o interior do rotor. O tubo de alimentação termina na parte intermediária do rotor. Isso permite variações na altura e na direção na qual a corrente de gás é introduzida. Os outros dois tubos terminam em extremidades opostas do rotor e possuem nas pontas tubos de pitot com a forma de um gancho montados em um plano perpendicular ao do eixo de rotação do cilindro. Esses dispositivos, chamados de coletores, usam a alta pressão de impacto do gás na região periférica do rotor para efetuar o transporte do gás. O coletor superior tem ainda a função de induzir o escoamento em contracorrente do gás através da redução localizada que provoca na velocidade angular do gás. O outro coletor é protegido por um disco que gira solidário ao rotor. A forma e o tamanho dos coletores, bem como o disco girante, foram largamente alterados ao longo dos ensaios de separação. As montagens testadas foram com discos girantes instalados tanto em uma extremidade do rotor, conforme mostrado na Figura 4.1, como em ambas extremidades simultaneamente. Na superfície interna da carcaça é montado um dispositivo que em

combinação com o cilindro em rotação atua como uma bomba turbo-molecular que tem a função de manter o vácuo ao redor do rotor.



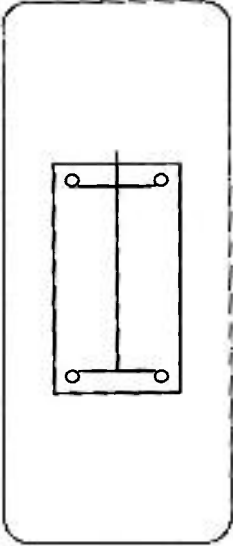
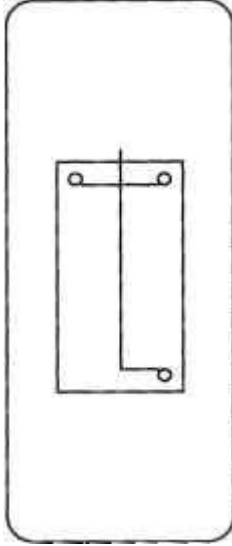
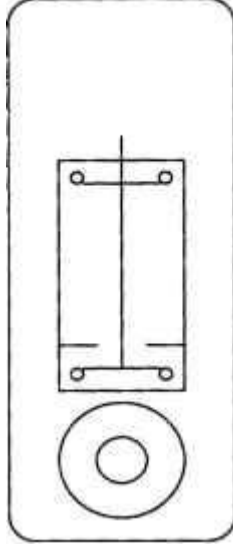
**FIGURA 4.1:** Esquema da centrífuga de vaso curto desenvolvida por ZIPPE

As dimensões básicas da centrífuga de ZIPPE são:

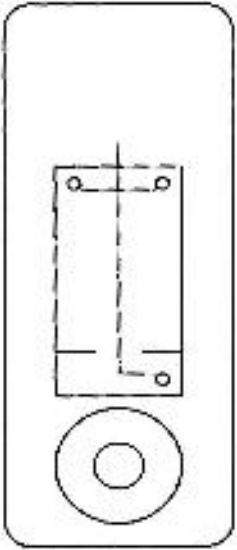
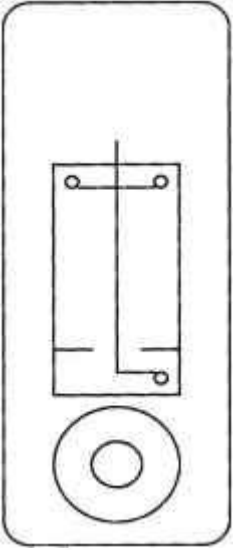
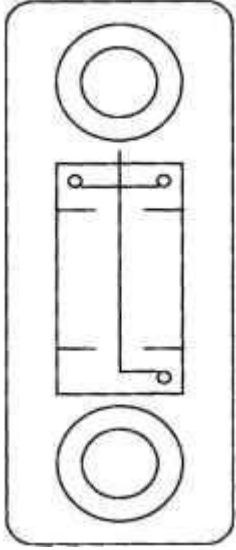
- ◆ comprimento útil  $Z = 0.305 \text{ m}$
- ◆ diâmetro interno do rotor  $\phi = 0.0741 \text{ m}$
- ◆ relação de aspecto  $Z/\phi = 4.1$
- ◆ frequência de rotação  $f = 1500 \text{ Hz}$
- ◆ velocidade periférica  $v = 350 \text{ m/s}$

ZIPPE pesquisou cerca de 40 diferentes arranjos de coletores e discos, porém em seu relatório só apresenta os resultados de 9 sistemas, considerados pelo autor como sendo típicos. Os resultados considerados mais relevantes são apresentados nas Tabelas 1 e 2 do relatório de ZIPPE [4.2]. Foram ainda realizados testes com diferentes sistemas de alimentação de gás no interior do rotor, com alteração da posição axial de introdução. Para estudar o uso das diferentes configurações de montagem testadas por ZIPPE, usaremos os dados das Tabelas 1, 2 e 3 do relatório de ZIPPE [4.2]. Esses dados são reproduzidos e codificados para serem apresentados à rede neural na Tabela 4.1. Será então procurada a configuração ótima, que apresente o máximo valor do poder de separação  $\delta U$ . Este estudo será doravante denominado de CASO 1.

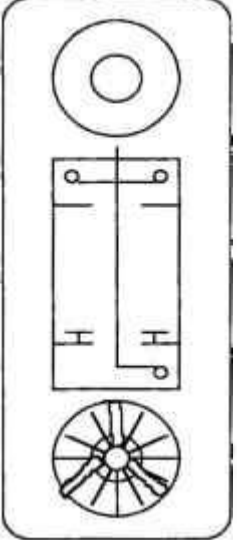
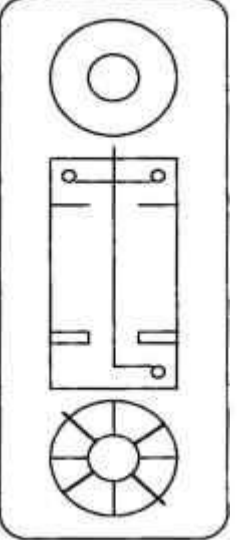
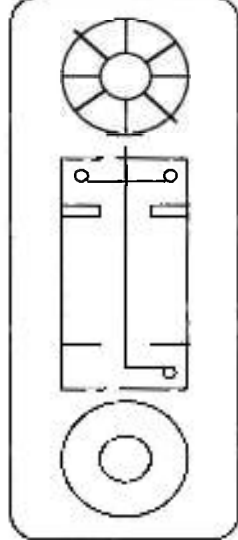
**TABELA 4.1**  
**Dados experimentais para o estudo do CASO 1**  
 (extraído de ZIPPE [4.2])

Sist. No.		10	5a	4
				
<b>Coletor superior</b>		duplo - 2	duplo - 2	duplo - 2
<b>Coletor inferior</b>		duplo - 2	simples - 1	duplo - 2
<b>Disco Superior</b>	existência	não - 0	não - 0	não - 0
	NPH <sup>(1)</sup>	não - 0	não - 0	não - 0
	ranhuras	não - 0	não - 0	não - 0
<b>Disco Inferior</b>	existência	não - 0	não - 0	sim - 1
	NPH <sup>(1)</sup>	não - 0	não - 0	12
	ranhuras	não - 0	não - 0	não - 0
	"aranha"	não - 0	não - 0	não - 0
<b>EDCH <sup>(2)</sup></b>		0	0	0.2
<b>RFL <sup>(3)</sup></b>		0.5	0.5	0.5
<b>Fluxo de Alimentação <sup>(4)</sup> (mg/s)</b>		-	4.6, 3.2	2.8
<b><math>\alpha</math></b>		-	1.123, 1.132	1.15
<b><math>\delta U \times 10^6</math> <sup>(5)</sup> (g/s)</b>		-	7.73, 6.14	6.83
<b>Potência (W)</b>		-	10.8, 7.9	14
<b>Observações</b>		Praticamente nenhuma separação		Rotor ficou muito quente

**TABELA 4.1 (cont.)**  
**Dados experimentais para o estudo do CASO 1**  
 (extraído de ZIPPE [4.2])

Sist. No.		5		6				13	
									
<b>Coletor superior</b>		duplo - 2		duplo - 2				duplo - 2	
<b>Coletor inferior</b>		simples - 1		simples - 1				simples - 1	
<b>Disco Superior</b>	existência	não - 0		não - 0				sim - 1	
	NPH <sup>(1)</sup>	não - 0		não - 0				12	
	ranhuras	não - 0		não - 0				não - 0	
<b>Disco Inferior</b>	existência	sim - 1		sim - 1				sim - 1	
	NPH <sup>(1)</sup>	12		12				não - 0	
	ranhuras	não - 0		não - 0				não - 0	
	"aranha"	não - 0		não - 0				não - 0	
<b>EDCH <sup>(2)</sup></b>		0.2		0.2				0.5	
<b>RFL <sup>(3)</sup></b>		0.5		0.5				0.33	
<b>Fluxo de Alimentação <sup>(4)</sup> (mg/s)</b>		3.81,	2.55	5.48,	0.5,	4.7,	7.4	6.18,	1.637
<b><math>\alpha</math></b>		1.193,	1.216	1.155,	1.267,	1.157,	1.125	1.138,	1.228
<b><math>\delta U \times 10^6</math> <sup>(5)</sup> (g/s)</b>		14.79,	12.15	14.20,	3.48,	12.47,	12.82	12.89,	8.58
<b>Potência (W)</b>		7.9,	6.25	8.9,	6.13,	9.1,	11.1	10.5,	7.7
<b>Observações</b>									

**TABELA 4.1 (cont.)**  
**Dados experimentais para o estudo do CASO 1**  
 (extraído de ZIPPE [4.2])

Sist. No.	29	30	31
			
<b>Coletor superior</b>	duplo - 2	duplo - 2	duplo - 2
<b>Coletor inferior</b>	simples - 1	simples - 1	simples - 1
<b>Disco Superior</b>	existência	sim - 1	sim - 1
	NPH <sup>(1)</sup>	24	24
	ranhuras	não - 0	não - 0
<b>Disco Inferior</b>	existência	sim - 1	sim - 1
	NPH <sup>(1)</sup>	0	12
	ranhuras	sim - 1	sim - 1
	“aranha”	sim - 3	não - 0
<b>EDCH</b> <sup>(2)</sup>	0.2	0.2	0.2
<b>RFL</b> <sup>(3)</sup>	0.5	0.5	0.5
<b>Fluxo de Alimentação</b> <sup>(4)</sup> (mg/s)	muito baixo - 0.1	muito baixo - 0.1	5.53, 3.8, 0.477
<b><math>\alpha</math></b>	1.355	1.355	1.180, 1.202, 1.274
<b><math>\delta U \times 10^6</math></b> <sup>(5)</sup> (g/s)	1.14	1.14	18.89, 16.03, 3.48
<b>Potência</b> (W)	6.9	10.5	10, 6.6, 4.6
<b>Observações</b>	sem tempo de otimizar o $\delta U$		

onde:

<sup>(1)</sup> NPH = Número de furos periféricos

<sup>(2)</sup> EDCH = Diâmetro equivalente do furo central do disco ou discos, definido por

$$\text{EDCH} = \frac{\text{diam. do furo central}}{\text{diam. do rotor}}$$

<sup>(3)</sup> RFL = Posição de alimentação relativa, definida pela relação

$$\text{RFL} = \frac{\text{distancia da tampa superior para a posição de alimentação}}{\text{altura do rotor}}$$

<sup>(4)</sup> quando o fluxo de alimentação era indicado como “muito baixo”, nós assumimos o valor de 0.1 mg/s

<sup>(5)</sup> calculado pela expressão

$$\delta U = F \cdot \theta (1 - \theta) \frac{\alpha - 1}{\alpha + 1} \cdot \ln(\alpha) \quad (4.1)$$

onde: F é o fluxo de alimentação,

$\alpha$  é o fator de separação,

$\theta$  é o corte, definido pela relação entre os fluxos de produto e de alimentação; assumido 0.5

O sistema No. 6, cuja configuração se encontra descrita na Tabela 4.1, foi mais exaustivamente testado. Os resultados desses testes são apresentados nas Figuras 31, 36, 37 e 38 e da Tabela 3 do relatório de ZIPPE [4.2] e reproduzidos aqui na Tabela 4.2. Esses dados serão utilizados para modelar o desempenho separativo da centrífuga de ZIPPE montada com o sistema No. 6. Este será denominado de CASO 2.

**TABELA 4.2**  
**Dados experimentais para o estudo do CASO 2 - Sistema No. 6**  
 (extraído de ZIPPE [4.2])

<b>Velocidade periférica <math>v</math> (m/s)</b>	<b>Fluxo de alimentação <math>F</math> (mg/s)</b>	<b>Fator de separação <math>\alpha</math></b>	<b>Poder de separação <math>\delta U</math> (g/s)</b>	<b>Potência consumida (W)</b>
350	2.20	1.048	0.6 E-6	4.30
350	2.50	1.062	1.4 E-6	4.10
350	3.10	1.100	3.7 E-6	4.70
350	3.70	1.126	6.7 E-6	5.80
350	3.90	1.126	7.8 E-6	6.50
350	4.30	1.141	9.7 E-6	7.35
350	4.90	1.139	11.4 E-6	7.60
350	5.30	1.134	12.1 E-6	8.30
350	5.70	1.130	11.5 E-6	8.70
350	6.10	1.130	12.2 E-6	9.20
350	6.50	1.108	12.0 E-6	10.50
350	4.72	1.157	12.7 E-6	9.10
350	5.40	1.155	13.9 E-6	8.90
350	7.39	1.125	12.7 E-6	11.10
245	0.80	1.080	0.5 E-6	7.10
245	1.20	1.088	0.9 E-6	7.80
245	1.50	1.088	1.1 E-6	8.20
245	1.80	1.088	1.1 E-6	9.00
245	2.10	1.078	1.5 E-6	9.40
245	2.30	1.080	1.5 E-6	9.50
245	2.50	1.078	1.7 E-6	10.30
245	2.90	1.074	1.7 E-6	10.80
245	3.30	1.065	1.6 E-6	11.60
303	1.50	1.053	1.5 E-6	5.30
303	3.20	1.094	3.2 E-6	7.20
303	4.10	1.115	5.1 E-6	8.20
303	5.10	1.970	5.5 E-6	9.20
303	5.30	1.094	5.5 E-6	9.70
303	6.70	1.085	5.3 E-6	10.90
303	6.80	1.076	4.5 E-6	11.50
350	1.50	1.043	0.5 E-6	4.80
350	2.80	1.104	3.9 E-6	5.80
350	4.10	1.128	8.5 E-6	7.20
350	5.20	1.144	12.0 E-6	7.80
350	5.30	1.134	11.4 E-6	7.80
350	5.80	1.136	12.5 E-6	8.90
350	6.40	1.132	11.5 E-6	9.40
350	6.50	1.126	12.5 E-6	9.80

## 4.2 Estudo do CASO 1

No CASO 1 serão tratados os dados obtidos nos ensaios com diferentes arranjos. Os dados utilizados são os apresentados na Tabela 4.1, excluindo os dados obtidos com o sistema No. 10. Esses dados são apresentados à rede neural no processo de treinamento considerando as seguintes variáveis como entrada:

- coletor inferior (1=simples, 2=duplo)
- existência do disco superior (0=não, 1=sim)
- número de orifícios periféricos do disco superior
- ranhuras no disco superior (0=não, 1=sim)
- existência do disco inferior (0=não, 1=sim)
- número de orifícios periféricos do disco inferior
- ranhuras no disco inferior (0=não, 1=sim)
- “aranha” no disco inferior (0=não, 3=sim, com 3 abas)
- diâmetro equivalente do furo central do disco
- posição de alimentação relativa
- fluxo de alimentação (mg/s)

e com as seguintes variáveis de saída:

- fator de separação  $\alpha$
- potência consumida (W)
- poder de separação  $\delta U$  (g/s)

Os dados experimentais foram divididos em dois grupos: o “learning set” com 12 conjuntos de dados e o “test set” com 4 conjuntos de dados, cujos valores se encontram no Apêndice 4.7.1. O “learning set” foi usado para o treinamento da rede neural e o “test set” para verificar os resultados fornecidos pela rede ao longo do treinamento. Foi utilizada uma rede neural de três camadas treinada pelo algoritmo de retro-propagação.

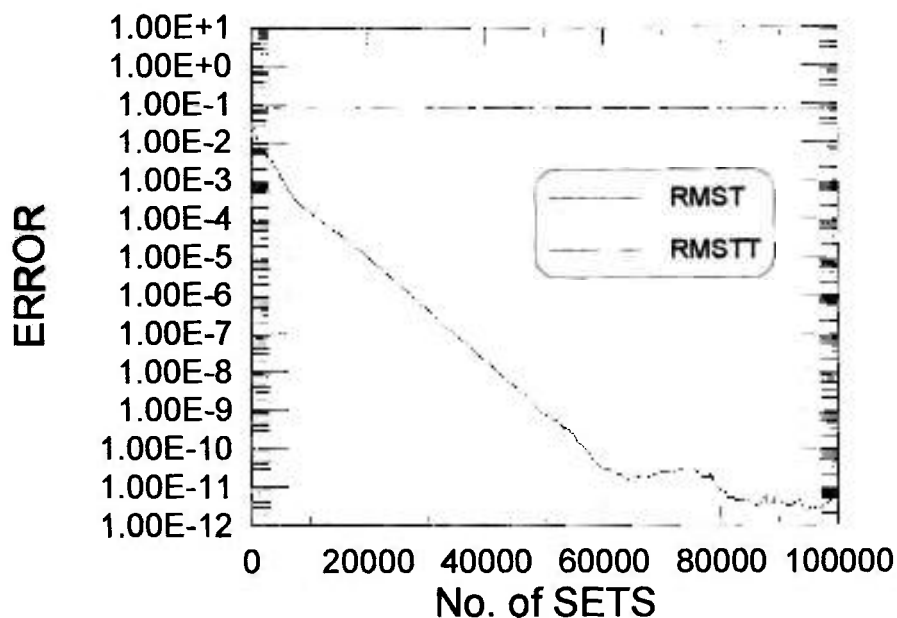
Foram testadas sete diferentes redes, com 4 (quatro) a 10 (dez) neurônios na camada oculta. Foram permitidas até 100.000 apresentações dos dados à rede neural para o treinamento. A tabela 4.3 mostra os erros obtidos no treinamento de cada uma das redes para os dois grupos, o “learning set” e o “test set”.

**TABELA 4.3**

Erro total calculado após o treinamento de redes neurais com diferentes números de neurônios na camada oculta NH para o CASO 1

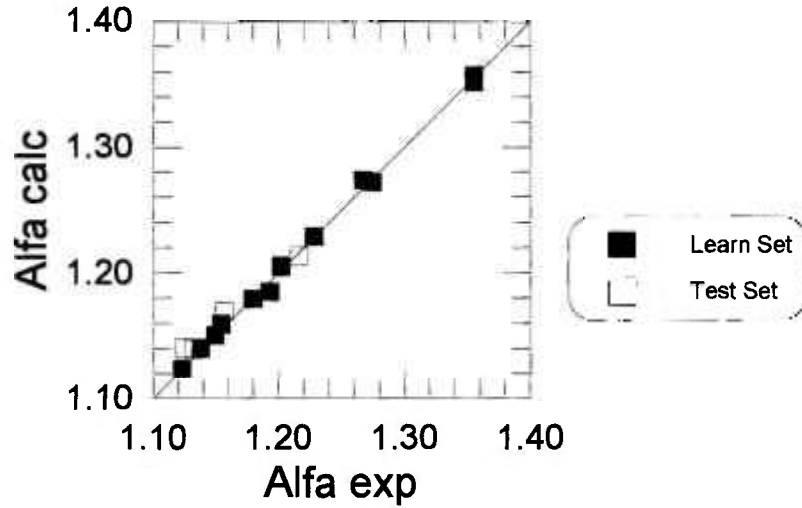
NH	“LEARNING SET”		“TEST SET”	
	No. de apresentações	RMST	No. de apresentações	RMSTT
4	100 000	$9.31 \times 10^{-4}$	36 400	$1.18 \times 10^{-1}$
5	100 000	$4.04 \times 10^{-5}$	6 600	$9.13 \times 10^{-2}$
<b>6</b>	<b>95 600</b>	<b><math>2.26 \times 10^{-12}</math></b>	<b>31 300 - 100 000</b>	<b><math>7.87 \times 10^{-2}</math></b>
7	100 000	$1.97 \times 10^{-7}$	92 000 - 100 000	$7.14 \times 10^{-2}$
8	100 000	$6.53 \times 10^{-11}$	44 000 - 100 000	$5.53 \times 10^{-2}$
9	97 200	$4.23 \times 10^{-12}$	54 600 - 100 000	$4.36 \times 10^{-2}$
10	100 000	$5.57 \times 10^{-12}$	38 900 - 100 000	$5.33 \times 10^{-2}$

A rede escolhida foi a com 6 (seis) neurônios na camada oculta, apesar de se observar o menor valor de erro para o “test set” na rede de 9 neurônios. As redes com 6 e 9 neurônios apresentaram os mesmos resultados, então decidiu-se escolher a rede com 6 neurônios para evitar super-ajuste (POLLARD [4.3]). O problema do super-ajuste é observado na forma de irregularidades na superfície de resposta, como por exemplo rugas ou cristas numa resposta sabidamente tênue. Por outro lado, o “test set” possuía um número muito pequeno de dados, o que tira a importância do ajuste deste conjunto de dados. A soma dos erros em função do número de apresentações é mostrada na Figura 4.2 para a rede com 6 neurônios.

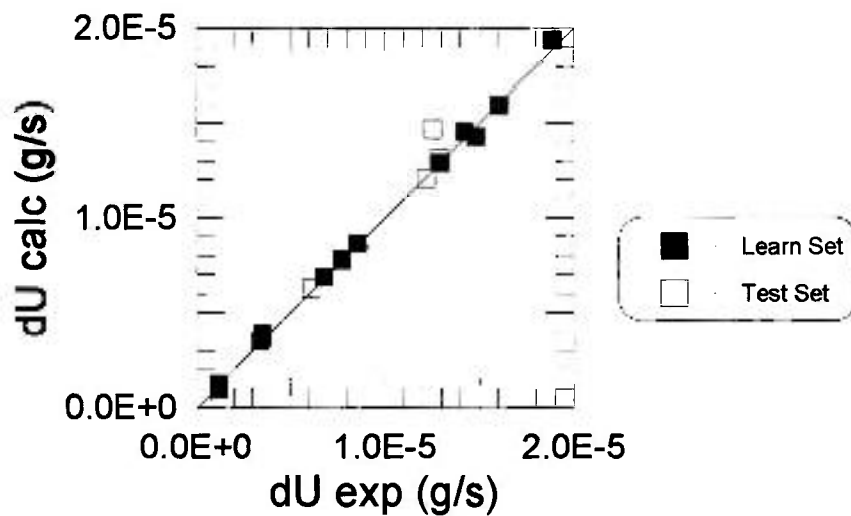


**FIGURA 4.2:** Erro global no treinamento para a rede neural com 6 neurônios na camada oculta para o CASO 1: “learning set” e “test set” ao longo do número de apresentações

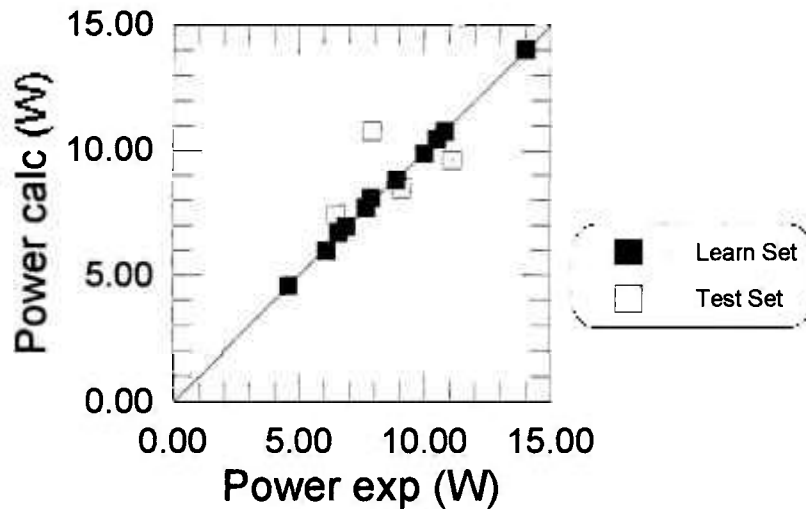
A comparação dos valores calculados pela rede neural com os valores experimentais das variáveis de saída  $\alpha$ ,  $\delta U$  e potência é feita através dos gráficos das Figuras 4.3, 4.4 e 4.5 respectivamente utilizando os dados do Apêndice 4.7.2. O ajuste entre os valores experimentais e os calculados mostrou-se bom. Infelizmente não dispomos de informações acerca dos erros experimentais relativos a esses dados, para proceder a uma análise estatística da precisão da previsão da rede neural. Os pesos escolhidos após o treinamento da rede neural se encontram no Apêndice 4.7.3.



**FIGURA 4.3:** Comparação entre os valores experimentais do fator de separação  $\alpha$  e os calculados pela rede neural



**FIGURA 4.4:** Comparação entre os valores experimentais do poder de separação  $\delta U$  e os calculados pela rede neural



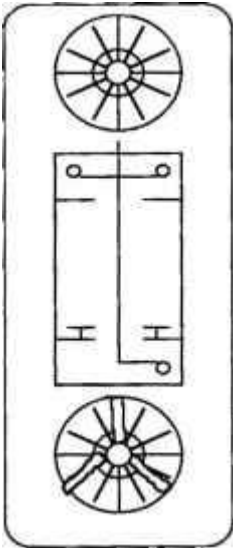
**FIGURA 4.5:** Comparação entre os valores experimentais da potência consumida e os calculados pela rede neural


### 4.3 Otimização da centrífuga do CASO 1

A rede neural treinada no CASO 1 representa uma centrífuga montada com diversos coletores e discos girantes. Procedemos então a uma busca na solução da rede procurando a combinação que resultasse o maior valor do poder de separação  $\delta U$ . Foi calculado o desempenho separativo de diferentes centrífugas utilizando os coletores e discos girantes descritos na Tabela 4.1, com fluxos de alimentação variando entre zero e 10 mg/s. A rede neural calculou um total de 36.288 diferentes soluções. O sistema que apresentou o melhor resultado é apresentado na Tabela 4.4, que corresponde a um sistema diferente daqueles testados por ZIPPE [4.2].

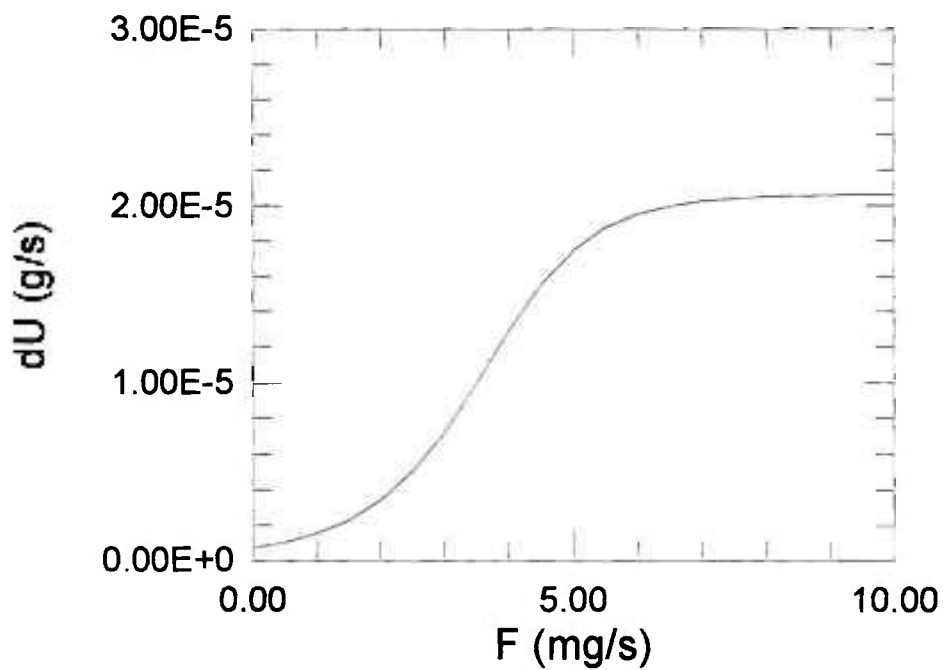
O desempenho separativo da centrífuga ótima, bem como de qualquer outra configuração desejada, pode agora ser previsto através da rede neural. Os valores esperados para o fator de separação  $\alpha$  e para o poder de separação  $\delta U$  são representados pelas Figuras 4.6 e 4.7, e a potência consumida pela Figura 4.8.

**TABELA 4.4**  
Centrífuga otimizada


		
<b>Coletor superior</b>		duplo - 2
<b>Coletor inferior</b>		simples - 1
<b>Disco superior</b>	existência	sim - 1
	NPH	24
	aletas	sim - 1
<b>Disco inferior</b>	existência	sim - 1
	NPH	24
	aletas	sim - 1
	“aranha”	sim - 3
<b>EDCH</b>		0.2
<b>RFL</b>		0.3
<b>Fluxo de Alimentação (mg/s)</b>		9.5
$\alpha$		1.199
$\delta U \times 10^5$ (g/s)		2.06
<b>Potência (W)</b>		12.6



**FIGURA 4.6:** Previsão do fator de separação  $\alpha$  em função do fluxo de alimentação  $F$  para a centrífuga ótima



**FIGURA 4.7:** Previsão do poder de separação  $\delta U$  em função do fluxo de alimentação  $F$  para a centrífuga ótima



**FIGURA 4.8:** Previsão da potência consumida em função do fluxo de alimentação  $F$  para a centrífuga ótima

#### 4.4 Estudo do CASO 2

No CASO 2 serão tratados os dados obtidos nos experimentos realizados com o sistema No. 6, cuja configuração é descrita na Tabela 4.1. Os dados utilizados são os da Tabela 4.2. Para cada velocidade analisada foi acrescentado um valor de referência (“bias”) representando a condição de fluxo de alimentação nulo, conseqüentemente com poder de separação zero e fator de separação 1.0. A potência consumida nestas condições foi obtida por extrapolação das curvas apresentadas por ZIPPE [4.2]. Esses dados são apresentados à rede neural com as seguintes variáveis de entrada:

- fluxo de alimentação  $F$  (mg/s)
- velocidade periférica  $v$  (m/s)

e com as seguintes variáveis de saída:

- fator de separação  $\alpha$
- potência consumida (W)
- poder de separação  $\delta U$  (g/s)

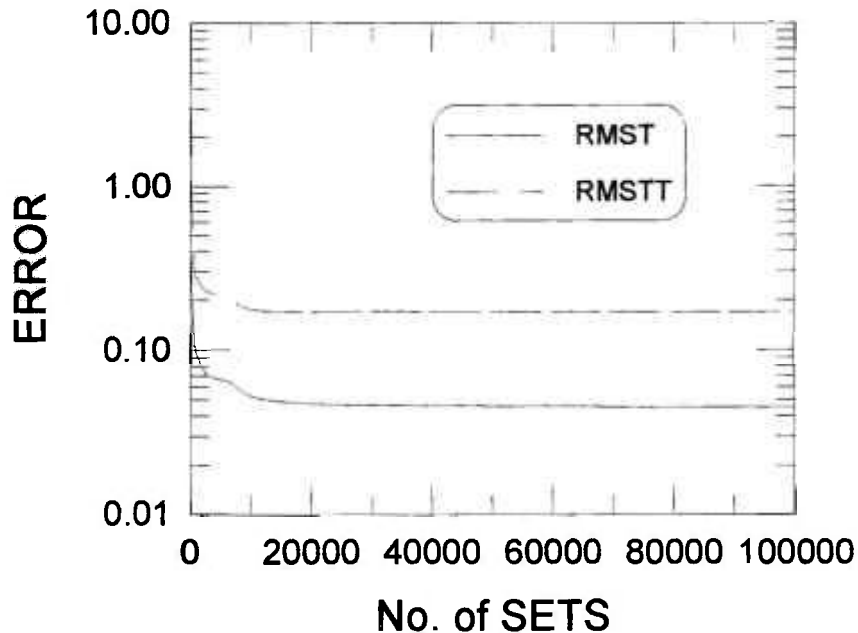
Os dados, como no caso anterior, foram divididos em dois grupos: o “learning set” com 21 conjuntos de dados e o “test set” também com 21 conjuntos de dados. O Apêndice 4.7.4 traz os valores utilizados no “learning set” e no “test set”. Foram verificadas nove diferentes redes neurais, possuindo de 4 (quatro) a 12 (doze) neurônios na camada oculta. O número máximo de apresentações permitido na fase de treinamento foi novamente de 100.000. A Tabela 4.5 traz os erros totais calculados para o “learning set” e para o “test set” de cada rede avaliada.

Apesar da rede neural com 8 neurônios na camada interna apresentar os menores erros, a rede que melhor representa o processo, sem a ocorrência de super-ajuste, é a rede com 6 (seis) neurônios. A soma dos erros ao longo do treinamento, isto é em função do número de apresentações, da rede escolhida se encontra representada na Figura 4.9.

**TABELA 4.5**

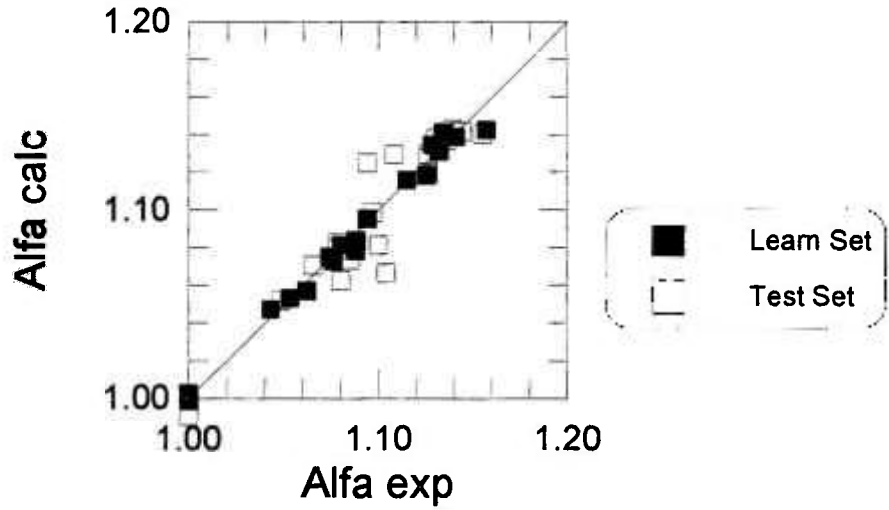
Erro total calculado após o treinamento de redes neurais com diferentes números de neurônios na camada oculta NH para o CASO 2

NH	“LEARNING SET”		“TEST SET”	
	No. de apresentações	RMST	No. de apresentações	RMSTT
4	9 500	0.0937	12 300	0.2740
5	100 000	0.0570	46 400	0.1981
<b>6</b>	<b>100 000</b>	<b>0.0452</b>	<b>100 000</b>	<b>0.1696</b>
7	100 000	0.0466	69 300	0.1892
8	100 000	0.0304	100 000	0.1445
9	100 000	0.0372	61 000	0.1539
10	100 000	0.0328	67 000	0.1475
11	100 000	0.0302	94 900	0.1474
12	100 000	0.0314	83 600	0.1529

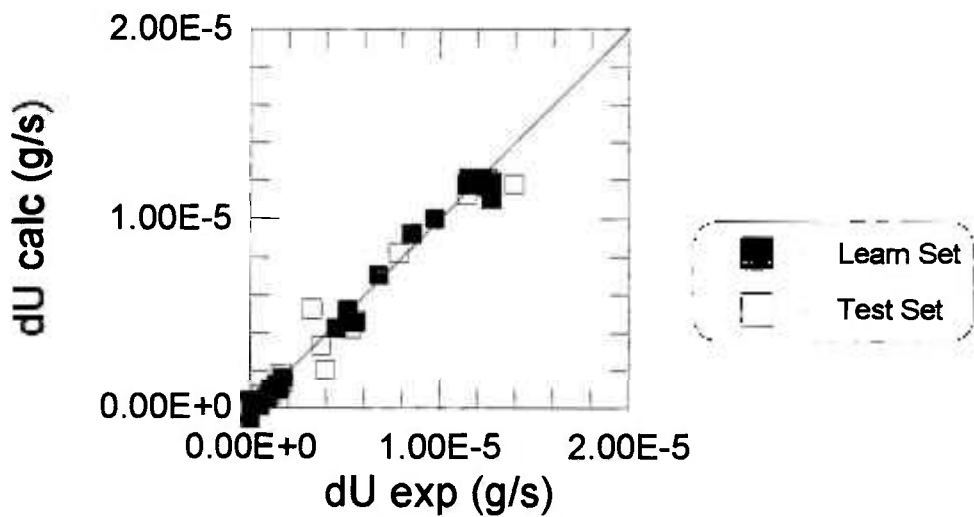


**FIGURA 4.9:** Erro global no treinamento para a rede neural com 6 neurônios na camada oculta para o CASO 2: “learning set” e “test set” ao longo do número de apresentações

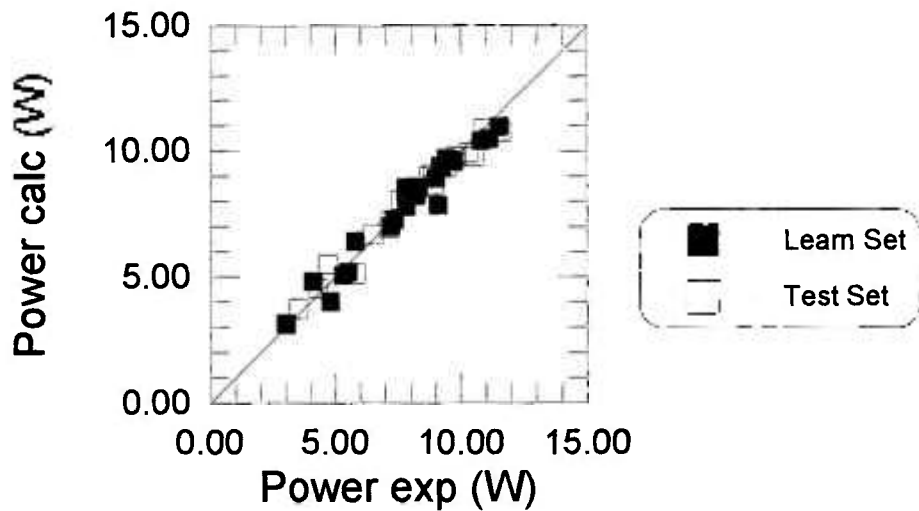
O procedimento para definição dos pesos foi semelhante ao do caso anterior, isto é, são escolhidos os pesos que minimizam os erros do “test set” para a rede neural com 6 neurônios na camada oculta. A comparação entre os valores experimentais e calculados pela rede das variáveis  $\alpha$ ,  $\delta U$  e potência é mostrada pelas Figuras 4.10, 4.11 e 4.12, respectivamente, cujos valores estão tabelados no Apêndice 4.7.5. O ajuste entre os dados experimentais e os valores calculados é satisfatório. Normalmente os dados do “learning set” são bem representados por uma rede neural (redes neurais do tipo utilizado no presente trabalho são consideradas aproximadores universais (HORNIK [4.4])). O mais importante neste caso é o bom ajuste observado no “test set”. Os pesos escolhidos se encontram relacionados no Apêndice 4.7.6.



**FIGURA 4.10:** Comparação entre os valores experimentais do fator de separação  $\alpha$  e os calculados pela rede neural



**FIGURA 4.11:** Comparação entre os valores experimentais do poder de separação  $\delta U$  e os calculados pela rede neural




**FIGURA 4.12:** Comparação entre os valores experimentais da potência consumida e os calculados pela rede neural

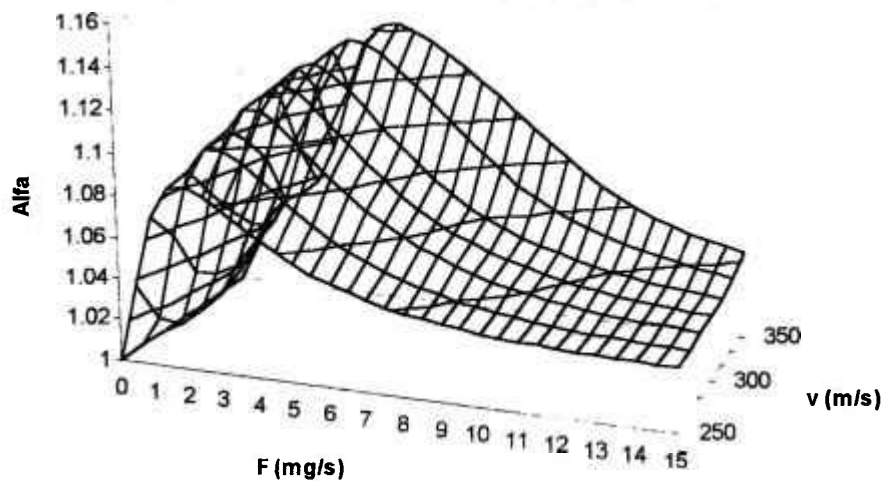
Esta rede neural foi treinada para representar a centrífuga de ZIPPE, montada com o sistema No. 6. A solução da rede foi mapeada em uma malha dentro do domínio dos dados do “learning set”, com exceção do fluxo de alimentação, que foi ligeiramente extrapolado. A Figura 4.13 representa a solução do poder de separação  $\delta U$  em função do fluxo de alimentação  $F$  e da velocidade periférica  $v$ . Da mesma forma, as Figuras 4.14 e 4.15 mostram a variação do fator de separação  $\alpha$  e a solução para a potência consumida, respectivamente.

Essas superfícies demonstram respostas contínuas e tênues, como esperado. O poder de separação aumenta com o fluxo de alimentação até um máximo, e depois decresce, definindo um fluxo de alimentação ótimo para cada velocidade periférica. O fator de separação também assume um valor máximo. Seu crescimento inicial é provavelmente causado pelo estabelecimento do perfil interno de escoamento em contracorrente. A queda do fator de separação com o fluxo de alimentação é característica de qualquer sistema de separação em contracorrente, à medida em que seu equilíbrio é perturbado. Essas tendências são acentuadas com o aumento da velocidade periférica, como prevê a teoria. O consumo de potência aumenta com o fluxo de alimentação, e os maiores valores são


observados nas velocidades periféricas mais baixas, devido à menor eficiência da bomba turbo-molecular.



**FIGURA 4.13:** Superfície de resposta do poder de separação  $\delta U$  em função da velocidade periférica  $v$  e do fluxo de alimentação  $F$

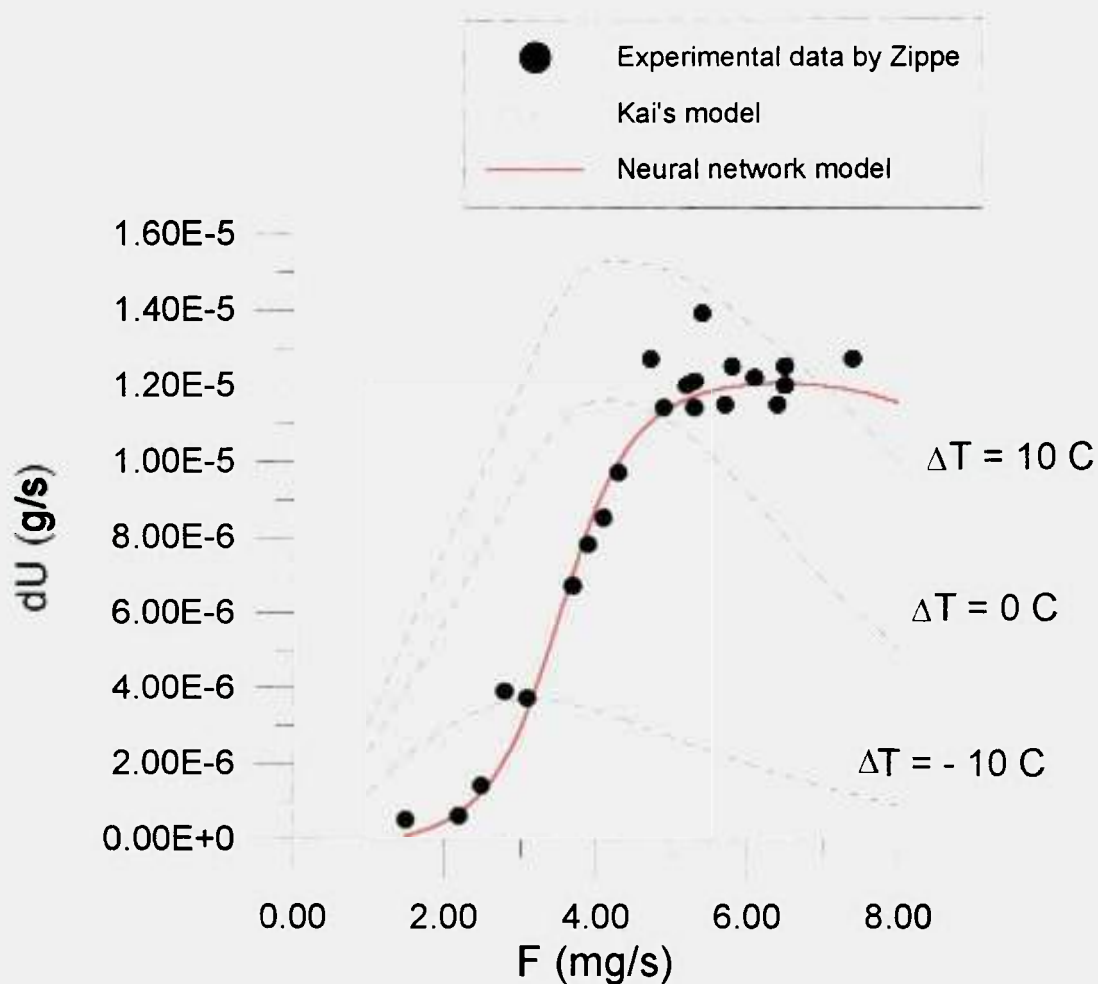


**FIGURA 4.14:** Superfície de resposta do fator de separação  $\alpha$  em função da velocidade periférica  $v$  e do fluxo de alimentação  $F$



**FIGURA 4.15:** Superfície de resposta do consumo de potência em função da velocidade periférica  $v$  e do fluxo de alimentação  $F$

Finalmente podemos comparar o modelo obtido através do treinamento da rede neural com um modelo fenomenológico, apresentado por KAI [4.5], para a velocidade de 350 m/s. A Figura 4.16 mostra essa comparação na forma de um gráfico do poder de separação  $SU$  em função do fluxo de alimentação  $F$ . KAI [4.5] sugere que a diferença de temperatura entre as tampas superior e inferior do rotor  $\Delta T$  seja de  $10^\circ\text{C}$  para o fluxo de alimentação  $F=3$  mg/s,  $0^\circ\text{C}$  em  $F=4.5$  mg/s e  $10^\circ\text{C}$  em  $F=6$  mg/s, concluindo que seu modelo apresenta uma boa concordância com os dados experimentais de ZIPPE [4.2]. Essas temperaturas não foram medidas por ZIPPE, por isso não são levadas em consideração na modelagem pela rede neural, apesar de saber-se que o perfil de temperaturas do rotor varia com o fluxo de alimentação. No entanto alguns dados de temperatura foram obtidos por ZIPPE [4.2] para uma configuração de montagem diferente, e a diferença entre as temperaturas das tampas não ultrapassava  $3^\circ\text{C}$ .



**FIGURA 4.16:** Comparação entre os dados experimentais de ZIPPE [4.2], o modelo teórico proposto por KAI [4.5] e o modelo obtido pela rede neural

A previsão obtida pela rede neural, por sua vez, apresenta um ajuste muito preciso. No entanto essa técnica de modelagem deve ser usada muito cuidadosamente uma vez que não está fundamentada em fenômenos básicos do processo.

## 4.5 Conclusão

Através da análise dos dados experimentais de ZIPPE [4.2] verificamos a viabilidade do emprego da simulação via redes neurais dos parâmetros separativos e operacionais de ultracentrífugas no enriquecimento do urânio.

O CASO 1 tratou dados obtidos com centrífugas montadas com diferentes configurações internas, quanto a coletores, discos girantes e sistema de alimentação. Apesar de existirem poucos dados publicados, foi possível treinar uma rede neural para representar essas variações. Observou-se um bom ajuste dos valores calculados com relação aos dados experimentais. Esse modelo foi então utilizado num processo de otimização, buscando as condições que fornecessem o máximo poder de separação. A otimização forneceu resultados bastante razoáveis. Infelizmente não é possível realizar um ensaio de verificação, para certificar os resultados da otimização. No entanto, nesta fase de avaliação do emprego da técnica de redes neurais ao processo da centrífuga a gás, o mais interessante é ter verificado a viabilidade do emprego de redes neurais na simulação dos diferentes dispositivos mecânicos utilizados no interior da centrífuga.

Os dados utilizados no estudo do CASO 2 cobriam um bom domínio das variáveis de entrada, o que permitiu o treinamento de uma rede neural para representar essa configuração específica com excelente ajuste, tanto para o “learning set” como para o “test set”. A modelagem de uma centrífuga via rede neural se mostra como um ótimo método para se obter modelos bem ajustados a uma centrífuga real. Este é um modelo para ser utilizado na previsão dos resultados da centrífuga estudada, principalmente tendo como finalidade o cálculo de cascatas.

## 4.6 Notação

calc	-	valores calculados pela rede neural
exp	-	valores experimentais
EDCH	-	diâmetro equivalente do furo central do(s) disco(s) girante(s)
f	-	freqüência de rotação da centrífuga
F	-	fluxo de alimentação
NH	-	número de neurônios na camada oculta da rede neural
No. Sets	-	número de apresentações dos dados de treinamento à rede neural
NPH	-	número de furos periféricos do(s) disco(s) girante(s)
pot ou power	-	potência consumida pela centrífuga
RFL	-	posição relativa de alimentação
RMST	-	somatório de erros do "learning set"
RMSTT	-	somatório de erros do "test set"
v	-	velocidade periférica do rotor da centrífuga
Z	-	comprimento útil da centrífuga
Z/ $\phi$	-	relação de aspecto da centrífuga

### letras gregas

$\alpha$	-	fator de separação
$\delta U$	-	poder ou capacidade de separação
$\Delta T$	-	diferença entre as temperaturas das tampas do rotor da centrífuga
$\phi$	-	diâmetro do rotor da centrífuga
$\theta$	-	corte

## 4.7 Apêndices

### 4.7.1 Valores apresentados à rede neural no CASO 1.

#### *“Learning Set”*

VARIÁVEIS DE ENTRADA										VARIÁVEIS DE SAÍDA				
colet	Disco Superior			Disco Inferior										
inf.	presen-ça	NPH	ranhu-ras	presen-ça	NPH	ranhu-ras	“ara-nha”	RFL	EDCH	F (mg/s)	$\alpha$	potência (W)	$\delta U$ (g/s)	
1	0	0	0	0	0	0	0	0.50	0	4.600	1.123	10.80	7.73E-06	
2	0	0	0	1	12	0	0	0.50	0.2	2.800	1.150	14.00	6.83E-06	
1	0	0	0	1	12	0	0	0.50	0.2	3.810	1.193	7.90	1.48E-05	
1	0	0	0	1	12	0	0	0.50	0.2	5.480	1.155	8.90	1.42E-05	
1	0	0	0	1	12	0	0	0.50	0.2	0.500	1.267	6.13	3.48E-06	
1	1	12	0	1	0	0	0	0.33	0.5	6.180	1.138	10.50	1.29E-05	
1	1	12	0	1	0	0	0	0.33	0.5	1.634	1.228	7.70	8.59E-06	
1	1	24	0	1	0	1	3	0.50	0.2	0.100	1.355	6.90	1.14E-06	
1	1	24	0	1	12	1	0	0.50	0.2	0.100	1.355	10.50	1.14E-06	
1	1	12	1	1	24	0	0	0.50	0.2	5.530	1.180	10.00	1.89E-05	
1	1	12	1	1	24	0	0	0.50	0.2	0.477	1.274	4.60	3.48E-06	
1	1	12	1	1	24	0	0	0.50	0.2	3.800	1.202	6.60	1.60E-05	

#### *“Test Set”*

VARIÁVEIS DE ENTRADA										VARIÁVEIS DE SAÍDA				
colet	Disco Superior			Disco Inferior										
inf.	presen-ça	NPH	ranhu-ras	presen-ça	NPH	ranhu-ras	“ara-nha”	RFL	EDCH	F (mg/s)	$\alpha$	potência (W)	$\delta U$ (g/s)	
1	0	0	0	0	0	0	0	0.5	0	3.2	1.132	7.9	6.14E-06	
1	0	0	0	1	12	0	0	0.5	0.2	2.55	1.216	6.5	1.22E-05	
1	0	0	0	1	12	0	0	0.5	0.2	4.7	1.157	9.1	1.25E-05	
1	0	0	0	1	12	0	0	0.5	0.2	7.4	1.125	11.1	1.28E-05	

4.7.2 Valores das variáveis de saída experimentais e calculados pela rede neural com seis neurônios na camada oculta no CASO I.

*“Learning Set”*

$\alpha$		potência (W)		$\delta U$ (g/s)	
exp.	calc.	exp.	calc.	exp.	calc.
1.123	1.123	10.80	10.78	7.73E-06	7.77E-06
1.150	1.150	14.00	14.02	6.83E-06	6.87E-06
1.193	1.184	7.90	8.09	1.48E-05	1.42E-05
1.155	1.159	8.90	8.80	1.42E-05	1.45E-05
1.267	1.273	6.13	5.96	3.48E-06	3.87E-06
1.138	1.140	10.50	10.50	1.29E-05	1.29E-05
1.228	1.229	7.70	7.68	8.59E-06	8.64E-06
1.355	1.351	6.90	6.93	1.14E-06	8.91E-07
1.355	1.357	10.50	10.48	1.14E-06	1.25E-06
1.180	1.179	10.00	9.89	1.89E-05	1.93E-05
1.274	1.272	4.60	4.58	3.48E-06	3.46E-06
1.202	1.205	6.60	6.68	1.60E-05	1.59E-05

*“Test Set”*

$\alpha$		potência (W)		$\delta U$ (g/s)	
exp.	calc.	exp.	calc.	exp.	calc.
1.132	1.140	7.90	10.81	6.14E-06	6.27E-06
1.216	1.213	6.50	7.45	1.22E-05	1.21E-05
1.157	1.170	9.10	8.47	1.25E-05	1.46E-05
1.125	1.140	11.10	9.64	1.28E-05	1.31E-05

**4.7.3** Pesos encontrados para a rede neural com seis neurônios na camada interna para o CASO 1.

**Pesos da camada oculta**

2.99E+00	-1.86E+00	-2.12E+00	7.39E-01	1.36E+00	5.13E-01
-6.00E-01	5.37E-01	-5.63E-01	5.21E-01	1.78E-01	7.42E-01
-4.10E-01	4.68E-01	-5.31E-01	1.05E+00	7.17E-01	-4.82E-01
-3.81E-01	1.86E+00	5.81E-01	3.83E-01	-8.53E-01	2.00E+00
-1.88E+00	5.25E-02	4.36E-01	-2.22E-02	-6.22E-01	-8.02E-01
-8.03E-01	1.24E+00	-6.52E-01	-2.81E-01	-3.49E-01	1.23E+00
-1.17E+00	2.05E-01	-1.20E+00	4.71E-01	1.69E+00	-1.56E-02
-9.33E-01	4.83E-02	1.86E+00	1.93E-01	7.90E-02	2.95E-01
-1.29E+00	-1.42E-01	7.41E-01	-6.24E-01	7.51E-01	-5.82E-02
5.89E-02	-2.61E-01	4.61E-01	4.55E-01	-4.29E-01	-7.49E-01
2.88E+00	-6.44E+00	-2.26E+00	5.91E-01	-4.78E+00	-1.33E+00
9.82E-01	1.74E-01	5.81E-01	8.87E-01	6.83E-01	4.23E-01

**Pesos da camada de saída**

-3.20E+00	2.10E-01	-3.37E+00
5.50E-01	-3.60E+00	-4.48E+00
-7.52E-01	-3.77E+00	-1.18E+00
5.87E-01	-4.03E-02	1.79E+00
2.33E+00	2.87E+00	-2.57E+00
-1.28E+00	1.66E+00	2.44E+00
2.53E-01	7.38E-01	9.28E-01

## 4.7.4 Valores apresentados à rede neural no CASO 2.

*“Learning Set”*

VARIÁVEIS DE ENTRADA		VARIÁVEIS DE SAÍDA		
v (m/s)	F (mg/s)	$\alpha$	$\delta U$ (g/s)	Potência (W)
350	0.00	1.000	0.00E+00	3.0
350	2.50	1.062	1.40E-06	4.1
350	3.70	1.126	6.75E-06	5.8
350	4.30	1.141	9.70E-06	7.4
350	5.30	1.134	1.21E-05	8.3
350	6.10	1.130	1.22E-05	9.2
350	4.72	1.157	1.27E-05	9.1
350	7.39	1.125	1.27E-05	11.1
245	0.00	1.000	0.00E+00	5.5
245	1.20	1.088	9.00E-07	7.8
245	1.80	1.088	1.10E-06	9.0
245	2.30	1.080	1.50E-06	9.5
245	2.90	1.074	1.70E-06	10.8
303	1.50	1.053	1.50E-06	5.3
303	4.10	1.115	5.10E-06	8.2
303	5.30	1.094	5.50E-06	9.7
303	6.80	1.076	4.50E-06	11.5
350	1.50	1.043	5.00E-07	4.8
350	4.10	1.128	8.50E-06	7.2
350	5.30	1.134	1.14E-05	7.8
350	6.40	1.132	1.15E-05	9.4

## 4.7.4 Valores apresentados à rede neural no CASO 2 (cont.).

*“Test Set”*

VARIÁVEIS DE ENTRADA		VARIÁVEIS DE SAÍDA		
v (m/s)	F (mg/s)	$\alpha$	$\delta U$ (g/s)	Potência (W)
350	2.2	1.048	6.00E-07	4.3
350	3.1	1.100	3.70E-06	4.7
350	3.9	1.126	7.80E-06	6.5
350	4.9	1.139	1.14E-05	7.6
350	5.7	1.130	1.15E-05	8.7
350	6.5	1.108	1.20E-05	10.5
350	5.4	1.155	1.39E-05	8.9
245	0.8	1.080	5.00E-07	7.1
245	1.5	1.088	1.10E-06	8.2
245	2.1	1.078	1.50E-06	9.4
245	2.5	1.078	1.70E-06	10.3
245	3.3	1.065	1.60E-06	11.6
303	0.0	1.000	0.00E+00	3.5
303	3.2	1.094	3.20E-06	7.2
303	5.1	1.097	5.50E-06	9.2
303	6.7	1.085	5.30E-06	10.9
350	0.0	1.000	0.00E+00	3.0
350	2.8	1.104	3.90E-06	5.8
350	5.2	1.144	1.25E-05	7.8
350	5.8	1.136	1.25E-05	8.9
350	6.5	1.126	1.25E-05	9.8

4.7.5 Valores das variáveis de saída experimentais e calculados pela rede neural com seis neurônios na camada oculta no CASO 2.

*“Learning Set”*

$\alpha$		$\delta U$ (g/s)		Potência (W)	
exp.	calc.	exp.	calc.	exp.	calc.
1.000	0.999	0.00E+0	3.76E-7	3.00	3.13
1.062	1.057	1.40E-6	1.20E-6	4.10	4.80
1.126	1.119	6.75E-6	7.02E-6	5.80	6.38
1.141	1.139	9.70E-6	9.98E-6	7.35	7.27
1.134	1.141	1.21E-5	1.17E-5	8.30	8.52
1.130	1.134	1.22E-5	1.20E-5	9.20	9.38
1.157	1.142	1.27E-5	1.10E-5	9.10	7.82
1.125	1.118	1.27E-5	1.19E-5	11.10	10.48
1.000	1.003	0.00E+0	-5.70E-7	5.50	5.18
1.088	1.078	9.00E-7	5.21E-7	7.80	7.78
1.088	1.084	1.10E-6	9.33E-7	9.00	8.90
1.080	1.081	1.50E-6	1.23E-6	9.50	9.67
1.074	1.075	1.70E-6	1.56E-6	10.80	10.39
1.053	1.053	1.50E-6	9.76E-7	5.30	5.05
1.115	1.116	5.10E-6	5.20E-6	8.20	8.22
1.094	1.095	5.50E-6	4.56E-6	9.70	9.57
1.076	1.072	4.50E-6	4.25E-6	11.50	10.95
1.043	1.047	5.00E-7	8.90E-8	4.80	4.00
1.128	1.134	8.50E-6	9.20E-6	7.20	6.98
1.134	1.141	1.14E-5	1.17E-5	7.80	8.52
1.132	1.131	1.15E-5	1.21E-5	9.40	9.67

4.7.5 Valores das variáveis de saída experimentais e calculados pela rede neural com seis neurônios na camada oculta no CASO 2 (cont.).

*“Test Set”*

$\alpha$		$\delta U$ (g/s)		Potência (W)	
exp.	calc.	exp.	calc.	exp.	calc.
1.048	1.052	6.00E-7	6.81E-7	4.30	4.53
1.100	1.081	3.70E-6	3.32E-6	4.70	5.50
1.126	1.128	7.80E-6	8.21E-6	6.50	6.69
1.139	1.143	1.14E-5	1.13E-5	7.60	8.05
1.130	1.138	1.15E-5	1.19E-5	8.70	8.97
1.108	1.129	1.20E-5	1.21E-5	10.50	9.77
1.155	1.140	1.39E-5	1.18E-5	8.90	8.64
1.080	1.063	5.00E-7	1.90E-7	7.10	6.94
1.088	1.083	1.10E-6	7.37E-7	8.20	8.36
1.078	1.082	1.50E-6	1.12E-6	9.40	9.38
1.078	1.079	1.70E-6	1.34E-6	10.30	9.93
1.065	1.070	1.60E-6	1.75E-6	11.60	10.76
1.000	0.992	0.00E+0	3.13E-7	3.50	3.73
1.094	1.125	3.20E-6	5.28E-6	7.20	7.19
1.097	1.099	5.50E-6	4.66E-6	9.20	9.36
1.085	1.074	5.30E-6	4.25E-6	10.90	10.88
1.000	0.999	0.00E+0	3.76E-7	3.00	3.13
1.104	1.066	3.90E-6	2.04E-6	5.80	5.13
1.144	1.142	1.25E-5	1.16E-5	7.80	8.41
1.136	1.137	1.25E-5	1.20E-5	8.90	9.07
1.126	1.129	1.25E-5	1.21E-5	9.80	9.77

4.7.6 Pesos encontrados para a rede neural com seis neurônios na camada interna para o CASO 2.

#### Pesos da camada oculta

-1.49E+00	-6.36E+00	8.97E+00	3.22E+00	-9.77E+00	-9.07E-01
2.77E+00	3.67E+00	-1.81E+01	-4.32E+00	5.61E+00	1.38E+01
9.97E-01	9.41E-01	4.73E-01	9.88E-01	4.09E-01	4.06E-02

#### Pesos da camada de saída

-7.65E+00	5.90E+00	3.89E+00
-2.43E+00	-8.64E+00	-3.68E+00
-3.78E+00	-2.61E+00	-4.06E-01
-1.36E-01	-1.21E+00	-3.90E+00
7.60E-01	3.72E+00	2.50E+00
7.99E+00	-2.79E+00	3.92E-01
2.03E-01	8.59E-01	2.65E-02

## 4.8 Referências

- [4.1] JORDAN, I. *Separação dos isótopos de urânio pelo processo da centrifugação em fase gasosa*. São Paulo, SP: Instituto de Pesquisas Energéticas e Nucleares, 1980. (IPEN-Inf-3).
- [4.2] ZIPPE, G. *The development of short bowl ultra-centrifuges*. Charlottesville, VI: University of Virginia, research Laboratories for the Engineering Science, 1960. (ORO-315).
- [4.3] POLLARD, J.F.; BROUSSARD, M.R.; GARRISON, D.B.; SAN, K.Y. Process identification using neural networks. *Comput. Chem. Eng.*, v.16, n.4, p.253-270, 1992.
- [4.4] HORNIK, K.; STINCHOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. *Neural Networks*, v.2, p.359-366, 1989.
- [4.5] KAI, T. Theoretical research on gas-centrifugal separation for uranium enrichment. *J. Nucl. Sci. Technol.*, v.26, n.1, p.157-160, 1989.

## 5 APLICAÇÃO AOS DADOS OBTIDOS NO ENSAIO SEPARATIVO DE UMA CENTRÍFUGA

O primeiro estudo de caso prático realizado consiste na aplicação da técnica de redes neurais a um ensaio de separação de uma dada centrífuga. Um ensaio de separação consiste na operação da centrífuga em diferentes condições de operação. Num ensaio são medidos: os fluxos mássicos das correntes de produto e de rejeito e as pressões nas linhas de alimentação, de produto e de rejeito. Em cada condição de operação são retiradas amostras que são analisadas por espectrometria de massa para identificação da razão de abundância de cada corrente processada pela centrífuga.

No presente caso, os fluxos de produto e de rejeito são mantidos aproximadamente iguais, com o objetivo de manter a operação próxima ao caso do processo simétrico, definido por  $\beta=\gamma$ . A aplicação da rede neural para a simulação dessa centrífuga foi realizada com as seguintes variáveis de entrada:

- $Q_P$  : fluxo mássico do produto;
- $Q_W$  : fluxo mássico do rejeito;
- $p_P$  : pressão na linha do produto.

Os dados de saída apresentados à rede para o treinamento foram:

- $p_F$  : pressão na linha da alimentação;
- $p_W$  : pressão na linha do rejeito;
- $R_P$  : razão de abundância do produto;
- $R_W$  : razão de abundância do rejeito.

Lembramos que a alimentação da centrífuga é estabelecida como sendo urânio natural, cuja razão de abundância molar é  $R_F=0.725\%$ . Os dados utilizados no treinamento da rede, bem como os resultados posteriores, são considerados sigilosos, e portanto são apresentados de forma normalizada.

## 5.1 Treinamento e testes da rede neural

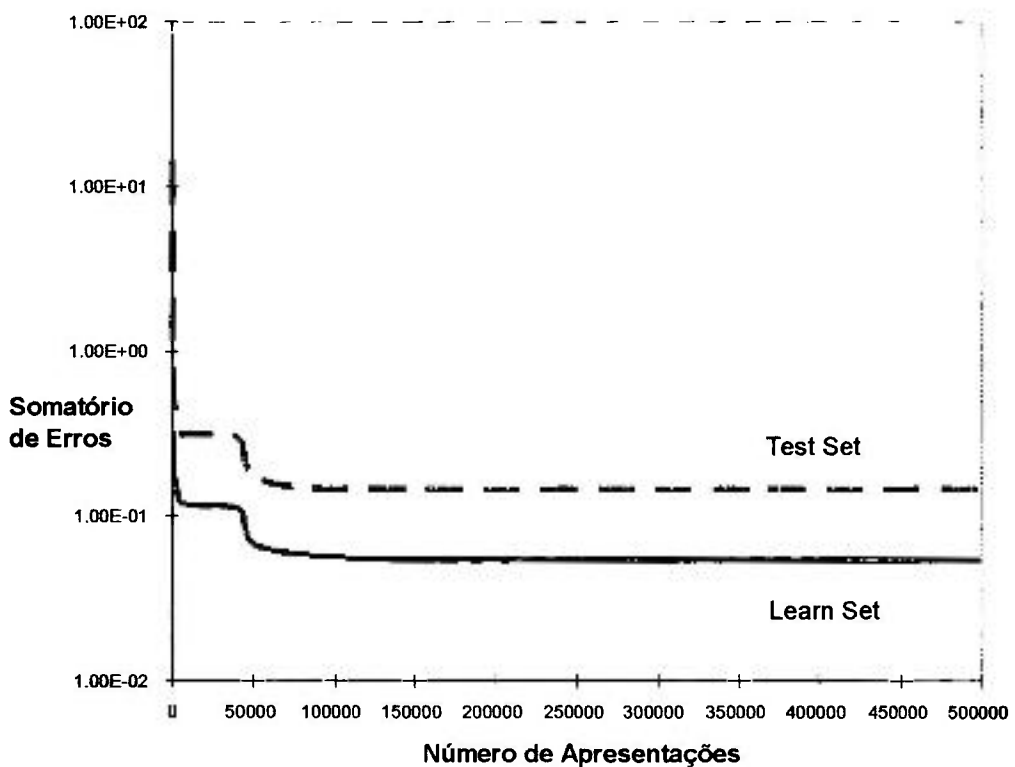
Os dados experimentais foram separados em dois grupos: o “learning set”, com 29 conjuntos de dados, usado para o treinamento da rede, e o “test set”, com 27 conjuntos de dados, usado para verificação do treinamento. Cada dado é resultante de uma média de três determinações. Os dados normalizados para o intervalo de zero a um se encontram no Apêndice 5.6.1.

Para este problema é utilizada uma rede neural de três camadas e o treinamento realizado pelo algoritmo de “retro-propagação”. Resta definir o número de neurônios na camada oculta. Foram testadas quatro diferentes redes, com 5, 6, 7 e 8 neurônios na camada oculta. A Tabela 5.1 mostra os erros calculados em cada caso para o “learning set” e para o “test set”, com um número máximo de 100 000 apresentações.

**TABELA 5.1**  
Somatório de erros calculados no treinamento de redes neurais com diferentes números de neurônios na camada oculta (NH)

NH	“LEARNING SET”		“TEST SET”	
	N. de apresentações	RMST min.	N. de apresentações	RMSTT min.
5	13 000	0.11128	12 000	0.30589
6	100 000	0.06628	100 000	0.17268
7	<b>100 000</b>	<b>0.05102</b>	<b>100 000</b>	<b>0.13271</b>
8	100 000	0.10087	87 000	0.26789

O treinamento de uma rede com sete neurônios na camada oculta permitindo até 500 000 apresentações dos dados, indicou que 100 000 apresentações são suficientes para determinar a configuração da rede. Nesse caso o processo de convergência apresentou um comportamento assintótico. Com esses resultados foi escolhida uma rede neural com 7 (sete) neurônios na camada oculta. O comportamento da soma dos erros para essa rede em função do número de apresentações é mostrado na Figura 5.1. No presente caso foi adotado um fator de aceleração de convergência constante, não sendo necessário usar um fator de aceleração de convergência dinâmico (NASCIMENTO [5.1]). O Apêndice 5.6.2 mostra os resultados das variáveis de saída calculados pela rede neural escolhida, e dos respectivos valores experimentais, enquanto o Apêndice 5.6.3 traz os valores dos pesos correspondentes a essa rede.



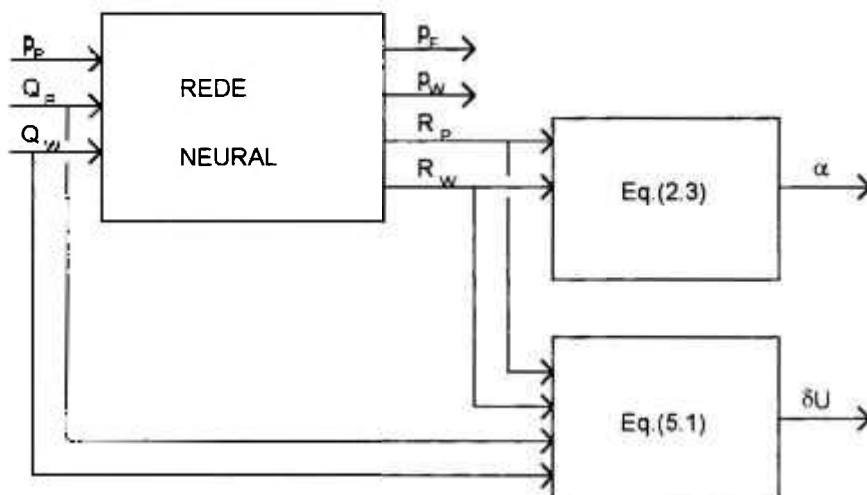
**FIGURA 5.1:** Erro total no treinamento de uma rede neural com sete neurônios na camada oculta ao longo do treinamento, em função do número de apresentações

## 5.2 Comparação entre os dados experimentais e os calculados

Tendo a rede treinada, os pesos são definidos e as variáveis de saída podem ser calculadas e comparadas aos valores experimentais. Os pesos escolhidos são aqueles que apresentam o menor erro total para o “test set”, que no presente caso também minimizaram os erros do “learning set”. As variáveis primárias de interesse imediato são as pressões  $p_F$  e  $p_W$ . No entanto, as variáveis de maior interesse prático são o fator de separação  $\alpha$ , definido pela Eq.2.3, e o poder de separação  $\delta U$ , definido pelas Eq.2.6 e Eq.2.7, que pode ser colocado diretamente em função das razões de abundância:

$$\delta U = Q_P \frac{R_P - 1}{R_P + 1} \ln(R_P) + Q_W \frac{R_W - 1}{R_W + 1} \ln(R_W) - (Q_P + Q_W) \frac{R_F - 1}{R_F + 1} \ln(R_F) \quad (5.1)$$

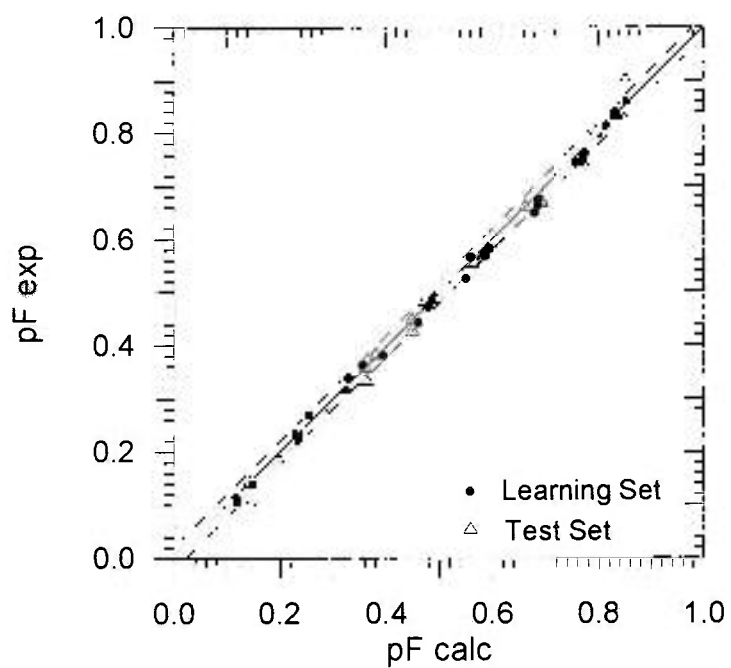
Na Figura 5.2 é mostrado o esquema do modelo adotado para o cálculo dos parâmetros da centrífuga via rede neural.




**FIGURA 5.2:** Esquema do modelo híbrido empregado para o cálculo dos parâmetros da centrífuga via rede neural

Das variáveis primárias é mostrada a comparação entre os valores experimentais e os calculados das pressões  $p_F$  e  $p_W$  nas Figuras 5.3 e 5.4. Os resultados calculados e os dados experimentais apresentam um bom grau de ajuste. A linha cheia em diagonal representa a situação ideal, com ajuste perfeito de todos os dados experimentais. No entanto esta é uma situação irreal, pois os próprios pontos experimentais carregam um erro. Nesse sentido, as linhas pontilhadas representam a faixa de variação aceitável entre os valores experimentais e os calculados, baseada numa estimativa do erro experimental, determinado pelas incertezas das medidas experimentais, sendo  $\Delta p_F = \Delta p_W = 0.02$ ,  $\Delta \alpha = 0.03$  e  $\Delta \delta U = 0.05$ . Normalmente os dados do “training set” são bem representados pela rede neural. O presente tipo de rede é considerado um “aproximador universal” (HORNIK [5.2]). O fato mais importante desse ajuste é que se obteve uma boa previsão através da rede treinada para os dados do “test set”.


O cálculo dos parâmetros  $\alpha$  e  $\delta U$  segue agora o esquema apresentado na Figura 5.2. As informações das razões de abundância são obtidas a partir da rede neural e os valores de  $\alpha$  e  $\delta U$  são obtidos pelas Eq.2.3 e Eq.5.1 respectivamente. Esses parâmetros são calculados diretamente através da rede pois não são variáveis primárias, isto é, experimentalmente esses parâmetros são obtidos através das expressões citadas, e não de uma medida direta. As Figuras 5.5 e 5.6 mostram a comparação dos valores experimentais e calculados para essas variáveis. Pode-se observar que o ajuste dos dados pertencentes ao “test set” foi bom e equivalente ao ajuste obtido para o “learning set”. O fato do ajuste do “test set” ter sido também muito bom mostra que a rede neural representa bem a superfície de resposta do problema real.




**FIGURA 5.3:** Comparação entre os resultados experimentais e os calculados pela rede neural da pressão de alimentação  $p_F$



**FIGURA 5.4:** Comparação entre os resultados experimentais e os calculados pela rede neural da pressão de rejeito  $p_W$



**FIGURA 5.5:** Comparação entre os resultados experimentais e os calculados através da rede neural do fator de separação  $\alpha$




**FIGURA 5.6:** Comparação entre os resultados experimentais e os calculados através da rede neural do poder de separação  $\delta U$

### 5.3 Otimização da centrífuga

Uma vez obtida a rede neural representativa do processo foi feito um mapeamento dentro do domínio dado pelo “learning set”. Nesse mapeamento foi usada uma malha com intervalos bem pequenos, e buscou-se as condições que forneciam o valor máximo do poder de separação  $\delta U$ . A Figura 5.7 apresenta uma superfície típica do valor de  $\delta U$  em função dos fluxos  $Q_p=Q_w$  e da pressão na retirada do produto  $p_p$ . Com esses dados a solução ótima, onde o poder de separação  $\delta U$  é maximizado, é encontrada por busca direta.

De volta à bancada experimental, realizou-se um novo experimento nas condições ótimas de operação definidas pela superfície de resposta simulada através da rede neural. As diferenças entre os resultados experimentais e os previstos pelo modelo utilizado foram da ordem de 1%, com exceção da pressão de alimentação  $p_F$  que apresentou um desvio da ordem de 5%. A Tabela 5.2 compara os dados previstos pela rede com os valores obtidos experimentalmente. Os desvios apresentados na Tabela 5.2 são referentes aos valores reais das variáveis, e não aos valores normalizados apresentados nessa tabela. Uma vez que o critério de normalização empregado distribuindo os valores no intervalo de 0.1 a 0.9, é diferente para cada uma das variáveis, a proporcionalidade nos desvios não é mantida. Desta forma, os desvios devem ser avaliados sobre os valores reais das variáveis envolvidas, e não sobre seus valores normalizados.



**FIGURA 5.7:** Superfície de resposta do poder de separação  $\delta U$  em função dos fluxos  $Q_p=Q_w$  e da pressão  $p_p$

**TABELA 5.2**

Comparação entre os valores dos parâmetros ótimos da centrífuga previstos através do modelo utilizando rede neural e os resultados experimentais (valores normalizados)

	Valores previstos	Valores experimentais	Desvios absolutos
$p_F$	0.7155	0.6560	5.5 %
$p_W$	0.8272	0.8302	0.4 %
$\alpha$	0.5584	0.5613	0.5 %
$\delta U$	0.9003	0.9066	0.7 %

## 5.4 Conclusão

A modelagem através de redes neurais do processo de separação por ultracentrifugação se apresenta como um campo muito promissor para a análise do processo. Essa técnica requer um conjunto de dados experimentais confiável e de boa qualidade.

No presente caso foi avaliada a aplicação desta técnica de modelagem aos resultados obtidos em um único ensaio separativo. Os dados disponíveis cobriam um largo domínio das variáveis estudadas, o que se mostrou importante para garantir que a rede neural fosse capaz de incorporar todas as não-linearidades do processo. O modelo obtido apresentou boa concordância com os valores experimentais utilizados no treinamento da rede neural, com o qual foi possível construir superfícies de respostas contínuas e com tendências coerentes.

A otimização dos parâmetros separativos da centrífuga foi realizada por inspeção direta da superfície de resposta gerada pelo modelo proposto. A condição ótima foi verificada experimentalmente e a diferença dos resultados separativos experimentais foi menor que 1% da previsão.

## 5.5 Notação

$NH$	-	número de neurônios na camada oculta da rede neural
No. Sets	-	número de apresentações do conjunto de dados no treinamento da rede
$p_F$	-	pressão na linha de alimentação
$p_P$	-	pressão na linha de retirada do produto
$p_W$	-	pressão na linha de retirada do rejeito
$Q_P$	-	fluxo de retirada do produto
$Q_W$	-	fluxo de retirada do rejeito
$R_F$	-	razão de abundância da alimentação (0.00725)
$R_P$	-	razão de abundância do produto
$R_W$	-	razão de abundância do rejeito
RMST	-	somatório de erros do “learning set”
RMSTT	-	somatório de erros do “test set”

### letras gregas

$\alpha$	-	fator de separação
$\beta$	-	fator de enriquecimento
$\delta U$	-	poder de separação
$\Delta$	-	intervalo de erro aceitável de uma variável

## 5.6 Apêndices

### 5.6.1 Valores normalizados apresentados à rede neural.

#### *“Learning Set”*

Variáveis de Entrada			Variáveis de Saída			
Q <sub>P</sub>	Q <sub>W</sub>	p <sub>P</sub>	p <sub>F</sub>	p <sub>W</sub>	R <sub>P</sub>	R <sub>W</sub>
1.04E-01	1.04E-01	2.52E-01	1.04E-01	2.41E-01	4.37E-01	5.47E-01
3.20E-01	3.20E-01	2.54E-01	3.39E-01	2.56E-01	2.91E-01	7.47E-01
5.59E-01	5.59E-01	2.56E-01	5.65E-01	2.81E-01	2.42E-01	7.57E-01
7.86E-01	7.86E-01	2.56E-01	7.47E-01	3.65E-01	2.84E-01	7.29E-01
9.00E-01	9.00E-01	2.53E-01	8.32E-01	4.22E-01	2.83E-01	7.37E-01
2.18E-01	2.29E-01	3.78E-01	2.70E-01	4.09E-01	5.92E-01	4.24E-01
4.45E-01	4.45E-01	3.78E-01	4.87E-01	4.57E-01	4.49E-01	5.99E-01
6.73E-01	6.73E-01	3.76E-01	6.74E-01	4.40E-01	3.36E-01	6.28E-01
9.00E-01	9.00E-01	3.75E-01	8.40E-01	4.78E-01	2.93E-01	6.93E-01
1.00E-01	1.00E-01	4.23E-01	1.39E-01	4.70E-01	8.46E-01	1.00E-01
3.31E-01	3.31E-01	4.14E-01	3.82E-01	4.71E-01	5.35E-01	4.48E-01
5.59E-01	5.59E-01	3.92E-01	5.81E-01	4.71E-01	3.98E-01	6.14E-01
7.82E-01	7.79E-01	3.88E-01	7.47E-01	4.71E-01	3.51E-01	6.94E-01
2.18E-01	2.18E-01	5.95E-01	3.15E-01	6.85E-01	8.39E-01	2.82E-01
4.45E-01	4.49E-01	5.71E-01	5.25E-01	6.86E-01	6.94E-01	3.59E-01
8.96E-01	8.89E-01	6.45E-01	8.60E-01	6.84E-01	5.08E-01	5.88E-01
1.08E-01	1.04E-01	8.41E-01	2.31E-01	8.98E-01	6.53E-01	3.27E-01
3.31E-01	3.31E-01	8.63E-01	4.73E-01	8.96E-01	6.36E-01	4.29E-01
5.59E-01	5.59E-01	8.70E-01	6.64E-01	9.00E-01	5.74E-01	5.03E-01
7.86E-01	7.82E-01	8.14E-01	8.13E-01	8.96E-01	4.90E-01	5.38E-01
2.18E-01	2.29E-01	1.15E-01	2.22E-01	1.26E-01	1.78E-01	8.42E-01
4.45E-01	4.45E-01	1.42E-01	4.44E-01	2.07E-01	2.52E-01	7.72E-01
6.73E-01	6.73E-01	1.72E-01	6.49E-01	3.25E-01	2.89E-01	7.09E-01
9.00E-01	8.96E-01	2.03E-01	8.31E-01	4.49E-01	3.11E-01	7.18E-01
1.04E-01	1.04E-01	2.28E-01	1.15E-01	2.28E-01	4.05E-01	5.92E-01
3.31E-01	3.31E-01	3.04E-01	3.64E-01	3.45E-01	4.31E-01	6.20E-01
5.59E-01	5.59E-01	3.65E-01	5.69E-01	4.34E-01	4.01E-01	6.09E-01
7.86E-01	7.86E-01	4.24E-01	7.62E-01	5.24E-01	3.90E-01	6.36E-01

## 5.6.1 Valores normalizados apresentados à rede neural (cont.).

*“Test Set”*

Variáveis de Entrada			Variáveis de Saída			
Q <sub>P</sub>	Q <sub>W</sub>	p <sub>P</sub>	p <sub>F</sub>	p <sub>W</sub>	R <sub>P</sub>	R <sub>W</sub>
2.14E-01	2.14E-01	2.55E-01	2.34E-01	2.53E-01	3.24E-01	6.99E-01
4.45E-01	4.45E-01	2.55E-01	4.48E-01	2.73E-01	2.64E-01	7.59E-01
6.73E-01	6.76E-01	2.54E-01	6.60E-01	3.09E-01	2.56E-01	7.60E-01
1.04E-01	1.04E-01	3.75E-01	1.42E-01	4.02E-01	7.78E-01	2.18E-01
3.31E-01	3.31E-01	3.77E-01	3.83E-01	4.35E-01	5.01E-01	5.38E-01
5.59E-01	5.59E-01	3.77E-01	5.81E-01	4.50E-01	3.69E-01	6.31E-01
7.86E-01	7.86E-01	3.76E-01	7.58E-01	4.49E-01	3.34E-01	7.04E-01
2.18E-01	2.18E-01	4.35E-01	2.70E-01	4.72E-01	6.63E-01	2.67E-01
4.45E-01	4.45E-01	3.89E-01	4.87E-01	4.71E-01	4.62E-01	5.58E-01
6.73E-01	6.73E-01	4.02E-01	6.69E-01	4.71E-01	3.86E-01	6.65E-01
8.96E-01	8.92E-01	3.62E-01	8.36E-01	4.70E-01	3.25E-01	7.23E-01
1.11E-01	1.08E-01	5.86E-01	1.83E-01	6.85E-01	9.00E-01	2.30E-01
3.31E-01	3.31E-01	5.82E-01	4.28E-01	6.85E-01	7.45E-01	3.23E-01
7.86E-01	7.94E-01	6.27E-01	7.99E-01	6.84E-01	5.05E-01	5.34E-01
2.18E-01	2.18E-01	8.56E-01	3.60E-01	8.99E-01	6.45E-01	3.54E-01
4.45E-01	4.53E-01	8.65E-01	5.70E-01	8.97E-01	5.86E-01	4.67E-01
6.73E-01	6.73E-01	8.71E-01	7.34E-01	9.00E-01	4.98E-01	5.08E-01
8.96E-01	8.92E-01	9.00E-01	9.00E-01	8.96E-01	4.46E-01	5.88E-01
1.15E-01	1.04E-01	1.00E-01	1.00E-01	1.00E-01	1.00E-01	9.00E-01
3.31E-01	3.20E-01	1.28E-01	3.34E-01	1.50E-01	2.18E-01	8.13E-01
5.59E-01	5.66E-01	1.58E-01	5.55E-01	2.58E-01	2.75E-01	7.52E-01
7.86E-01	7.86E-01	1.87E-01	7.40E-01	3.87E-01	2.78E-01	7.02E-01
2.18E-01	2.18E-01	2.69E-01	2.48E-01	2.93E-01	4.05E-01	5.92E-01
4.45E-01	4.45E-01	3.40E-01	4.82E-01	4.00E-01	4.26E-01	5.96E-01
6.73E-01	6.73E-01	3.96E-01	6.70E-01	4.80E-01	3.89E-01	6.06E-01
9.00E-01	9.00E-01	4.47E-01	8.43E-01	5.59E-01	3.67E-01	6.49E-01

5.6.2 Valores das variáveis de saída experimentais e calculados pela rede neural com sete neurônios na camada oculta.

*“Learning Set”*

$p_F$		$p_W$		$R_P$		$R_W$	
exp.	calc.	exp.	calc.	exp.	calc.	exp.	calc.
0.10371	0.11940	0.24124	0.23493	0.43153	0.46726	0.24424	0.26607
0.33882	0.32986	0.25573	0.28030	0.25942	0.30223	0.23393	0.27225
0.56452	0.55922	0.28088	0.32334	0.23248	0.26219	0.28666	0.32460
0.74687	0.75710	0.36529	0.40563	0.26504	0.25225	0.41363	0.39139
0.83150	0.82950	0.42198	0.46119	0.26076	0.25836	0.44784	0.44311
0.26985	0.25428	0.40863	0.42263	0.57330	0.62070	0.47655	0.52974
0.48720	0.48763	0.45680	0.43705	0.40826	0.45561	0.46892	0.53977
0.67424	0.68572	0.43989	0.44562	0.34093	0.35590	0.49636	0.52590
0.83986	0.83288	0.47754	0.50620	0.28788	0.31630	0.50207	0.56423
0.13924	0.14749	0.46987	0.49691	0.90000	0.84166	0.59335	0.54378
0.38166	0.39362	0.47101	0.49555	0.53273	0.57572	0.54490	0.60668
0.58124	0.59536	0.47101	0.45298	0.37734	0.41577	0.49563	0.56130
0.74687	0.77028	0.47058	0.48387	0.31328	0.33831	0.50081	0.55094
0.31531	0.32583	0.68486	0.73290	0.77734	0.75366	0.71099	0.68020
0.52482	0.54986	0.68628	0.70570	0.66019	0.62834	0.90000	0.83935
0.85972	0.85393	0.68372	0.73469	0.44132	0.42704	0.86697	0.82995
0.23067	0.23285	0.89771	0.87506	0.66033	0.68782	0.40384	0.42562
0.47309	0.48158	0.89643	0.91347	0.59144	0.56054	0.62932	0.58515
0.66379	0.68511	0.89999	0.92532	0.51909	0.52481	0.75599	0.76754
0.81322	0.81464	0.89643	0.88389	0.46114	0.46771	0.83199	0.84860
0.22179	0.23406	0.12600	0.12997	0.16213	0.14128	0.14159	0.13131
0.44384	0.46044	0.20671	0.23634	0.22894	0.22094	0.24747	0.23946
0.64916	0.67919	0.32479	0.33980	0.27781	0.26058	0.39078	0.36411
0.83098	0.83929	0.44856	0.46712	0.28314	0.27276	0.49230	0.47109
0.11520	0.11668	0.22803	0.20213	0.39195	0.37883	0.22152	0.21414
0.36390	0.35390	0.34454	0.33858	0.38897	0.38948	0.36765	0.36826
0.56870	0.58683	0.43435	0.42211	0.38068	0.38414	0.50111	0.50718
0.76149	0.77514	0.52443	0.51072	0.36130	0.36836	0.60215	0.61740

5.6.2 Valores das variáveis de saída experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.).

*“Test Set”*

$p_F$		$p_w$		$R_p$		$R_w$	
exp.	calc.	exp.	calc.	exp.	calc.	exp.	calc.
0.23433	0.23017	0.25303	0.26517	0.29875	0.34353	0.22199	0.25504
0.44801	0.44842	0.27293	0.29926	0.24112	0.27835	0.26001	0.30068
0.66014	0.66149	0.30859	0.35359	0.23714	0.25743	0.32984	0.36001
0.14185	0.14158	0.40152	0.42415	0.78859	0.78420	0.50581	0.50187
0.38323	0.37966	0.43463	0.43926	0.46635	0.52078	0.45965	0.53048
0.58124	0.59066	0.44955	0.43575	0.35484	0.39855	0.45900	0.53150
0.75836	0.76781	0.44884	0.47074	0.30027	0.33032	0.47843	0.53764
0.26985	0.28422	0.47243	0.52760	0.70210	0.69082	0.61173	0.60339
0.48720	0.49180	0.47143	0.45204	0.43689	0.47091	0.51096	0.56368
0.66850	0.69202	0.47143	0.47210	0.34423	0.38168	0.50432	0.57485
0.83568	0.83208	0.46987	0.50147	0.28676	0.30419	0.49793	0.53509
0.18260	0.19777	0.68500	0.70817	0.84033	0.85806	0.56519	0.57912
0.42764	0.44792	0.68514	0.72885	0.70670	0.69021	0.80611	0.77975
0.79911	0.79522	0.68429	0.71521	0.46978	0.46116	0.85870	0.83707
0.35972	0.35854	0.89942	0.89744	0.64018	0.59021	0.54308	0.48848
0.56975	0.58381	0.89729	0.91952	0.54558	0.54417	0.69128	0.68889
0.73433	0.75752	0.89984	0.92178	0.48123	0.49390	0.78201	0.81157
0.89995	0.85234	0.89601	0.91113	0.41292	0.40449	0.79414	0.77224
0.10005	0.14376	0.10000	0.07875	0.10000	0.06079	0.10001	0.09043
0.33359	0.36292	0.15016	0.19460	0.19382	0.15285	0.18384	0.15594
0.55512	0.56550	0.25801	0.27851	0.24945	0.26284	0.30936	0.32681
0.74007	0.76890	0.38731	0.39970	0.27628	0.27110	0.43286	0.42446
0.24843	0.23668	0.29282	0.28326	0.39217	0.37501	0.29623	0.28228
0.48250	0.47320	0.39996	0.38677	0.39966	0.39802	0.45647	0.45426
0.67006	0.69061	0.47967	0.46604	0.37722	0.37610	0.56538	0.56407
0.84248	0.83906	0.55910	0.55437	0.34429	0.36304	0.62785	0.67259

**5.6.3** Pesos encontrados para a rede neural com sete neurônios na camada interna.

**Pesos da camada oculta**

1.55E-01	-5.03E-01	-2.65E+00	8.09E+00	2.06E+00	2.02E+00	2.79E+00
4.09E+00	7.05E+00	1.45E+00	3.70E+00	-2.09E+00	-8.29E-01	-4.21E+00
-4.70E+00	7.15E+00	-1.51E+00	1.94E+00	-5.06E+00	-2.04E+00	1.32E+01
3.59E-01	8.39E-02	7.04E-01	2.13E-01	2.94E-01	9.35E-01	8.53E-01

**Pesos da camada de saída**

-1.13E+00	-3.09E+00	-3.73E+00	2.45E+00
-1.90E+00	7.53E+00	1.80E+01	-2.38E+01
-1.00E+01	-9.84E+00	5.56E+00	-5.85E+00
4.92E+00	-1.03E+00	-8.87E+00	1.42E+01
-1.09E-01	2.19E+00	-1.31E+01	1.20E+01
7.06E+00	-3.24E-02	9.91E+00	-6.99E+00
-3.19E+00	-2.08E+00	-1.38E+01	1.32E+01
1.33E-01	8.55E-01	2.39E-01	1.64E-01

## 5.7 Referências

- [5.1] NASCIMENTO,C.A.O.; OLIVEROS,E. & BRAUN,A.M. Neural network modeling for photochemical processes. *Chem. Eng. Proc.*, v.33, p.319-324, 1994.
- [5.2] HORNIK,K.; STINCHOMBE.M.; WHITE,H. Multilayer feedforward networks are universal approximators. *Neural Networks*, v.2, p.359-366, 1989.

## 6 APLICAÇÃO AOS DADOS OBTIDOS NO ENSAIO SEPARATIVO DE UMA CENTRÍFUGA EM CONDIÇÕES ASSIMÉTRICAS

O próximo caso trata os dados experimentais obtidos em um ensaio de separação de uma dada centrífuga operando em condições assimétricas, isto é, com variações de corte. O procedimento experimental para a obtenção dos dados foi o mesmo do caso anterior, eliminando no entanto a restrição de igualdade entre os fluxos de retirada. As variáveis de processo controladas no ensaio são as vazões de retirada  $Q_P$  e  $Q_W$  e a pressão da retirada do produto  $p_P$ . Nesse sentido, o corte  $\theta$  é definido pela relação entre as vazões das retiradas, através da expressão

$$\theta = Q_P / (Q_P + Q_W) \quad (6.1)$$

onde,  $Q_P$  é a vazão de retirada de produto e  $Q_W$  é a vazão de retirada de rejeito. O corte também pode ser obtido a partir das concentrações ou através das razões da abundância, quando se considera o balanço material do isótopo leve, segundo

$$\theta = \frac{(R_F - R_{\overline{F}}) \cdot (R_P + 1)}{(R_P - R_W) \cdot (R_F + 1)} \quad (6.2)$$

onde,  $R_F$ ,  $R_P$  e  $R_W$  são as razões de abundância, respectivamente, da alimentação, produto e rejeito.

As variáveis de interesse do processo são, como anteriormente, as pressões nas linhas de alimentação  $p_F$  e na linha de retirada do rejeito  $p_w$ , e os parâmetros de separação  $\alpha$ ,  $\beta$ ,  $\gamma$  e  $\delta U$ .


Inicialmente foram avaliadas duas diferentes definições de variáveis de entrada e duas diferentes definições de variáveis de saída, perfazendo um total de quatro modelos candidatos à representação da centrífuga. Foram essas:

- MODELO 1A: variáveis de entrada:  $Q_P, Q_W$  e  $p_P$   
variáveis de saída:  $p_F, p_w, R_P$  e  $R_W$
- MODELO 1B: variáveis de entrada:  $Q_P, Q_W$  e  $p_P$   
variáveis de saída:  $p_F, p_w, \beta, \gamma$  e  $\delta U$
- MODELO 2A: variáveis de entrada:  $F, \theta$  e  $p_P$   
variáveis de saída:  $p_F, p_w, R_P$  e  $R_W$
- MODELO 2B: variáveis de entrada:  $F, \theta$  e  $p_P$   
variáveis de saída:  $p_F, p_w, \beta, \gamma$  e  $\delta U$

onde o fluxo de alimentação  $F$  é dado pela soma das vazões das retiradas, convertidas as unidades,  $\theta$  é obtido experimentalmente através da expressão (6.2), uma vez que a precisão na determinação das razões de abundância é muito maior que a precisão dos medidores de vazão, tornando a indicação do corte  $\theta$  calculado pelas razões de abundância mais precisa que a estimada pelas vazões  $Q_P$  e  $Q_W$ .

Os modelos denominados 2, aqueles cujas variáveis de entrada foram  $F, p_P$ , e  $\theta$ , se mostraram melhores na comparação dos valores calculados pela rede com os valores experimentais, tanto para o “learning set” como para o “test set”. Isto pode ser atribuído à melhor estimativa do corte  $\theta$  nesses casos. Na análise da variável mais importante do processo, o poder de separação  $\delta U$ , observamos que os modelos onde o  $\delta U$  é calculado diretamente pela rede neural mostraram um melhor ajuste. Isto pode ser explicado pela

variação exponencial do poder de separação  $\delta U$  com as razões de abundância. Desta forma, um pequeno erro nos valores calculados das razões de abundância são propagados exponencialmente para o  $\delta U$ . Este fato pode ser visualizado na Figura 6.1, que ilustra a propagação do erro na razão de abundância do produto RP no cálculo do poder de separação para o caso simétrico ( $\beta=\gamma$ ).



**FIGURA 6.1:** Ilustração da propagação de erro das razões de abundância para o poder de separação  $\delta U$  (valor normalizado)

Por esta rápida avaliação, é possível observar que erros da ordem de  $1E-4$  no cálculo das razões de abundância, que correspondem a um erro relativo da ordem de 1%, representam erros de até 30% no valor obtido do poder de separação  $\delta U$ . Esta propagação de erros exponencial conduz a uma preferência aos modelos cujas variáveis de saída são classificadas com **B**, uma vez que o presente caso é mais complexo que o anterior.

No caso específico do modelo 2B, foi observado um bom ajuste aos valores do poder de separação  $\delta U$  e das pressões das linhas de alimentação  $p_F$  e de rejeito  $p_W$ . No entanto, os parâmetros separativos  $\beta$  e  $\gamma$  não conseguiram ser razoavelmente estimados por essa rede neural. Há também o problema da consistência dos resultados finais: com os valores de  $\beta$  e  $\gamma$  calculados pela rede neural é possível recalculer o corte e o próprio poder de separação  $\delta U$ . Devido ao mau ajuste desses parâmetros, foi então proposto o caminho inverso: calcular os valores de  $\beta$  e  $\gamma$  a partir do corte, obtido experimentalmente, e considerado uma variável de entrada do modelo, e do valor do poder de separação  $\delta U$  obtido. Isto é realizado através da solução de um pequeno sistema de equações não lineares, definido pelas equações (6.2) e (2.6), rescrita em termos das razões de abundância:

$$\theta = \frac{(R_F - R_W) \cdot (R_P + 1)}{(R_P - R_W) \cdot (R_F + 1)} \quad (6.2)$$

$$\delta U = F \left[ \theta \cdot \frac{(R_F - 1)}{(R_P + 1)} \cdot \ln(R_F) + (1 - \theta) \cdot \frac{(R_W - 1)}{(R_W + 1)} \cdot \ln(R_W) - \frac{(R_F - 1)}{(R_P + 1)} \cdot \ln(R_F) \right] \quad (6.3)$$

onde  $F$  é o fluxo de alimentação dado em kg de U/ano, obtido a partir da soma das vazões das retiradas  $Q_P$  e  $Q_W$ .

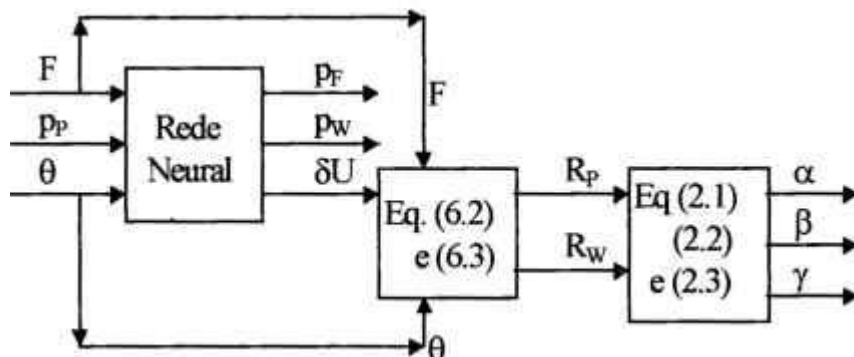
Uma vez testado este procedimento de cálculo, com resultados extremamente satisfatórios em termos do ajuste dos valores calculados dos parâmetros  $\beta$  e  $\gamma$ , a opção do esquema de variáveis recai em uma variação do modelo 2B, excluindo os parâmetros  $\beta$  e  $\gamma$  para o treinamento de uma nova rede neural. Assim, para o modelo final, foi definida uma rede neural tendo como variáveis de entrada:

- $F$  : fluxo da alimentação
- $\theta$  : corte
- $p_P$  : pressão na linha de retirada do produto

e como variáveis de saída:

- $p_F$  : pressão na linha da alimentação
- $p_W$  : pressão na linha de retirada do rejeito
- $\delta U$  : poder de separação

O esquema do modelo final adotado para o cálculo dos parâmetros operacionais e de separação da centrífuga em estudo, quando se considera variações no corte, é representado na Figura 6.2. A solução do sistema de equações não lineares dado pelas Eqs.(6.2) e (6.3) é resolvido através da subrotina SNSQE, adaptada para trabalhar em dupla precisão, descrita por KAHANER [6.1], baseada numa modificação do método híbrido de Powell.



**FIGURA 6.2:** Esquema do modelo adotado para o cálculo dos parâmetros da centrífuga com variações de corte

Lembramos que a alimentação da centrífuga é estabelecida como sendo urânio natural, cuja razão de abundância é  $R_F=0.725\%$ . Os dados utilizados no treinamento

da rede, bem como os resultados posteriores, são considerados sigilosos, e portanto são apresentados de forma normalizada.

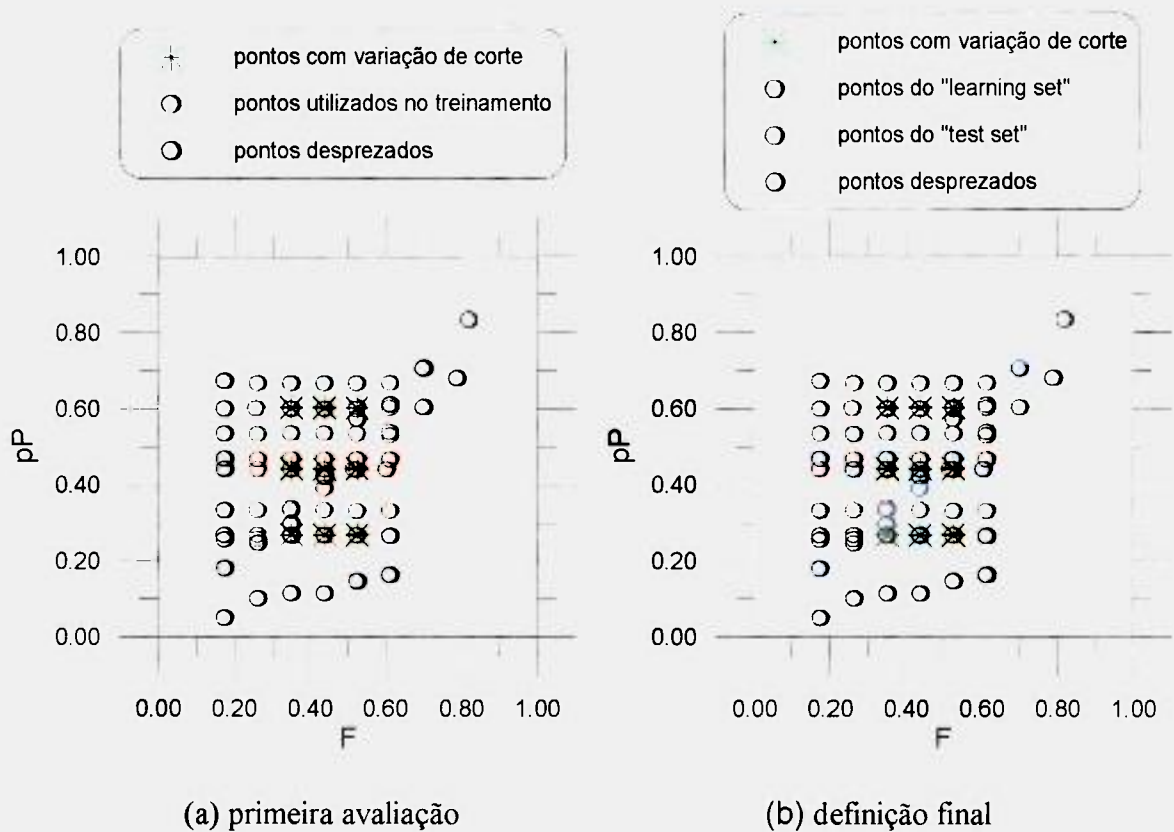
## 6.1 Treinamento e testes da rede neural

Os experimentos foram realizados de modo a se observar a variação de um parâmetro de cada vez: para cortes próximos a 0.5 foi alterado o fluxo de alimentação para diferentes pressões de produto  $p_p$  e posteriormente, para três valores de pressão  $p_p$  e três valores de fluxo  $F$ , totalizando nove condições definidas pelo par  $(F, p_p)$ , foi avaliada a variação do corte  $\theta$ . Foram ainda realizados experimentos sem controle do valor da pressão de produto (mantendo uma válvula de retirada em posição fixa) e sem controle do valor do corte (mantendo as duas válvulas das retiradas em posições fixas).

Os dados experimentais passaram por uma triagem, onde foram excluídos os pontos obtidos com o procedimento experimental descrito por último e os pontos obtidos com fluxos e pressões fora da fronteira do domínio da maioria dos dados. Foram também excluídos dois pontos experimentais, obtidos com o mais baixo nível da pressão  $p_p$ , por apresentarem visivelmente um grande erro experimental, possível de ser observado na superfície de resposta dos valores experimentais do poder de separação  $\delta U$ . A Figura 6.3-a mostra esquematicamente o domínio da pressão do produto  $p_p$  e do fluxo de alimentação  $F$ , indicando os pontos excluídos e os pontos onde foi verificada a variação do corte. Nesta seleção os pontos foram distribuídos aleatoriamente entre o “learning set” e o “test set”. O modelo obtido com este conjunto não se mostrou satisfatório, representando a influência da pressão  $p_p$  de forma mais pobre ainda que o modelo inicial (2B).

Retornando ao conjunto completo dos dados experimentais, foi feita uma nova seleção, excluindo agora os dois pontos com o excessivo erro experimental e os pontos com valores de pressão muito baixos e de vazão muito altos. Foram então separados em dois grupos: o “learning set”, com 67 conjuntos de dados, usado para o treinamento da

rede, e o “test set”, também com 67 conjuntos de dados, usado para verificação do treinamento. A distribuição dos dados experimentais entre o “learning set” e o “test set” foi estabelecida de forma a apresentar a melhor distribuição espacial dentro do domínio, isto é, procuramos distribuir dados obtidos nas mesmas condições experimentais entre os dois conjuntos e intercalar no espaço os demais dados. O domínio dos dados bem como a distribuição entre o “learning set” e o “test set” realizada desta forma é esquematizada na Figura 6.3-b. Cada dado é resultante de uma média de três determinações. Os dados normalizados para o intervalo de zero a um se encontram no Apêndice 6.7.1.



**FIGURA 6.3:** Esquema do domínio das pressões e vazões utilizadas e da distribuição entre o “learning set” e o “test set”

A estrutura de rede é semelhante à utilizada nos casos anteriores, a saber, uma rede neural de três camadas com o treinamento realizado pelo algoritmo de “retropropagação”. Foram testadas diferentes redes, com 4 (quatro) a 12 (doze) neurônios na camada oculta. A Tabela 6.1 mostra os erros calculados em cada caso para o “learning set”


e para o “test set”, com um número máximo de 100 000 apresentações. Foram ainda avaliadas a possibilidade de um maior número de apresentações e a utilização de fator de aceleração de convergência  $\eta$  dinâmico (NASCIMENTO [6.2].), recursos estes que não se mostraram necessários para melhorar o treinamento da rede.

TABELA 6.1


Somatório de erros calculados no treinamento de redes neurais com diferentes números de neurônios na camada oculta (NH)- máximo de 100 000 apresentações e fator de aceleração de convergência constante  $\eta=1$

NH	“LEARNING SET”		“TEST SET”	
	N. de apresentações	RMST min.	N. de apresentações	RMSTT min.
4	21 500	0.5630	19 000	1.6448
5	30.000	0.2151	27 600	0.6096
6	9 800	0.2859	9 800	0.8627
7	<b>31 000</b>	<b>0.1810</b>	<b>29 800</b>	<b>0.5236</b>
8	4 000	0.2657	3 600	0.7491
9	4 700	0.2248	4 600	0.6319
10	12 600	0.2210	12 400	0.6324
11	100 000	0.1531	100 000	0.4833
12	100 000	0.1781	100 000	0.5463

Os erros mínimos observados para cada rede treinada, mostrados na Tabela 6.1, são também apresentados na forma de um gráfico de barras na Figura 6.4. Com esses resultados foi escolhida uma rede neural com 7 (sete) neurônios na camada oculta. O comportamento da soma dos erros para essa rede em função do número de apresentações é mostrado na Figura 6.5. O Apêndice 6.7.2 mostra os resultados das variáveis de saída calculados pela rede neural escolhida, e dos respectivos valores experimentais, enquanto o Apêndice 6.7.3 traz os valores dos pesos correspondentes a essa rede.



**FIGURA 6.4:** Erro total no treinamento de redes neurais com diferentes números de neurônios na camada oculta para o “learning set” e para o “test set”




**FIGURA 6.5:** Erro total no treinamento de uma rede neural com sete neurônios na camada oculta ao longo do treinamento, em função do número de apresentações


## 6.2 Comparação entre os dados experimentais e os calculados

Tendo a rede treinada, os pesos são definidos e as variáveis de saída podem ser calculadas e comparadas aos valores experimentais. Os pesos escolhidos são aqueles que apresentam o menor erro total para o “test set”.


A comparação entre os valores experimentais e os calculados das pressões  $p_F$  e  $p_W$  e do poder de separação  $\delta U$  é mostrada nas Figuras 6.6, 6.7 e 6.8. Como no capítulo anterior, a linha cheia em diagonal representa a situação ideal, com ajuste perfeito de todos os dados experimentais e as linhas pontilhadas representam a faixa de variação aceitável entre os valores experimentais e os calculados, baseada numa estimativa do erro experimental, sendo  $\Delta p_F = \Delta p_W = 0.05$ ,  $\Delta \delta U = 0.09$ ,  $\Delta \alpha = \Delta \beta = \Delta \gamma = 0.02$ . Os resultados calculados e os dados experimentais apresentam um bom grau de ajuste, tanto no “learning set” como no “test set”. O cálculo dos parâmetros  $\alpha$ ,  $\beta$  e  $\gamma$  segue agora o esquema apresentado na Figura 6.2. As razões de abundância são calculadas a partir dos valores do poder de separação calculado pela rede neural e do corte, obtido experimentalmente e utilizado como variável de entrada no modelo. Com esses valores de razão de abundância são então calculados os parâmetros separativos. As Figuras 6.9, 6.10 e 6.11 mostram a comparação dos valores experimentais e calculados desses parâmetros. Os valores ditos experimentais foram obtidos pelas equações 2.1, 2.2 e 2.3 a partir dos valores experimentais das razões de abundância, medidos por espectrometria de massa. Novamente foi observado um bom ajuste dos dados de ambos conjuntos.



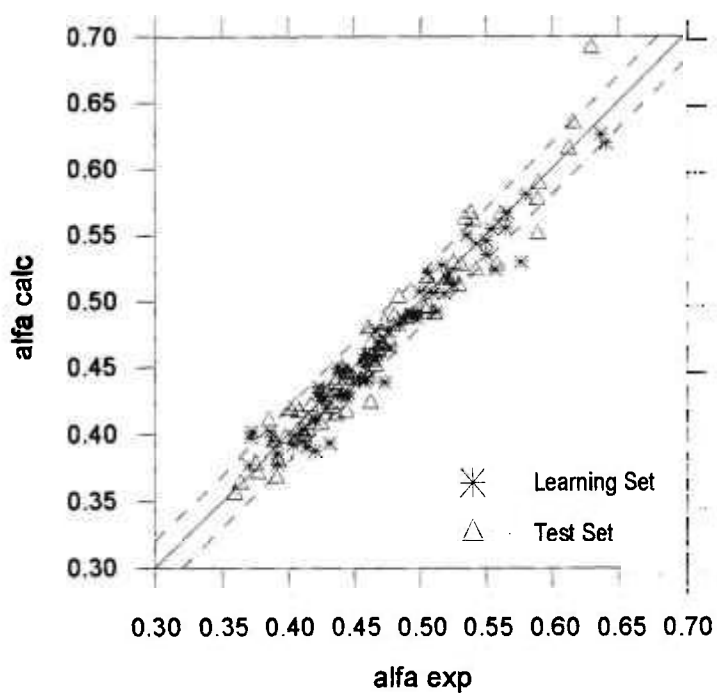
**FIGURA 6.6:** Comparação entre os resultados experimentais e os calculados pela rede neural da pressão de alimentação  $p_F$




**FIGURA 6.7:** Comparação entre os resultados experimentais e os calculados pela rede neural da pressão de rejeito  $p_W$



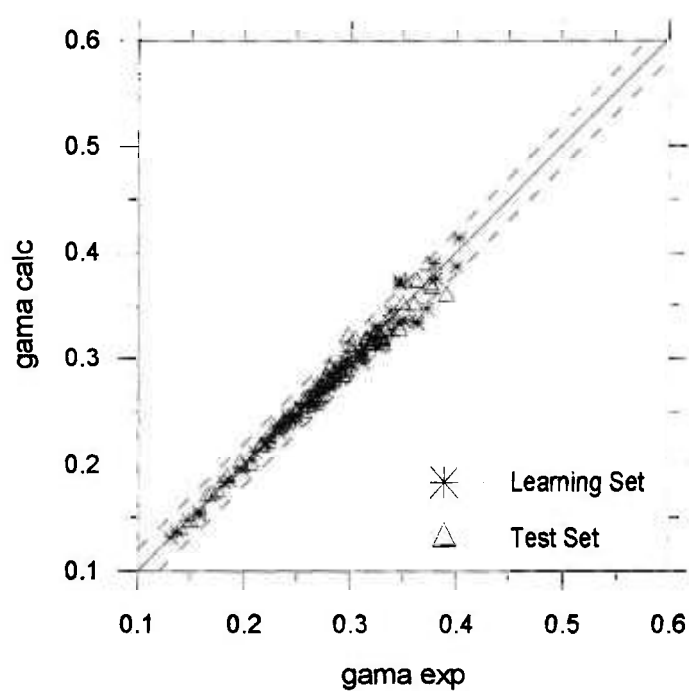
**FIGURA 6.8:** Comparação entre os resultados experimentais e os calculados através da rede neural do poder de separação  $\delta U$



**FIGURA 6.9:** Comparação entre os resultados experimentais e os calculados através da rede neural do fator de separação  $\alpha$




**FIGURA 6.10:** Comparação entre os resultados experimentais e os calculados através da rede neural do fator de enriquecimento  $\beta$




**FIGURA 6.11:** Comparação entre os resultados experimentais e os calculados através da rede neural do fator de empobrecimento  $\gamma$


A seguir é avaliado o ajuste do modelo através de curvas de resposta comparadas aos pontos experimentais, mantidas as demais condições constantes. Desta forma podemos observar nas Figuras 6.12, 6.13 e 6.14 a resposta do poder de separação em função das variáveis de entrada: fluxo de alimentação  $F$ , pressão de produto  $p_p$  e corte  $\theta$ , respectivamente. Novamente podemos observar um bom ajuste do modelo frente aos dados experimentais, tanto do “learning set” como do “test set”. Outros valores de referência foram adotados para realizar esta avaliação, apresentando também resultados satisfatórios, e ainda melhores no caso da variação com o fluxo de alimentação  $F$ , porém não serão aqui apresentados por se tratar de uma avaliação repetitiva. Os valores de referência aqui apresentados foram escolhidos tendo como critério o ponto de operação nominal da centrífuga para instalação em cascata.



**FIGURA 6.12:** Curva de resposta do poder de separação  $\delta U$  em função do fluxo de alimentação  $F$ , mantidos constantes o corte  $\theta=0.5$  e a pressão na linha do produto  $p_p=0.49$




**FIGURA 6.13:** Curva de resposta do poder de separação  $\delta U$  em função da pressão na linha do produto  $p_P$ , mantidos constantes o corte  $\theta=0.5$  e o fluxo de alimentação  $F=0.63$




**FIGURA 6.14:** Curva de resposta do poder de separação  $\delta U$  em função do corte  $\theta$ , mantidos constantes o fluxo de alimentação  $F=0.63$  e a pressão na linha do produto  $p_P=0.49$


Da mesma forma, as respostas das pressões das linhas de alimentação  $p_F$  e de retirada do rejeito  $p_W$ , são analisadas nas Figuras 6.15 a 6.17. Cabe lembrar que essas curvas representam uma pequena parte da resposta total do modelo. Dentre os modelos avaliados, o presente modelo foi o que melhor se ajustou aos dados experimentais disponíveis.



**FIGURA 6.15:** Curvas de resposta das pressões nas linhas de alimentação  $p_F$  e de rejeito  $p_W$  em função do fluxo de alimentação  $F$ , mantidos constantes o corte  $\theta=0.5$  e a pressão na linha do produto  $p_P=0.49$




**FIGURA 6.16:** Curvas de resposta das pressões nas linhas de alimentação  $p_F$  e de rejeito  $p_W$  em função da pressão na linha do produto  $p_P$ , mantidos constantes o corte  $\theta=0.5$  e o fluxo de alimentação  $F=0.63$




**FIGURA 6.17:** Curvas de resposta das pressões nas linhas de alimentação  $p_F$  e de rejeito  $p_W$  em função do corte  $\theta$ , mantidos constantes o fluxo de alimentação  $F=0.63$  e a pressão na linha do produto  $p_P=0.49$


As Figuras 6.18 a 6.20 trazem agora a avaliação da resposta do modelo em relação aos fatores de enriquecimento  $\beta$ , de empobrecimento  $\gamma$  e de separação  $\alpha$ , com as variáveis de entrada do sistema.



**FIGURA 6.18:** Curvas de resposta dos fatores de separação  $\alpha$ , de enriquecimento  $\beta$  e de empobrecimento  $\gamma$  em função do fluxo de alimentação  $F$ , mantidos constantes o corte  $\theta=0.5$  e a pressão na linha do produto  $p_p=0.49$



**FIGURA 6.19:** Curvas de resposta dos fatores de separação  $\alpha$ , de enriquecimento  $\beta$  e de empobrecimento  $\gamma$  em função da pressão na linha do produto  $p_P$ , mantidos constantes o corte  $\theta=0.5$  e o fluxo de alimentação  $F=0.63$




**FIGURA 6.20:** Curvas de resposta dos fatores de separação  $\alpha$ , de enriquecimento  $\beta$  e de empobrecimento  $\gamma$  em função do corte  $\theta$ , mantidos constantes o fluxo de alimentação  $F=0.63$  e a pressão na linha do produto  $p_P=0.49$

A resposta do modelo pode também ser analisada através das superfícies de resposta. No presente momento, vamos analisar a resposta referente ao poder de separação  $\delta U$ , com as variáveis de entrada do modelo, a saber o fluxo de alimentação  $F$ , a pressão na linha do produto  $p_p$  e o corte  $\theta$ , agrupados dois a dois, mantendo a terceira variável constante no nível de referência adotado. Cabe salientar que, para resguardar o sigilo envolvido no processo do enriquecimento do urânio, as superfícies apresentadas são construídas com valores normalizados, tanto das variáveis de entrada como das respostas, exceção feita unicamente para o corte  $\theta$ , que, por definição varia de zero a um e não representa nenhuma informação sensível do processo. No entanto serão adotados os mesmos critérios de normalização e de representação (esquema de cores) em todos os gráficos do presente capítulo, para facilitar a interpretação e comparação das superfícies obtidas nos diversos casos analisados.


Desta forma, a Figura 6.21 mostra a superfície de resposta do poder de separação  $\delta U$  em função do fluxo de alimentação  $F$  e da pressão do produto  $p_p$ , mantido o corte constante. Nessa superfície observamos que o poder de separação  $\delta U$  é mais sensível a variações da pressão  $p_p$  para fluxos de alimentação  $F$  baixos. Por outro lado o fluxo de alimentação  $F$  apresenta maior influência quando se trabalha em níveis de pressão  $p_p$  altos. Com isso se conclui que, para esse valor de corte, o ponto de operação mais conveniente é com fluxos de alimentação  $F$  altos e pressões de produto  $p_p$  baixas, onde o poder de separação  $\delta U$  assume valores mais elevados e é menos sensível a variações das condições de operação.

Da mesma forma, a Figura 6.22 traz a superfície de resposta do poder de separação  $\delta U$  com o fluxo de alimentação  $F$  e com o corte  $\theta$ , para a pressão de produto  $p_p$ .

Na Figura 6.23 observamos a superfície de resposta do poder de separação  $\delta U$  em função da pressão do produto  $p_p$  e do corte  $\theta$ , mantido o fluxo de alimentação  $F$  no nível de referência adotado.




(a)




(b)

**FIGURA 6.21:** Superfície de resposta do poder de separação  $\delta U$  em função do fluxo de alimentação  $F$  e da pressão do produto  $p_p$ , mantido constante o corte  $\theta=0.5$ : (a) vista em perspectiva e (b) vista de topo




(a)



(b)

**FIGURA 6.22:** Superfície de resposta do poder de separação  $\delta U$  em função do fluxo de alimentação  $F$  e do corte  $\theta$ , mantido constante a pressão do produto  $p_p=0.49$ : (a) vista em perspectiva e (b) vista de topo



**FIGURA 6.23:** Superfície de resposta do poder de separação  $\delta U$  em função da pressão do produto  $p_P$  e do corte  $\theta$ , mantido constante do fluxo de alimentação  $F=0.63$ : (a) vista em perspectiva e (b) vista de topo

### 6.3 Otimização das condições de operação da centrífuga

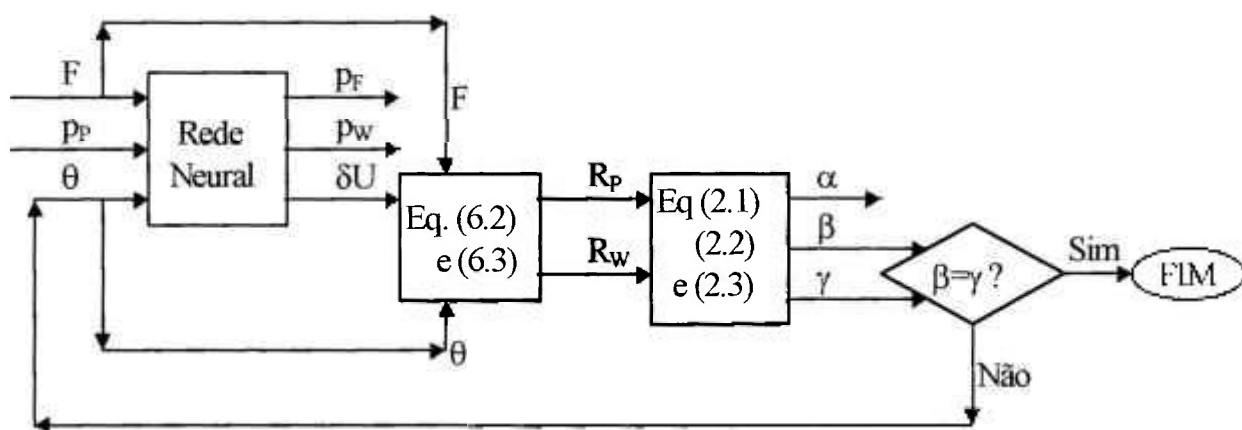
O modelo obtido permite avaliar o desempenho da centrífuga em qualquer condição de operação, uma vez que engloba todas as variáveis de processo envolvidas na operação da centrífuga. Assim este modelo numérico será utilizado para avaliar algumas condições de operação especiais, a saber:

- a) o caso simétrico, determinado pelo corte simétrico  $\theta^*$  onde  $\beta=\gamma=\sqrt{\alpha}$  ;
- b) o caso em que o corte  $\theta$  é otimizado, tendo como critério a maximização do poder de separação  $\delta U$ , para cada condição de operação definida pelo par  $F$  e  $p_P$ .

#### 6.3.1 Caso simétrico

O esquema de cálculo para obtenção dos parâmetros da centrífuga em estudo, operando no caso simétrico ( $\beta=\gamma$ ), é representado na Figura 6.24. O sistema de


equações não-lineares definido pelas Eqs.(6.2) e (6.3), como já foi dito, é resolvido através da subrotina SNSQE [6.1] e a convergência para a condição de processo simétrico, dada por  $\beta=\gamma$  é feita pela subrotina FZERO, do mesmo pacote numérico [6.1], também adaptada para operação em dupla precisão. Este procedimento usa uma eficiente combinação do método da bisseção e da regra da secante.




**FIGURA 6.24:** Esquema para o cálculo numérico dos parâmetros da centrífuga em estudo para o caso simétrico ( $\beta=\gamma$ )

Nesse caso, as variáveis de entrada do modelo global são: o fluxo de alimentação  $F$  e a pressão  $p_p$ , o corte  $\theta^*$  é definido internamente de modo a satisfazer a condição do processo simétrico. As respostas assim obtidas são o poder de separação  $\delta U^*$ , os fatores  $\beta^*$  ( $=\gamma^*$ ) e  $\alpha^*$  e o valor do corte  $\theta^*$ , para a condição de processo simétrico além das respectivas pressões de alimentação  $p_F$  e de rejeito  $p_w$ .


Nas Figuras 6.25 a 6.28 são apresentadas, respectivamente, as superfícies de resposta do corte  $\theta^*$ , do poder de separação  $\delta U^*$ , do fator de separação  $\alpha^*$  e do fator de enriquecimento  $\beta^*$ , em função das condições de operação dadas pelo fluxo de alimentação  $F$  e pela pressão na linha do produto  $p_p$ .



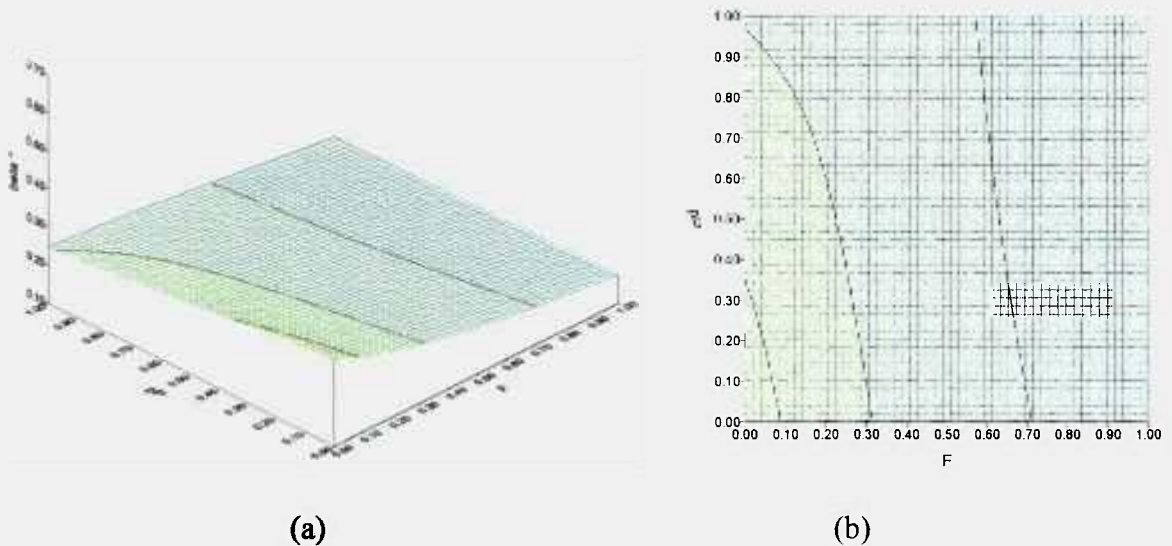
**FIGURA 6.25:** Superfície de resposta do corte  $\theta^*$  do processo simétrico ( $\beta=\gamma$ ) em função do fluxo de alimentação  $F$  e da pressão do produto  $p_P$ : (a) vista em perspectiva e (b) vista de topo



**FIGURA 6.26:** Superfície de resposta do poder de separação  $\delta U^*$  do processo simétrico ( $\beta=\gamma$ ) em função do fluxo de alimentação  $F$  e da pressão do produto  $p_P$ : (a) vista em perspectiva e (b) vista de topo



**FIGURA 6.27:** Superfície de resposta do fator de separação  $\alpha^*$  do processo simétrico ( $\beta=\gamma$ ) em função do fluxo de alimentação  $F$  e da pressão do produto  $p_P$ : (a) vista em perspectiva e (b) vista de topo



**FIGURA 6.28:** Superfície de resposta do fator de enriquecimento  $\beta^*$  do processo simétrico ( $\beta=\gamma$ ) em função do fluxo de alimentação  $F$  e da pressão do produto  $p_P$ : (a) vista em perspectiva e (b) vista de topo

Na Figura 6.27 nota-se claramente que o corte  $\theta^*$ , no qual se estabelece o processo simétrico, é praticamente constante nessa centrífuga, variando na terceira casa

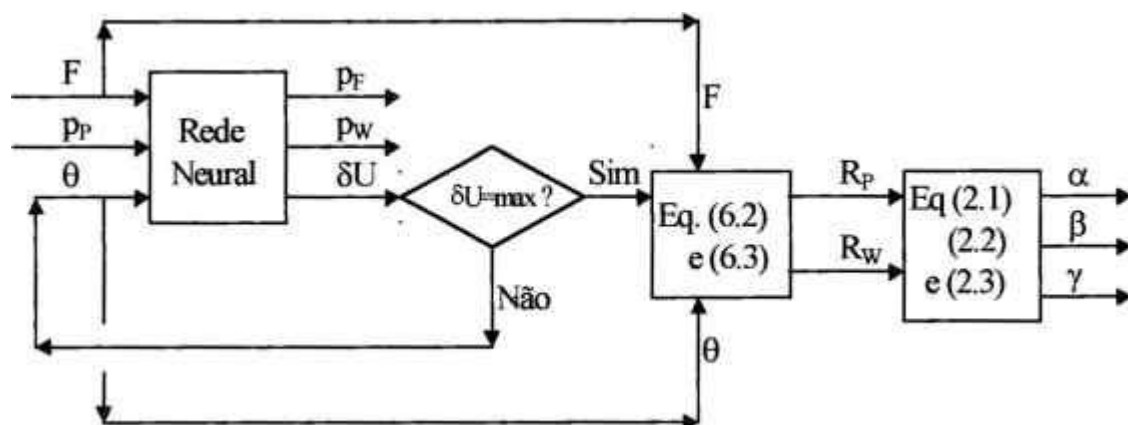
decimal com a alteração das condições de operação  $F$  e  $p_p$ . Por isso a superfície apresentada na Figura 6.25 se mostra plana.

Como o corte  $\theta^*$  do processo simétrico é ligeiramente inferior ao corte  $\theta$  escolhido anteriormente como valor de referência para as curvas de resposta e para a superfície de resposta da Figura 6.21, o poder de separação  $\delta U^*$  obtido também é ligeiramente diferente. No caso, foi alcançada uma ligeira melhora nos valores de  $\delta U^*$ , em comparação aos resultados da Figura 6.21.

Este esquema de cálculo foi executado para todo o domínio das variáveis de entrada definido pelo conjunto de pontos utilizado no treinamento da rede, de forma discreta, com intervalos de variação pequenos, porém coerentes com as grandezas medidas. Nesse universo, representado pelas figuras citadas, foi selecionado, por busca direta, as condições de operação que apresentaram o maior valor do poder de separação  $\delta U$ , apresentadas na Tabela 6.2 de forma normalizada. Esse ponto otimizado será discutido mais adiante, juntamente com o próximo critério de otimização.

### 6.3.2 Corte otimizado

A Figura 6.29 mostra o esquema de cálculo utilizado na presente otimização. Para cada par das variáveis de entrada  $F$  e  $p_p$  é encontrado o valor do corte  $\theta_{ot}$  que maximiza o poder de separação  $\delta U$  através de um processo iterativo, utilizando a subrotina FMIN [6.1], também adaptada para dupla precisão. Este é um subprograma que encontra numericamente o valor mínimo de uma dada função num intervalo determinado através de um método que combina a busca por seção-dourada (que utiliza a clássica “razão dourada” 0,6180) e a interpolação parabólica sucessiva.

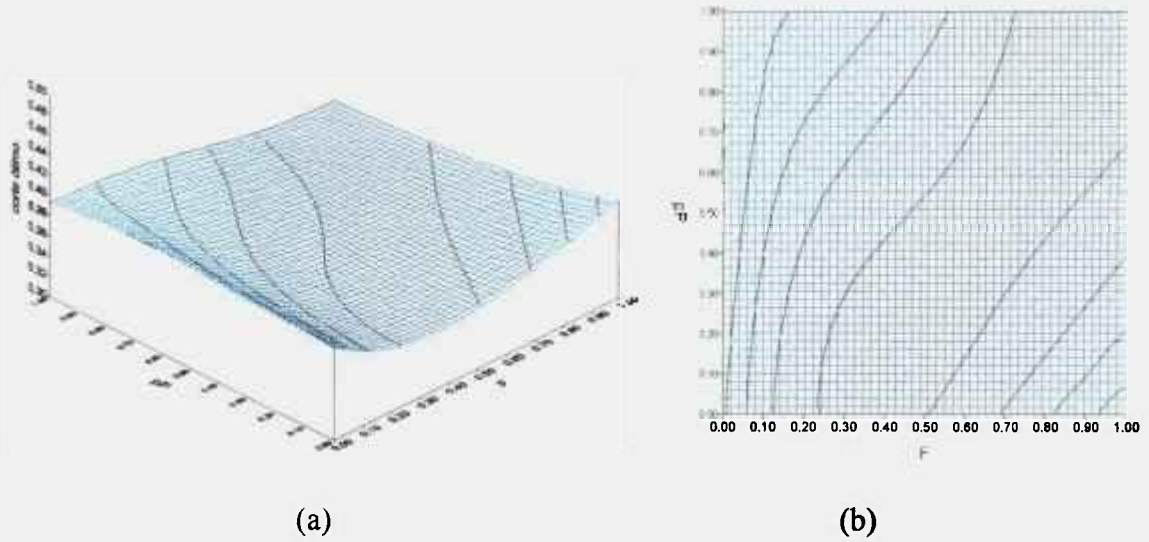


**FIGURA 6.29:** Esquema para o cálculo numérico dos parâmetros da centrífuga em estudo otimizando o corte, de modo a maximizar o poder de separação  $\delta U$


O presente esquema também tem como entradas o fluxo de alimentação  $F$  e a pressão de produto  $p_p$ , e como resultados os parâmetros da centrífuga  $\delta U$ ,  $\alpha$ ,  $\beta$ ,  $\gamma$ ,  $p_F$ ,  $p_W$  e o valor ótimo  $\theta_{ot}$ . Esses parâmetros são a seguir apresentados na forma de superfícies de respostas através das Figuras 6.30 a 6.34. Como nos casos anteriores, são mantidos os critérios de normalização e de representação para facilitar a interpretação e comparação dos resultados.

Nesse caso, o corte  $\theta_{ot}$  se mostrou sensível às condições de operação da centrífuga definida por  $F$  e  $p_p$ . O valor ótimo do corte  $\theta$  diminui com o aumento do fluxo de alimentação  $F$ , passando por um mínimo, e torna a crescer. O corte  $\theta_{ot}$  se mostrou pouco variável com  $p_p$  quando o fluxo de alimentação  $F$  é baixo, e um pouco mais sensível quando  $F$  é mais alto. Os valores de  $\theta_{ot}$  encontrados se mostraram sistematicamente menores que os valores obtidos para o processo simétrico  $\theta^*$ .


O poder de separação  $\delta U$ , maximizado em relação ao corte  $\theta$ , por princípio, apresenta valores mais elevados que os obtidos nos casos analisados anteriormente.




**FIGURA 6.30:** Superfície de resposta do corte otimizado  $\theta_{ot}$  em função do fluxo de alimentação  $F$  e da pressão do produto  $p_p$  com o corte otimizado: (a) vista em perspectiva e (b) vista de topo




**FIGURA 6.31:** Superfície de resposta do poder de separação  $\delta U_{max}$  em função do fluxo de alimentação  $F$  e da pressão do produto  $p_p$  com o corte otimizado: (a) vista em perspectiva e (b) vista de topo



**FIGURA 6.32:** Superfície de resposta do fator de separação  $\alpha$  otimizado em função do fluxo de alimentação  $F$  e da pressão do produto  $p_p$  com o corte otimizado: (a) vista em perspectiva e (b) vista de topo



**FIGURA 6.33:** Superfície de resposta do fator de enriquecimento  $\beta$  otimizado em função do fluxo de alimentação  $F$  e da pressão do produto  $p_p$  com o corte otimizado: (a) vista em perspectiva e (b) vista de topo



**FIGURA 6.34:** Superfície de resposta do fator de empobrecimento  $\gamma$  otimizado em função do fluxo de alimentação  $F$  e da pressão do produto  $p_P$  com o corte otimizado: (a) vista em perspectiva e (b) vista de topo

Novamente o ponto ótimo desta condição foi encontrado dentre os pontos calculados, e seus valores apresentados na Tabela 6.2. Esta otimização mostra as condições de operação ótimas sem nenhuma restrição, ao contrário do caso anterior onde o corte era restrito pela condição de operação em processo simétrico.

**TABELA 6.2**

Valores normalizados dos parâmetros ótimos da centrífuga

	<b>PROCESSO SIMÉTRICO</b>	<b>CORTE ÓTIMO</b>
<b>Fluxo de alimentação <math>F</math></b>	0.7464	0.6323
<b>Pressão do produto <math>p_P</math></b>	0.1281	0.1281
<b>Corte <math>\theta</math></b>	0.4911	0.3831
<b>Poder de separação <math>\delta U</math></b>	0.8870	0.9127
<b>Pressão de alimentação <math>p_F</math></b>	0.7074	0.6078
<b>Pressão do rejeito <math>p_W</math></b>	0.5109	0.3305
<b>Fator de separação <math>\alpha</math></b>	0.4170	0.4564
<b>Fator de enriquecimento <math>\beta</math></b>	0.2526	0.3114
<b>Fator de empobrecimento <math>\gamma</math></b>	0.2526	0.2312

Como era esperado, o ponto ótimo encontrado sem a restrição do processo simétrico apresentou o poder de separação  $\delta U$  mais elevado. A operação em processo simétrico representou uma pequena perda de 2.5% no valor do poder de separação  $\delta U$ , em relação ao corte otimizado, no entanto, para que não ocorram misturas de composições diferentes em uma cascata, as centrífugas que a compõem devem trabalhar no processo simétrico. O caso do processo simétrico apresentou um fluxo de alimentação ótimo um pouco mais alto, o que representa valores do fator de separação mais baixos, o que é desvantajoso para uma cascata. O valor do corte ótimo encontrado foi significativamente mais baixo que o corte simétrico. Modelos fenomenológicos prevêm uma relação crescente entre o corte e a posição axial da alimentação para a condição de não-mistura de composições isotópicas no interior da centrífuga, o que melhora o desempenho separativo da máquina. MIGLIAVACCA [6.3] apresenta esta relação através da Figura 21 (Página 79) em termos da posição axial adimensional da alimentação  $\eta_F$  ( $\eta_F=1-Z_E/Z$ ) que satisfaz a condição de não-mistura versus o corte  $\theta$ . A centrífuga utilizada no presente estudo possuía uma relação  $\eta_F$  baixa (da ordem de 0.3). Segundo a referida figura, para satisfazer a condição de não mistura no interior do rotor, o corte correspondente seria também baixo. Por se tratar de um modelo bastante simplificado, calculado para outro modelo de centrífuga, desta análise podemos tirar somente a tendência, isto é, centrífugas com posições de alimentação representadas por um  $\eta_F$  baixo são otimizadas com valores de cortes baixos, abaixo do valor do corte simétrico.

Do ponto de vista prático, deve ser imposta uma restrição de processo em termos da pressão de retirada do produto  $p_P$  de forma a possibilitar o transporte de gás interestágios numa cascata com  $p_P > p_F$ . Nessas condições os valores otimizados através do modelo definido pela rede neural são apresentados na Tabela 6.3, novamente são resguardados por uma normalização com os mesmos parâmetros utilizados na Tabela 6.2. Um novo experimento foi realizado, com outra centrífuga da mesma geração, montada exatamente com as mesmas características, para verificação dos pontos otimizados. Os resultados obtidos experimentalmente se encontram na Tabela 6.3, para comparação com os valores previstos. A Tabela 6.3 também apresenta os desvios percentuais observados. Esses desvios foram calculados com os valores originais das variáveis envolvidas, não com os

valores normalizados. Devido ao critério de normalização adotado, os desvios obtidos com os valores normalizados são ligeiramente diferentes dos desvios reais.

**TABELA 6.3**

Valores normalizados dos parâmetros ótimos da centrífuga sujeita à restrição de  $p_P > p_F$

	PROCESSO SIMÉTRICO			CORTE ÓTIMO		
	PREVISTO	EXP.	DESVIO	PREVISTO	EXP.	DESVIO
<b>Fluxo de alimentação F</b>	0.5183	0.5137	-0.67%	0.5183	0.5198	0.22%
<b>Pressão do produto <math>p_P</math></b>	0.5734	0.5352	0.14%	0.5734	0.5352	0.14%
<b>Corte <math>\theta</math></b>	0.4894	0.5079	4.04%	0.3750	0.3819	2.03%
<b>Poder de separação <math>\delta U</math></b>	0.7940	0.8208	2.98%	0.8379	0.9342	10.2%
<b>Pressão de alimentação <math>p_F</math></b>	0.5224	0.4893	-6.89%	0.5369	0.5015	-4.60%
<b>Pressão do rejeito <math>p_W</math></b>	0.6144	0.5613	-6.99%	0.5264	0.5216	0.71%
<b>Fator de separação <math>\alpha</math></b>	0.4510	0.4582	2.05%	0.4736	0.4916	4.82%
<b>Fator de enriquecimento <math>\beta</math></b>	0.2684	0.2646	-2.26%	0.3242	0.3312	3.12%
<b>Fator de empobrecimento <math>\gamma</math></b>	0.2684	0.2788	6.18%	0.2344	0.2438	6.36%

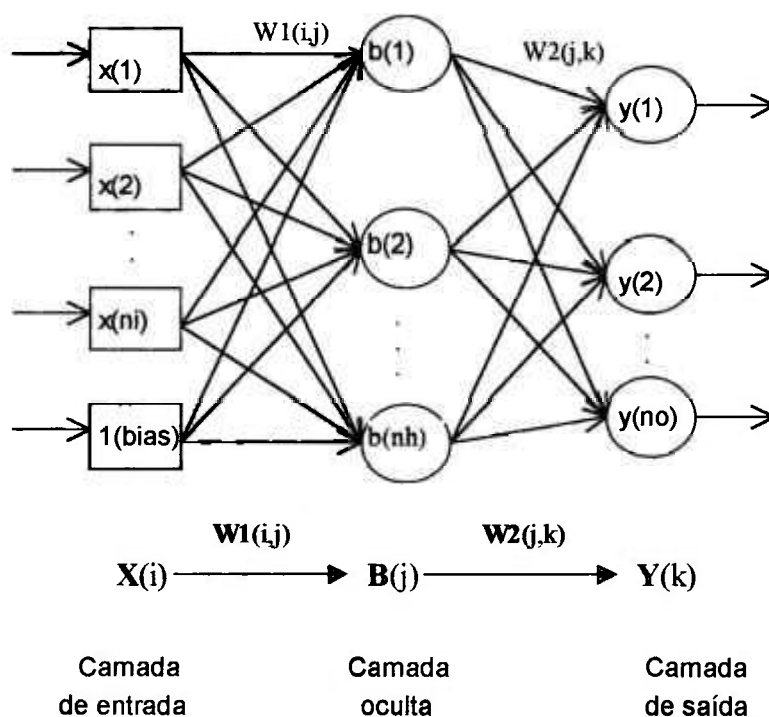
Os desvios observados nos valores do fluxo de alimentação F, da pressão do produto  $p_P$  e do corte  $\theta$  são devidos à imprecisão experimental. Essa imprecisão é propagada aos resultados experimentais analisados, assim os desvios das variáveis de saída, ou seja, dos parâmetros separativos e das pressões  $p_F$  e  $p_W$ , representam uma soma dos erros experimentais e de ajuste do modelo. Considerando que o erro experimental observado nesses ensaios está entre 5 e 10 %, podemos considerar a previsão feita pelo modelo da rede neural muito boa.

## 6.4 Análise de sensibilidade

A análise de sensibilidade em um modelo numérico busca identificar as variáveis mais importantes do processo que está sendo estudado. Isto é feito tomando-se os valores das derivadas parciais  $\partial y_k / \partial x_i$ , onde  $y_k$  são as variáveis de saída do modelo e  $x_i$  são as variáveis de entrada do modelo.

Uma rede neural treinada para descrever um processo é basicamente uma função capaz de mapear um conjunto de vetores de entrada  $\mathbf{X}$ , de dimensão  $n_i$ , em um outro conjunto de vetores  $\mathbf{Y}$  de saída, com dimensão  $n_o$ . Segundo GUO e UHRIG [6.4] este processo de mapeamento pode ser quebrado em duas etapas numa rede neural de três camadas, introduzindo um terceiro vetor  $\mathbf{B}$ , obtido na camada interna, de modo a permitir o uso da regra da cadeia para obter as derivadas parciais:

$$\frac{\partial y_k}{\partial x_i} = \frac{\partial y_k}{\partial b_j} \cdot \frac{\partial b_j}{\partial x_i} \quad (6.4)$$



**FIGURA 6.35:** Esquema de uma rede neural de três camadas e seus parâmetros internos

A Figura 6.35 mostra detalhadamente o esquema sugerido, onde:

- X(i):** é o vetor com os dados de entrada
- B(j):** é o vetor com os dados intermediários da rede neural
- Y(k):** é o vetor com os resultados das variáveis de saída calculados pela rede
- W1(i,j):** é o conjunto de pesos entre a camada de entrada e a camada oculta
- W2(j,k):** é o conjunto de pesos entre a camada oculta e a camada de saída
- Sendo:

$$b(j) = f(S_o(j)) \quad (6.5)$$

$$S_o(j) = \sum_{i=1}^{m-1} w1(i, j).x(i) \quad (6.6)$$

e

$$y(k) = f(S_v(k)) \quad (6.7)$$

$$S_v(k) = \sum_{j=1}^{nh} w2(j, k).b(j) \quad (6.8)$$

onde  $f(S)$  é a função de ativação, no presente trabalho, adotada a função sigmoideal:

$$f(S) = \frac{1}{1 + e^{-S}} \quad (6.9)$$

então

$$b(j) = \frac{1}{1 + \exp \left[ - \sum_{i=1}^{m+1} w1(i, j).x(i) \right]} \quad (6.10)$$

sendo  $x(n_i+1)=1$ , o valor de referência utilizado no treinamento da rede neural (bias), e

$$y(k) = \frac{1}{1 + \exp\left[-\sum_{j=1}^{no} w2(j,k).b(j)\right]} \quad (6.11)$$

Assim

$$\frac{\partial b_j}{\partial x_i} = b_j^2 \cdot w1_{i,j} \cdot \exp\left(-\sum_i w1_{i,j} \cdot x_i\right) \quad (6.12)$$

$$\frac{\partial y_k}{\partial b_j} = y_k^2 \cdot w2_{j,k} \cdot \exp\left(-\sum_j w2_{j,k} \cdot b_j\right) \quad (6.13)$$

então

$$\frac{\partial y_k}{\partial x_i} = \sum_j \left( \frac{\partial y_k}{\partial b_j} \cdot \frac{\partial b_j}{\partial x_i} \right) \quad (6.14)$$

que finalmente resulta em

$$\frac{\partial y_k}{\partial x_i} = y_k \cdot (1 - y_k) \cdot \sum [b_j \cdot (1 - b_j) \cdot w1_{i,j} \cdot w2_{j,k}] \quad (6.15)$$

Esta expressão é facilmente introduzida no programa de simulação por redes neurais, permitindo uma rápida análise de sensibilidade do modelo obtido, baseada numa solução analítica.

Como pode ser observado em (6.15), os valores de  $\partial y_k / \partial x_i$  dependem não só dos pesos da rede **W1** e **W2**, ajustados para descrever o processo, mas também dos valores de  $y_k$ , ou seja, do conjunto de dados de entrada. Isto conduz a dois enfoques diferentes na análise de sensibilidade:

- i) avaliação global do sistema, tomando os valores médios de  $\partial y_k / \partial x_i$  em todo o intervalo das variáveis de entrada;
- ii) avaliação local da resposta do sistema, onde, para um dado conjunto das variáveis de entrada, ou seja, para um dado ponto de operação é avaliada a sensibilidade do sistema a cada uma das variáveis de entrada.

A análise de sensibilidade global do modelo numérico que descreve os parâmetros separativos e operacionais de uma dada centrífuga, obtido no presente capítulo, nos forneceu os valores médios das derivadas parciais, dentro do domínio das variáveis de entrada utilizado no treinamento da rede, apresentados abaixo de forma normalizada. A análise dos valores normalizados das derivadas parciais é decorrente da necessidade de resguardar os valores absolutos das grandezas estudadas, mas por outro lado, mostra uma grande vantagem em relação aos valores absolutos das referidas derivadas: a identificação da importância relativa das variáveis de entrada independe das unidades de medida adotadas, que por sua natureza devem considerar intervalos de variação distintos.

$$\begin{array}{lll}
 \partial p_F / \partial F = 0.826 & \partial p_W / \partial F = 0.071 & \partial \delta U / \partial F = 0.286 \\
 \partial p_F / \partial p_P = 0.039 & \partial p_W / \partial p_P = 0.405 & \partial \delta U / \partial p_P = -0.193 \\
 \partial p_F / \partial \theta = 0.029 & \partial p_W / \partial \theta = 0.556 & \partial \delta U / \partial \theta = -0.110
 \end{array}$$

Esses valores mostram que:

- (a) a pressão de alimentação  $p_F$  é mais sensível ao fluxo de alimentação  $F$  e praticamente independente de  $p_P$  e de  $\theta$ ;
- (b) a pressão da linha  $p_W$  do rejeito varia com a pressão do produto  $p_P$  e com o corte  $\theta$ , e é menos sensível ao fluxo de alimentação  $F$ ;
- (c) poder de separação  $\delta U$ , que normalmente apresenta um comportamento crescente com  $F$  e  $\theta$ , passa por um máximo e então diminui, na maior parte dos pontos analisados, de acordo com os valores médios de  $\partial \delta U / \partial X_i$ , é crescente com o fluxo de alimentação  $F$  e decrescente com a pressão  $p_P$  e com o corte  $\theta$ .

A análise pontual das derivadas parciais em todo o domínio determinado para as variáveis de entrada, no entanto indica, como esperado pela teoria do processo de separação isotópica, que o poder de separação  $\delta U$  apresenta um valor máximo em relação ao fluxo de alimentação  $F$  e em relação ao corte  $\theta$ . Quanto à influência da pressão na linha do produto  $p_P$ , novamente o aumento dessa pressão, dentro dos intervalos estudados, provocou a diminuição do poder de separação  $\delta U$  da centrífuga. Estas constatações concordam com o formato das superfícies apresentadas nas Figuras 6.21 a 6.23, válidas para um caso particular, onde uma das variáveis de entrada era mantida constante.

A título de ilustração apresentamos os valores das derivadas parciais normalizadas obtidos no ponto ótimo, com  $\theta_{ot}$ , definido na Tabela 6.2. As derivadas  $\partial\delta U/\partial F$  e  $\partial\delta U/\partial\theta$  são praticamente zero, por se tratar de um ponto de máximo. Com isso devemos ressaltar que esses valores das derivadas, que poderiam indicar a importância das variáveis de entrada na resposta do modelo, têm validade local na superfície de resposta. Um ponto de operação diferente deste apresentaria outros valores das derivadas.

$$\begin{array}{lll}
 \partial p_F/\partial F = 0.892 & \partial p_w/\partial F = 0.145 & \partial\delta U/\partial F = 0.004 \\
 \partial p_F/\partial p_P = 0.147 & \partial p_w/\partial p_P = 0.520 & \partial\delta U/\partial p_P = -0.152 \\
 \partial p_F/\partial\theta = 0.073 & \partial p_w/\partial\theta = 1.366 & \partial\delta U/\partial\theta = -0.0001
 \end{array}$$

## 6.5 Conclusão

O trabalho de modelagem e simulação desenvolvido neste capítulo reforçou as conclusões do capítulo anterior, e nos permitiu identificar outros pontos importantes no processo:

- É necessário realizar a seleção dos dados para o treinamento da rede neural com muito cuidado, evitando dados com suspeita de desvios experimentais, pontos isolados fora do domínio geral dos pontos experimentais e uma distribuição racional entre os dados utilizados para o treinamento (“learning set”) e para a verificação (“test set”).

- Também é preciso definir de forma apropriada as variáveis de entrada e de saída, face à natureza dos parâmetros estudados, tarefa esta baseada no conhecimento prático e teórico do processo em estudo. Este processo pode frequentemente ter que ser refeito ao longo do estabelecimento do modelo.

- No presente caso, após avaliação de diferentes arranjos das variáveis e dos dados, foi possível ajustar um modelo através do treinamento de uma rede neural com sete neurônios na camada oculta de forma bastante satisfatória, capaz de representar com fidelidade, dentro dos intervalos de erros experimentais usuais, os dados experimentais disponíveis.

- As otimizações efetuadas através do modelo numérico obtido, tanto para o processo simétrico, como para o caso em que o corte  $\theta_{ot}$  adotado maximizava o poder de separação  $\delta U$ , apresentaram resultados coerentes. Um ensaio de verificação realizado posteriormente indicou boa concordância entre os valores previstos pela rede neural e os resultados experimentais, com desvios menores que 10%.

• A análise de sensibilidade realizada permitiu definir o modo de avaliar os dados obtidos, mostrando-se mais apropriada a análise dos valores normalizados das derivadas parciais. Os resultados observados concordaram inteiramente com o conhecimento prévio do processo, que no presente caso é simples de ser visualizado por termos somente três variáveis de entrada. Esta análise representou um bom aprendizado para a interpretação futura dos resultados de análises de sensibilidade de modelos mais complexos.

## 6.6 Notação

$B(j)$	-	vetor com dados intermediários de uma rede neural
$F$	-	fluxo de alimentação
$NH$	-	número de neurônios na camada oculta da rede neural
$NI$	-	número de neurônios na camada de entrada da rede neural
$NO$	-	número de neurônios na camada de saída da rede neural
No. Sets	-	número de apresentações do conjunto de dados no treinamento da rede
$p_F$	-	pressão na linha de alimentação
$p_P$	-	pressão na linha de retirada do produto
$p_W$	-	pressão na linha de retirada do rejeito
$Q_P$	-	fluxo de retirada do produto
$Q_W$	-	fluxo de retirada do rejeito
$R_F$	-	razão de abundância da alimentação (0.00725)
$R_P$	-	razão de abundância do produto
$R_W$	-	razão de abundância do rejeito
RMST	-	somatório de erros do “learning set”
RMSTT	-	somatório de erros do “test set”
$X(i)$	-	vetor com os dados de entrada de uma rede neural
$Y(k)$	-	vetor com os resultados calculados por uma rede neural
$W1(i,j)$	-	conjunto de pesos entre a camada de entrada e a camada oculta de uma rede neural

- $W2(j,k)$  - conjunto de pesos entre a camada oculta e a camada de saída de uma rede neural
- $Z$  - comprimento útil do rotor
- $Z_E$  - comprimento da seção de enriquecimento

#### letras gregas

- $\alpha$  - fator de separação
- $\beta$  - fator de enriquecimento
- $\delta U$  - poder de separação
- $\gamma$  - fator de empobrecimento
- $\eta$  - fator de aceleração de convergência no treinamento de redes neurais
- $\eta_F$  - posição axial adimensional da alimentação no interior do rotor
- $\theta$  - corte
- $\Delta$  - intervalo de erro aceitável de uma variável

#### símbolos

- \*
- notação para variáveis correspondentes ao processo de separação simétrico
- ot - índice para variáveis otimizadas em relação ao poder de separação  $\delta U$

## 6.7 Apêndices

### 6.7.1 Valores normalizados apresentados à rede neural.

#### “Learning Set”

Variáveis de Entrada			Variáveis de Saída		
F	p <sub>P</sub>	θ	p <sub>F</sub>	p <sub>w</sub>	δU
0.1000000	0.2329950	0.5316873	0.1346864	0.3857040	0.6445825
0.2338403	0.2343487	0.5221255	0.2704797	0.4205180	0.6714597
0.6330798	0.2333335	0.5355182	0.6678967	0.4950367	0.8830389
0.2338403	0.3335027	0.4993378	0.2402214	0.4603668	0.7240418
0.3669201	0.3321491	0.5344966	0.3830259	0.4805072	0.7713516
0.5000000	0.3355332	0.5133311	0.5398525	0.5081281	0.8457859
0.7661597	0.3321491	0.4900120	0.8140221	0.5471138	0.8765343
0.1000000	0.4962777	0.5014189	0.1273063	0.5389138	0.5142922
0.3669201	0.4942473	0.5001001	0.4077492	0.5604926	0.7520136
0.6201521	0.4962777	0.4939694	0.6428045	0.5803452	0.8887953
0.2338403	0.5350256	0.5090737	0.2562731	0.5650963	0.7459846
0.5000000	0.5351948	0.4905871	0.5461256	0.5921415	0.8409026
0.6330798	0.5362100	0.4844895	0.6874539	0.6013488	0.8050451
0.7661597	0.5355331	0.4753036	0.8177122	0.6131451	0.8359036
0.1000000	0.6387481	0.4902562	0.1553506	0.6204818	0.4574751
0.3669201	0.6397634	0.5043447	0.4066420	0.6161661	0.7239484
0.6330798	0.6384097	0.5080190	0.6450185	0.6486781	0.8255057
0.7661597	0.6458548	0.4990901	0.7900369	0.6653659	0.8312216
0.2269962	0.7402710	0.4947639	0.2383764	0.6662290	0.5513747
0.3669201	0.7406095	0.4991379	0.3693728	0.6640711	0.6918987
0.6330798	0.7362101	0.5438617	0.6357934	0.6873763	0.7720225
0.7661597	0.7423015	0.4658367	0.7693728	0.7098182	0.7371560
0.1000000	0.8492385	0.4997785	0.1007381	0.7292393	0.3926934
0.2338403	0.8407787	0.5366788	0.2398525	0.7211830	0.5532895
0.5000000	0.8407787	0.5334594	0.4879152	0.7217945	0.7606203
0.7661597	0.8411167	0.5197605	0.8029521	0.7547023	0.7634957
0.5000000	0.2336718	0.2412017	0.4512916	0.1000000	0.8774553
0.5000000	0.2329950	0.3868768	0.5118081	0.3940476	0.8859640
0.5000000	0.2316414	0.5878487	0.4922510	0.5393454	0.7719324
0.5000000	0.2326566	0.7922924	0.5169742	0.7016184	0.3879825
0.3669201	0.2360408	0.1342193	0.3564576	0.1379788	0.5201858
0.3669201	0.2346871	0.3062640	0.3498155	0.3300306	0.8817625
0.3669201	0.2357023	0.5602594	0.3154982	0.4422405	0.8183191
0.3669201	0.2336718	0.7289862	0.3520296	0.5393454	0.4952633
0.3669201	0.2336718	0.8601759	0.3564576	0.6342923	0.1933914
0.6330798	0.2357023	0.3671429	0.5523986	0.3982197	0.9000000
0.6330798	0.2336718	0.5346312	0.5933579	0.5855241	0.7890180
0.6330798	0.2316414	0.6878287	0.6254612	0.7939758	0.5030826
0.6330798	0.2390863	0.9000000	0.5487086	0.8636034	0.1000000

## 6.7.1 Valores normalizados apresentados à rede neural (cont.).

*“Learning Set”* (cont.)

Variáveis de Entrada			Variáveis de Saída		
F	p <sub>P</sub>	$\theta$	p <sub>F</sub>	p <sub>w</sub>	$\delta U$
0.500000	0.4956008	0.2174138	0.2826568	0.3396689	0.6747882
0.500000	0.4976313	0.3795338	0.5103321	0.5402085	0.7863970
0.500000	0.4939088	0.5713024	0.4822879	0.5876819	0.7638170
0.500000	0.4966161	0.8133241	0.4856088	0.6994604	0.3181242
0.3669201	0.4986466	0.1294213	0.3715868	0.4681352	0.3518091
0.3669201	0.4983082	0.3645471	0.3634686	0.5328717	0.7422013
0.3669201	0.4976313	0.5036068	0.3619927	0.5787627	0.7599069
0.3669201	0.4928935	0.6839466	0.3446494	0.6200503	0.5155790
0.3669201	0.4935704	0.8870635	0.3630997	0.6565186	0.1262749
0.6330798	0.4976313	0.1000000	0.6249078	0.1742313	0.3472487
0.6330798	0.5000002	0.3039619	0.6151292	0.4059881	0.8977611
0.6330798	0.4945857	0.4795657	0.6177122	0.5714979	0.8160996
0.6330798	0.4976313	0.6776541	0.6398524	0.7067972	0.6273637
0.6330798	0.4945857	0.8740299	0.6531366	0.8739613	0.1519282
0.5000000	0.7385790	0.2310227	0.4819188	0.5240965	0.7230262
0.5000000	0.7460240	0.4239750	0.4885609	0.6199065	0.7869785
0.5000000	0.7392558	0.5988638	0.5073801	0.7194567	0.6715974
0.5000000	0.7419631	0.7986227	0.5236163	0.7611759	0.3227328
0.3669201	0.7392558	0.1484066	0.3870850	0.5292754	0.4492078
0.3669201	0.7382406	0.3083433	0.3752768	0.5894083	0.7202598
0.3669201	0.7379022	0.5424746	0.3970481	0.6512675	0.6558580
0.3669201	0.7402710	0.6717145	0.3741698	0.6951447	0.5241379
0.3669201	0.7433168	0.8578284	0.3520296	0.7538391	0.1637524
0.6330798	0.7399326	0.1181970	0.6723248	0.3917460	0.3791736
0.6330798	0.7453471	0.3405328	0.6223616	0.6069304	0.7907136
0.6330798	0.7463624	0.5369300	0.6619927	0.6878078	0.7690162
0.6330798	0.7423015	0.7293699	0.6409594	0.8379967	0.4656752
0.6330798	0.7429783	0.8951322	0.6605166	0.9000000	0.1117913

## 6.7.1 Valores normalizados apresentados à rede neural (cont.).

## "Test Set"

Variáveis de Entrada			Variáveis de Saída		
F	p <sub>F</sub>	$\theta$	p <sub>F</sub>	p <sub>w</sub>	$\delta U$
0.500000	0.2363792	0.5235686	0.5398525	0.4743209	0.8482995
0.100000	0.3328259	0.4965313	0.1095941	0.4303001	0.5915537
0.6330798	0.3311338	0.4947054	0.6837639	0.5274050	0.8276629
0.2338403	0.4956008	0.5455359	0.2557196	0.5901278	0.6317851
0.500000	0.4956008	0.5035893	0.5103321	0.5682611	0.8319543
0.7532319	0.4959393	0.5099670	0.7833948	0.5919977	0.8659844
0.100000	0.5368869	0.4851769	0.1520295	0.5570400	0.5348106
0.3669201	0.5377328	0.4645429	0.4234318	0.5784031	0.8064678
0.2338403	0.6367177	0.4963737	0.2756458	0.6109872	0.6255454
0.500000	0.6404402	0.5417005	0.5321034	0.6358749	0.8088984
0.100000	0.7385790	0.5328556	0.1232472	0.6757237	0.4010587
0.500000	0.7379022	0.5106987	0.5088561	0.6722711	0.7439894
0.3669201	0.8407787	0.5194526	0.3841329	0.7194567	0.6374053
0.6330798	0.8407787	0.5060163	0.5664206	0.7316850	0.8640609
0.500000	0.2316414	0.1750540	0.5077491	0.1539471	0.5988451
0.500000	0.2360408	0.3035353	0.5125461	0.2746448	0.8605975
0.500000	0.2323183	0.4912002	0.5136532	0.4796441	0.8559298
0.500000	0.2341795	0.6619714	0.4970480	0.6217766	0.5675778
0.500000	0.2333335	0.8775502	0.4948340	0.7641970	0.1641897
0.3669201	0.2316414	0.2227104	0.3442805	0.2169574	0.7548756
0.3669201	0.2367175	0.3930569	0.3011070	0.3990828	0.8455084
0.3669201	0.2326566	0.5783610	0.3199262	0.4879877	0.7197315
0.3669201	0.2316414	0.7970105	0.3586716	0.5859557	0.3502922
0.6330798	0.2326566	0.2879718	0.6387454	0.2381046	0.7847632
0.6330798	0.2316414	0.4538405	0.5811809	0.4841035	0.8626360
0.6330798	0.2306262	0.5963675	0.6044281	0.6886710	0.6732171
0.6330798	0.2306262	0.7789088	0.6332104	0.8781332	0.3364629
0.500000	0.4962777	0.1290625	0.5059041	0.2732063	0.5172927
0.500000	0.4959393	0.3431023	0.5228783	0.4619494	0.8043064
0.500000	0.4957700	0.5294069	0.5092251	0.6113467	0.7188498
0.500000	0.4983082	0.6739429	0.4988930	0.7275129	0.6207744
0.500000	0.4976313	0.8949456	0.4955720	0.7768565	0.1132189
0.3669201	0.4969545	0.2141681	0.3560886	0.4986334	0.5788475
0.3669201	0.4939088	0.4056088	0.3630997	0.4885630	0.8733034
0.3669201	0.4996618	0.5884338	0.3483396	0.6023556	0.6624979
0.3669201	0.4949240	0.7816010	0.3612546	0.7013305	0.3069703
0.6330798	0.5006770	0.2108646	0.6387454	0.3156448	0.7523637
0.6330798	0.4986466	0.4197305	0.6033211	0.5099981	0.8354579
0.6330798	0.4986466	0.6265332	0.6321034	0.6463765	0.6911168
0.6330798	0.4989850	0.8395184	0.6535055	0.7879338	0.2666852
0.500000	0.7392558	0.1200071	0.4911440	0.5000719	0.3694407
0.500000	0.7412862	0.3285671	0.4743543	0.5818557	0.7800427
0.500000	0.7385790	0.5049181	0.5158672	0.6685306	0.7377832
0.500000	0.7439935	0.7088333	0.5129151	0.7265061	0.5057722
0.500000	0.7385790	0.8711770	0.5254613	0.8356950	0.1379219

## 6.7.1 Valores normalizados apresentados à rede neural (cont.).

## "Test Set" (cont.)

Variáveis de Entrada			Variáveis de Saída		
F	p <sub>P</sub>	$\theta$	p <sub>F</sub>	p <sub>w</sub>	$\delta U$
0.3669201	0.7385790	0.2544070	0.3826569	0.5614995	0.7422929
0.3669201	0.7402710	0.4343601	0.3767528	0.6393275	0.8141260
0.3669201	0.7458548	0.6272356	0.3448340	0.7281603	0.5950537
0.3669201	0.7423015	0.8187513	0.3531366	0.7499549	0.2558415
0.6330798	0.7382406	0.2103201	0.6712177	0.4807946	0.6368737
0.6330798	0.7382406	0.3697309	0.5546126	0.5889767	0.8619836
0.6330798	0.7433168	0.6246958	0.6372694	0.7605286	0.6141995
0.6330798	0.7410325	0.7820502	0.5889299	0.8242940	0.3376778
0.1000000	0.2150594	0.5182794	0.1000000	0.3344900	0.5978128
0.2338403	0.2187818	0.4812585	0.2354245	0.3895882	0.6705749
0.3669201	0.3423013	0.4823001	0.3804429	0.4628125	0.7196683
0.5000000	0.4194587	0.5078287	0.4918819	0.5337349	0.8037272
0.6330798	0.5359562	0.5122563	0.6254612	0.5904872	0.7625586
0.7661597	0.6323184	0.4847114	0.7726938	0.6426360	0.7519762
0.9000000	0.7439935	0.5180669	0.9000000	0.7112567	0.7130023
0.1000000	0.1000000	0.3880075	0.1136532	0.2385362	0.5989746
0.2338403	0.2015229	0.4781329	0.1634687	0.3672899	0.7616847
0.3669201	0.2773266	0.4300092	0.3457565	0.5551700	0.7899402
0.5000000	0.4661592	0.4454750	0.4904059	0.5570400	0.8586903
0.6330798	0.6976314	0.5154001	0.6202952	0.6617696	0.7185385
0.7661597	0.7548226	0.5578476	0.7667897	0.7152851	0.7517551
0.9000000	0.9000000	0.5555580	0.8996313	0.8004494	0.6799572

6.7.2 Valores das variáveis de saída experimentais e calculados pela rede neural com sete neurônios na camada oculta.

*“Learning Set”*

$P_F$		$P_W$		$\delta U$	
exp.	calc.	exp.	calc.	exp.	calc.
0.13469	0.13850	0.38570	0.39757	0.64458	0.62017
0.27048	0.22884	0.42053	0.41013	0.67147	0.71975
0.66789	0.63400	0.49502	0.58021	0.88303	0.82370
0.24022	0.23350	0.46036	0.45579	0.72403	0.70896
0.38303	0.36466	0.48051	0.51103	0.77136	0.74461
0.53986	0.51108	0.50814	0.54970	0.84577	0.80651
0.81402	0.74358	0.54711	0.59976	0.87654	0.83737
0.12731	0.14169	0.53891	0.55401	0.51427	0.51513
0.40775	0.37338	0.56048	0.56963	0.75201	0.74578
0.64281	0.64209	0.58034	0.62729	0.88881	0.80480
0.25628	0.24001	0.56510	0.57093	0.74596	0.63560
0.54612	0.52304	0.59212	0.61163	0.84089	0.78973
0.68745	0.65509	0.60135	0.63407	0.80502	0.80552
0.81772	0.75632	0.61314	0.64805	0.83588	0.80430
0.15535	0.14204	0.62047	0.64447	0.45746	0.45624
0.40664	0.37728	0.61616	0.63666	0.72394	0.71212
0.64502	0.65950	0.64865	0.68176	0.82551	0.77132
0.79004	0.76125	0.66536	0.69803	0.83124	0.76811
0.23838	0.23545	0.66622	0.68154	0.55136	0.57459
0.36938	0.37776	0.66406	0.67835	0.69191	0.69552
0.63579	0.66212	0.68737	0.72698	0.77204	0.72354
0.76937	0.76170	0.70981	0.69039	0.73716	0.78066
0.10074	0.14069	0.72923	0.75668	0.39267	0.36397
0.23986	0.24031	0.72116	0.72198	0.55330	0.51711
0.48792	0.52714	0.72176	0.72815	0.76062	0.70693
0.80295	0.76399	0.75469	0.74809	0.76351	0.72715
0.45130	0.48587	0.10000	0.21924	0.87744	0.81919
0.51181	0.49351	0.39403	0.37228	0.88597	0.88854
0.49226	0.50351	0.53934	0.57119	0.77195	0.73558
0.51698	0.51043	0.70161	0.70860	0.38798	0.28900
0.35646	0.35129	0.13798	0.16711	0.52018	0.47565
0.34982	0.35147	0.33003	0.29226	0.88177	0.84473
0.31550	0.35749	0.44223	0.48272	0.81833	0.73468
0.35203	0.36596	0.53934	0.58832	0.49527	0.39863
0.35646	0.37840	0.63428	0.66108	0.19339	0.17134
0.55240	0.62209	0.39821	0.36546	0.90000	0.89517
0.59336	0.63399	0.58552	0.57934	0.78900	0.82447
0.62546	0.64043	0.79396	0.71930	0.50308	0.56255
0.54871	0.64268	0.86358	0.82590	0.10000	0.13715
0.28266	0.50696	0.33965	0.36460	0.67481	0.71208
0.51033	0.51611	0.54020	0.51163	0.78639	0.84139
0.48229	0.52358	0.58767	0.64900	0.76383	0.70702
0.48561	0.52506	0.69945	0.76216	0.31812	0.24247

**6.7.2** Valores das variáveis de saída experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.).

*“Learning Set”* (cont.)

$p_F$		$p_w$		$\delta U$	
exp.	calc.	exp.	calc.	exp.	calc.
0.37159	0.37012	0.46813	0.36628	0.35179	0.35346
0.36347	0.37194	0.53286	0.51081	0.74222	0.79943
0.36200	0.37354	0.57874	0.57270	0.75990	0.74181
0.34465	0.37530	0.62004	0.63946	0.51558	0.45976
0.36310	0.38508	0.65651	0.71058	0.12627	0.14056
0.62491	0.62641	0.17423	0.20339	0.34724	0.34697
0.61513	0.64117	0.40598	0.42713	0.89774	0.83358
0.61771	0.65282	0.57149	0.61611	0.81608	0.81590
0.63985	0.65938	0.70679	0.76509	0.62734	0.53051
0.65314	0.65711	0.87393	0.84342	0.15193	0.16626
0.48192	0.51274	0.52410	0.55263	0.72304	0.67643
0.48856	0.52374	0.61991	0.65577	0.78697	0.79067
0.50738	0.52946	0.71943	0.72586	0.67160	0.63817
0.52362	0.52927	0.76116	0.78853	0.32273	0.28191
0.38709	0.37333	0.52928	0.59794	0.44921	0.35378
0.37528	0.37491	0.58940	0.64658	0.72024	0.70671
0.39705	0.37798	0.65124	0.68344	0.65586	0.65513
0.37417	0.37811	0.69513	0.70355	0.52415	0.46689
0.35203	0.38172	0.75383	0.73687	0.16375	0.18181
0.67232	0.63584	0.39174	0.38915	0.37918	0.37016
0.62236	0.65092	0.60692	0.58798	0.79072	0.81107
0.66199	0.66189	0.68780	0.72487	0.76902	0.73003
0.64096	0.66477	0.83798	0.81662	0.46567	0.41807
0.66052	0.66179	0.90000	0.86414	0.11179	0.15677

6.7.2 Valores das variáveis de saída experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.).

*“Test Set”*

$p_F$		$p_w$		$\delta U$	
exp.	calc.	exp.	calc.	exp.	calc.
0.53986	0.50129	0.47430	0.51564	0.84829	0.81833
0.10960	0.13950	0.43028	0.45018	0.59156	0.59756
0.68377	0.64179	0.52738	0.57287	0.82767	0.83629
0.25572	0.23939	0.59013	0.55410	0.63176	0.60902
0.51033	0.52176	0.56825	0.60558	0.83196	0.78549
0.78340	0.74754	0.59199	0.67079	0.86598	0.78562
0.15203	0.14184	0.55703	0.58206	0.53480	0.50506
0.42343	0.37466	0.57839	0.57680	0.80647	0.76401
0.27565	0.24138	0.61098	0.62626	0.62554	0.61466
0.53211	0.52756	0.63588	0.67593	0.80890	0.72448
0.12325	0.14150	0.67571	0.68892	0.40106	0.39150
0.50886	0.52740	0.67226	0.69069	0.74398	0.74217
0.38414	0.37693	0.71943	0.71973	0.63740	0.65680
0.56643	0.66015	0.73169	0.72681	0.86404	0.74930
0.50775	0.48273	0.15395	0.16066	0.59882	0.68284
0.51255	0.48922	0.27464	0.28359	0.86061	0.87293
0.51365	0.49922	0.47965	0.48220	0.85592	0.84734
0.49705	0.50638	0.62177	0.62954	0.56756	0.58899
0.49484	0.51425	0.76419	0.74886	0.16419	0.15219
0.34428	0.35076	0.21696	0.22559	0.75489	0.74862
0.30111	0.35303	0.39908	0.36170	0.84550	0.85971
0.31993	0.35789	0.48798	0.49350	0.71975	0.70797
0.35867	0.37154	0.58595	0.62669	0.35030	0.26472
0.63875	0.61591	0.23810	0.26020	0.78476	0.86959
0.58118	0.62821	0.48410	0.47987	0.86264	0.88042
0.60443	0.63700	0.68866	0.64266	0.67323	0.74641
0.63321	0.64178	0.87812	0.77467	0.33646	0.34496
0.50591	0.50254	0.27320	0.28454	0.51729	0.42999
0.52288	0.51399	0.46196	0.47957	0.80430	0.83814
0.50923	0.52261	0.61132	0.62311	0.71884	0.75981
0.49890	0.52501	0.72750	0.70571	0.62075	0.52036
0.49558	0.52579	0.77683	0.78792	0.11322	0.13497
0.35609	0.37020	0.49864	0.42359	0.57884	0.63627
0.36310	0.37231	0.48854	0.52794	0.87329	0.79866
0.34835	0.37429	0.60235	0.60662	0.66249	0.63375
0.36125	0.37836	0.70131	0.67446	0.30697	0.27760
0.63875	0.63454	0.31566	0.31846	0.75237	0.71799
0.60332	0.64936	0.50999	0.55746	0.83543	0.84455
0.63210	0.65871	0.64637	0.73462	0.69109	0.63118
0.65350	0.65806	0.78792	0.83367	0.26668	0.21371
0.49115	0.50744	0.50006	0.48043	0.36943	0.33160
0.47436	0.51843	0.58185	0.60796	0.78003	0.78521
0.51587	0.52720	0.66851	0.68844	0.73779	0.74700
0.51291	0.52993	0.72651	0.76388	0.50579	0.44569

6.7.2 Valores das variáveis de saída experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.).

*"Test Set" (cont.)*

$p_F$		$p_W$		$\delta U$	
exp.	calc.	exp.	calc.	exp.	calc.
0.52547	0.52877	0.83570	0.80527	0.13792	0.17752
0.38266	0.37400	0.56148	0.63420	0.74231	0.63826
0.37675	0.37709	0.63933	0.66907	0.81414	0.73215
0.34484	0.37805	0.72815	0.69837	0.59503	0.53967
0.35314	0.38023	0.74994	0.72927	0.25584	0.22978
0.67122	0.64177	0.48077	0.47266	0.63686	0.67084
0.55461	0.65291	0.58897	0.60787	0.86196	0.81653
0.63727	0.66422	0.76052	0.77182	0.61421	0.61056
0.58893	0.66424	0.82426	0.83453	0.33767	0.32017
0.10000	0.13743	0.33447	0.38350	0.59783	0.64119
0.23543	0.22665	0.38958	0.38203	0.67056	0.76342
0.38045	0.36440	0.46282	0.48487	0.71966	0.79464
0.49188	0.51747	0.53373	0.57947	0.80371	0.79519
0.62546	0.65647	0.59048	0.65802	0.76256	0.78260
0.77269	0.76032	0.64261	0.68214	0.75196	0.78174
0.90000	0.83571	0.71123	0.74973	0.71298	0.71271
0.11366	0.12916	0.23853	0.26697	0.59896	0.75016
0.16348	0.22540	0.36727	0.37046	0.76166	0.77172
0.34576	0.35785	0.55518	0.41388	0.78995	0.84058
0.49041	0.51777	0.55703	0.55008	0.85867	0.83002
0.62029	0.66075	0.66177	0.70105	0.71853	0.75706
0.76679	0.76479	0.71529	0.76116	0.75174	0.69240
0.89967	0.83731	0.80044	0.79323	0.67995	0.65477

**6.7.3** Pesos encontrados para a rede neural com sete neurônios na camada interna.

**Pesos da camada oculta**

6.340E-01	-1.216E+00	8.476E-01	5.155E+00	-3.265E+00	-1.366E+00	-1.808E+00
-1.169E+00	2.506E+00	1.811E-01	1.247E+00	1.555E+00	3.272E-01	1.547E-01
-6.266E+00	2.617E+00	-2.687E+00	-4.070E+00	-3.286E+00	-1.482E+00	-7.876E-01
3.592E-01	8.389E-02	7.035E-01	2.130E-01	2.941E-01	9.347E-01	8.533E-01

**Pesos da camada de saída**

9.649E-01	-2.325E+00	-1.702E+01
1.729E+00	3.311E+00	-8.951E+00
2.512E+00	-3.226E+00	6.590E+00
6.845E-01	1.444E+00	2.122E+00
-2.703E-01	6.477E+00	-8.749E+00
-2.460E+00	-3.691E+00	8.856E+00
-5.816E+00	-3.835E+00	5.227E+00
2.280E-01	4.333E-01	2.414E-01

## 6.8 Referências

- [6.1] KAHANER,D.; MOLER,C.; NASH,S. *Numerical Methods and Software*. New Jersey, NJ: Prentice-Hall, 1989.
- [6.2] NASCIMENTO,C.A.O.; OLIVEROS,E. & BRAUN,A.M. Neural network modeling for photochemical processes. *Chem. Eng. Proc.*, v.33, p.319-324, 1994.
- [6.3] MIGLIAVACCA,S.C.P. *Cálculo dos parâmetros de separação de uma centrífuga a contracorrente com variação axial do fluxo interno*. São Paulo, SP, 1991. Dissertação (Mestrado) - Instituto de Pesquisas Energéticas e Nucleares.
- [6.4] GUO,Z.; UHRIG,R.E. Use of artificial neural networks to analyze nuclear power plant performance. *Nucl. Technol.*, v.99, p.36-42, 1992.

## 7 MODELAGEM DE CENTRÍFUGAS COM DIFERENTES CONFIGURAÇÕES INTERNAS

Neste capítulo será estudada a aplicação da modelagem por redes neurais a um conjunto de dados obtidos em vários ensaios de separação isotópica, realizados com diversas centrífugas, montadas com diferentes configurações internas ao longo de aproximadamente 5 anos. O objetivo deste estudo é obter um modelo numérico capaz de descrever os parâmetros separativos de uma centrífuga desta geração considerando as condições de operação e algumas características de montagem mais significativas do ponto de vista separativo. Trata-se, sem dúvida, do estudo mais importante desta tese, pois possibilita a otimização dos parâmetros internos de uma centrífuga, que representa um dos tópicos mais difíceis de se realizar através de modelos fenomenológicos e muito trabalhoso de ser feito experimentalmente, podendo vir a ser impraticável devido a sua vasta extensão.

Inicialmente será realizada a apresentação e análise dos dados experimentais disponíveis. Nessa análise serão discutidas as variáveis envolvidas, seus domínios, sua importância, sua confiabilidade e seus erros. Essa análise é muito importante, pois é a partir desse conjunto de dados experimentais que se pretende chegar a um modelo numérico.

Conhecido o conjunto de dados experimentais, passaremos à definição da estrutura de rede a ser empregada, em termos das variáveis de entrada e de saída, número de neurônios, etc. Apresentaremos o treinamento da rede, sua avaliação e verificação, através da análise de resíduos. Definido o modelo através da rede neural, procederemos ao mapeamento da superfície de resposta e otimização de alguns parâmetros, com verificação experimental da resposta prevista pela rede neural. Finalmente, realizaremos uma análise de sensibilidade.

## 7.1 Dados experimentais

Os dados disponíveis são referentes a 55 ensaios de separação isotópica realizados desde o final de 1993 até o final de 1997 com um mesmo modelo de centrífuga. Um modelo ou uma geração de centrífugas é definido pelas características externas, a saber o diâmetro, o comprimento útil e a frequência ou velocidade de rotação do cilindro. Desses, 23 ensaios foram excluídos numa primeira triagem, por apresentarem fortes indícios de problemas na centrífuga ou na bancada de experimentos durante ou imediatamente após o término do ensaio. O treinamento de redes neurais teve início com os 776 pontos experimentais resultantes dos 32 ensaios restantes realizados com 13 diferentes configurações de montagem das centrífugas. No entanto, uma nova análise dos resultados experimentais obtidos nesses ensaios, tanto em termos da coerência das curvas de respostas, como através da análise de relações entre os valores experimentais e os calculados pelas redes iniciais, nos levou a descartar mais 4 ensaios, restando portanto 28 ensaios aprovados com 731 pontos experimentais, referentes a 11 configurações de montagem. São estes ensaios que serão aqui apresentados e discutidos.

O conhecimento do processo de enriquecimento do urânio pela centrífuga a gás, tanto de seus fundamentos teóricos como de seu comportamento na prática, nos levou a definir os parâmetros mais significativos para sua otimização. A seguir são relacionadas as variáveis envolvidas num ensaio para avaliação do desempenho separativo de uma centrífuga:

1. Características externas da centrífuga:
  - Diâmetro do rotor ( $d$ )
  - Comprimento útil do rotor ( $Z$ )
  - Frequência de rotação ( $f$ )

## 2. Características internas da centrífuga:

- Disco girante:
  - posição no rotor (superior ou inferior)
  - diâmetro do furo central ( $D_1$ )
  - outras características geométricas
- sistema de alimentação do gás no interior do rotor:
  - posição axial da alimentação, em termos do comprimento da seção de enriquecimento do rotor ( $Z_E$ )
  - condutância do sistema
  - outras características geométricas
- sistema de retirada do produto do interior do rotor:
  - tipo de coletor (forma e dimensões do perfil)
  - raio de coleta ( $r_P$ )
  - condutância do sistema
- sistema de retirada do rejeito do interior do rotor:
  - tipo de coletor (forma e dimensões do perfil)
  - raio de coleta ( $r_W$ )
  - condutância do sistema
- características da carcaça:
  - material
  - sistemas de bombeamento molecular
  - acabamento superficial da carcaça, do lado externo do rotor e de cada um dos demais componentes
  - controles ativos de temperatura
- sistemas de acionamento e controle do rotor

## 3. Parâmetros de processo (definidos pelas condições de operação impostas ao sistema e pelas respostas obtidas):

- Pressões nas linhas de processo:
  - Pressão na linha da alimentação ( $p_F$ )
  - Pressão na linha de retirada do produto ( $p_P$ )
  - Pressão na linha de retirada do rejeito ( $p_W$ )

- Fluxos nas linhas de processo:
  - fluxo da alimentação (F)
  - fluxo do produto (P)
  - fluxo do rejeito (W)
- concentrações das correntes de processo (expressas em termos das razões de abundância):
  - razão de abundância da alimentação ( $R_F$ )
  - razão de abundância do produto ( $R_P$ )
  - razão de abundância do rejeito ( $R_W$ )
- temperaturas internas

Dentre as variáveis citadas acima, no presente estudo não serão consideradas as variáveis externas, por tratar-se de um mesmo modelo de centrífugas. As variáveis internas mais importantes e que foram avaliadas experimentalmente são:

- ◆ raio de coleta do produto ( $r_P$ ),
- ◆ raio de coleta do rejeito ( $r_W$ ),
- ◆ diâmetro do furo central do disco girante ( $D_I$ ),
- ◆ comprimento da seção de enriquecimento ( $Z_E$ ).

Os parâmetros de processo de interesse prático geralmente são variáveis secundárias, isto é, são calculadas a partir das variáveis primárias citadas acima, como por exemplo o corte  $\theta$  e o poder de separação  $\delta U$ , definidos no Capítulo 2. Os parâmetros de processo devem ser divididos entre as condições de operação impostas no ensaio e as respostas obtidas. Devido às características das bancadas de ensaio, temos três graus de liberdade na operação de uma centrífuga, assim, devemos impor três parâmetros de processo para definir uma condição de operação. Os demais parâmetros constituem então as respostas obtidas do sistema. Assim, os parâmetros de processo que definem as condições de operação nos ensaios de separação isotópica são:

- ◆ fluxo de alimentação ( $F$ ),
- ◆ pressão na linha de retirada do produto ( $p_p$ ),
- ◆ corte ( $\theta$ ).

O desenvolvimento de uma centrífuga é sempre realizado em processo simétrico. Assim os ensaios são realizados em pontos operacionais próximos a essa condição. Os resultados experimentais sofrem então uma correção para o processo simétrico, eliminando-se assim as flutuações devidas ao corte. Com isso, o corte passa a ser constante.

Os 28 ensaios considerados foram realizados com 13 centrífugas, montadas com 11 diferentes configurações internas, ao longo de 4 anos. Alguns desses ensaios eram parte de um projeto de experimentos fatorial fracionado, empregando a técnica denominada Taguchi [7.1], no entanto, esse projeto de experimentos não foi completado. Durante este período, alguns detalhes de projeto foram alterados: alguns que não afetam o desempenho separativo da centrífuga, mas outros que, direta ou indiretamente poderiam trazer alguma alteração no desempenho das máquinas. No entanto, essas alterações acabaram assumindo um caráter irreversível, devido à dinâmica do processo de desenvolvimento das centrífugas e à melhoria incorporada ao projeto. Essas alterações tiveram que ser tratadas como ruídos no processo, pois caso contrário não teríamos dados suficientes para realizar um estudo com o objetivo de definir um modelo numérico para um modelo de centrífuga. Por outro lado, como será discutido adiante, o erro experimental intrínseco desses ensaios é relativamente grande, mesmo quando considerando centrífugas com montagens rigorosamente iguais. Assim, as alterações de projeto citadas resultam em variações menores ou da mesma ordem de grandeza dos erros experimentais dos ensaios.

A Tabela 7.1 apresenta a relação dos ensaios considerados, com suas principais características, segundo as variáveis discutidas acima. Para resguardar o sigilo do processo, os valores apresentados são normalizados.


TABELA 7.1

Relação dos ensaios de separação isotópica utilizados, com as respectivas características das centrífugas


Tipo de Montagem	$r_p$	$r_w$	$D_I$	$Z_E$	No. Ensaio	Centrífuga
1	0.1	0.5	0.9	0.4765	A4-01/95	05
3	0.1	0.5	0.9	0.1	L3-01/97	12
4	0.5	0.9	0.3667	0.4765	A4-13/93	01
					A4-02/94	01
5	0.9	0.5	0.3667	0.1024	A4-05/94	01
6	0.1	0.9	0.3667	0.4765	A4-06/94	01
				0.5047	N4-05/96	14
7	0.1	0.9	0.3667	0.6553	L4-01/97	15
					L3-03/97	15
8	0.5	0.1	0.3667	0.9	L3-02/97	15
					L2-03/97	01
9	0.9	0.5	0.3667	0.2788	L2-04/97	01
					L1-05/97	15
10	0.1	0.1	0.1	0.1024	A4-07/94	03
11	0.1	0.5	0.1	0.2788	L4-06/97	19
					L2-10/97	28
13	0.1	0.1	0.1	0.2788	L4-03/97	17
					L2-05/97	23
					L2-06/97	28
					L2-07/97	28
					L1-12/97	23
					L1-13/97	23
					L2-09/97	28
					L1-14/97	32
					L3-06/97	33
					L4-09/97	30
L3-07/97	34					
L4-10/97	30					

Passaremos a seguir a analisar o domínio das variáveis de entrada. Como visto anteriormente, as variáveis de entrada podem ser divididas em dois tipos: as de montagem e as de processo.

As variáveis de processo determinadas como variáveis de entrada no modelo numérico, ou variáveis de controle nos ensaios, são relativamente bem exploradas dentro de cada um dos ensaios separativos citados. Normalmente se determina alguns valores fixos da pressão  $p_P$  e o fluxo de alimentação  $F$  varia dentro da faixa de interesse. As Figuras 7.1 e 7.2 mostram a quantidade de pontos experimentais obtidos dentro dos ensaios com cada valor das variáveis de entrada,  $p_P$  e  $F$  respectivamente. Ambas as variáveis apresentam uma boa distribuição até 60% do máximo valor do domínio.




**FIGURA 7.1:** Distribuição dos valores experimentais de  $p_P$  no conjunto de dados utilizado em termos da quantidade de pontos experimentais



**FIGURA 7.2:** Distribuição dos valores experimentais de  $F$  no conjunto de dados utilizado em termos da quantidade de pontos experimentais

Já as variáveis de montagem, que definem as características de um ensaio, apresentam uma distribuição mais espaçada, segundo os valores apresentados na Tabela 7.1, representados a seguir na Figura 7.3. São três variáveis com três níveis de variação e uma com cinco níveis, resultando num total de 135 possíveis combinações, das quais foram feitas somente 11, ou seja 8%. Além disso, como pode ser visualizado na Figura 7.3, os pontos executados não seguem uma distribuição ortogonal, o que compromete a qualidade dos dados experimentais. A maior parte desses ensaios não seguiu um projeto de experimentos com um planejamento apropriado a um programa de otimização, pois parte desses ensaios tinha caráter exploratório e outros tinham um objetivo mais imediato, ou seja, atingir uma determinada meta de interesse prático.


Evidentemente todas as medidas citadas apresentam incertezas. Os valores medidos das variáveis de processo têm incertezas que são características dos instrumentos utilizados. A saber, a incerteza das medidas de vazão  $F$  é da ordem de  $0.02$ , valor este referente à escala normalizada apresentada. Da mesma forma, a incerteza das medidas da pressão da linha de produto  $p_P$  é de  $0.02$  (unidades de pressão normalizadas). As demais pressões, que se configuram como respostas, apresentam incertezas devidas à precisão dos instrumentos mais os erros provenientes do próprio processo, que se mostram mais significativos. Assim, as incertezas das respostas serão estimadas com base nas variâncias observadas, discutida adiante.



**FIGURA 7.3:** Distribuição das variáveis de montagem no conjunto de dados utilizado

As variáveis internas da centrífuga também apresentam incertezas provenientes da precisão mecânica da fabricação e montagem do equipamento. As variáveis dimensionais na direção radial do cilindro apresentam maior sensibilidade devido ao forte campo centrífugo. Também a dilatação sofrida pelo cilindro em alta rotação e as vibrações do sistema contribuem para as incertezas das dimensões radiais da centrífuga. Desta forma, as variáveis que se configuram mais imprecisas são os raios de coleta  $r_p$  e  $r_w$ , sendo a segunda a menos precisa devido às características do projeto. Algumas alterações foram implementadas no desenho da centrífuga com o objetivo de melhorar essa precisão ao longo do desenvolvimento da centrífuga, mas na maioria dos ensaios considerados no presente trabalho essas melhorias ainda não haviam sido implementadas. O diâmetro do furo central do disco girante, por ser parte integrante de todo o conjunto girante apresenta menos problemas de precisão.

Passaremos agora a analisar as respostas obtidas nos ensaios de separação isotópica. Primeiramente será discutida a pressão da linha de alimentação  $p_F$ . Sabemos que a pressão na linha de alimentação é unicamente função da geometria do sistema de alimentação e do fluxo que por ali passa, pois a pressão no interior do cilindro onde a alimentação é introduzida é muito baixa, podendo ser aproximada a zero para efeito do cálculo de condutância. A Figura 7.4 mostra a relação entre o fluxo e a pressão de alimentação de todos os ensaios considerados. Cada ensaio individualmente pode ser plenamente representado por uma reta, mas quando todos os ensaios são comparados, como na Figura 7.4, observamos um feixe de retas. Esta dispersão é atribuída às incertezas dos sensores de pressão e de fluxo, mas principalmente às modificações efetuadas no sistema de alimentação ao longo do desenvolvimento.



**FIGURA 7.4:** Relação entre as pressões de alimentação  $p_F$  e os fluxos de alimentação  $F$  observados nos ensaios de separação isotópica

Uma vez que as medidas obtidas ao longo dos anos não mantêm o padrão de resposta esperado, não faz sentido utilizar esta informação no treinamento de uma rede neural. De fato, nas primeiras redes treinadas, não se observou um bom ajuste da pressão de alimentação, o que motivou uma reavaliação individual dessas medidas. Assim, o mais indicado com relação a esta variável, é obter dados consistentes e então realizar uma modelagem simplesmente através de uma regressão linear.

As alterações realizadas no sistema de alimentação e retirada do gás de processo do interior do rotor da centrífuga, que se fizeram notar claramente nas pressões de alimentação  $p_F$ , também afetaram as pressões das retiradas  $p_P$  e  $p_W$ . A pressão de retirada do rejeito constitui uma resposta do sistema, que será discutida a seguir. A pressão da linha do produto representa uma variável de controle do ensaio, ou seja, é uma variável de entrada. As alterações físicas efetuadas tiveram o cuidado de minimizar os possíveis efeitos sobre a condutância da retirada do produto. Aliado a isso, a própria posição do coletor de produto no interior do rotor, próximo à saída do sistema, e a barreira representada pela proteção do disco girante, contribuem para a atenuação das variações de projeto nos resultados dos ensaios de separação isotópica.

A pressão na linha de retirada do rejeito é função da condutância do sistema de retirada, da pressão no interior do rotor, controlada pela pressão de retirada do produto  $p_P$  e pelo raio do coletor do produto  $r_P$ , pelo diâmetro do orifício central do disco girante  $D_I$  e pelo raio de coleta do coletor de rejeito  $r_W$ , e do fluxo que por ali passa; no presente caso, em que o corte é fixo, representado pelo fluxo da alimentação  $F$ . Em suma, esta resposta depende de todas as variáveis de entrada definidas. Com isso, a qualidade da resposta obtida só pode ser avaliada nos ensaios com montagem do TIPO 13, em que vários ensaios, com diferentes máquinas foram realizados. O mesmo se aplica com relação ao poder de separação  $\delta U$ , ou qualquer outra variável separativa.

Os gráficos da Figura 7.5 apresentam os valores experimentais (normalizados) da pressão na linha de retirada do rejeito  $p_W$  obtidos nos ensaios realizados com centrífugas montadas com os parâmetros internos definidos pela configuração TIPO

13. A dispersão dos valores experimentais da pressão  $p_w$  observada é muito grande. Esta dispersão pode ser atribuída a diversos fatores, entre eles: a incerteza dos medidores de pressão e de vazão, a imprecisão mecânica de montagem do sistema de retirada do gás e a vibração do sistema de retirada. Pequenas alterações foram incorporadas posteriormente ao desenho da centrífuga e aos procedimentos experimentais de avaliação, no sentido de diminuir esta dispersão. No entanto a utilização de dados antigos, sem os quais o presente trabalho não teria suficiente abertura do domínio das variáveis, requer a estimativa de erros na condição mais próxima de sua realização, que é a apresentada aqui, com esta larga faixa de dispersão. O mesmo argumento é válido para a análise do desempenho separativo das centrífugas, que é uma função complexa que depende de todo o sistema, igualmente à pressão de rejeito  $p_w$ .

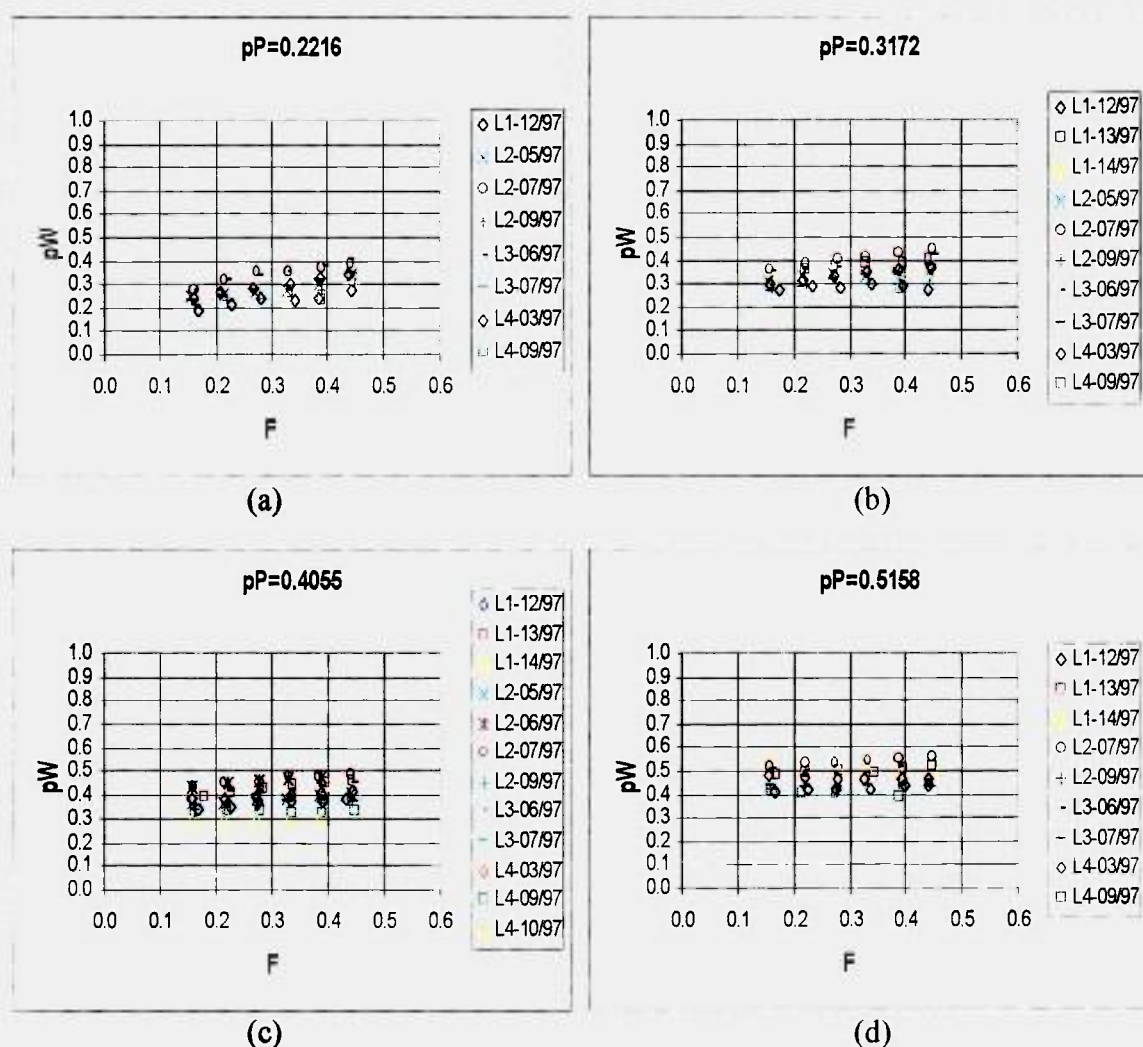



FIGURA 7.5: Valores experimentais da pressão de rejeito  $p_w$  em função do fluxo de alimentação  $F$  para cada um dos valores da pressão de produto estipulada nos ensaios realizados com a configuração interna TIPO 13


Procedemos então a uma análise de variância dos valores experimentais de  $p_w$ , agrupando os valores por condições nominais de operação, definindo assim os níveis de avaliação, sendo o resultado de cada ensaio considerado como uma determinação. Para cada um dos níveis foram calculados a média, a variância e o desvio padrão, este representado na Figura 7.6.



**FIGURA 7.6:** Desvio padrão da pressão de rejeito  $p_w$  em função do fluxo de alimentação  $F$  para cada um dos valores da pressão de produto estipulados nos ensaios realizados com a configuração interna TIPO 13

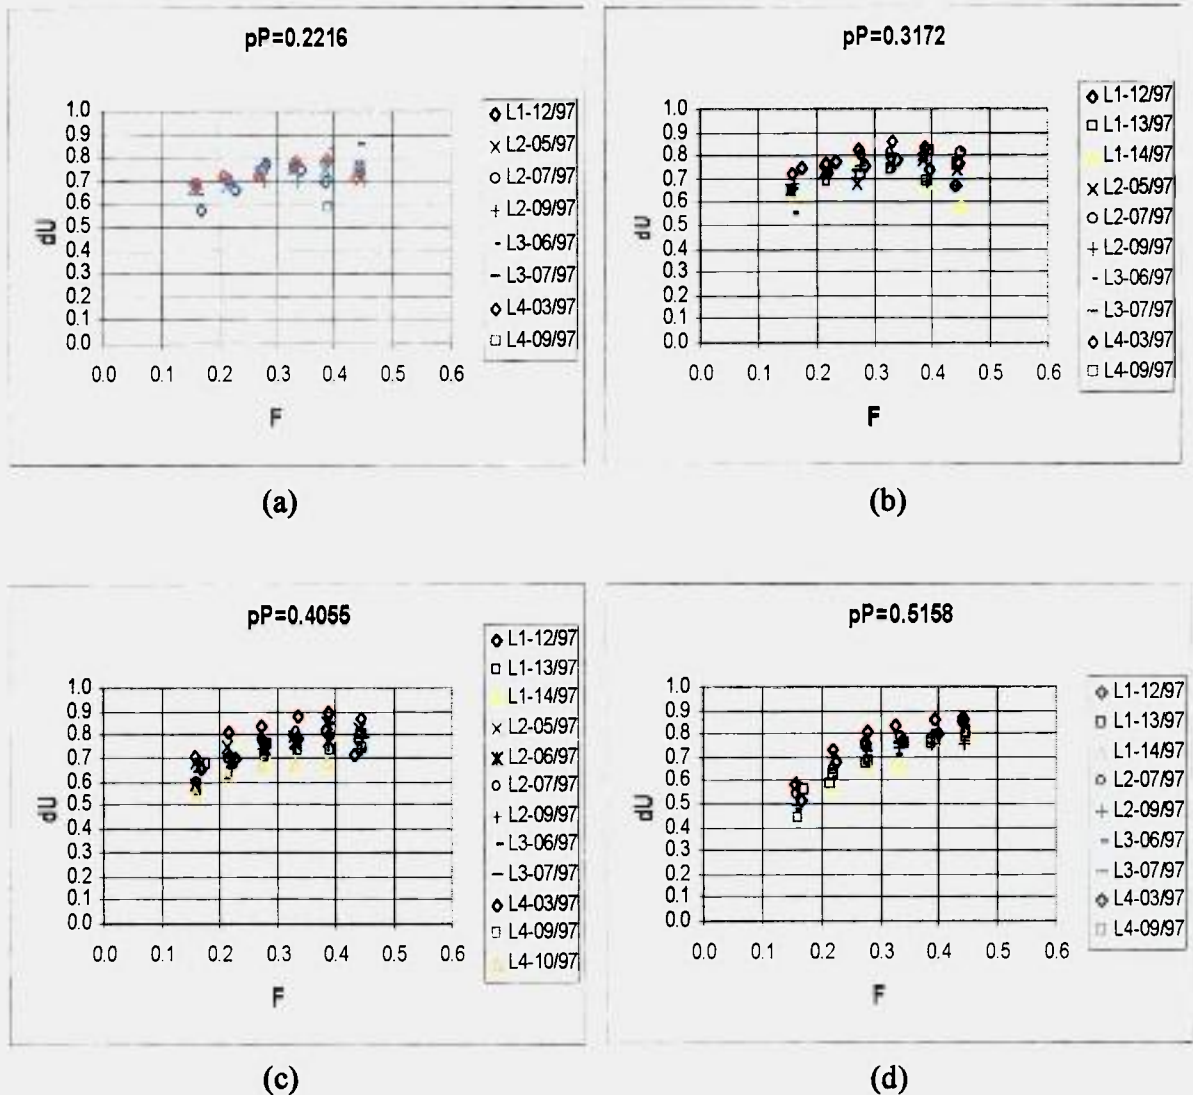
Na Figura 7.6 não é observada nenhuma dependência do desvio de  $p_w$  com a pressão de controle  $p_p$ , mas observamos uma suave tendência crescente do desvio com o fluxo de alimentação  $F$ . No entanto, quando observado em toda a escala de variação de  $p_w$ , esta dependência se mostra desprezível, como pode ser observado na Figura 7.7, que apresenta os valores dos desvios padrão advindos da média das variâncias, mantendo o fluxo de alimentação como único fator determinante de nível. Neste gráfico os valores dos desvios foram normalizados segundo o mesmo padrão utilizado para os valores experimentais de  $p_w$ . Sendo assim, é possível adotar um valor único, determinado pela média ponderada das variâncias, como a estimativa do erro experimental para os valores da pressão de rejeito  $p_w$ . Desta forma, temos a estimativa da variância da pressão do rejeito,  $s_{p_w}^2$ , e a respectiva estimativa do desvio padrão,  $s_{p_w}$ . Adotando um nível de confiança de

95%, é estabelecido o intervalo de confiança para a pressão de rejeito  $p_w$  de  $\pm 0.1$  (unidades de pressão  $p_w$  normalizada).




**FIGURA 7.7:** Desvios padrão médios da pressão de rejeito  $p_w$  em função do fluxo de alimentação  $F$  nos ensaios realizados com a configuração interna TIPO 13

Passaremos agora a analisar a resposta do poder de separação  $\delta U$ . Desde o início partimos da opção de modelar o poder de separação  $\delta U$  diretamente na rede neural, em decorrência dos resultados encontrados no capítulo anterior. Como o desempenho separativo da centrífuga depende de todas as variáveis consideradas, o erro experimental só pode ser avaliado frente a ensaios repetidos. Assim, a exemplo da análise realizada com a pressão de rejeito  $p_w$ , a resposta do poder de separação  $\delta U$  será avaliada através dos ensaios realizados com a configuração TIPO 13. Desta forma a Figura 7.8 mostra as curvas experimentais do poder de separação  $\delta U$  em função do fluxo de alimentação para cada pressão de controle  $p_p$ .



**FIGURA 7.8:** Valores experimentais do poder de separação  $\delta U$  em função do fluxo de alimentação  $F$  para cada um dos valores da pressão de produto estipulada nos ensaios realizados com a configuração interna TIPO 13

Novamente foi realizada uma análise estatística dos dados experimentais para cada nível de condições de operação, resultando nos desvios padrão apresentados na Figura 7.9. Os erros se mostram bem distribuídos em relação à pressão  $p_p$ , mas com uma leve dependência em relação ao fluxo de alimentação  $F$ . Novamente podemos adotar a média geral das variâncias para a estimativa do erro experimental. Assim, chegamos à estimativa da variância do poder de separação  $s^2_{\delta U}$  e ao respectivo desvio padrão  $s_{\delta U}$ , que nos conduzem ao intervalo de confiança para o poder de separação  $\delta U$  de  $\pm 0.09$  (unidades de separação normalizadas), considerando um nível de confiança de 95%.



**FIGURA 7.9:** Desvios padrão do poder de separação  $\delta U$  em função do fluxo de alimentação  $F$  para cada um dos valores da pressão de produto estipulados nos ensaios realizados com a configuração interna TIPO 13

Os erros experimentais encontrados são relativamente altos, mas como já foi mencionado, são referentes à etapa de desenvolvimento de um equipamento, desde seus primeiros protótipos. Ao final desse desenvolvimento os erros experimentais foram sensivelmente reduzidos. No entanto, nessa fase não foram obtidos dados suficientes para um estudo como o aqui proposto.

## 7.2 Estrutura das redes neurais

A busca do modelo numérico através do treinamento de uma rede neural que melhor representasse este conjunto de dados experimentais passou por diversas etapas, onde foram avaliados os arranjos das variáveis de entrada e de saída, o domínio das variáveis, o número de neurônios da camada interna, o número de apresentações e o fator de amortecimento do treinamento. Os modelos obtidos nesse processo eram avaliados através das seguintes técnicas:

- ◆ comparação entre os valores calculados pelo modelo e os valores experimentais: quanto maior o distanciamento da diagonal, pior o modelo;
- ◆ função distância: gráfico de barras dos erros, obtidos pela diferença entre os valores calculados e os valores experimentais, organizados em ordem crescente; a simetria em relação ao ponto médio indica que os erros apresentam uma distribuição próxima à distribuição normal;
- ◆ avaliação da função distância por faixas do domínio das condições de operação;
- ◆ comparação da previsão do poder de separação pela rede neural com os resultados experimentais de dois ensaios de verificação externos ao conjunto de dados utilizados no processo de treinamento das redes.

Foram avaliados os arranjos das variáveis representados pelos esquemas da Figura 7.10, onde se verificou a possibilidade da exclusão das variáveis de montagem que apresentavam menor grau de confiabilidade.

Neste estudo, as redes foram treinadas conforme os esquemas da Figura 7.10, com número de neurônios na camada interna de 6 a 10. Em cada estrutura de variáveis a rede com o menor erro para o conjunto de teste era avaliada conforme as técnicas citadas acima. O arranjo que apresentou o melhor ajuste foi o representado pela Figura 7.10, com uma rede neural para cada variável de saída (“Rede A  $\delta U$ ” e “Rede A  $p_w$ ”).

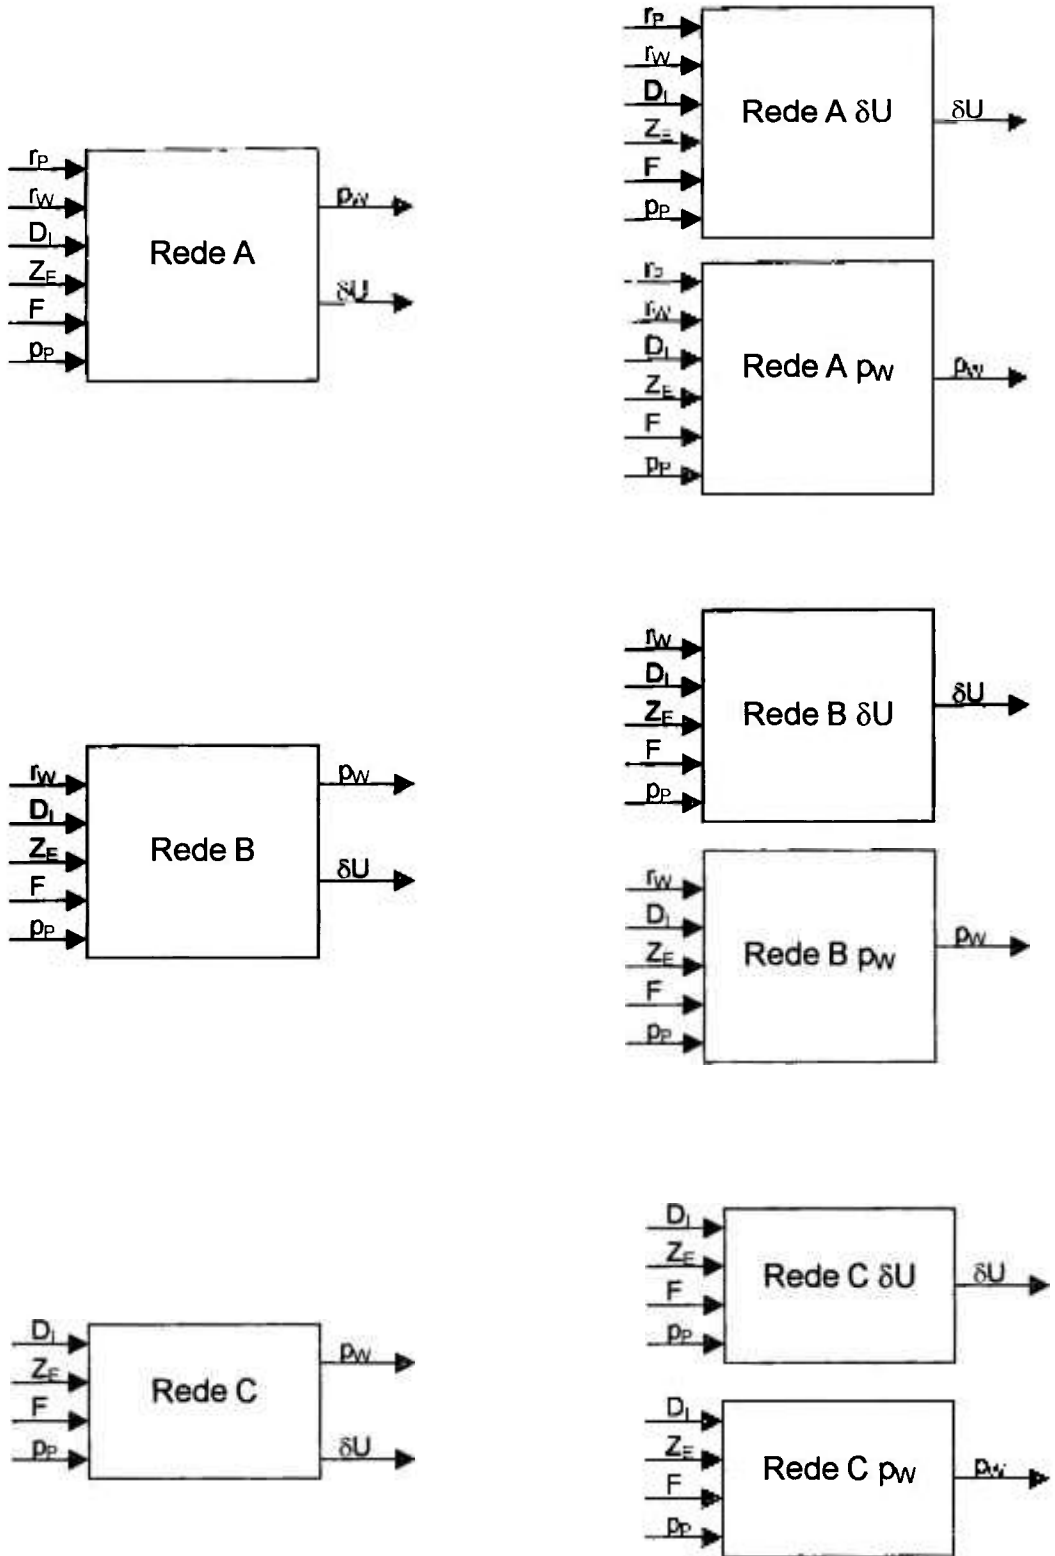


FIGURA 7.10: Esquema de arranjo das variáveis apresentadas para o treinamento das redes neurais

Mesmo nos melhores casos, observamos desvios pouco maiores nas regiões onde as variáveis de saída  $\delta U$  ou  $p_w$  apresentavam valores experimentais muito baixos ou muito altos, através de um leve desvio da diagonal, com os pontos experimentais apresentando uma inclinação levemente inferior à diagonal. Esta tendência é também observada no gráfico dos desvios, definidos pela diferença entre os valores experimentais e os valores calculados, em função dos valores experimentais, onde se observa uma tendência decrescente. Esse comportamento pode ser atribuído simplesmente a problemas numéricos, uma vez que há maior concentração de dados experimentais nos valores intermediários. Este problema foi solucionado com a repetição desses valores no conjunto de dados de treinamento.

A análise dos gráficos da função distância por faixas dos fluxos de alimentação  $F$  indicou um ajuste mais falho para baixos valores de  $F$ . Assim foi avaliado o treinamento de uma rede com um domínio em  $F$  mais restrito, excluindo os dados experimentais com  $F < 0.25$ . Este recurso não surtiu o efeito desejado, resultando num modelo pior que o original. A avaliação da distribuição dos dados no domínio, apresentada através das Figuras 7.1 e 7.2, nos conduziu a excluir os dados obtidos com os fluxos  $F$  e pressões  $p_p$  mais elevados. Assim, foram então excluídos os pontos com fluxos extremos,  $F < 0.18$  e  $F > 0.51$  e com pressões de produto extremas,  $p_p < 0.20$  e  $p_p > 0.64$ . Nesse caso, a análise de desvios apresentou bons resultados, mas a previsão dos ensaios de verificação foi ruim. Finalmente, com base na distribuição dos domínios de  $F$  e  $p_p$ , treinamos uma rede excluindo somente os dados obtidos com valores elevados de  $F$  e  $p_p$ , a saber  $F > 0.64$  e  $p_p > 0.64$ . Este conjunto foi o que apresentou melhores resultados na análise de desvios e na previsão dos resultados dos ensaios de verificação.

A rede treinada para a modelagem da pressão de rejeito  $p_w$  apresentou uma má previsão dos ensaios de verificação. O modelo obtido associava uma grande variação de  $p_w$  com a posição axial da alimentação descrita pela variável  $Z_E$ . Esta correlação, no entanto, não tem fundamento físico. Devido à pobre distribuição das configurações de montagem, a rede neural atribuiu as variações provenientes do grande erro experimental de  $p_w$  e das pequenas alterações efetuadas no sistema de retirada do rejeito ao longo do desenvolvimento da centrífuga à variável  $Z_E$ . Assim, o modelo para o cálculo da pressão

$p_w$  mais coerente não deve ter a variável  $Z_E$  como dado de entrada. O erro total encontrado neste caso foi um pouco maior, mas a previsão do modelo se tornou muito mais próxima aos valores experimentais dos ensaios de verificação.

### 7.3 Treinamento da rede neural para o cálculo do poder de separação $\delta U$

O esquema da Figura 7.11 representa a estrutura das variáveis escolhida para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$ . A pressão na retirada do rejeito  $p_w$  deve ser obtida separadamente, através de outra rede neural que será apresentada a seguir. Os demais parâmetros separativos podem então ser obtidos a partir das variáveis de entrada e do poder de separação  $\delta U$  calculado através da rede neural, como foi feito no Capítulo 6.

O conjunto de dados utilizado, proveniente do conjunto original excluindo os pontos com  $F > 0.64$  e  $p_p > 0.64$ , contém 706 pontos experimentais. Esses pontos foram divididos entre o conjunto para treinamento (“*learning-set*” - LS) com 355 pontos e o conjunto para verificação do treinamento (“*test-set*” - TS) com 351 pontos. Os pontos com  $\delta U < 0.34$  e  $\delta U > 0.82$  foram repetidos duas vezes no conjunto de treinamento, resultando em mais 58 pontos a serem lidos pela rede neural. Os dados experimentais apresentados à rede neural se encontram no Apêndice 7.10.1.



**FIGURA 7.11:** Esquema adotado para a modelagem do poder de separação  $\delta U$  da centrífuga em estudo

Foram avaliadas redes neurais de três camadas com camadas internas contendo de 6 a 12 neurônios, treinadas com o algoritmo da retro-propagação. Foram permitidas até 50000 apresentações, com o fator de aceleração constante  $\eta=1$ . Os erros atingidos por essas redes para os conjuntos de treinamento (RMST) e para o conjunto de teste (RMSTT) são apresentados na Tabela 7.2. Foi avaliado o uso de fatores de aceleração de convergência  $\eta=0.5$ ,  $\eta=2$  e variáveis. Nenhum desses recursos acelerou o treinamento das redes, e portanto mantivemos o fator constante de  $\eta=1$ . O treinamento foi feito para as redes com 8 e 9 neurônios na camada interna permitindo até 100000 apresentações.

TABELA 7.2


Somatório de erros calculados no treinamento de redes neurais para o cálculo do poder de separação  $\delta U$  com diferentes números de neurônios na camada oculta (NH) com até 50000 apresentações do conjunto de dados e  $\eta=1$

NH	CONJUNTO DE TREINAMENTO		CONJUNTO DE TESTE	
	N. de apresentações	RMST min.	N. de apresentações	RMSTT min.
6	12 200	0.514	12 800	1.462
7	4 800	0.503	5 800	1.500
<b>8</b>	<b>50 000</b>	<b>0.334</b>	<b>50 000</b>	<b>1.065</b>
9	50 000	0.336	50 000	1.033
10	37 400	0.417	36 900	1.246
11	24 800	0.300	24 800	0.989
12	50 000	0.375	37 300	1.223

A melhor rede neural, segundo o critério heurístico normalmente usado, é aquela que apresenta o menor somatório de erros para o conjunto de teste, com o menor número de apresentações e o menor número de neurônios na camada oculta. Várias redes foram analisadas segundo as técnicas citadas. A escolha da rede levou em consideração os erros RMST e RMSTT mas também o ajuste do modelo observado frente aos dados experimentais, através da análise das funções distância, da análise de resíduos e da capacidade de previsão dos resultados dos ensaios de verificação. Assim, a modelagem do poder de separação  $\delta U$  será feita com uma rede com **8** (oito) neurônios na camada oculta, com treinamento permitido até 100000 apresentações, resultando em um erro total de 0.328 no conjunto de treinamento e de 1.052 no conjunto de teste. O Apêndice 7.10.2 traz os

valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural. Os pesos que minimizam os erros no conjunto de testes são apresentados no Apêndice 7.10.3.

A Figura 7.12 mostra o somatório dos erros com o número de apresentações durante o processo de treinamento da rede neural com 8 neurônios na camada interna determinada para o cálculo do poder de separação  $\delta U$ . Observamos uma tendência assintótica nos erros calculados ao longo do treinamento, o que indica que um número maior de apresentações não é necessário no presente caso.



**FIGURA 7.12:** Somatório de erros ao longo do treinamento da rede neural com 8 neurônios na camada interna para o cálculo do poder de separação  $\delta U$

A análise da rede treinada é feita através da comparação entre os valores do poder de separação  $\delta U$  experimentais e os valores calculados pelo modelo, apresentada na Figura 7.13. O Apêndice 7.10.2 traz esses valores de forma normalizada. Os pontos, tanto do conjunto de treinamento (LS) como do conjunto de teste (TS) se apresentam distribuídos ao longo da diagonal, dentro do intervalo de confiança definido. A função distância, que avalia a distribuição dos erros, é mostrada na Figura 7.14. Nestes gráficos verificamos uma boa simetria em torno dos valores de erro próximos a zero, que representa a aprovação do modelo também por este critério de avaliação.

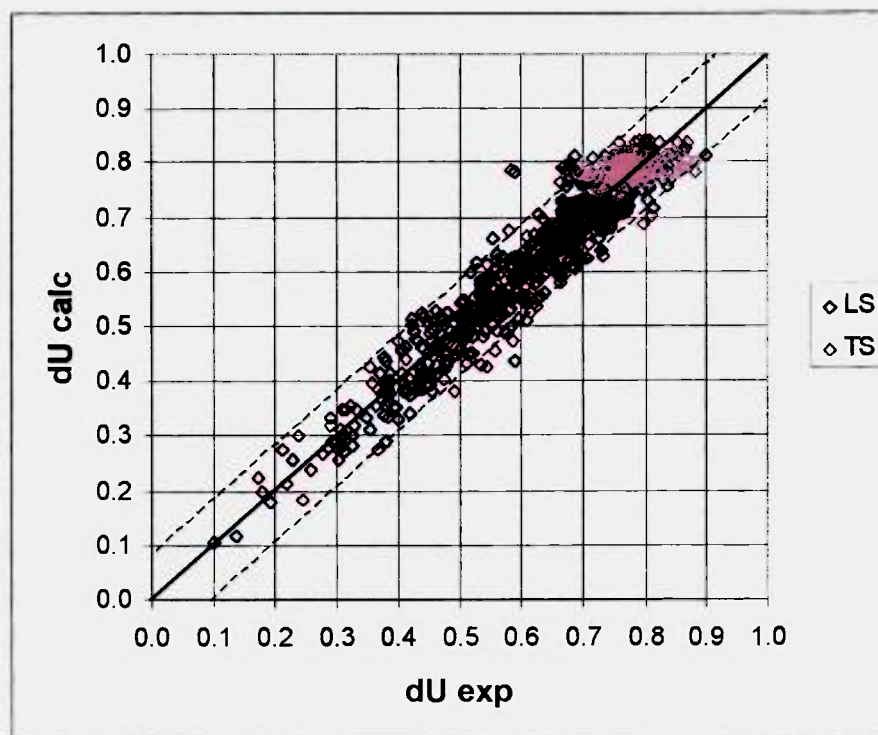


FIGURA 7.13: Comparação entre os valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com 8 neurônios na camada interna

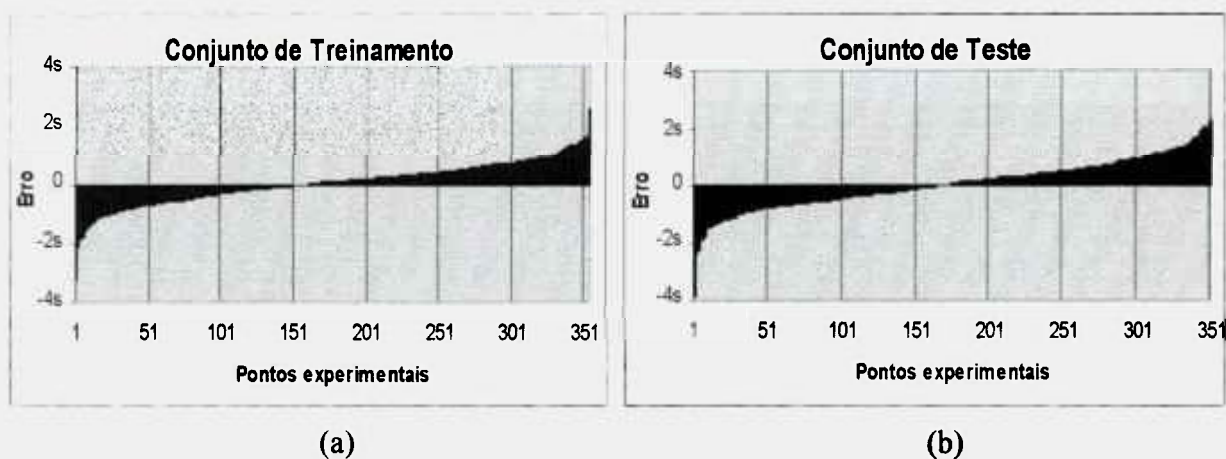



FIGURA 7.14: Função distância dos erros obtidos no treinamento da rede neural com 8 neurônios na camada interna para o cálculo do poder de separação  $\delta U$  (a) no conjunto de treinamento, (b) no conjunto de teste

A seguir é feita a análise de resíduos do modelo obtido. A análise de resíduos estuda a distribuição do erro  $E$ , determinado pela diferença entre os valores experimentais e calculados. Este tipo de análise foi realizado ao longo de todo o estudo, dando subsídios para a seleção dos dados experimentais e para a escolha do modelo. Algumas das capacidades desta ferramenta são:

- detectar pontos experimentais fora do grupo,
- detectar tendências ao longo dos experimentos,
- detectar mudanças abruptas nos desvios,
- detectar mudanças abruptas na variância do erro,
- verificar a distribuição normal do erro, através da distribuição da frequência relativa dos erros,
- detectar desvios sistemáticos dos valores estimados, o que indicaria um modelo não adequado.

A Figura 7.15 mostra a distribuição do erro em função do valor experimental do poder de separação  $\delta U$ . As Figuras 7.16 a 7.21 apresentam a distribuição dos erros observados em função dos valores das variáveis de entrada. Essas figuras apresentam uma boa distribuição do erro, sem nenhuma tendência significativa.



**FIGURA 7.15:** Distribuição do erro  $E = \delta U_{\text{exp}} - \delta U_{\text{calc}}$  em função do valor experimental do poder de separação  $\delta U$




FIGURA 7.16: Distribuição do erro  $E = \delta U_{\text{exp}} - \delta U_{\text{calc}}$  em função do fluxo de alimentação F







FIGURA 7.17: Distribuição do erro  $E = \delta U_{\text{exp}} - \delta U_{\text{calc}}$  em função da pressão do produto  $p_P$




**FIGURA 7.18:** Distribuição do erro  $E = \delta U_{exp} - \delta U_{calc}$  em função do raio de coleta do produto  $r_P$



**FIGURA 7.19:** Distribuição do erro  $E = \delta U_{exp} - \delta U_{calc}$  em função do raio de coleta do rejeito  $r_W$




**FIGURA 7.20:** Distribuição do erro  $E = \delta U_{exp} - \delta U_{calc}$  em função do diâmetro do orifício central do disco girante  $D_I$




**FIGURA 7.21:** Distribuição do erro  $E = \delta U_{exp} - \delta U_{calc}$  em função da posição axial da alimentação, em termos do comprimento da seção de enriquecimento  $Z_E$

A Figura 7.22 mostra a distribuição do erro em função dos diversos ensaios. Alguns dos ensaios apresentam erros sistematicamente acima ou abaixo do zero, porém dentro dos limites de confiança estabelecidos ( $\pm 2s$ ). Estes ensaios, por outro lado, não apresentaram outros indícios de erro experimental, sendo assim mantidos no conjunto de dados utilizado.




**FIGURA 7.22:** Distribuição do erro  $E = \delta U_{\text{exp}} - \delta U_{\text{calc}}$  em função dos ensaios

Finalmente a Figura 7.23 traz a distribuição da frequência dos erros. O erros encontrados apresentam uma distribuição satisfatória, próxima à distribuição normal.



(a)




(b)

**FIGURA 7.23:** Distribuição da frequência dos erros no cálculo do poder de separação  $\delta U$  (a) para o conjunto de treinamento, (b) para o conjunto de teste

## 7.4 Treinamento da rede neural para o cálculo da pressão de rejeito $p_w$

O esquema da Figura 7.24 representa a estrutura das variáveis escolhida para o treinamento da rede neural para o cálculo da pressão na retirada do rejeito  $p_w$ . Salientamos que a pressão  $p_w$  se mostrou mais sensível às alterações ocorridas ao longo do processo de desenvolvimento da centrífuga. A previsão dos níveis de pressão  $p_w$  para uma centrífuga em desenvolvimento é de vital importância para sua futura operação em cascata, onde as centrífugas têm suas correntes de alimentação e de retiradas interligadas em arranjos em série e em paralelo.



**FIGURA 7.24:** Esquema adotado para a modelagem da pressão de rejeito  $p_w$  da centrífuga em estudo

No treinamento da rede para a pressão  $p_w$  foram repetidos os pontos com  $p_w < 0.20$  e  $p_w > 0.77$ , acrescentando assim mais 26 pontos ao conjunto de 706 dados experimentais a serem apresentados à rede neural no seu treinamento. Os dados experimentais apresentados à rede neural se encontram no Apêndice 7.10.4.

Foram avaliadas redes neurais de três camadas com camadas internas contendo de 4 a 12 neurônios, treinadas pelo algoritmo da retro-propagação. Foram permitidas até 50000 apresentações, com o fator de aceleração constante  $\eta=1$ . Os erros atingidos por essas redes para os conjuntos de treinamento (RMST) e para o conjunto de teste (RMSTT) são apresentados na Tabela 7.3.

TABELA 7.3

Somatório de erros calculados no treinamento de redes neurais para o cálculo da pressão de rejeito  $p_w$  com diferentes números de neurônios na camada oculta (NH) e  $\eta=1$

NH	CONJUNTO DE TREINAMENTO		CONJUNTO DE TESTE	
	N. de apresentações	RMST min.	N. de apresentações	RMSTT min.
4	400	1.019	400	3.010
5	400	0.996	800	2.732
6	6 000	0.915	5 300	2.951
7	<b>900</b>	<b>0.969</b>	<b>900</b>	<b>2.615</b>
8	2 500	1.019	1 800	2.907
9	700	1.027	700	2.934
10	2 000	1.001	1 500	2.796
11	500	0.988	600	2.615
12	600	0.933	700	2.536

Tendo em vista os resultados apresentados na Tabela 7.3 e a avaliação geral do modelo, a modelagem da pressão de rejeito  $p_w$  será através de uma rede neural com 7 (sete) neurônios na camada interna, treinada com até 50000 apresentações. Os pesos desta rede neural são apresentados no Apêndice 7.10.5. A Figura 7.25 traz o erro total observado na rede neural ao longo do treinamento.




FIGURA 7.25: Somatório de erros ao longo do treinamento da rede neural com 7 neurônios na camada interna para o cálculo da pressão de rejeito  $p_w$

A comparação entre os valores experimentais e os calculados pela rede neural escolhida é observada na Figura 7.26, cujos valores normalizados podem ser encontrados no Anexo 7.10.6. Notamos alguma dispersão, às vezes ultrapassando os limites de confiança estimados, devido à má qualidade dos dados experimentais utilizados. A função distância está representada pela Figura 7.27.






FIGURA 7.26: Comparação entre os valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com 7 neurônios na camada interna



(a)


(b)

FIGURA 7.27: Função distância dos erros obtidos no treinamento da rede neural com 7 neurônios na camada interna para o cálculo da pressão  $p_w$  (a) no conjunto de treinamento, (b) no conjunto de teste




**FIGURA 7.28:** Distribuição do erro  $E=p_{w_{exp}}-p_{w_{calc}}$  em função do valor experimental da pressão de rejeito  $p_w$


A Figura 7.28 traz a distribuição do erro  $E=p_{w_{exp}}-p_{w_{calc}}$  com os valores experimentais da pressão de rejeito  $p_w$ . Não se observa aí nenhuma dependência definida. Todos os gráficos do erro com as variáveis de entrada apresentaram distribuição aleatória e não serão mostrados aqui por não acrescentarem nenhuma informação ao trabalho. A Figura 7.29 mostra a distribuição do erro em função dos diversos ensaios. Alguns ensaios aparentemente carregam um erro sistemático em função do modelo obtido, porém não há indícios suficientes para considerar os dados experimentais errados, e portanto não podem ser simplesmente excluídos do conjunto de dados. Nos gráficos da Figura 7.30 são apresentadas as a distribuições da frequência de erros para os dois conjuntos de dados.



**FIGURA 7.29:** Distribuição do erro  $E=p_{w_{exp}}-p_{w_{calc}}$  em função dos ensaios



(a)



(b)

**FIGURA 7.30:** Distribuição da frequência dos erros no cálculo da pressão de rejeito  $p_w$  (a) para o conjunto de treinamento, (b) para o conjunto de teste

## 7.5 Ensaios de verificação


Foram realizados dois novos ensaios, com montagens diferentes daquelas usadas no treinamento das redes neurais, para avaliação dos modelos numéricos para o cálculo do poder de separação  $\delta U$  e da pressão de rejeito  $p_w$ . Estes ensaios estão descritos na Tabela 7.4. Os resultados experimentais obtidos nesses ensaios se encontram no Anexo 7.10.7.

TABELA 7.4


Relação dos ensaios de separação isotópica de verificação, com as respectivas características das centrífugas

Tipo de Montagem	$r_p$	$r_w$	$D_1$	$Z_E$	No. Ensaio	Máquina
14	0.1	0.5	0.1	0.8529	L6-24/98	01A
15	0.1	0.1	0.1	0.6553	L1-16/98	01A

A comparação dos resultados experimentais destes dois ensaios é feita através dos gráficos do poder de separação  $\delta U$  e da pressão de rejeito  $p_w$  em função do fluxo de alimentação  $F$  para pressões de produto  $p_p=0.4055$  e  $p_p=0.5158$  (valores normalizados) das Figuras 7.31 a 7.34.




(a)  $p_p=0.4055$




(b)  $p_p=0.5158$

**FIGURA 7.31:** Comparação entre os valores do poder de separação  $\delta U$  previstos pela rede neural e os valores experimentais obtidos no ensaio L6-24/98




(a)  $p_p=0.4055$

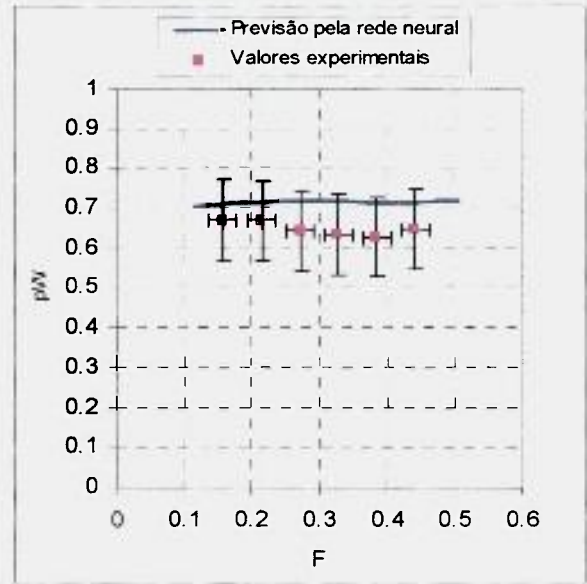


(b)  $p_p=0.5158$

**FIGURA 7.32:** Comparação entre os valores do poder de separação  $\delta U$  previstos pela rede neural e os valores experimentais obtidos no ensaio L1-16/98




(a)  $p_p=0.4055$




(b)  $p_p=0.5158$

**FIGURA 7.33:** Comparação entre os valores da pressão de rejeito  $p_w$  previstos pela rede neural e os valores experimentais obtidos no ensaio L6-24/98




(a)  $p_p=0.4055$




(b)  $p_p=0.5158$

**FIGURA 7.34:** Comparação entre os valores da pressão de rejeito  $p_w$  previstos pela rede neural e os valores experimentais obtidos no ensaio L1-16/98


Esses gráficos mostram uma boa concordância entre os valores da pressão de rejeito  $p_w$  previstos pela rede neural e os experimentais em ambos ensaios de verificação. O poder de separação  $\delta U$ , no entanto, não apresentou resultados tão bons, principalmente para baixos fluxos de alimentação. As Figuras 7.35 e 7.36 mostram os erros encontrados no cálculo dos valores do poder de separação  $\delta U$  dos ensaios L6-24/98 e L1-16/98, respectivamente. Da mesma forma as Figuras 7.37 e 7.38 trazem os erros resultantes do cálculo das pressões de rejeito  $p_w$ . Os erros do poder de separação  $\delta U$  se apresentam sistematicamente menores que zero, com uma tendência crescente com o fluxo de alimentação  $F$ . Em valores de fluxo muito baixos, menores que 0.3, os erros observados são maiores que o limite de confiança estabelecido com base nos dados experimentais do conjunto de treinamento, para um nível de confiança de 95%. Neste caso o modelo apresentou boa concordância para fluxos de alimentação de 0.3 a 0.5. No cálculo da pressão de rejeito  $p_w$  também se observa uma tendência sistemática em erros menores que zero, com uma tendência, desta vez, decrescente com o fluxo de alimentação  $F$ . Neste caso, os erros que se apresentam melhor encaixados nos limites de confiança.




**FIGURA 7.35:** Erros encontrados no cálculo do poder de separação  $\delta U$  no ensaio de verificação L6-24/98



**FIGURA 7.36:** Erros encontrados no cálculo do poder de separação  $\delta U$  no ensaio de verificação L1-16/98



**FIGURA 7.37:** Erros encontrados no cálculo da pressão de rejeito  $p_w$  no ensaio de verificação L6-24/98



**FIGURA 7.38:** Erros encontrados no cálculo da pressão de rejeito  $p_w$  no ensaio de verificação L1-16/98

O modelo numérico definido para o cálculo do poder de separação  $\delta U$  e da pressão de rejeito  $p_w$  da centrífuga em estudo aparentemente apresenta boa previsão. No entanto, dada a discrepância observada no poder de separação  $\delta U$  em baixos fluxos de alimentação quando comparado aos ensaios de verificação, seria prudente a realização de novos ensaios de validação com diferentes configurações de montagem. Como a realização de um ensaio de separação em uma centrífuga é uma tarefa de difícil realização, o presente trabalho deve ser concluído sem esta valiosa informação complementar. De qualquer forma, o modelo aqui desenvolvido apresentou bons resultados na faixa de fluxo de alimentação  $F$  de maior interesse, onde o poder de separação  $\delta U$  assume os maiores valores. Com isso, este modelo tem grande utilidade no direcionamento de novos ensaios para a continuidade ou confirmação da otimização desta geração de centrífugas.

## 7.6 Mapeamento da solução e otimização

O modelo obtido permite calcular o poder de separação  $\delta U$  e a pressão  $p_w$  para o domínio das variáveis de entrada estabelecido, a saber:

- raio de coleta do produto  $r_p$ : de 0.1 a 0.9
- raio de coleta do rejeito  $r_w$ : de 0.1 a 0.9
- diâmetro do furo interno do disco girante  $D_I$ : de 0.1 a 0.9
- posição da alimentação  $Z_E$ : de 0.1 a 0.9
- fluxo de alimentação  $F$ : de 0.1 a 0.64
- pressão de produto  $p_p$ : de 0.1 a 0.64

O cálculo de um modelo obtido por redes neurais é extremamente rápido, permitindo assim o mapeamento completo da solução. Assim, foram avaliadas todas as possíveis combinações das variáveis de montagem, dentro do domínio definido, com passos de variação compatíveis com os níveis de precisão mecânica executáveis. Os valores utilizados neste mapeamento da solução são apresentados na Tabela 7.5. Resultam daí 180 diferentes configurações de montagem, com 156 condições de operação, fornecendo o total de 28080 pontos calculados.

**TABELA 7.5**

Distribuição das variáveis de entrada utilizadas no mapeamento da solução

<b>VARIÁVEL</b>	<b>VALOR MÍNIMO</b>	<b>VALOR MÁXIMO</b>	<b>VALOR DO PASSO</b>	<b>QUANTIDADE DE INTERVALOS</b>
<b>r<sub>p</sub></b>	0.1	0.9	0.4	3
<b>r<sub>w</sub></b>	0.1	0.9	0.4	3
<b>D<sub>I</sub></b>	0.1	0.9	0.27	4
<b>Z<sub>E</sub></b>	0.1	0.85	0.19	5
<b>F</b>	0.12	0.51	0.03	13
<b>p<sub>p</sub></b>	0.22	0.63	0.04	12

A inspeção direta desta superfície de resposta hiper-dimensional permite encontrar o ponto que maximiza o poder de separação  $\delta U$ . A otimização pode atender restrições de caráter prático, uma vez que a análise da superfície de resposta pode ser realizada de forma direta. A título de exemplo, vamos proceder à otimização simples e direta da superfície de resposta obtida pelos critérios acima descritos. Esta otimização indicou uma centrífuga com as características de montagem descritas na Tabela 7.6, que trabalhando nas condições de operação ali indicadas fornecem os resultados apresentados também na Tabela 7.6.

As Figuras 7.39 a 7.41 mostram o mapeamento da superfície de resposta do poder de separação  $\delta U$  em torno dos parâmetros da centrífuga otimizada. Superfícies semelhantes podem ser construídas para qualquer configuração desejada. As superfícies obtidas apresentam formas contínuas, sem alterações abruptas e com tendências coerentes.

TABELA 7.6

Otimização da centrífuga em estudo

$r_p$	0.1
$r_w$	0.1
$D_I$	0.9
$Z_E$	0.29
$F$	0.28
$p_p$	0.22
$\delta U$	0.99
$p_w$	0.45






FIGURA 7.39: Superfície de resposta do poder de separação  $\delta U$  com a variação do fluxo de alimentação  $F$  e a pressão de produto  $p_p$  para a centrífuga otimizada ( $r_p=0.1$ ,  $r_w=0.1$ ,  $D_I=0.9$ ,  $Z_E=0.29$ )




**FIGURA 7.40:** Superfície de resposta do poder de separação  $\delta U$  com a variação do raio de coleta do produto  $r_P$  e do raio de coleta do rejeito  $r_W$  para a centrífuga otimizada ( $D_I=0.9$ ,  $Z_E=0.29$ ,  $F=0.28$  e  $p_P=0.22$ )




**FIGURA 7.41:** Superfície de resposta do poder de separação  $\delta U$  com a variação diâmetro interno do disco girante  $D_I$  e da posição axial da alimentação  $Z_E$  para a centrífuga otimizada ( $r_P=0.1$ ,  $r_W=0.1$ ,  $F=0.28$  e  $p_P=0.22$ )


Da mesma forma as Figuras 7.42 e 7.43 trazem as superfícies de resposta das pressões de rejeito  $p_w$  e a Figura 7.44 a curva de  $p_w$  com o diâmetro do furo interno do disco girante  $D_I$ , uma vez que esta pressão independe da posição de alimentação expressa através de  $Z_E$ . As respostas obtidas novamente se apresentam com tendências coerentes. Por exemplo: a pressão de rejeito  $p_w$  aumenta com o aumento da pressão de produto  $p_p$ , com o aumento do raio de coleta  $r_w$  e com o aumento do furo central do disco girante  $D_I$ .



**FIGURA 7.42:** Superfície de resposta da pressão de rejeito  $p_w$  com a variação do fluxo de alimentação  $F$  e a pressão de produto  $p_p$  para a centrífuga otimizada ( $r_p=0.1$ ,  $r_w=0.1$ ,  $D_I=0.9$ ,  $Z_E=0.29$ )



**FIGURA 7.43:** Superfície de resposta da pressão de rejeito  $p_w$  com a variação do raio de coleta do produto  $r_p$  e do raio de coleta do rejeito  $r_w$  para a centrífuga otimizada ( $D_I=0.9$ ,  $Z_E=0.29$ ,  $F=0.28$  e  $p_P=0.22$ )



**FIGURA 7.44:** Resposta pressão de rejeito com a variação diâmetro interno do disco girante  $D_I$  para a centrífuga otimizada ( $r_P=0.1$ ,  $r_W=0.1$ ,  $Z_E=0.29$ ,  $F=0.28$  e  $p_P=0.22$ )

## 7.7 Análise de sensibilidade

Com o modelo estabelecido para o cálculo do poder de separação  $\delta U$  e para a pressão de rejeito  $p_w$ , diversos tipos de análises e cálculos periféricos, como por exemplo o cálculo dos fatores de separação, podem ser facilmente executados. Uma das análises mais interessantes no caso do desenvolvimento de uma centrífuga, é a análise de sensibilidade. O cálculo das derivadas parciais é realizado como descrito no capítulo anterior. As derivadas parciais podem ser calculadas ponto a ponto nas superfícies de respostas do processo. A avaliação dessas derivadas parciais permite encontrar configurações de montagem e pontos de operação mais robustos para uma determinada resposta, tornando-se assim um critério para a otimização da centrífuga.

A título de exemplo, na Tabela 7.7 são apresentados os valores encontrados das derivadas parciais  $\partial\delta U/\partial X_i$  e  $\partial p_w/\partial X_i$  para a centrífuga otimizada, descrita pela Tabela 7.6. Esses números não apresentam significado físico direto, uma vez que são valores normalizados, porém são uma indicação da importância de cada variável no processo. A observação dos valores absolutos das derivadas parciais, por sua vez, traduz a taxa de variação das respostas por unidade da variável de entrada. No entanto, dadas as diferenças dimensionais características das centrífugas, não se tem uma boa comparação entre as variáveis de entrada.

Os valores das derivadas parciais encontrados para outros conjuntos de dados de entrada podem se apresentar de forma completamente diferente, em alguns casos até invertendo tendências. A Tabela 7.8 mostra os valores máximos, mínimos e médios das derivadas parciais normalizadas para o universo de valores descrito pela Tabela 7.5.

**TABELA 7.7**

Análise de sensibilidade da centrífuga otimizada

Variável $X_i$	Valor	$\partial\delta U/\partial X_i$	$\partial p_w/\partial X_i$
$r_P$	0.1	-104.8	-4.8
$r_W$	0.1	-92.1	16.6
$D_I$	0.9	-50.9	5.0
$Z_E$	0.29	-10.4	-
F	0.28	1.6	16.8
$p_P$	0.22	-2.9	27.2

**TABELA 7.8**

Análise de sensibilidade da centrífuga estudada

Variável $X_i$	$\partial\delta U/\partial X_i$	$\partial\delta U/\partial X_i$	$\partial\delta U/\partial X_i$	$\partial p_w/\partial X_i$	$\partial p_w/\partial X_i$	$\partial p_w/\partial X_i$
	mín	máx	médio	mín	máx	médio
$r_P$	-113.5	27.0	-5.5	-109.2	72.2	-10.5
$r_W$	-107.1	18.6	-4.5	-44.6	126.5	23.7
$D_I$	-72.7	55.5	-3.7	-12.3	50.0	8.2
$Z_E$	-21.3	44.7	2.3	-	-	-
F	-33.6	72.7	3.7	-17.4	71.3	15.7
$p_P$	-49.0	51.4	-1.4	-0.6	136.2	42.5

## 7.8 Conclusão

Neste capítulo foi realizada a modelagem do desempenho separativo de um modelo de centrífuga, através do cálculo do poder de separação  $\delta U$  e da pressão na retirada do rejeito  $p_w$ . Pudemos avaliar o potencial de aproveitamento que a rede neural apresenta como ferramenta para a modelagem de uma centrífuga. Este estudo nos permitiu chegar às seguintes conclusões:

- A qualidade dos dados experimentais utilizados no treinamento de uma rede neural é de fundamental importância. O uso de dados inconsistentes pode levar à obtenção de modelos totalmente errôneos. Por isso, é necessária uma cuidadosa análise e avaliação dos dados experimentais disponíveis antes de começar o trabalho de treinamento de uma rede neural. Esta tarefa exige um profundo conhecimento do processo a ser modelado bem como de todas as circunstâncias ao redor dos ensaios propriamente ditos.

- Novamente a definição das variáveis de entrada e saída se mostrou vital para a obtenção de um modelo numérico coerente.

- No presente caso, dada a complexidade do sistema, a opção de calcular as respostas desejadas por redes independentes foi a que apresentou melhores resultados. Assim, a pressão na linha de rejeito  $p_w$  da presente centrífuga trabalhando no processo de separação simétrico pode ser modelada por uma rede neural com sete neurônios na camada oculta, tendo como parâmetros de entrada três variáveis de montagem, a saber: o raio de coleta do produto  $r_p$ , o raio de coleta do rejeito  $r_w$  e o diâmetro do orifício central do disco girante  $D_i$ ; e duas variáveis de processo: o fluxo de alimentação  $F$  e a pressão na linha de retirada do produto  $p_p$ . O poder de separação  $\delta U$ , da mesma forma, foi modelado por uma rede neural com oito neurônios na camada oculta, com as variáveis de entrada citadas mais a posição axial da alimentação no interior do rotor, representada pelo comprimento da

seção de enriquecimento  $Z_E$ . A pressão na linha de alimentação  $p_F$  não apresentou dados experimentais consistentes para a realização de uma modelagem.

- Os modelos obtidos apresentaram boa concordância com os dados experimentais utilizados tanto no treinamento como no teste da rede neural. A distribuição de erro neste caso foi satisfatória. Porém, quando comparados aos resultados de ensaios de verificação externos ao conjunto de dados original, os valores previstos pelas redes neurais apresentaram erros tendenciosos e em alguns casos fora dos limites de confiança determinados. Os ensaios de verificação no entanto foram restritos, isto é, não cobriram uma região significativa do domínio. Talvez em outra região do domínio os erros apresentassem tendências opostas às observadas.

- Os dados experimentais disponíveis não possuíam uma boa qualidade, tanto em termos da distribuição dentro do domínio das variáveis, como em termos dos erros avaliados. Mesmo assim, as previsões decorrentes desses modelos apresentam coerência tanto com relação às tendências como em relação aos valores encontrados. Isto é um ponto positivo, pois de qualquer forma este modelo numérico pode ser usado para direcionar um novo conjunto de ensaios.

- A análise de sensibilidade também apresentou resultados plausíveis, coerentes com as expectativas teóricas, e se mostrou mais uma ferramenta com alto potencial de aplicação para a otimização criteriosa de um modelo de centrífuga.

- Seria desejável acrescentar novos dados experimentais ao conjunto de dados utilizado no treinamento das redes neurais para enriquecer a distribuição de resultados dentro do domínio das variáveis de montagem. No entanto, seria necessário a realização de novos ensaios.

## 7.9 Notação

$d$	-	diâmetro do rotor
$D_I$	-	diâmetro do orifício interno do disco girante
$E$	-	erro: diferença entre os valores experimentais e os calculados
$f$	-	freqüência de rotação da centrífuga
$F$	-	fluxo de alimentação
$NH$	-	número de neurônios na camada oculta da rede neural
$NI$	-	número de neurônios na camada de entrada da rede neural
$NO$	-	número de neurônios na camada de saída da rede neural
No. Sets	-	número de apresentações do conjunto de dados no treinamento da rede
$P$	-	fluxo de retirada do produto
$p_F$	-	pressão na linha de alimentação
$p_P$	-	pressão na linha de retirada do produto
$p_W$	-	pressão na linha de retirada do rejeito
$R_F$	-	razão de abundância da alimentação (0.00725)
$R_P$	-	razão de abundância do produto
$R_W$	-	razão de abundância do rejeito
$RRMST$	-	somatório de erros do “learning set”
$RMSTT$	-	somatório de erros do “test set”
$r_P$	-	raio de coleta do produto
$r_W$	-	raio de coleta do rejeito
$s$	-	estimativa do desvio padrão de uma variável
$s^2$	-	estimativa da variância de uma variável
$v$	-	velocidade periférica do rotor
$W$	-	fluxo de retirada do rejeito
$X(i)$	-	vetor com os dados de entrada de uma rede neural
$Y(k)$	-	vetor com os resultados calculados por uma rede neural
$Z$	-	comprimento útil do rotor
$Z_E$	-	comprimento da seção de enriquecimento

**letras gregas**

$\alpha$	-	fator de separação
$\beta$	-	fator de enriquecimento
$\delta U$	-	poder de separação
$\gamma$	-	fator de empobrecimento
$\eta$	-	fator de aceleração de convergência no treinamento de redes neurais
$\theta$	-	corte

## 7.10 Apêndices

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$

*“Learning Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_i$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.5000	0.9000	0.4765	0.1000	0.2220	0.2927
0.1000	0.5000	0.9000	0.4765	0.2145	0.2250	0.4337
0.1000	0.5000	0.9000	0.4765	0.3231	0.2232	0.5565
0.1000	0.5000	0.9000	0.4765	0.4431	0.2226	0.6541
0.1000	0.5000	0.9000	0.4765	0.5572	0.2236	0.6792
0.1000	0.5000	0.9000	0.4765	0.1000	0.3172	0.3835
0.1000	0.5000	0.9000	0.4765	0.2145	0.3172	0.5086
0.1000	0.5000	0.9000	0.4765	0.3345	0.3181	0.6334
0.1000	0.5000	0.9000	0.4765	0.4431	0.3189	0.6757
0.1000	0.5000	0.9000	0.4765	0.5572	0.3188	0.6877
0.1000	0.5000	0.9000	0.4765	0.1000	0.2092	0.3132
0.1000	0.5000	0.9000	0.4765	0.1000	0.2888	0.3984
0.1000	0.5000	0.9000	0.4765	0.2145	0.2232	0.4740
0.1000	0.5000	0.9000	0.4765	0.1000	0.3616	0.3954
0.1000	0.5000	0.9000	0.4765	0.2145	0.3297	0.5417
0.1000	0.5000	0.9000	0.4765	0.3286	0.2736	0.6052
0.1000	0.5000	0.9000	0.4765	0.1000	0.4374	0.2857
0.1000	0.5000	0.9000	0.4765	0.2145	0.4430	0.5192
0.1000	0.5000	0.9000	0.4765	0.3257	0.4068	0.6508
0.1000	0.5000	0.9000	0.4765	0.4431	0.3589	0.6996
0.1000	0.5000	0.9000	0.4765	0.1000	0.5178	0.1914
0.1000	0.5000	0.9000	0.4765	0.2115	0.5273	0.4524
0.1000	0.5000	0.9000	0.4765	0.3286	0.5396	0.5848
0.1000	0.5000	0.9000	0.4765	0.4431	0.5031	0.7042
0.1000	0.5000	0.9000	0.4765	0.5543	0.4595	0.7368
0.1000	0.5000	0.9000	0.4765	0.1000	0.5921	0.1370
0.1000	0.5000	0.9000	0.4765	0.2145	0.6025	0.3252
0.1000	0.5000	0.9000	0.4765	0.5572	0.6369	0.7306
0.1000	0.5000	0.9000	0.4765	0.1000	0.1020	0.1000
0.1000	0.5000	0.9000	0.4765	0.2086	0.1229	0.3817
0.1000	0.5000	0.9000	0.4765	0.3231	0.1467	0.5559
0.1000	0.5000	0.9000	0.4765	0.4402	0.1699	0.6440
0.1000	0.5000	0.9000	0.1000	0.1641	0.2179	0.5723
0.1000	0.5000	0.9000	0.1000	0.2849	0.2192	0.7206
0.1000	0.5000	0.9000	0.1000	0.3900	0.2173	0.7736
0.1000	0.5000	0.9000	0.1000	0.1613	0.3180	0.4795
0.1000	0.5000	0.9000	0.1000	0.2755	0.3180	0.6239
0.1000	0.5000	0.9000	0.1000	0.3898	0.3202	0.7005
0.5000	0.9000	0.3667	0.4765	0.1600	0.2223	0.5392

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Learning Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.5000	0.9000	0.3667	0.4765	0.2715	0.2220	0.6866
0.5000	0.9000	0.3667	0.4765	0.3857	0.2229	0.7377
0.5000	0.9000	0.3667	0.4765	0.5002	0.2244	0.7734
0.5000	0.9000	0.3667	0.4765	0.6143	0.2222	0.7831
0.5000	0.9000	0.3667	0.4765	0.1574	0.3181	0.5221
0.5000	0.9000	0.3667	0.4765	0.2715	0.3199	0.6589
0.5000	0.9000	0.3667	0.4765	0.3857	0.3172	0.7143
0.5000	0.9000	0.3667	0.4765	0.5002	0.3172	0.7711
0.5000	0.9000	0.3667	0.4765	0.6143	0.3188	0.7756
0.5000	0.9000	0.3667	0.4765	0.1000	0.1405	0.4002
0.5000	0.9000	0.3667	0.4765	0.1574	0.2372	0.5757
0.5000	0.9000	0.3667	0.4765	0.1000	0.3797	0.3776
0.5000	0.9000	0.3667	0.4765	0.2145	0.2871	0.6311
0.5000	0.9000	0.3667	0.4765	0.3257	0.1680	0.7286
0.5000	0.9000	0.3667	0.4765	0.1574	0.4418	0.4404
0.5000	0.9000	0.3667	0.4765	0.2715	0.3515	0.6618
0.5000	0.9000	0.3667	0.4765	0.3831	0.2791	0.7307
0.5000	0.9000	0.3667	0.4765	0.1574	0.5082	0.3469
0.5000	0.9000	0.3667	0.4765	0.2715	0.5479	0.5720
0.5000	0.9000	0.3667	0.4765	0.3857	0.4917	0.7003
0.5000	0.9000	0.3667	0.4765	0.5002	0.4447	0.7596
0.5000	0.9000	0.3667	0.4765	0.1000	0.2236	0.3878
0.5000	0.9000	0.3667	0.4765	0.2145	0.2253	0.5337
0.5000	0.9000	0.3667	0.4765	0.3286	0.2218	0.6165
0.5000	0.9000	0.3667	0.4765	0.4431	0.2217	0.6891
0.5000	0.9000	0.3667	0.4765	0.1000	0.3182	0.3845
0.5000	0.9000	0.3667	0.4765	0.2145	0.3176	0.5834
0.5000	0.9000	0.3667	0.4765	0.3286	0.3172	0.6577
0.5000	0.9000	0.3667	0.4765	0.4431	0.3189	0.7131
0.5000	0.9000	0.3667	0.4765	0.1000	0.1091	0.3087
0.5000	0.9000	0.3667	0.4765	0.1574	0.1521	0.4486
0.5000	0.9000	0.3667	0.4765	0.1574	0.2383	0.5035
0.5000	0.9000	0.3667	0.4765	0.1029	0.3309	0.4089
0.5000	0.9000	0.3667	0.4765	0.2715	0.2689	0.6263
0.5000	0.9000	0.3667	0.4765	0.1000	0.4296	0.3819
0.5000	0.9000	0.3667	0.4765	0.2174	0.3824	0.5572
0.5000	0.9000	0.3667	0.4765	0.3257	0.3732	0.6512
0.5000	0.9000	0.3667	0.4765	0.4431	0.3003	0.7126
0.5000	0.9000	0.3667	0.4765	0.1574	0.1167	0.4443
0.5000	0.9000	0.3667	0.4765	0.2686	0.1400	0.5905
0.5000	0.9000	0.3667	0.4765	0.3857	0.1635	0.6697
0.5000	0.9000	0.3667	0.4765	0.5002	0.1876	0.7434
0.5000	0.9000	0.3667	0.4765	0.6143	0.3226	0.7282

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Learning Set”*

Variáveis de Entrada						Saída
$r_p$	$r_w$	$D_l$	$Z_E$	F	$p_p$	$\delta U$
0.9000	0.5000	0.3667	0.1024	0.1574	0.2239	0.2290
0.9000	0.5000	0.3667	0.1024	0.2715	0.2241	0.3236
0.9000	0.5000	0.3667	0.1024	0.3857	0.2234	0.3721
0.9000	0.5000	0.3667	0.1024	0.5002	0.2233	0.3872
0.9000	0.5000	0.3667	0.1024	0.1574	0.3191	0.3871
0.9000	0.5000	0.3667	0.1024	0.3286	0.3187	0.4756
0.9000	0.5000	0.3667	0.1024	0.4431	0.3198	0.4755
0.9000	0.5000	0.3667	0.1024	0.1000	0.3229	0.3652
0.9000	0.5000	0.3667	0.1024	0.2145	0.2469	0.3553
0.9000	0.5000	0.3667	0.1024	0.1000	0.4673	0.4112
0.9000	0.5000	0.3667	0.1024	0.2145	0.4251	0.5272
0.9000	0.5000	0.3667	0.1024	0.3286	0.3778	0.5191
0.9000	0.5000	0.3667	0.1024	0.4431	0.2822	0.4497
0.9000	0.5000	0.3667	0.1024	0.2145	0.5587	0.5602
0.9000	0.5000	0.3667	0.1024	0.3286	0.5550	0.6315
0.9000	0.5000	0.3667	0.1024	0.4431	0.4997	0.6023
0.9000	0.5000	0.3667	0.1024	0.2145	0.1286	0.3263
0.9000	0.5000	0.3667	0.1024	0.3286	0.1484	0.4390
0.9000	0.5000	0.3667	0.1024	0.4431	0.1720	0.4385
0.1000	0.9000	0.3667	0.4765	0.1000	0.2231	0.4553
0.1000	0.9000	0.3667	0.4765	0.2145	0.2232	0.6228
0.1000	0.9000	0.3667	0.4765	0.3286	0.2221	0.7122
0.1000	0.9000	0.3667	0.4765	0.4431	0.2225	0.7481
0.1000	0.9000	0.3667	0.4765	0.1000	0.3195	0.4719
0.1000	0.9000	0.3667	0.4765	0.2145	0.3172	0.6417
0.1000	0.9000	0.3667	0.4765	0.3316	0.3174	0.7701
0.1000	0.9000	0.3667	0.4765	0.4431	0.3188	0.7740
0.1000	0.9000	0.3667	0.4765	0.5572	0.3177	0.7678
0.1000	0.9000	0.3667	0.4765	0.1000	0.2033	0.4083
0.1000	0.9000	0.3667	0.4765	0.1000	0.2866	0.4846
0.1000	0.9000	0.3667	0.4765	0.2145	0.2264	0.6359
0.1000	0.9000	0.3667	0.4765	0.1000	0.3661	0.4401
0.1000	0.9000	0.3667	0.4765	0.2145	0.3297	0.6204
0.1000	0.9000	0.3667	0.4765	0.3286	0.2887	0.7363
0.1000	0.9000	0.3667	0.4765	0.1000	0.4445	0.4116
0.1000	0.9000	0.3667	0.4765	0.2145	0.4420	0.5922
0.1000	0.9000	0.3667	0.4765	0.3286	0.4125	0.7241
0.1000	0.9000	0.3667	0.4765	0.4431	0.3810	0.7628
0.1000	0.9000	0.3667	0.4765	0.5572	0.2800	0.7818
0.1000	0.9000	0.3667	0.4765	0.1574	0.5456	0.4394
0.1000	0.9000	0.3667	0.4765	0.2715	0.5734	0.6069
0.1000	0.9000	0.3667	0.4765	0.3857	0.5593	0.7003
0.1000	0.9000	0.3667	0.4765	0.5002	0.5233	0.7483

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Learning Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.9000	0.3667	0.4765	0.6143	0.5136	0.7643
0.1000	0.9000	0.3667	0.4765	0.1574	0.1196	0.4843
0.1000	0.9000	0.3667	0.4765	0.2715	0.1271	0.6723
0.1000	0.9000	0.3667	0.4765	0.3857	0.1636	0.7487
0.1000	0.9000	0.3667	0.4765	0.5002	0.1753	0.7765
0.1000	0.9000	0.3667	0.4765	0.6143	0.2130	0.7846
0.1000	0.9000	0.3667	0.5047	0.2167	0.2228	0.6836
0.1000	0.9000	0.3667	0.5047	0.3329	0.2222	0.7919
0.1000	0.9000	0.3667	0.5047	0.4470	0.2216	0.8088
0.1000	0.9000	0.3667	0.5047	0.1613	0.3180	0.5915
0.1000	0.9000	0.3667	0.5047	0.2755	0.3180	0.7357
0.1000	0.9000	0.3667	0.5047	0.3898	0.3180	0.8267
0.1000	0.9000	0.3667	0.5047	0.5024	0.3202	0.8668
0.1000	0.9000	0.3667	0.5047	0.2190	0.1330	0.6774
0.1000	0.9000	0.3667	0.5047	0.3312	0.1584	0.7944
0.1000	0.9000	0.3667	0.5047	0.4445	0.1856	0.8176
0.1000	0.9000	0.3667	0.5047	0.2186	0.4068	0.6368
0.1000	0.9000	0.3667	0.5047	0.3355	0.4061	0.7634
0.1000	0.9000	0.3667	0.5047	0.4479	0.4073	0.7942
0.1000	0.9000	0.3667	0.6553	0.2186	0.2238	0.6573
0.1000	0.9000	0.3667	0.6553	0.3340	0.2238	0.7760
0.1000	0.9000	0.3667	0.6553	0.4498	0.2217	0.7966
0.1000	0.9000	0.3667	0.6553	0.2186	0.3172	0.6600
0.1000	0.9000	0.3667	0.6553	0.3359	0.3178	0.7346
0.1000	0.9000	0.3667	0.6553	0.4471	0.3176	0.8094
0.1000	0.9000	0.3667	0.6553	0.1702	0.2228	0.6373
0.1000	0.9000	0.3667	0.6553	0.2727	0.2204	0.6903
0.1000	0.9000	0.3667	0.6553	0.3736	0.2173	0.7805
0.1000	0.9000	0.3667	0.6553	0.5024	0.2204	0.8074
0.1000	0.9000	0.3667	0.6553	0.2190	0.3111	0.6614
0.1000	0.9000	0.3667	0.6553	0.3363	0.3154	0.7265
0.1000	0.9000	0.3667	0.6553	0.4426	0.3123	0.8082
0.1000	0.9000	0.3667	0.6553	0.1672	0.3994	0.5408
0.1000	0.9000	0.3667	0.6553	0.2773	0.4000	0.6604
0.1000	0.9000	0.3667	0.6553	0.3969	0.4012	0.7664
0.5000	0.1000	0.3667	0.9000	0.1679	0.2185	0.4354
0.5000	0.1000	0.3667	0.9000	0.2780	0.2210	0.5160
0.5000	0.1000	0.3667	0.9000	0.3877	0.2173	0.4985
0.5000	0.1000	0.3667	0.9000	0.1771	0.3160	0.4498
0.5000	0.1000	0.3667	0.9000	0.3315	0.3180	0.5043
0.5000	0.1000	0.3667	0.9000	0.4331	0.3105	0.4268
0.5000	0.1000	0.3667	0.9000	0.2232	0.4012	0.5798
0.5000	0.1000	0.3667	0.9000	0.3435	0.4000	0.5347

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Learning Set”*

Variáveis de Entrada						Saída
$r_p$	$r_w$	$D_i$	$Z_E$	F	$p_p$	$\delta U$
0.5000	0.1000	0.3667	0.9000	0.4433	0.3994	0.4682
0.5000	0.1000	0.3667	0.9000	0.2167	0.2216	0.4304
0.5000	0.1000	0.3667	0.9000	0.3336	0.2210	0.4754
0.5000	0.1000	0.3667	0.9000	0.4430	0.2216	0.5011
0.5000	0.1000	0.3667	0.9000	0.2182	0.3182	0.5204
0.5000	0.1000	0.3667	0.9000	0.3306	0.3154	0.5428
0.5000	0.1000	0.3667	0.9000	0.4372	0.3148	0.5194
0.5000	0.1000	0.3667	0.9000	0.2159	0.4043	0.5654
0.5000	0.1000	0.3667	0.9000	0.3313	0.4012	0.6314
0.5000	0.1000	0.3667	0.9000	0.4424	0.4064	0.5492
0.5000	0.1000	0.3667	0.9000	0.2205	0.5293	0.5361
0.5000	0.1000	0.3667	0.9000	0.3374	0.5281	0.6239
0.5000	0.1000	0.3667	0.9000	0.4426	0.5140	0.6145
0.5000	0.1000	0.3667	0.9000	0.2182	0.6341	0.5362
0.5000	0.1000	0.3667	0.9000	0.3287	0.6261	0.5867
0.5000	0.1000	0.3667	0.9000	0.4498	0.6243	0.6038
0.9000	0.5000	0.3667	0.2788	0.2144	0.2204	0.2908
0.9000	0.5000	0.3667	0.2788	0.3287	0.2234	0.3820
0.9000	0.5000	0.3667	0.2788	0.4430	0.2210	0.4126
0.9000	0.5000	0.3667	0.2788	0.2144	0.3183	0.3787
0.9000	0.5000	0.3667	0.2788	0.3287	0.3172	0.4246
0.9000	0.5000	0.3667	0.2788	0.4430	0.3184	0.4619
0.9000	0.5000	0.3667	0.2788	0.2144	0.4036	0.5336
0.9000	0.5000	0.3667	0.2788	0.3287	0.4040	0.5189
0.9000	0.5000	0.3667	0.2788	0.4430	0.4073	0.5281
0.9000	0.5000	0.3667	0.2788	0.2213	0.2204	0.4199
0.9000	0.5000	0.3667	0.2788	0.3401	0.2167	0.4794
0.9000	0.5000	0.3667	0.2788	0.4451	0.2155	0.5018
0.9000	0.5000	0.3667	0.2788	0.2243	0.3099	0.5910
0.9000	0.5000	0.3667	0.2788	0.3325	0.3099	0.6084
0.9000	0.5000	0.3667	0.2788	0.4452	0.3062	0.5632
0.9000	0.5000	0.3667	0.2788	0.2761	0.4079	0.6648
0.9000	0.5000	0.3667	0.2788	0.3931	0.4067	0.6391
0.1000	0.1000	0.1000	0.1024	0.1000	0.2249	0.4334
0.1000	0.1000	0.1000	0.1024	0.2145	0.2238	0.6189
0.1000	0.1000	0.1000	0.1024	0.3231	0.2230	0.6965
0.1000	0.1000	0.1000	0.1024	0.4402	0.2226	0.6704
0.1000	0.1000	0.1000	0.1024	0.1000	0.3183	0.4641
0.1000	0.1000	0.1000	0.1024	0.2145	0.3184	0.6400
0.1000	0.1000	0.1000	0.1024	0.3231	0.3197	0.7300
0.1000	0.1000	0.1000	0.1024	0.4431	0.3193	0.7054
0.1000	0.1000	0.1000	0.1024	0.1000	0.2080	0.4559
0.1000	0.1000	0.1000	0.1024	0.1000	0.3169	0.4442

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Learning Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.1000	0.1000	0.1024	0.2115	0.2553	0.5979
0.1000	0.1000	0.1000	0.1024	0.1000	0.4138	0.3769
0.1000	0.1000	0.1000	0.1024	0.2145	0.3654	0.5342
0.1000	0.1000	0.1000	0.1024	0.3286	0.3170	0.7362
0.1000	0.1000	0.1000	0.1024	0.4402	0.2406	0.7263
0.1000	0.1000	0.1000	0.1024	0.1574	0.5217	0.4212
0.1000	0.1000	0.1000	0.1024	0.2715	0.5259	0.5540
0.1000	0.1000	0.1000	0.1024	0.3857	0.5067	0.6755
0.1000	0.1000	0.1000	0.1024	0.5031	0.4505	0.7186
0.1000	0.1000	0.1000	0.1024	0.1574	0.6335	0.3097
0.1000	0.1000	0.1000	0.1024	0.1000	0.1000	0.3285
0.1000	0.1000	0.1000	0.1024	0.1574	0.1586	0.5686
0.1000	0.1000	0.1000	0.1024	0.2715	0.1412	0.6577
0.1000	0.1000	0.1000	0.1024	0.3857	0.1623	0.7272
0.1000	0.5000	0.1000	0.2788	0.1601	0.2249	0.6542
0.1000	0.5000	0.1000	0.2788	0.2715	0.2234	0.8050
0.1000	0.5000	0.1000	0.2788	0.3858	0.2216	0.8820
0.1000	0.5000	0.1000	0.2788	0.1573	0.3191	0.5487
0.1000	0.5000	0.1000	0.2788	0.2715	0.3194	0.6716
0.1000	0.5000	0.1000	0.2788	0.3858	0.3172	0.8117
0.1000	0.5000	0.1000	0.2788	0.1573	0.4073	0.4360
0.1000	0.5000	0.1000	0.2788	0.2715	0.4058	0.6496
0.1000	0.5000	0.1000	0.2788	0.3858	0.4077	0.8078
0.1000	0.5000	0.1000	0.2788	0.1607	0.2216	0.6092
0.1000	0.5000	0.1000	0.2788	0.2734	0.2216	0.7081
0.1000	0.5000	0.1000	0.2788	0.3912	0.2234	0.7331
0.1000	0.5000	0.1000	0.2788	0.1615	0.3178	0.5660
0.1000	0.5000	0.1000	0.2788	0.3329	0.3172	0.7022
0.1000	0.5000	0.1000	0.2788	0.4498	0.3172	0.7646
0.1000	0.5000	0.1000	0.2788	0.2194	0.4061	0.5962
0.1000	0.5000	0.1000	0.2788	0.3336	0.4071	0.6979
0.1000	0.5000	0.1000	0.2788	0.4464	0.4055	0.7794
0.1000	0.5000	0.1000	0.2788	0.2773	0.5170	0.5645
0.1000	0.5000	0.1000	0.2788	0.3877	0.5164	0.6805
0.1000	0.1000	0.1000	0.2788	0.1618	0.2227	0.6772
0.1000	0.1000	0.1000	0.2788	0.2693	0.2237	0.7198
0.1000	0.1000	0.1000	0.2788	0.3892	0.2236	0.7899
0.1000	0.1000	0.1000	0.2788	0.1603	0.3173	0.7267
0.1000	0.1000	0.1000	0.2788	0.2734	0.3192	0.8295
0.1000	0.1000	0.1000	0.2788	0.3885	0.3175	0.8363
0.1000	0.1000	0.1000	0.2788	0.1590	0.4068	0.7053
0.1000	0.1000	0.1000	0.2788	0.2712	0.4065	0.8376
0.1000	0.1000	0.1000	0.2788	0.3892	0.4067	0.9000

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Learning Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_i$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.1000	0.1000	0.2788	0.1573	0.5202	0.5825
0.1000	0.1000	0.1000	0.2788	0.2799	0.5186	0.8142
0.1000	0.1000	0.1000	0.2788	0.3934	0.5241	0.8635
0.1000	0.1000	0.1000	0.2788	0.1573	0.2283	0.6703
0.1000	0.1000	0.1000	0.2788	0.2715	0.2204	0.7308
0.1000	0.1000	0.1000	0.2788	0.3858	0.2210	0.7498
0.1000	0.1000	0.1000	0.2788	0.1573	0.3148	0.6528
0.1000	0.1000	0.1000	0.2788	0.2715	0.3160	0.6780
0.1000	0.1000	0.1000	0.2788	0.3858	0.3209	0.7856
0.1000	0.1000	0.1000	0.2788	0.1573	0.3987	0.6858
0.1000	0.1000	0.1000	0.2788	0.2715	0.4055	0.8080
0.1000	0.1000	0.1000	0.2788	0.3858	0.4055	0.8562
0.1000	0.1000	0.1000	0.2788	0.1596	0.4030	0.5896
0.1000	0.1000	0.1000	0.2788	0.2769	0.4049	0.7432
0.1000	0.1000	0.1000	0.2788	0.3883	0.4058	0.7788
0.1000	0.1000	0.1000	0.2788	0.2171	0.2241	0.7050
0.1000	0.1000	0.1000	0.2788	0.3313	0.2234	0.7598
0.1000	0.1000	0.1000	0.2788	0.4426	0.2241	0.7584
0.1000	0.1000	0.1000	0.2788	0.2220	0.3148	0.7278
0.1000	0.1000	0.1000	0.2788	0.3287	0.3191	0.8071
0.1000	0.1000	0.1000	0.2788	0.4491	0.3172	0.8061
0.1000	0.1000	0.1000	0.2788	0.2159	0.4049	0.6999
0.1000	0.1000	0.1000	0.2788	0.3327	0.4064	0.8160
0.1000	0.1000	0.1000	0.2788	0.4426	0.4055	0.7736
0.1000	0.1000	0.1000	0.2788	0.2205	0.5146	0.6489
0.1000	0.1000	0.1000	0.2788	0.3348	0.5127	0.7805
0.1000	0.1000	0.1000	0.2788	0.4464	0.5146	0.8027
0.1000	0.1000	0.1000	0.2788	0.2277	0.2155	0.6677
0.1000	0.1000	0.1000	0.2788	0.3435	0.2130	0.7489
0.1000	0.1000	0.1000	0.2788	0.4435	0.2216	0.7433
0.1000	0.1000	0.1000	0.2788	0.2335	0.3123	0.7776
0.1000	0.1000	0.1000	0.2788	0.3416	0.3086	0.7851
0.1000	0.1000	0.1000	0.2788	0.4411	0.3074	0.6754
0.1000	0.1000	0.1000	0.2788	0.2274	0.4043	0.7041
0.1000	0.1000	0.1000	0.2788	0.3348	0.4030	0.7844
0.1000	0.1000	0.1000	0.2788	0.4346	0.4030	0.7163
0.1000	0.1000	0.1000	0.2788	0.2258	0.5195	0.6806
0.1000	0.1000	0.1000	0.2788	0.3378	0.5121	0.7669
0.1000	0.1000	0.1000	0.2788	0.4407	0.5121	0.8531
0.1000	0.1000	0.1000	0.2788	0.2776	0.3074	0.7180
0.1000	0.1000	0.1000	0.2788	0.3972	0.3111	0.8229
0.1000	0.1000	0.1000	0.2788	0.1813	0.4006	0.6769
0.1000	0.1000	0.1000	0.2788	0.2826	0.4006	0.7629

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Learning Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.1000	0.1000	0.2788	0.3944	0.4018	0.7972
0.1000	0.1000	0.1000	0.2788	0.1725	0.5146	0.5561
0.1000	0.1000	0.1000	0.2788	0.2826	0.5158	0.6809
0.1000	0.1000	0.1000	0.2788	0.3976	0.5195	0.7652
0.1000	0.1000	0.1000	0.2788	0.1653	0.2314	0.6759
0.1000	0.1000	0.1000	0.2788	0.2784	0.2247	0.6981
0.1000	0.1000	0.1000	0.2788	0.3900	0.2216	0.7178
0.1000	0.1000	0.1000	0.2788	0.1623	0.3246	0.6814
0.1000	0.1000	0.1000	0.2788	0.2755	0.3203	0.7586
0.1000	0.1000	0.1000	0.2788	0.3904	0.3148	0.6855
0.1000	0.1000	0.1000	0.2788	0.1645	0.4024	0.6895
0.1000	0.1000	0.1000	0.2788	0.2744	0.4055	0.7430
0.1000	0.1000	0.1000	0.2788	0.3891	0.4066	0.7632
0.1000	0.1000	0.1000	0.2788	0.1592	0.5121	0.5966
0.1000	0.1000	0.1000	0.2788	0.2767	0.5250	0.7417
0.1000	0.1000	0.1000	0.2788	0.3892	0.5299	0.7596
0.1000	0.1000	0.1000	0.2788	0.1656	0.3172	0.6457
0.1000	0.1000	0.1000	0.2788	0.2731	0.3172	0.7796
0.1000	0.1000	0.1000	0.2788	0.3894	0.3172	0.6813
0.1000	0.1000	0.1000	0.2788	0.1616	0.4055	0.5689
0.1000	0.1000	0.1000	0.2788	0.2776	0.4055	0.7162
0.1000	0.1000	0.1000	0.2788	0.3948	0.4116	0.8061
0.1000	0.1000	0.1000	0.2788	0.1607	0.5293	0.4551
0.1000	0.1000	0.1000	0.2788	0.2784	0.5342	0.6684
0.1000	0.1000	0.1000	0.2788	0.3895	0.5187	0.7732
0.1000	0.1000	0.1000	0.2788	0.1636	0.2204	0.6368
0.1000	0.1000	0.1000	0.2788	0.2776	0.2228	0.7769
0.1000	0.1000	0.1000	0.2788	0.3934	0.2198	0.8370
0.1000	0.1000	0.1000	0.2788	0.1613	0.3166	0.5532
0.1000	0.1000	0.1000	0.2788	0.2784	0.3166	0.7666
0.1000	0.1000	0.1000	0.2788	0.3972	0.3160	0.8279
0.1000	0.1000	0.1000	0.2788	0.1576	0.4061	0.5839
0.1000	0.1000	0.1000	0.2788	0.2759	0.4061	0.7333
0.1000	0.1000	0.1000	0.2788	0.3892	0.4067	0.8452
0.1000	0.1000	0.1000	0.2788	0.1590	0.5164	0.4729
0.1000	0.1000	0.1000	0.2788	0.2740	0.5158	0.6689
0.1000	0.1000	0.1000	0.2788	0.3908	0.5172	0.7990
0.1000	0.1000	0.1000	0.2788	0.3900	0.2228	0.5890
0.1000	0.1000	0.1000	0.2788	0.1634	0.4074	0.5606
0.1000	0.1000	0.1000	0.2788	0.2788	0.4070	0.7094
0.1000	0.1000	0.1000	0.2788	0.3912	0.4063	0.7351
0.1000	0.1000	0.1000	0.2788	0.1630	0.5167	0.4420
0.1000	0.1000	0.1000	0.2788	0.2761	0.5174	0.6736

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Learning Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.1000	0.1000	0.2788	0.1554	0.2223	0.6371
0.1000	0.1000	0.1000	0.2788	0.2734	0.2238	0.7582
0.1000	0.1000	0.1000	0.2788	0.3858	0.2216	0.7854
0.1000	0.1000	0.1000	0.2788	0.1601	0.3180	0.6571
0.1000	0.1000	0.1000	0.2788	0.2715	0.3180	0.7326
0.1000	0.1000	0.1000	0.2788	0.3849	0.3177	0.7801
0.1000	0.1000	0.1000	0.2788	0.1634	0.4074	0.6402
0.1000	0.1000	0.1000	0.2788	0.2784	0.4061	0.7753
0.1000	0.1000	0.1000	0.2788	0.3929	0.4063	0.8029
0.1000	0.1000	0.1000	0.2788	0.1582	0.5174	0.4910
0.1000	0.1000	0.1000	0.2788	0.2780	0.5172	0.7265
0.1000	0.1000	0.1000	0.2788	0.3953	0.5176	0.8145
0.1000	0.1000	0.1000	0.2788	0.1582	0.4085	0.5594
0.1000	0.1000	0.1000	0.2788	0.2715	0.4067	0.6732
0.1000	0.1000	0.1000	0.2788	0.3858	0.4073	0.6857

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_p$	$r_w$	$D_i$	$Z_E$	F	$p_p$	$\delta U$
0.1000	0.5000	0.9000	0.4765	0.1574	0.2233	0.3825
0.1000	0.5000	0.9000	0.4765	0.2715	0.2237	0.5116
0.1000	0.5000	0.9000	0.4765	0.3857	0.2244	0.6033
0.1000	0.5000	0.9000	0.4765	0.5002	0.2228	0.6800
0.1000	0.5000	0.9000	0.4765	0.6143	0.2247	0.7045
0.1000	0.5000	0.9000	0.4765	0.1574	0.3172	0.4673
0.1000	0.5000	0.9000	0.4765	0.2715	0.3172	0.5928
0.1000	0.5000	0.9000	0.4765	0.3801	0.3197	0.6630
0.1000	0.5000	0.9000	0.4765	0.5002	0.3186	0.6831
0.1000	0.5000	0.9000	0.4765	0.6143	0.3189	0.7250
0.1000	0.5000	0.9000	0.4765	0.1574	0.1577	0.3077
0.1000	0.5000	0.9000	0.4765	0.1574	0.2597	0.4618
0.1000	0.5000	0.9000	0.4765	0.2715	0.1572	0.4973
0.1000	0.5000	0.9000	0.4765	0.1574	0.3574	0.4995
0.1000	0.5000	0.9000	0.4765	0.2715	0.3014	0.5927
0.1000	0.5000	0.9000	0.4765	0.3857	0.2318	0.6072
0.1000	0.5000	0.9000	0.4765	0.1600	0.4431	0.4554
0.1000	0.5000	0.9000	0.4765	0.2686	0.4302	0.6051
0.1000	0.5000	0.9000	0.4765	0.3857	0.3770	0.6857
0.1000	0.5000	0.9000	0.4765	0.5002	0.3290	0.6746
0.1000	0.5000	0.9000	0.4765	0.1545	0.5123	0.3076
0.1000	0.5000	0.9000	0.4765	0.2745	0.5430	0.5788
0.1000	0.5000	0.9000	0.4765	0.3857	0.5306	0.6681
0.1000	0.5000	0.9000	0.4765	0.5002	0.4928	0.7201
0.1000	0.5000	0.9000	0.4765	0.6088	0.4523	0.7100
0.1000	0.5000	0.9000	0.4765	0.1574	0.6000	0.2439
0.1000	0.5000	0.9000	0.4765	0.2715	0.6212	0.4377
0.1000	0.5000	0.9000	0.4765	0.6143	0.6305	0.7360
0.1000	0.5000	0.9000	0.4765	0.1600	0.1119	0.2563
0.1000	0.5000	0.9000	0.4765	0.2745	0.1380	0.4822
0.1000	0.5000	0.9000	0.4765	0.3801	0.1564	0.6249
0.1000	0.5000	0.9000	0.4765	0.5002	0.1815	0.6573
0.1000	0.5000	0.9000	0.1000	0.2277	0.2192	0.6673
0.1000	0.5000	0.9000	0.1000	0.3390	0.2192	0.7383
0.1000	0.5000	0.9000	0.1000	0.4470	0.2216	0.7654
0.1000	0.5000	0.9000	0.1000	0.2194	0.3227	0.5576
0.1000	0.5000	0.9000	0.1000	0.3327	0.3180	0.6884
0.5000	0.9000	0.3667	0.4765	0.1000	0.2232	0.4338
0.5000	0.9000	0.3667	0.4765	0.2145	0.2223	0.6132
0.5000	0.9000	0.3667	0.4765	0.3257	0.2220	0.7101
0.5000	0.9000	0.3667	0.4765	0.4431	0.2226	0.7575
0.5000	0.9000	0.3667	0.4765	0.5602	0.2220	0.7686

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_p$	$r_w$	$D_i$	$Z_E$	F	$p_p$	$\delta U$
0.5000	0.9000	0.3667	0.4765	0.2145	0.3178	0.6045
0.5000	0.9000	0.3667	0.4765	0.3286	0.3186	0.6916
0.5000	0.9000	0.3667	0.4765	0.4431	0.3172	0.7734
0.5000	0.9000	0.3667	0.4765	0.5572	0.3185	0.7725
0.5000	0.9000	0.3667	0.4765	0.1000	0.3178	0.4396
0.5000	0.9000	0.3667	0.4765	0.2115	0.1921	0.6065
0.5000	0.9000	0.3667	0.4765	0.1574	0.3143	0.5387
0.5000	0.9000	0.3667	0.4765	0.2715	0.2515	0.6813
0.5000	0.9000	0.3667	0.4765	0.1000	0.4274	0.3009
0.5000	0.9000	0.3667	0.4765	0.2115	0.3751	0.5821
0.5000	0.9000	0.3667	0.4765	0.3257	0.3269	0.6850
0.5000	0.9000	0.3667	0.4765	0.1000	0.5272	0.2186
0.5000	0.9000	0.3667	0.4765	0.2145	0.5138	0.4580
0.5000	0.9000	0.3667	0.4765	0.3306	0.5301	0.6365
0.5000	0.9000	0.3667	0.4765	0.4431	0.4631	0.7217
0.5000	0.9000	0.3667	0.4765	0.5572	0.4275	0.7715
0.5000	0.9000	0.3667	0.4765	0.1574	0.2238	0.4537
0.5000	0.9000	0.3667	0.4765	0.2715	0.2220	0.5617
0.5000	0.9000	0.3667	0.4765	0.3857	0.2221	0.6578
0.5000	0.9000	0.3667	0.4765	0.4943	0.2228	0.6895
0.5000	0.9000	0.3667	0.4765	0.1574	0.3180	0.5041
0.5000	0.9000	0.3667	0.4765	0.2715	0.3172	0.6228
0.5000	0.9000	0.3667	0.4765	0.3857	0.3172	0.6835
0.5000	0.9000	0.3667	0.4765	0.5002	0.3182	0.7155
0.5000	0.9000	0.3667	0.4765	0.1000	0.1979	0.3697
0.5000	0.9000	0.3667	0.4765	0.1000	0.2655	0.4203
0.5000	0.9000	0.3667	0.4765	0.2145	0.1971	0.5646
0.5000	0.9000	0.3667	0.4765	0.1574	0.3182	0.5111
0.5000	0.9000	0.3667	0.4765	0.3286	0.1613	0.6583
0.5000	0.9000	0.3667	0.4765	0.1574	0.3882	0.4894
0.5000	0.9000	0.3667	0.4765	0.2686	0.3882	0.6127
0.5000	0.9000	0.3667	0.4765	0.3857	0.3611	0.6933
0.5000	0.9000	0.3667	0.4765	0.1000	0.1034	0.3019
0.5000	0.9000	0.3667	0.4765	0.2145	0.1289	0.5274
0.5000	0.9000	0.3667	0.4765	0.3231	0.1514	0.6563
0.5000	0.9000	0.3667	0.4765	0.4431	0.1755	0.7146
0.5000	0.9000	0.3667	0.4765	0.5572	0.2013	0.7321
0.9000	0.5000	0.3667	0.1024	0.1000	0.2230	0.1734
0.9000	0.5000	0.3667	0.1024	0.2145	0.2227	0.2378
0.9000	0.5000	0.3667	0.1024	0.3286	0.2237	0.3592
0.9000	0.5000	0.3667	0.1024	0.4431	0.2234	0.4088
0.9000	0.5000	0.3667	0.1024	0.1000	0.3176	0.3078

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.9000	0.5000	0.3667	0.1024	0.2145	0.3172	0.4175
0.9000	0.5000	0.3667	0.1024	0.3857	0.3199	0.4953
0.9000	0.5000	0.3667	0.1024	0.5002	0.3219	0.4139
0.9000	0.5000	0.3667	0.1024	0.1574	0.2858	0.3841
0.9000	0.5000	0.3667	0.1024	0.2715	0.1385	0.3146
0.9000	0.5000	0.3667	0.1024	0.1574	0.4568	0.4992
0.9000	0.5000	0.3667	0.1024	0.2715	0.3926	0.5054
0.9000	0.5000	0.3667	0.1024	0.3857	0.3332	0.4814
0.9000	0.5000	0.3667	0.1024	0.1574	0.5885	0.4905
0.9000	0.5000	0.3667	0.1024	0.2715	0.5669	0.5850
0.9000	0.5000	0.3667	0.1024	0.3857	0.5484	0.6171
0.9000	0.5000	0.3667	0.1024	0.5002	0.4869	0.5599
0.9000	0.5000	0.3667	0.1024	0.1574	0.1141	0.1783
0.9000	0.5000	0.3667	0.1024	0.2715	0.1382	0.3321
0.9000	0.5000	0.3667	0.1024	0.3857	0.1618	0.4767
0.9000	0.5000	0.3667	0.1024	0.5002	0.1854	0.4642
0.1000	0.9000	0.3667	0.4765	0.1574	0.2221	0.5529
0.1000	0.9000	0.3667	0.4765	0.2715	0.2221	0.6685
0.1000	0.9000	0.3667	0.4765	0.3857	0.2238	0.6698
0.1000	0.9000	0.3667	0.4765	0.5002	0.2238	0.7768
0.1000	0.9000	0.3667	0.4765	0.1545	0.3176	0.5450
0.1000	0.9000	0.3667	0.4765	0.2715	0.3197	0.6887
0.1000	0.9000	0.3667	0.4765	0.3857	0.3180	0.7572
0.1000	0.9000	0.3667	0.4765	0.5002	0.3175	0.8465
0.1000	0.9000	0.3667	0.4765	0.6143	0.3175	0.7658
0.1000	0.9000	0.3667	0.4765	0.1574	0.1598	0.5077
0.1000	0.9000	0.3667	0.4765	0.1574	0.2556	0.5626
0.1000	0.9000	0.3667	0.4765	0.2686	0.1560	0.6776
0.1000	0.9000	0.3667	0.4765	0.1574	0.3498	0.5553
0.1000	0.9000	0.3667	0.4765	0.2715	0.3100	0.7028
0.1000	0.9000	0.3667	0.4765	0.3857	0.1586	0.7503
0.1000	0.9000	0.3667	0.4765	0.1600	0.4519	0.5166
0.1000	0.9000	0.3667	0.4765	0.2715	0.4302	0.6767
0.1000	0.9000	0.3667	0.4765	0.3857	0.3959	0.7461
0.1000	0.9000	0.3667	0.4765	0.5002	0.3560	0.7771
0.1000	0.9000	0.3667	0.4765	0.1000	0.5507	0.3033
0.1000	0.9000	0.3667	0.4765	0.2145	0.5693	0.5320
0.1000	0.9000	0.3667	0.4765	0.3286	0.5726	0.6637
0.1000	0.9000	0.3667	0.4765	0.4431	0.5375	0.7274
0.1000	0.9000	0.3667	0.4765	0.5572	0.5176	0.7875
0.1000	0.9000	0.3667	0.4765	0.1000	0.1060	0.3126
0.1000	0.9000	0.3667	0.4765	0.2145	0.1297	0.5995

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.9000	0.3667	0.4765	0.3286	0.1544	0.7333
0.1000	0.9000	0.3667	0.4765	0.4372	0.1749	0.7673
0.1000	0.9000	0.3667	0.4765	0.5572	0.1965	0.7807
0.1000	0.9000	0.3667	0.5047	0.1618	0.2222	0.5906
0.1000	0.9000	0.3667	0.5047	0.2761	0.2222	0.7269
0.1000	0.9000	0.3667	0.5047	0.3898	0.2216	0.7945
0.1000	0.9000	0.3667	0.5047	0.5030	0.2223	0.8640
0.1000	0.9000	0.3667	0.5047	0.2184	0.3180	0.6411
0.1000	0.9000	0.3667	0.5047	0.3327	0.3180	0.7832
0.1000	0.9000	0.3667	0.5047	0.4470	0.3180	0.8378
0.1000	0.9000	0.3667	0.5047	0.1641	0.1261	0.5634
0.1000	0.9000	0.3667	0.5047	0.2784	0.1471	0.7156
0.1000	0.9000	0.3667	0.5047	0.3881	0.1711	0.8231
0.1000	0.9000	0.3667	0.5047	0.1599	0.4065	0.5218
0.1000	0.9000	0.3667	0.5047	0.2754	0.4073	0.7020
0.1000	0.9000	0.3667	0.5047	0.3931	0.4070	0.8010
0.1000	0.9000	0.3667	0.6553	0.1634	0.2236	0.6324
0.1000	0.9000	0.3667	0.6553	0.2746	0.2238	0.7469
0.1000	0.9000	0.3667	0.6553	0.3854	0.2238	0.8009
0.1000	0.9000	0.3667	0.6553	0.1615	0.3178	0.5470
0.1000	0.9000	0.3667	0.6553	0.2754	0.3178	0.7308
0.1000	0.9000	0.3667	0.6553	0.3904	0.3178	0.7610
0.1000	0.9000	0.3667	0.6553	0.5071	0.3184	0.7902
0.1000	0.9000	0.3667	0.6553	0.2190	0.2179	0.6906
0.1000	0.9000	0.3667	0.6553	0.3321	0.2228	0.7489
0.1000	0.9000	0.3667	0.6553	0.4451	0.2204	0.7630
0.1000	0.9000	0.3667	0.6553	0.1896	0.3160	0.6777
0.1000	0.9000	0.3667	0.6553	0.2803	0.3172	0.7192
0.1000	0.9000	0.3667	0.6553	0.3961	0.3166	0.7830
0.1000	0.9000	0.3667	0.6553	0.4995	0.3144	0.8067
0.1000	0.9000	0.3667	0.6553	0.2251	0.4012	0.6111
0.1000	0.9000	0.3667	0.6553	0.3405	0.3987	0.7285
0.1000	0.9000	0.3667	0.6553	0.4399	0.3994	0.7545
0.5000	0.1000	0.3667	0.9000	0.2255	0.2216	0.5089
0.5000	0.1000	0.3667	0.9000	0.3340	0.2192	0.5201
0.5000	0.1000	0.3667	0.9000	0.4407	0.2198	0.5055
0.5000	0.1000	0.3667	0.9000	0.2744	0.3180	0.5331
0.5000	0.1000	0.3667	0.9000	0.3927	0.3154	0.4596
0.5000	0.1000	0.3667	0.9000	0.1885	0.4024	0.6257
0.5000	0.1000	0.3667	0.9000	0.2807	0.3994	0.5730
0.5000	0.1000	0.3667	0.9000	0.3885	0.3920	0.5418
0.5000	0.1000	0.3667	0.9000	0.1607	0.2198	0.3765

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_p$	$r_w$	$D_i$	$Z_E$	F	$p_p$	$\delta U$
0.5000	0.1000	0.3667	0.9000	0.2700	0.2192	0.4496
0.5000	0.1000	0.3667	0.9000	0.3820	0.2216	0.5106
0.5000	0.1000	0.3667	0.9000	0.1615	0.3123	0.4921
0.5000	0.1000	0.3667	0.9000	0.2891	0.3295	0.5382
0.5000	0.1000	0.3667	0.9000	0.3896	0.3135	0.5330
0.5000	0.1000	0.3667	0.9000	0.1683	0.4079	0.4387
0.5000	0.1000	0.3667	0.9000	0.2715	0.3987	0.5958
0.5000	0.1000	0.3667	0.9000	0.3870	0.4085	0.5925
0.5000	0.1000	0.3667	0.9000	0.1573	0.5158	0.4834
0.5000	0.1000	0.3667	0.9000	0.2765	0.5379	0.6245
0.5000	0.1000	0.3667	0.9000	0.3862	0.5189	0.6444
0.5000	0.1000	0.3667	0.9000	0.1613	0.6256	0.4237
0.5000	0.1000	0.3667	0.9000	0.2776	0.6298	0.5625
0.5000	0.1000	0.3667	0.9000	0.3896	0.6267	0.6163
0.9000	0.5000	0.3667	0.2788	0.1573	0.2130	0.2759
0.9000	0.5000	0.3667	0.2788	0.2715	0.2216	0.3581
0.9000	0.5000	0.3667	0.2788	0.3858	0.2216	0.4059
0.9000	0.5000	0.3667	0.2788	0.1573	0.3160	0.3546
0.9000	0.5000	0.3667	0.2788	0.2715	0.3160	0.3997
0.9000	0.5000	0.3667	0.2788	0.3858	0.3095	0.4782
0.9000	0.5000	0.3667	0.2788	0.1573	0.3987	0.5008
0.9000	0.5000	0.3667	0.2788	0.2715	0.4036	0.5393
0.9000	0.5000	0.3667	0.2788	0.3858	0.4043	0.5431
0.9000	0.5000	0.3667	0.2788	0.1630	0.2155	0.3668
0.9000	0.5000	0.3667	0.2788	0.2761	0.2135	0.4515
0.9000	0.5000	0.3667	0.2788	0.3931	0.2167	0.5206
0.9000	0.5000	0.3667	0.2788	0.1725	0.3135	0.5430
0.9000	0.5000	0.3667	0.2788	0.2769	0.3099	0.5864
0.9000	0.5000	0.3667	0.2788	0.3934	0.3086	0.6165
0.9000	0.5000	0.3667	0.2788	0.2213	0.4043	0.6661
0.9000	0.5000	0.3667	0.2788	0.3367	0.4055	0.6600
0.9000	0.5000	0.3667	0.2788	0.4452	0.4043	0.6034
0.1000	0.1000	0.1000	0.1024	0.1574	0.2230	0.5348
0.1000	0.1000	0.1000	0.1024	0.2696	0.2226	0.7067
0.1000	0.1000	0.1000	0.1024	0.3857	0.2242	0.7478
0.1000	0.1000	0.1000	0.1024	0.5002	0.2233	0.6392
0.1000	0.1000	0.1000	0.1024	0.1574	0.3177	0.5745
0.1000	0.1000	0.1000	0.1024	0.2745	0.3198	0.6839
0.1000	0.1000	0.1000	0.1024	0.3857	0.3190	0.7236
0.1000	0.1000	0.1000	0.1024	0.5031	0.3193	0.6781
0.1000	0.1000	0.1000	0.1024	0.1574	0.1576	0.5361
0.1000	0.1000	0.1000	0.1024	0.1574	0.2910	0.5618

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.1000	0.1000	0.1024	0.2715	0.1907	0.6560
0.1000	0.1000	0.1000	0.1024	0.1574	0.4130	0.5560
0.1000	0.1000	0.1000	0.1024	0.2715	0.3822	0.6633
0.1000	0.1000	0.1000	0.1024	0.3857	0.3245	0.7125
0.1000	0.1000	0.1000	0.1024	0.1000	0.5232	0.2888
0.1000	0.1000	0.1000	0.1024	0.2145	0.5289	0.5119
0.1000	0.1000	0.1000	0.1024	0.3286	0.5134	0.6229
0.1000	0.1000	0.1000	0.1024	0.4431	0.4907	0.6797
0.1000	0.1000	0.1000	0.1024	0.1000	0.6236	0.2125
0.1000	0.1000	0.1000	0.1024	0.2145	0.1520	0.6321
0.1000	0.1000	0.1000	0.1024	0.3286	0.1499	0.7040
0.1000	0.1000	0.1000	0.1024	0.5002	0.1848	0.7980
0.1000	0.5000	0.1000	0.2788	0.2173	0.2249	0.7447
0.1000	0.5000	0.1000	0.2788	0.3287	0.2223	0.8085
0.1000	0.5000	0.1000	0.2788	0.4430	0.2231	0.8649
0.1000	0.5000	0.1000	0.2788	0.2144	0.3183	0.6351
0.1000	0.5000	0.1000	0.2788	0.3287	0.3191	0.7722
0.1000	0.5000	0.1000	0.2788	0.4430	0.3183	0.8211
0.1000	0.5000	0.1000	0.2788	0.2144	0.4070	0.5391
0.1000	0.5000	0.1000	0.2788	0.3287	0.4066	0.7256
0.1000	0.5000	0.1000	0.2788	0.4430	0.4055	0.7960
0.1000	0.5000	0.1000	0.2788	0.2201	0.2216	0.6607
0.1000	0.5000	0.1000	0.2788	0.3340	0.2216	0.7538
0.1000	0.5000	0.1000	0.2788	0.4475	0.2216	0.7743
0.1000	0.5000	0.1000	0.2788	0.2171	0.3184	0.6081
0.1000	0.5000	0.1000	0.2788	0.3896	0.3172	0.7223
0.1000	0.5000	0.1000	0.2788	0.1636	0.4055	0.5142
0.1000	0.5000	0.1000	0.2788	0.2780	0.4055	0.6474
0.1000	0.5000	0.1000	0.2788	0.3883	0.4068	0.7244
0.1000	0.5000	0.1000	0.2788	0.2201	0.5170	0.5341
0.1000	0.5000	0.1000	0.2788	0.3325	0.5158	0.6228
0.1000	0.5000	0.1000	0.2788	0.4462	0.5176	0.7387
0.1000	0.1000	0.1000	0.2788	0.2102	0.2221	0.7234
0.1000	0.1000	0.1000	0.2788	0.3336	0.2238	0.7824
0.1000	0.1000	0.1000	0.2788	0.4372	0.2222	0.7163
0.1000	0.1000	0.1000	0.2788	0.2182	0.3180	0.7634
0.1000	0.1000	0.1000	0.2788	0.3329	0.3194	0.8585
0.1000	0.1000	0.1000	0.2788	0.4475	0.3176	0.7645
0.1000	0.1000	0.1000	0.2788	0.2175	0.4072	0.8098
0.1000	0.1000	0.1000	0.2788	0.3355	0.4071	0.8814
0.1000	0.1000	0.1000	0.2788	0.4458	0.4065	0.8699
0.1000	0.1000	0.1000	0.2788	0.2201	0.5162	0.7322

**7.10.1** Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.1000	0.1000	0.2788	0.3256	0.5196	0.8392
0.1000	0.1000	0.1000	0.2788	0.4418	0.5176	0.8687
0.1000	0.1000	0.1000	0.2788	0.2144	0.2228	0.6779
0.1000	0.1000	0.1000	0.2788	0.3287	0.2210	0.7594
0.1000	0.1000	0.1000	0.2788	0.4430	0.2216	0.7636
0.1000	0.1000	0.1000	0.2788	0.2144	0.3209	0.7286
0.1000	0.1000	0.1000	0.2788	0.3287	0.3142	0.7681
0.1000	0.1000	0.1000	0.2788	0.4430	0.3178	0.7429
0.1000	0.1000	0.1000	0.2788	0.2125	0.3889	0.7506
0.1000	0.1000	0.1000	0.2788	0.3287	0.4030	0.7922
0.1000	0.1000	0.1000	0.2788	0.4430	0.4049	0.8264
0.1000	0.1000	0.1000	0.2788	0.2224	0.4061	0.6938
0.1000	0.1000	0.1000	0.2788	0.3313	0.4036	0.7714
0.1000	0.1000	0.1000	0.2788	0.1607	0.2234	0.6903
0.1000	0.1000	0.1000	0.2788	0.2761	0.2210	0.7427
0.1000	0.1000	0.1000	0.2788	0.3908	0.2204	0.7842
0.1000	0.1000	0.1000	0.2788	0.1599	0.3178	0.6467
0.1000	0.1000	0.1000	0.2788	0.2780	0.3172	0.7978
0.1000	0.1000	0.1000	0.2788	0.3892	0.3180	0.8004
0.1000	0.1000	0.1000	0.2788	0.1611	0.4055	0.5980
0.1000	0.1000	0.1000	0.2788	0.2773	0.4043	0.7603
0.1000	0.1000	0.1000	0.2788	0.3872	0.4052	0.8113
0.1000	0.1000	0.1000	0.2788	0.1580	0.5140	0.5411
0.1000	0.1000	0.1000	0.2788	0.2765	0.5140	0.7561
0.1000	0.1000	0.1000	0.2788	0.3889	0.5109	0.7758
0.1000	0.1000	0.1000	0.2788	0.1710	0.2142	0.5796
0.1000	0.1000	0.1000	0.2788	0.2811	0.2155	0.7721
0.1000	0.1000	0.1000	0.2788	0.3864	0.2216	0.7007
0.1000	0.1000	0.1000	0.2788	0.1748	0.3050	0.7468
0.1000	0.1000	0.1000	0.2788	0.2834	0.3086	0.7554
0.1000	0.1000	0.1000	0.2788	0.3969	0.3123	0.7437
0.1000	0.1000	0.1000	0.2788	0.1700	0.4030	0.6565
0.1000	0.1000	0.1000	0.2788	0.2757	0.4043	0.7741
0.1000	0.1000	0.1000	0.2788	0.3915	0.4061	0.8011
0.1000	0.1000	0.1000	0.2788	0.1664	0.5121	0.5162
0.1000	0.1000	0.1000	0.2788	0.2776	0.5060	0.7614
0.1000	0.1000	0.1000	0.2788	0.3978	0.5140	0.8043
0.1000	0.1000	0.1000	0.2788	0.2201	0.3135	0.6868
0.1000	0.1000	0.1000	0.2788	0.3287	0.3172	0.7418
0.1000	0.1000	0.1000	0.2788	0.4449	0.3123	0.7574
0.1000	0.1000	0.1000	0.2788	0.2239	0.4006	0.6776
0.1000	0.1000	0.1000	0.2788	0.3382	0.4043	0.7734

**7.10.1** Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.1000	0.1000	0.2788	0.4445	0.4018	0.8051
0.1000	0.1000	0.1000	0.2788	0.2216	0.5146	0.6215
0.1000	0.1000	0.1000	0.2788	0.3443	0.5134	0.7595
0.1000	0.1000	0.1000	0.2788	0.4460	0.5134	0.7852
0.1000	0.1000	0.1000	0.2788	0.2194	0.2339	0.7074
0.1000	0.1000	0.1000	0.2788	0.3363	0.2216	0.7010
0.1000	0.1000	0.1000	0.2788	0.4491	0.2223	0.6946
0.1000	0.1000	0.1000	0.2788	0.2226	0.3235	0.7510
0.1000	0.1000	0.1000	0.2788	0.3336	0.3172	0.7552
0.1000	0.1000	0.1000	0.2788	0.4426	0.3209	0.6690
0.1000	0.1000	0.1000	0.2788	0.2163	0.4051	0.7177
0.1000	0.1000	0.1000	0.2788	0.3296	0.4070	0.7521
0.1000	0.1000	0.1000	0.2788	0.4439	0.4062	0.7436
0.1000	0.1000	0.1000	0.2788	0.2205	0.5195	0.6963
0.1000	0.1000	0.1000	0.2788	0.3310	0.5311	0.7452
0.1000	0.1000	0.1000	0.2788	0.4449	0.5250	0.7593
0.1000	0.1000	0.1000	0.2788	0.2176	0.3172	0.7465
0.1000	0.1000	0.1000	0.2788	0.3317	0.3172	0.7735
0.1000	0.1000	0.1000	0.2788	0.4487	0.3160	0.5835
0.1000	0.1000	0.1000	0.2788	0.2218	0.4055	0.7591
0.1000	0.1000	0.1000	0.2788	0.3306	0.4055	0.7619
0.1000	0.1000	0.1000	0.2788	0.4452	0.4055	0.8048
0.1000	0.1000	0.1000	0.2788	0.2201	0.5330	0.5798
0.1000	0.1000	0.1000	0.2788	0.3313	0.5354	0.6636
0.1000	0.1000	0.1000	0.2788	0.4479	0.5317	0.8016
0.1000	0.1000	0.1000	0.2788	0.2209	0.2216	0.6899
0.1000	0.1000	0.1000	0.2788	0.3313	0.2216	0.7799
0.1000	0.1000	0.1000	0.2788	0.4418	0.2210	0.8558
0.1000	0.1000	0.1000	0.2788	0.2167	0.3166	0.7205
0.1000	0.1000	0.1000	0.2788	0.3325	0.3160	0.7968
0.1000	0.1000	0.1000	0.2788	0.4485	0.3154	0.8219
0.1000	0.1000	0.1000	0.2788	0.2222	0.4067	0.6789
0.1000	0.1000	0.1000	0.2788	0.3325	0.4058	0.7824
0.1000	0.1000	0.1000	0.2788	0.4433	0.4049	0.8187
0.1000	0.1000	0.1000	0.2788	0.2197	0.5164	0.6099
0.1000	0.1000	0.1000	0.2788	0.3294	0.5164	0.7089
0.1000	0.1000	0.1000	0.2788	0.4447	0.5172	0.8241
0.1000	0.1000	0.1000	0.2788	0.3915	0.3184	0.6933
0.1000	0.1000	0.1000	0.2788	0.2205	0.4058	0.6300
0.1000	0.1000	0.1000	0.2788	0.3352	0.4076	0.7343
0.1000	0.1000	0.1000	0.2788	0.4483	0.4071	0.7437
0.1000	0.1000	0.1000	0.2788	0.2159	0.5172	0.5895

7.10.1 Valores normalizados apresentados para o treinamento da rede neural para o cálculo do poder de separação  $\delta U$  (cont.)

*“Test Set”*

Variáveis de Entrada						Saída
$r_P$	$r_W$	$D_I$	$Z_E$	F	$p_P$	$\delta U$
0.1000	0.1000	0.1000	0.2788	0.3881	0.5195	0.7596
0.1000	0.1000	0.1000	0.2788	0.2144	0.2237	0.6957
0.1000	0.1000	0.1000	0.2788	0.3287	0.2237	0.7348
0.1000	0.1000	0.1000	0.2788	0.4439	0.2223	0.7544
0.1000	0.1000	0.1000	0.2788	0.2144	0.3187	0.6994
0.1000	0.1000	0.1000	0.2788	0.3287	0.3175	0.8026
0.1000	0.1000	0.1000	0.2788	0.4439	0.3194	0.7887
0.1000	0.1000	0.1000	0.2788	0.2182	0.4063	0.7090
0.1000	0.1000	0.1000	0.2788	0.3277	0.4062	0.7908
0.1000	0.1000	0.1000	0.2788	0.4481	0.4067	0.7833
0.1000	0.1000	0.1000	0.2788	0.2198	0.5158	0.6452
0.1000	0.1000	0.1000	0.2788	0.3325	0.5164	0.7575
0.1000	0.1000	0.1000	0.2788	0.4430	0.5180	0.8524
0.1000	0.1000	0.1000	0.2788	0.2144	0.4066	0.6337
0.1000	0.1000	0.1000	0.2788	0.3296	0.4068	0.6792

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta

*“Learning Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.2927	0.2887
0.4337	0.4756
0.5565	0.5710
0.6541	0.6467
0.6792	0.6872
0.3835	0.3634
0.5086	0.5182
0.6334	0.6127
0.6757	0.6717
0.6877	0.7033
0.3132	0.2706
0.3984	0.3539
0.4740	0.4743
0.3954	0.3540
0.5417	0.5206
0.6052	0.5951
0.2857	0.2802
0.5192	0.5021
0.6508	0.6227
0.6996	0.6792
0.1914	0.1818
0.4524	0.4149
0.5848	0.6085
0.7042	0.6907
0.7368	0.7149
0.1370	0.1177
0.3252	0.3022
0.7306	0.7086
0.1000	0.1073
0.3817	0.3553
0.5559	0.5288
0.6440	0.6269
0.5723	0.5520
0.7206	0.6867
0.7736	0.7098
0.4795	0.4307
0.6239	0.6160
0.7005	0.6872
0.5392	0.4914
0.6866	0.6074
0.7377	0.6859
0.7734	0.7288
0.7831	0.7477
0.5221	0.4807
0.6589	0.6091
0.7143	0.6873

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Learning Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.7711	0.7190
0.7756	0.7216
0.4002	0.3301
0.5757	0.4903
0.3776	0.3396
0.6311	0.5558
0.7286	0.6389
0.4404	0.4028
0.6618	0.6056
0.7307	0.6867
0.3469	0.3357
0.5720	0.5470
0.7003	0.6720
0.7596	0.7078
0.3878	0.3991
0.5337	0.5546
0.6165	0.6512
0.6891	0.7115
0.3845	0.3873
0.5834	0.5519
0.6577	0.6546
0.7131	0.7080
0.3087	0.2836
0.4486	0.4526
0.5035	0.4904
0.4089	0.3853
0.6263	0.6111
0.3819	0.2897
0.5572	0.5399
0.6512	0.6484
0.7126	0.7091
0.4443	0.4168
0.5905	0.5803
0.6697	0.6791
0.7434	0.7322
0.7282	0.7208
0.2290	0.2584
0.3236	0.3569
0.3721	0.4140
0.3872	0.4144
0.3871	0.3800
0.4756	0.4210
0.4755	0.4505
0.3652	0.3561
0.3553	0.3130

**7.10.2** Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Learning Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.4112	0.3817
0.5272	0.5168
0.5191	0.4525
0.4497	0.4337
0.5602	0.5201
0.6315	0.6238
0.6023	0.5576
0.3263	0.2840
0.4390	0.3843
0.4385	0.4111
0.4553	0.4753
0.6228	0.6703
0.7122	0.7676
0.7481	0.8124
0.4719	0.4862
0.6417	0.6602
0.7701	0.7640
0.7740	0.8097
0.7678	0.8211
0.4083	0.4597
0.4846	0.4927
0.6359	0.6708
0.4401	0.4639
0.6204	0.6559
0.7363	0.7671
0.4116	0.3979
0.5922	0.6030
0.7241	0.7322
0.7628	0.7961
0.7818	0.8242
0.4394	0.4159
0.6069	0.6061
0.7003	0.7097
0.7483	0.7618
0.7643	0.7751
0.4843	0.4941
0.6723	0.6876
0.7487	0.7828
0.7765	0.8163
0.7846	0.8245
0.6836	0.6687
0.7919	0.7682
0.8088	0.8167
0.5915	0.5864
0.7357	0.7185

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Learning Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.8267	0.7959
0.8668	0.8274
0.6774	0.6229
0.7944	0.7488
0.8176	0.8093
0.6368	0.6203
0.7634	0.7382
0.7942	0.7957
0.6573	0.6565
0.7760	0.7455
0.7966	0.8081
0.6600	0.6451
0.7346	0.7424
0.8094	0.8161
0.6373	0.5973
0.6903	0.7031
0.7805	0.7679
0.8074	0.8290
0.6614	0.6478
0.7265	0.7433
0.8082	0.8140
0.5408	0.5467
0.6604	0.6576
0.7664	0.7650
0.4354	0.3977
0.5160	0.5111
0.4985	0.5184
0.4498	0.5085
0.5043	0.5466
0.4268	0.4930
0.5798	0.5562
0.5347	0.5856
0.4682	0.5201
0.4304	0.4778
0.4754	0.5165
0.5011	0.5200
0.5204	0.5500
0.5428	0.5457
0.5194	0.4917
0.5654	0.5520
0.6314	0.5896
0.5492	0.5260
0.5361	0.5404
0.6239	0.5822
0.6145	0.6161

**7.10.2** Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Learning Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.5362	0.5210
0.5867	0.5525
0.6038	0.6378
0.2908	0.3345
0.3820	0.4371
0.4126	0.4620
0.3787	0.4460
0.4246	0.5162
0.4619	0.5296
0.5336	0.5782
0.5189	0.5978
0.5281	0.6167
0.4199	0.3424
0.4794	0.4370
0.5018	0.4598
0.5910	0.4379
0.6084	0.5119
0.5632	0.5184
0.6648	0.5936
0.6391	0.6179
0.4334	0.3878
0.6189	0.6108
0.6965	0.6920
0.6704	0.6878
0.4641	0.4101
0.6400	0.5608
0.7300	0.6747
0.7054	0.6820
0.4559	0.3807
0.4442	0.4102
0.5979	0.5897
0.3769	0.3809
0.5342	0.5416
0.7362	0.6781
0.7263	0.6850
0.4212	0.3742
0.5540	0.5032
0.6755	0.6436
0.7186	0.6908
0.3097	0.2974
0.3285	0.3187
0.5686	0.5228
0.6577	0.6824
0.7272	0.7057
0.6542	0.6042

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Learning Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.8050	0.7333
0.8820	0.7819
0.5487	0.5543
0.6716	0.7244
0.8117	0.7757
0.4360	0.4288
0.6496	0.6775
0.8078	0.7523
0.6092	0.6048
0.7081	0.7343
0.7331	0.7832
0.5660	0.5656
0.7022	0.7603
0.7646	0.7830
0.5962	0.5913
0.6979	0.7303
0.7794	0.7639
0.5645	0.5598
0.6805	0.7018
0.6772	0.6656
0.7198	0.7557
0.7899	0.7813
0.7267	0.6611
0.8295	0.7690
0.8363	0.7925
0.7053	0.6252
0.8376	0.7574
0.9000	0.8135
0.5825	0.5010
0.8142	0.7179
0.8635	0.8215
0.6703	0.6596
0.7308	0.7559
0.7498	0.7807
0.6528	0.6580
0.6780	0.7679
0.7856	0.7932
0.6858	0.6280
0.8080	0.7580
0.8562	0.8132
0.5896	0.6285
0.7432	0.7630
0.7788	0.8133
0.7050	0.7264
0.7598	0.7730

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Learning Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.7584	0.7840
0.7278	0.7286
0.8071	0.7891
0.8061	0.7879
0.6999	0.7000
0.8160	0.8016
0.7736	0.8067
0.6489	0.6319
0.7805	0.7807
0.8027	0.8381
0.6677	0.7327
0.7489	0.7738
0.7433	0.7840
0.7776	0.7396
0.7851	0.7889
0.6754	0.7878
0.7041	0.7131
0.7844	0.8024
0.7163	0.8076
0.6806	0.6361
0.7669	0.7837
0.8531	0.8373
0.7180	0.7707
0.8229	0.7911
0.6769	0.6597
0.7629	0.7690
0.7972	0.8122
0.5561	0.5400
0.6809	0.7231
0.7652	0.8247
0.6759	0.6712
0.6981	0.7593
0.7178	0.7812
0.6814	0.6622
0.7586	0.7703
0.6855	0.7919
0.6895	0.6360
0.7430	0.7607
0.7632	0.8135
0.5966	0.5157
0.7417	0.7091
0.7596	0.8174
0.6457	0.6673
0.7796	0.7688
0.6813	0.7924

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Learning Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.5689	0.6300
0.7162	0.7636
0.8061	0.8147
0.4551	0.4960
0.6684	0.7043
0.7732	0.8204
0.6368	0.6677
0.7769	0.7587
0.8370	0.7813
0.5532	0.6623
0.7666	0.7717
0.8279	0.7919
0.5839	0.6237
0.7333	0.7619
0.8452	0.8135
0.4729	0.5096
0.6689	0.7122
0.7990	0.8214
0.5890	0.7813
0.5606	0.6312
0.7094	0.7643
0.7351	0.8134
0.4420	0.5176
0.6736	0.7138
0.6371	0.6560
0.7582	0.7573
0.7854	0.7808
0.6571	0.6608
0.7326	0.7679
0.7801	0.7926
0.6402	0.6312
0.7753	0.7641
0.8029	0.8134
0.4910	0.5067
0.7265	0.7165
0.8145	0.8238
0.5594	0.6228
0.6732	0.7577
0.6857	0.8136

**7.10.2** Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Test Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.3825	0.3989
0.5116	0.5299
0.6033	0.6148
0.6800	0.6710
0.7045	0.6959
0.4673	0.4559
0.5928	0.5669
0.6630	0.6412
0.6831	0.6910
0.7250	0.7097
0.3077	0.3112
0.4618	0.4307
0.4973	0.4846
0.4995	0.4556
0.5927	0.5624
0.6072	0.6176
0.4554	0.4055
0.6051	0.5732
0.6857	0.6562
0.6746	0.6927
0.3076	0.2978
0.5788	0.5298
0.6681	0.6599
0.7201	0.7071
0.7100	0.7191
0.2439	0.1841
0.4377	0.4223
0.7360	0.7166
0.2563	0.2385
0.4822	0.4711
0.6249	0.5817
0.6573	0.6596
0.6673	0.6442
0.7383	0.7050
0.7654	0.7055
0.5576	0.5363
0.6884	0.6622
0.4338	0.3989
0.6132	0.5542
0.7101	0.6492
0.7575	0.7115
0.7686	0.7409
0.6045	0.5518
0.6916	0.6545
0.7734	0.7081

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Test Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.7725	0.7225
0.4396	0.3875
0.6065	0.5440
0.5387	0.4819
0.6813	0.6105
0.3009	0.2919
0.5821	0.5346
0.6850	0.6521
0.2186	0.2139
0.4580	0.4615
0.6365	0.6286
0.7217	0.6965
0.7715	0.7099
0.4537	0.4882
0.5617	0.6074
0.6578	0.6859
0.6895	0.7274
0.5041	0.4807
0.6228	0.6093
0.6835	0.6873
0.7155	0.7189
0.3697	0.3865
0.4203	0.4044
0.5646	0.5486
0.5111	0.4807
0.6583	0.6393
0.4894	0.4463
0.6127	0.5972
0.6933	0.6848
0.3019	0.2743
0.5274	0.5147
0.6563	0.6322
0.7146	0.7109
0.7321	0.7444
0.1734	0.2245
0.2378	0.3003
0.3592	0.3982
0.4088	0.4163
0.3078	0.3503
0.4175	0.3820
0.4953	0.4473
0.4139	0.4412
0.3841	0.3332
0.3146	0.3477
0.4992	0.4846

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Test Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.5054	0.4728
0.4814	0.4524
0.4905	0.3823
0.5850	0.5898
0.6171	0.6162
0.5599	0.5505
0.1783	0.1980
0.3321	0.3477
0.4767	0.4029
0.4642	0.4137
0.5529	0.5903
0.6685	0.7270
0.6698	0.7953
0.7768	0.8215
0.5450	0.5800
0.6887	0.7182
0.7572	0.7917
0.8465	0.8188
0.7658	0.8187
0.5077	0.5489
0.5626	0.5957
0.6776	0.7032
0.5553	0.5708
0.7028	0.7207
0.7503	0.7812
0.5166	0.5117
0.6767	0.6762
0.7461	0.7711
0.7771	0.8125
0.3033	0.2591
0.5320	0.5178
0.6637	0.6661
0.7274	0.7421
0.7875	0.7714
0.3126	0.3008
0.5995	0.6189
0.7333	0.7492
0.7673	0.8035
0.7807	0.8236
0.5906	0.5940
0.7269	0.7272
0.7945	0.7975
0.8640	0.8275
0.6411	0.6597
0.7832	0.7637

**7.10.2** Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Test Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.8378	0.8165
0.5634	0.5132
0.7156	0.7022
0.8231	0.7848
0.5218	0.5380
0.7020	0.6850
0.8010	0.7734
0.6324	0.5874
0.7469	0.7050
0.8009	0.7759
0.5470	0.5868
0.7308	0.6942
0.7610	0.7816
0.7902	0.8437
0.6906	0.6556
0.7489	0.7442
0.7630	0.8055
0.6777	0.6177
0.7192	0.6985
0.7830	0.7856
0.8067	0.8408
0.6111	0.6052
0.7285	0.7181
0.7545	0.7964
0.5089	0.4859
0.5201	0.5164
0.5055	0.5208
0.5331	0.5674
0.4596	0.5110
0.6257	0.5376
0.5730	0.5851
0.5418	0.5552
0.3765	0.3837
0.4496	0.5079
0.5106	0.5169
0.4921	0.4859
0.5382	0.5705
0.5330	0.5121
0.4387	0.5274
0.5958	0.5816
0.5925	0.5682
0.4834	0.5265
0.6245	0.5519
0.6444	0.6126
0.4237	0.5039

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Test Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.5625	0.5372
0.6163	0.5845
0.2759	0.2695
0.3581	0.3968
0.4059	0.4543
0.3546	0.4246
0.3997	0.4751
0.4782	0.5265
0.5008	0.5426
0.5393	0.5872
0.5431	0.6145
0.3668	0.2771
0.4515	0.3950
0.5206	0.4526
0.5430	0.4250
0.5864	0.4731
0.6165	0.5260
0.6661	0.5809
0.6600	0.6016
0.6034	0.6131
0.5348	0.5068
0.7067	0.6701
0.7478	0.6946
0.6392	0.6759
0.5745	0.4878
0.6839	0.6350
0.7236	0.6895
0.6781	0.6649
0.5361	0.5229
0.5618	0.4918
0.6560	0.6776
0.5560	0.4553
0.6633	0.5970
0.7125	0.6894
0.2888	0.3181
0.5119	0.4323
0.6229	0.5778
0.6797	0.6942
0.2125	0.2760
0.6321	0.6310
0.7040	0.7027
0.7980	0.6887
0.7447	0.6859
0.8085	0.7639
0.8649	0.7917

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Test Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.6351	0.6636
0.7722	0.7582
0.8211	0.7825
0.5391	0.5795
0.7256	0.7276
0.7960	0.7636
0.6607	0.6885
0.7538	0.7660
0.7743	0.7923
0.6081	0.6673
0.7223	0.7764
0.5142	0.4496
0.6474	0.6853
0.7244	0.7533
0.5341	0.4286
0.6228	0.6533
0.7387	0.7255
0.7234	0.7205
0.7824	0.7735
0.7163	0.7839
0.7634	0.7243
0.8585	0.7899
0.7645	0.7882
0.8098	0.7009
0.8814	0.8029
0.8699	0.8063
0.7322	0.6296
0.8392	0.7687
0.8687	0.8382
0.6779	0.7241
0.7594	0.7721
0.7636	0.7840
0.7286	0.7199
0.7681	0.7882
0.7429	0.7887
0.7506	0.7017
0.7922	0.7997
0.8264	0.8064
0.6938	0.7070
0.7714	0.8009
0.6903	0.6640
0.7427	0.7578
0.7842	0.7811
0.6467	0.6606
0.7978	0.7715

7.10.2 Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Test Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.8004	0.7925
0.5980	0.6291
0.7603	0.7635
0.8113	0.8131
0.5411	0.5109
0.7561	0.7167
0.7758	0.8216
0.5796	0.6770
0.7721	0.7584
0.7007	0.7808
0.7468	0.6794
0.7554	0.7736
0.7437	0.7913
0.6565	0.6433
0.7741	0.7622
0.8011	0.8134
0.5162	0.5306
0.7614	0.7233
0.8043	0.8256
0.6868	0.7269
0.7418	0.7887
0.7574	0.7879
0.6776	0.7106
0.7734	0.8038
0.8051	0.8052
0.6215	0.6339
0.7595	0.7889
0.7852	0.8378
0.7074	0.7294
0.7010	0.7737
0.6946	0.7840
0.7510	0.7278
0.7552	0.7896
0.6690	0.7891
0.7177	0.7004
0.7521	0.8002
0.7436	0.8066
0.6963	0.6268
0.7452	0.7681
0.7593	0.8394
0.7465	0.7239
0.7735	0.7892
0.5835	0.7879
0.7591	0.7065
0.7619	0.8006

**7.10.2** Valores do poder de separação  $\delta U$  experimentais e calculados pela rede neural com oito neurônios na camada oculta (cont.)

*“Test Set”*

$\delta U_{\text{exp}}$	$\delta U_{\text{calc}}$
0.8048	0.8061
0.5798	0.6112
0.6636	0.7661
0.8016	0.8404
0.6899	0.7289
0.7799	0.7728
0.8558	0.7839
0.7205	0.7230
0.7968	0.7891
0.8219	0.7878
0.6789	0.7065
0.7824	0.8015
0.8187	0.8064
0.6099	0.6286
0.7089	0.7740
0.8241	0.8384
0.6933	0.7925
0.6300	0.7049
0.7343	0.8027
0.7437	0.8059
0.5895	0.6211
0.7596	0.8194
0.6957	0.7242
0.7348	0.7726
0.7544	0.7840
0.6994	0.7203
0.8026	0.7888
0.7887	0.7888
0.7090	0.7021
0.7908	0.7992
0.7833	0.8059
0.6452	0.6295
0.7575	0.7769
0.8524	0.8383
0.6337	0.6976
0.6792	0.8002

**7.10.3** Pesos da rede neural para o cálculo do poder de separação  $\delta U$  com oito neurônios na camada interna

**Pesos da camada oculta**

-1.26E+00	8.94E-01	3.54E-01	8.66E+00	-1.02E+01	1.04E+00	5.71E+00	1.59E+00
2.76E+00	8.54E-01	-1.69E+00	8.18E+00	9.71E+00	1.94E+00	-6.90E+00	2.80E+00
-7.22E+00	-6.06E-01	-3.51E-01	-4.26E+00	1.69E+01	-1.07E+00	-1.61E+00	-4.47E+00
3.80E+00	-2.33E+00	7.60E+00	-6.24E-02	-1.71E+00	5.66E+00	-3.73E+00	-4.64E+00
8.39E-01	7.67E+00	-4.93E+00	2.55E+00	6.34E+00	5.08E+00	-1.38E+01	3.44E+00
-4.83E+00	6.16E+00	-2.10E+00	1.37E-01	-7.94E+00	-4.68E+00	1.14E+01	-5.40E+00
2.11E-01	2.28E-01	4.33E-01	2.41E-01	5.03E-01	6.92E-01	5.56E-01	3.22E-01

**Pesos da camada de saída**

2.43E+00
6.42E+00
-2.04E+00
-8.06E+00
-2.07E+00
4.13E+00
-8.50E-01
-1.54E+00
4.67E-01

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$

*“Learning Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_l$	F	$p_p$	$p_w$
0.1000	0.5000	0.9000	0.1000	0.2220	0.2691
0.1000	0.5000	0.9000	0.2145	0.2250	0.3541
0.1000	0.5000	0.9000	0.3231	0.2232	0.4143
0.1000	0.5000	0.9000	0.4431	0.2226	0.5058
0.1000	0.5000	0.9000	0.5572	0.2236	0.5833
0.1000	0.5000	0.9000	0.1000	0.3172	0.3889
0.1000	0.5000	0.9000	0.2145	0.3172	0.4439
0.1000	0.5000	0.9000	0.3345	0.3181	0.4897
0.1000	0.5000	0.9000	0.4431	0.3189	0.4952
0.1000	0.5000	0.9000	0.5572	0.3188	0.5863
0.1000	0.5000	0.9000	0.1000	0.2092	0.2601
0.1000	0.5000	0.9000	0.1000	0.2888	0.3579
0.1000	0.5000	0.9000	0.2145	0.2232	0.3571
0.1000	0.5000	0.9000	0.1000	0.3616	0.4566
0.1000	0.5000	0.9000	0.2145	0.3297	0.4563
0.1000	0.5000	0.9000	0.3286	0.2736	0.4565
0.1000	0.5000	0.9000	0.1000	0.4374	0.5564
0.1000	0.5000	0.9000	0.2145	0.4430	0.5540
0.1000	0.5000	0.9000	0.3257	0.4068	0.5551
0.1000	0.5000	0.9000	0.4431	0.3589	0.4891
0.1000	0.5000	0.9000	0.1000	0.5178	0.6581
0.1000	0.5000	0.9000	0.2115	0.5273	0.6526
0.1000	0.5000	0.9000	0.3286	0.5396	0.6522
0.1000	0.5000	0.9000	0.4431	0.5031	0.6531
0.1000	0.5000	0.9000	0.5543	0.4595	0.6524
0.1000	0.5000	0.9000	0.1000	0.5921	0.7513
0.1000	0.5000	0.9000	0.2145	0.6025	0.7503
0.1000	0.5000	0.9000	0.5572	0.6369	0.7502
0.1000	0.5000	0.9000	0.1000	0.1020	0.1686
0.1000	0.5000	0.9000	0.2086	0.1229	0.2949
0.1000	0.5000	0.9000	0.3231	0.1467	0.4161
0.1000	0.5000	0.9000	0.4402	0.1699	0.5109
0.1000	0.5000	0.9000	0.1641	0.2179	0.4072
0.1000	0.5000	0.9000	0.2849	0.2192	0.4773
0.1000	0.5000	0.9000	0.3900	0.2173	0.5461
0.1000	0.5000	0.9000	0.1613	0.3180	0.5375
0.1000	0.5000	0.9000	0.2755	0.3180	0.5952
0.1000	0.5000	0.9000	0.3898	0.3202	0.6567
0.5000	0.9000	0.3667	0.1600	0.2223	0.4602
0.5000	0.9000	0.3667	0.2715	0.2220	0.5526
0.5000	0.9000	0.3667	0.3857	0.2229	0.6512
0.5000	0.9000	0.3667	0.5002	0.2244	0.7490

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Learning Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.5000	0.9000	0.3667	0.6143	0.2222	0.8293
0.5000	0.9000	0.3667	0.1574	0.3181	0.5667
0.5000	0.9000	0.3667	0.2715	0.3199	0.6297
0.5000	0.9000	0.3667	0.3857	0.3172	0.6851
0.5000	0.9000	0.3667	0.5002	0.3172	0.7438
0.5000	0.9000	0.3667	0.6143	0.3188	0.8276
0.5000	0.9000	0.3667	0.1000	0.1405	0.2590
0.5000	0.9000	0.3667	0.1574	0.2372	0.4557
0.5000	0.9000	0.3667	0.1000	0.3797	0.5544
0.5000	0.9000	0.3667	0.2145	0.2871	0.5555
0.5000	0.9000	0.3667	0.3257	0.1680	0.5565
0.5000	0.9000	0.3667	0.1574	0.4418	0.6518
0.5000	0.9000	0.3667	0.2715	0.3515	0.6529
0.5000	0.9000	0.3667	0.3831	0.2791	0.6521
0.5000	0.9000	0.3667	0.1574	0.5082	0.7509
0.5000	0.9000	0.3667	0.2715	0.5479	0.7512
0.5000	0.9000	0.3667	0.3857	0.4917	0.7514
0.5000	0.9000	0.3667	0.5002	0.4447	0.7520
0.5000	0.9000	0.3667	0.1000	0.2236	0.3791
0.5000	0.9000	0.3667	0.2145	0.2253	0.4754
0.5000	0.9000	0.3667	0.3286	0.2218	0.5519
0.5000	0.9000	0.3667	0.4431	0.2217	0.6561
0.5000	0.9000	0.3667	0.1000	0.3182	0.5582
0.5000	0.9000	0.3667	0.2145	0.3176	0.5671
0.5000	0.9000	0.3667	0.3286	0.3172	0.6096
0.5000	0.9000	0.3667	0.4431	0.3189	0.6584
0.5000	0.9000	0.3667	0.1000	0.1091	0.2589
0.5000	0.9000	0.3667	0.1574	0.1521	0.3583
0.5000	0.9000	0.3667	0.1574	0.2383	0.4555
0.5000	0.9000	0.3667	0.1029	0.3309	0.5540
0.5000	0.9000	0.3667	0.2715	0.2689	0.5541
0.5000	0.9000	0.3667	0.1000	0.4296	0.6519
0.5000	0.9000	0.3667	0.2174	0.3824	0.6531
0.5000	0.9000	0.3667	0.3257	0.3732	0.6531
0.5000	0.9000	0.3667	0.4431	0.3003	0.6524
0.5000	0.9000	0.3667	0.1574	0.1167	0.3632
0.5000	0.9000	0.3667	0.2686	0.1400	0.5068
0.5000	0.9000	0.3667	0.3857	0.1635	0.6161
0.5000	0.9000	0.3667	0.5002	0.1876	0.7061
0.5000	0.9000	0.3667	0.6143	0.3226	0.7875
0.9000	0.5000	0.3667	0.1574	0.2239	0.2121
0.9000	0.5000	0.3667	0.2715	0.2241	0.2731
0.9000	0.5000	0.3667	0.3857	0.2234	0.3272

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Learning Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_1$	F	$p_p$	$p_w$
0.9000	0.5000	0.3667	0.5002	0.2233	0.3730
0.9000	0.5000	0.3667	0.1574	0.3191	0.2757
0.9000	0.5000	0.3667	0.3286	0.3187	0.3294
0.9000	0.5000	0.3667	0.4431	0.3198	0.3744
0.9000	0.5000	0.3667	0.1000	0.3229	0.2596
0.9000	0.5000	0.3667	0.2145	0.2469	0.2588
0.9000	0.5000	0.3667	0.1000	0.4673	0.3573
0.9000	0.5000	0.3667	0.2145	0.4251	0.3613
0.9000	0.5000	0.3667	0.3286	0.3778	0.3576
0.9000	0.5000	0.3667	0.4431	0.2822	0.3579
0.9000	0.5000	0.3667	0.2145	0.5587	0.4559
0.9000	0.5000	0.3667	0.3286	0.5550	0.4557
0.9000	0.5000	0.3667	0.4431	0.4997	0.4553
0.9000	0.5000	0.3667	0.2145	0.1286	0.2433
0.9000	0.5000	0.3667	0.3286	0.1484	0.3046
0.9000	0.5000	0.3667	0.4431	0.1720	0.3647
0.1000	0.9000	0.3667	0.1000	0.2231	0.2997
0.1000	0.9000	0.3667	0.2145	0.2232	0.3663
0.1000	0.9000	0.3667	0.3286	0.2221	0.4325
0.1000	0.9000	0.3667	0.4431	0.2225	0.5159
0.1000	0.9000	0.3667	0.1000	0.3195	0.3898
0.1000	0.9000	0.3667	0.2145	0.3172	0.4465
0.1000	0.9000	0.3667	0.3316	0.3174	0.4852
0.1000	0.9000	0.3667	0.4431	0.3188	0.5231
0.1000	0.9000	0.3667	0.5572	0.3177	0.5574
0.1000	0.9000	0.3667	0.1000	0.2033	0.2594
0.1000	0.9000	0.3667	0.1000	0.2866	0.3582
0.1000	0.9000	0.3667	0.2145	0.2264	0.3573
0.1000	0.9000	0.3667	0.1000	0.3661	0.4568
0.1000	0.9000	0.3667	0.2145	0.3297	0.4561
0.1000	0.9000	0.3667	0.3286	0.2887	0.4565
0.1000	0.9000	0.3667	0.1000	0.4445	0.5525
0.1000	0.9000	0.3667	0.2145	0.4420	0.5532
0.1000	0.9000	0.3667	0.3286	0.4125	0.5538
0.1000	0.9000	0.3667	0.4431	0.3810	0.5550
0.1000	0.9000	0.3667	0.5572	0.2800	0.5551
0.1000	0.9000	0.3667	0.1574	0.5456	0.6534
0.1000	0.9000	0.3667	0.2715	0.5734	0.6519
0.1000	0.9000	0.3667	0.3857	0.5593	0.6544
0.1000	0.9000	0.3667	0.5002	0.5233	0.6535
0.1000	0.9000	0.3667	0.6143	0.5136	0.6524
0.1000	0.9000	0.3667	0.1574	0.1196	0.2543
0.1000	0.9000	0.3667	0.2715	0.1271	0.3522

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Learning Set”*

Variáveis de Entrada					Saída
$r_P$	$r_W$	$D_i$	F	$p_P$	$p_w$
0.1000	0.9000	0.3667	0.3857	0.1636	0.4555
0.1000	0.9000	0.3667	0.5002	0.1753	0.4559
0.1000	0.9000	0.3667	0.6143	0.2130	0.6072
0.1000	0.9000	0.3667	0.2167	0.2228	0.3823
0.1000	0.9000	0.3667	0.3329	0.2222	0.4431
0.1000	0.9000	0.3667	0.4470	0.2216	0.4970
0.1000	0.9000	0.3667	0.1613	0.3180	0.4680
0.1000	0.9000	0.3667	0.2755	0.3180	0.4750
0.1000	0.9000	0.3667	0.3898	0.3180	0.5180
0.1000	0.9000	0.3667	0.5024	0.3202	0.5648
0.1000	0.9000	0.3667	0.2190	0.1330	0.3304
0.1000	0.9000	0.3667	0.3312	0.1584	0.4180
0.1000	0.9000	0.3667	0.4445	0.1856	0.4946
0.1000	0.9000	0.3667	0.2186	0.4068	0.5683
0.1000	0.9000	0.3667	0.3355	0.4061	0.5210
0.1000	0.9000	0.3667	0.4479	0.4073	0.5037
0.1000	0.9000	0.3667	0.2186	0.2238	0.5109
0.1000	0.9000	0.3667	0.3340	0.2238	0.5445
0.1000	0.9000	0.3667	0.4498	0.2217	0.6327
0.1000	0.9000	0.3667	0.2186	0.3172	0.5614
0.1000	0.9000	0.3667	0.3359	0.3178	0.6086
0.1000	0.9000	0.3667	0.4471	0.3176	0.6512
0.1000	0.9000	0.3667	0.1702	0.2228	0.4671
0.1000	0.9000	0.3667	0.2727	0.2204	0.5025
0.1000	0.9000	0.3667	0.3736	0.2173	0.5477
0.1000	0.9000	0.3667	0.5024	0.2204	0.6317
0.1000	0.9000	0.3667	0.2190	0.3111	0.5415
0.1000	0.9000	0.3667	0.3363	0.3154	0.6027
0.1000	0.9000	0.3667	0.4426	0.3123	0.6204
0.1000	0.9000	0.3667	0.1672	0.3994	0.6197
0.1000	0.9000	0.3667	0.2773	0.4000	0.6417
0.1000	0.9000	0.3667	0.3969	0.4012	0.6666
0.5000	0.1000	0.3667	0.1679	0.2185	0.1075
0.5000	0.1000	0.3667	0.2780	0.2210	0.1000
0.5000	0.1000	0.3667	0.3877	0.2173	0.1085
0.5000	0.1000	0.3667	0.1771	0.3160	0.1495
0.5000	0.1000	0.3667	0.3315	0.3180	0.1887
0.5000	0.1000	0.3667	0.4331	0.3105	0.1724
0.5000	0.1000	0.3667	0.2232	0.4012	0.2015
0.5000	0.1000	0.3667	0.3435	0.4000	0.2176
0.5000	0.1000	0.3667	0.4433	0.3994	0.2336
0.5000	0.1000	0.3667	0.2167	0.2216	0.1930
0.5000	0.1000	0.3667	0.3336	0.2210	0.2431

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Learning Set”*

Variáveis de Entrada					Saída
$r_P$	$r_w$	$D_i$	F	$p_P$	$p_w$
0.5000	0.1000	0.3667	0.4430	0.2216	0.2994
0.5000	0.1000	0.3667	0.2182	0.3182	0.2579
0.5000	0.1000	0.3667	0.3306	0.3154	0.2755
0.5000	0.1000	0.3667	0.4372	0.3148	0.3021
0.5000	0.1000	0.3667	0.2159	0.4043	0.3044
0.5000	0.1000	0.3667	0.3313	0.4012	0.3214
0.5000	0.1000	0.3667	0.4424	0.4064	0.3468
0.5000	0.1000	0.3667	0.2205	0.5293	0.3784
0.5000	0.1000	0.3667	0.3374	0.5281	0.3947
0.5000	0.1000	0.3667	0.4426	0.5140	0.4006
0.5000	0.1000	0.3667	0.2182	0.6341	0.4409
0.5000	0.1000	0.3667	0.3287	0.6261	0.4396
0.5000	0.1000	0.3667	0.4498	0.6243	0.4573
0.9000	0.5000	0.3667	0.2144	0.2204	0.3266
0.9000	0.5000	0.3667	0.3287	0.2234	0.4226
0.9000	0.5000	0.3667	0.4430	0.2210	0.4805
0.9000	0.5000	0.3667	0.2144	0.3183	0.4217
0.9000	0.5000	0.3667	0.3287	0.3172	0.4701
0.9000	0.5000	0.3667	0.4430	0.3184	0.5461
0.9000	0.5000	0.3667	0.2144	0.4036	0.4141
0.9000	0.5000	0.3667	0.3287	0.4040	0.4435
0.9000	0.5000	0.3667	0.4430	0.4073	0.4714
0.9000	0.5000	0.3667	0.2213	0.2204	0.2402
0.9000	0.5000	0.3667	0.3401	0.2167	0.2962
0.9000	0.5000	0.3667	0.4451	0.2155	0.3469
0.9000	0.5000	0.3667	0.2243	0.3099	0.3011
0.9000	0.5000	0.3667	0.3325	0.3099	0.3135
0.9000	0.5000	0.3667	0.4452	0.3062	0.3397
0.9000	0.5000	0.3667	0.2761	0.4079	0.3476
0.9000	0.5000	0.3667	0.3931	0.4067	0.3594
0.1000	0.1000	0.1000	0.1000	0.2249	0.2868
0.1000	0.1000	0.1000	0.2145	0.2238	0.3602
0.1000	0.1000	0.1000	0.3231	0.2230	0.4167
0.1000	0.1000	0.1000	0.4402	0.2226	0.4434
0.1000	0.1000	0.1000	0.1000	0.3183	0.3651
0.1000	0.1000	0.1000	0.2145	0.3184	0.4093
0.1000	0.1000	0.1000	0.3231	0.3197	0.4431
0.1000	0.1000	0.1000	0.4431	0.3193	0.4813
0.1000	0.1000	0.1000	0.1000	0.2080	0.2590
0.1000	0.1000	0.1000	0.1000	0.3169	0.3573
0.1000	0.1000	0.1000	0.2115	0.2553	0.3576
0.1000	0.1000	0.1000	0.1000	0.4138	0.4558
0.1000	0.1000	0.1000	0.2145	0.3654	0.4566

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Learning Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.1000	0.1000	0.1000	0.3286	0.3170	0.4566
0.1000	0.1000	0.1000	0.4402	0.2406	0.4562
0.1000	0.1000	0.1000	0.1574	0.5217	0.5546
0.1000	0.1000	0.1000	0.2715	0.5259	0.5550
0.1000	0.1000	0.1000	0.3857	0.5067	0.5555
0.1000	0.1000	0.1000	0.5031	0.4505	0.5566
0.1000	0.1000	0.1000	0.1574	0.6335	0.6535
0.1000	0.1000	0.1000	0.1000	0.1000	0.1599
0.1000	0.1000	0.1000	0.1574	0.1586	0.2622
0.1000	0.1000	0.1000	0.2715	0.1412	0.3649
0.1000	0.1000	0.1000	0.3857	0.1623	0.4355
0.1000	0.5000	0.1000	0.1601	0.2249	0.4520
0.1000	0.5000	0.1000	0.2715	0.2234	0.5143
0.1000	0.5000	0.1000	0.3858	0.2216	0.5732
0.1000	0.5000	0.1000	0.1573	0.3191	0.5375
0.1000	0.5000	0.1000	0.2715	0.3194	0.5856
0.1000	0.5000	0.1000	0.3858	0.3172	0.6371
0.1000	0.5000	0.1000	0.1573	0.4073	0.6267
0.1000	0.5000	0.1000	0.2715	0.4058	0.6379
0.1000	0.5000	0.1000	0.3858	0.4077	0.6813
0.1000	0.5000	0.1000	0.1607	0.2216	0.4661
0.1000	0.5000	0.1000	0.2734	0.2216	0.5297
0.1000	0.5000	0.1000	0.3912	0.2234	0.6056
0.1000	0.5000	0.1000	0.1615	0.3178	0.5614
0.1000	0.5000	0.1000	0.3329	0.3172	0.6194
0.1000	0.5000	0.1000	0.4498	0.3172	0.6754
0.1000	0.5000	0.1000	0.2194	0.4061	0.6456
0.1000	0.5000	0.1000	0.3336	0.4071	0.6921
0.1000	0.5000	0.1000	0.4464	0.4055	0.7177
0.1000	0.5000	0.1000	0.2773	0.5170	0.7357
0.1000	0.5000	0.1000	0.3877	0.5164	0.7789
0.1000	0.1000	0.1000	0.1618	0.2227	0.2439
0.1000	0.1000	0.1000	0.2693	0.2237	0.2867
0.1000	0.1000	0.1000	0.3892	0.2236	0.3281
0.1000	0.1000	0.1000	0.1603	0.3173	0.3042
0.1000	0.1000	0.1000	0.2734	0.3192	0.3354
0.1000	0.1000	0.1000	0.3885	0.3175	0.3640
0.1000	0.1000	0.1000	0.1590	0.4068	0.3845
0.1000	0.1000	0.1000	0.2712	0.4065	0.3913
0.1000	0.1000	0.1000	0.3892	0.4067	0.4124
0.1000	0.1000	0.1000	0.1573	0.5202	0.4807
0.1000	0.1000	0.1000	0.2799	0.5186	0.4659
0.1000	0.1000	0.1000	0.3934	0.5241	0.4652

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Learning Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.1000	0.1000	0.1000	0.1573	0.2283	0.2493
0.1000	0.1000	0.1000	0.2715	0.2204	0.2680
0.1000	0.1000	0.1000	0.3858	0.2210	0.3053
0.1000	0.1000	0.1000	0.1573	0.3148	0.3116
0.1000	0.1000	0.1000	0.2715	0.3160	0.3456
0.1000	0.1000	0.1000	0.3858	0.3209	0.3492
0.1000	0.1000	0.1000	0.1573	0.3987	0.3692
0.1000	0.1000	0.1000	0.2715	0.4055	0.3849
0.1000	0.1000	0.1000	0.3858	0.4055	0.4042
0.1000	0.1000	0.1000	0.1596	0.4030	0.4318
0.1000	0.1000	0.1000	0.2769	0.4049	0.4606
0.1000	0.1000	0.1000	0.3883	0.4058	0.4760
0.1000	0.1000	0.1000	0.2171	0.2241	0.3224
0.1000	0.1000	0.1000	0.3313	0.2234	0.3561
0.1000	0.1000	0.1000	0.4426	0.2241	0.3892
0.1000	0.1000	0.1000	0.2220	0.3148	0.3866
0.1000	0.1000	0.1000	0.3287	0.3191	0.4137
0.1000	0.1000	0.1000	0.4491	0.3172	0.4458
0.1000	0.1000	0.1000	0.2159	0.4049	0.4517
0.1000	0.1000	0.1000	0.3327	0.4064	0.4774
0.1000	0.1000	0.1000	0.4426	0.4055	0.4864
0.1000	0.1000	0.1000	0.2205	0.5146	0.5339
0.1000	0.1000	0.1000	0.3348	0.5127	0.5424
0.1000	0.1000	0.1000	0.4464	0.5146	0.5624
0.1000	0.1000	0.1000	0.2277	0.2155	0.2143
0.1000	0.1000	0.1000	0.3435	0.2130	0.2313
0.1000	0.1000	0.1000	0.4435	0.2216	0.2742
0.1000	0.1000	0.1000	0.2335	0.3123	0.2958
0.1000	0.1000	0.1000	0.3416	0.3086	0.3027
0.1000	0.1000	0.1000	0.4411	0.3074	0.2775
0.1000	0.1000	0.1000	0.2274	0.4043	0.3515
0.1000	0.1000	0.1000	0.3348	0.4030	0.3754
0.1000	0.1000	0.1000	0.4346	0.4030	0.3843
0.1000	0.1000	0.1000	0.2258	0.5195	0.4252
0.1000	0.1000	0.1000	0.3378	0.5121	0.4232
0.1000	0.1000	0.1000	0.4407	0.5121	0.4370
0.1000	0.1000	0.1000	0.2776	0.3074	0.3679
0.1000	0.1000	0.1000	0.3972	0.3111	0.3889
0.1000	0.1000	0.1000	0.1813	0.4006	0.3954
0.1000	0.1000	0.1000	0.2826	0.4006	0.4272
0.1000	0.1000	0.1000	0.3944	0.4018	0.4519
0.1000	0.1000	0.1000	0.1725	0.5146	0.4835
0.1000	0.1000	0.1000	0.2826	0.5158	0.4969

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Learning Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.1000	0.1000	0.1000	0.3976	0.5195	0.5123
0.1000	0.1000	0.1000	0.1653	0.2314	0.2143
0.1000	0.1000	0.1000	0.2784	0.2247	0.2379
0.1000	0.1000	0.1000	0.3900	0.2216	0.2742
0.1000	0.1000	0.1000	0.1623	0.3246	0.2879
0.1000	0.1000	0.1000	0.2755	0.3203	0.3076
0.1000	0.1000	0.1000	0.3904	0.3148	0.3197
0.1000	0.1000	0.1000	0.1645	0.4024	0.3453
0.1000	0.1000	0.1000	0.2744	0.4055	0.3579
0.1000	0.1000	0.1000	0.3891	0.4066	0.3717
0.1000	0.1000	0.1000	0.1592	0.5121	0.4255
0.1000	0.1000	0.1000	0.2767	0.5250	0.4266
0.1000	0.1000	0.1000	0.3892	0.5299	0.4396
0.1000	0.1000	0.1000	0.1656	0.3172	0.3312
0.1000	0.1000	0.1000	0.2731	0.3172	0.3764
0.1000	0.1000	0.1000	0.3894	0.3172	0.3649
0.1000	0.1000	0.1000	0.1616	0.4055	0.4373
0.1000	0.1000	0.1000	0.2776	0.4055	0.4488
0.1000	0.1000	0.1000	0.3948	0.4116	0.4435
0.1000	0.1000	0.1000	0.1607	0.5293	0.5349
0.1000	0.1000	0.1000	0.2784	0.5342	0.5192
0.1000	0.1000	0.1000	0.3895	0.5187	0.4940
0.1000	0.1000	0.1000	0.1636	0.2204	0.2765
0.1000	0.1000	0.1000	0.2776	0.2228	0.3322
0.1000	0.1000	0.1000	0.3934	0.2198	0.3790
0.1000	0.1000	0.1000	0.1613	0.3166	0.3512
0.1000	0.1000	0.1000	0.2784	0.3166	0.3692
0.1000	0.1000	0.1000	0.3972	0.3160	0.4078
0.1000	0.1000	0.1000	0.1576	0.4061	0.4254
0.1000	0.1000	0.1000	0.2759	0.4061	0.4160
0.1000	0.1000	0.1000	0.3892	0.4067	0.4370
0.1000	0.1000	0.1000	0.1590	0.5164	0.5084
0.1000	0.1000	0.1000	0.2740	0.5158	0.4891
0.1000	0.1000	0.1000	0.3908	0.5172	0.5162
0.1000	0.1000	0.1000	0.3900	0.2228	0.2355
0.1000	0.1000	0.1000	0.1634	0.4074	0.3283
0.1000	0.1000	0.1000	0.2788	0.4070	0.3294
0.1000	0.1000	0.1000	0.3912	0.4063	0.3265
0.1000	0.1000	0.1000	0.1630	0.5167	0.4122
0.1000	0.1000	0.1000	0.2761	0.5174	0.4029
0.1000	0.1000	0.1000	0.1554	0.2223	0.2316
0.1000	0.1000	0.1000	0.2734	0.2238	0.2736
0.1000	0.1000	0.1000	0.3858	0.2216	0.3156

**7.10.4** Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Learning Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_l$	F	$p_p$	$p_w$
0.1000	0.1000	0.1000	0.1601	0.3180	0.2687
0.1000	0.1000	0.1000	0.2715	0.3180	0.3228
0.1000	0.1000	0.1000	0.3849	0.3177	0.3484
0.1000	0.1000	0.1000	0.1634	0.4074	0.3555
0.1000	0.1000	0.1000	0.2784	0.4061	0.3744
0.1000	0.1000	0.1000	0.3929	0.4063	0.3852
0.1000	0.1000	0.1000	0.1582	0.5174	0.4357
0.1000	0.1000	0.1000	0.2780	0.5172	0.4295
0.1000	0.1000	0.1000	0.3953	0.5176	0.4403
0.1000	0.1000	0.1000	0.1582	0.4085	0.2993
0.1000	0.1000	0.1000	0.2715	0.4067	0.2987
0.1000	0.1000	0.1000	0.3858	0.4073	0.2972

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.1000	0.5000	0.9000	0.1574	0.2233	0.3124
0.1000	0.5000	0.9000	0.2715	0.2237	0.3877
0.1000	0.5000	0.9000	0.3857	0.2244	0.4612
0.1000	0.5000	0.9000	0.5002	0.2228	0.5490
0.1000	0.5000	0.9000	0.6143	0.2247	0.6221
0.1000	0.5000	0.9000	0.1574	0.3172	0.4194
0.1000	0.5000	0.9000	0.2715	0.3172	0.4676
0.1000	0.5000	0.9000	0.3801	0.3197	0.5093
0.1000	0.5000	0.9000	0.5002	0.3186	0.5444
0.1000	0.5000	0.9000	0.6143	0.3189	0.6254
0.1000	0.5000	0.9000	0.1574	0.1577	0.2594
0.1000	0.5000	0.9000	0.1574	0.2597	0.3581
0.1000	0.5000	0.9000	0.2715	0.1572	0.3596
0.1000	0.5000	0.9000	0.1574	0.3574	0.4570
0.1000	0.5000	0.9000	0.2715	0.3014	0.4564
0.1000	0.5000	0.9000	0.3857	0.2318	0.4574
0.1000	0.5000	0.9000	0.1600	0.4431	0.5546
0.1000	0.5000	0.9000	0.2686	0.4302	0.5540
0.1000	0.5000	0.9000	0.3857	0.3770	0.5540
0.1000	0.5000	0.9000	0.5002	0.3290	0.5565
0.1000	0.5000	0.9000	0.1545	0.5123	0.6526
0.1000	0.5000	0.9000	0.2745	0.5430	0.6531
0.1000	0.5000	0.9000	0.3857	0.5306	0.6530
0.1000	0.5000	0.9000	0.5002	0.4928	0.6524
0.1000	0.5000	0.9000	0.6088	0.4523	0.6522
0.1000	0.5000	0.9000	0.1574	0.6000	0.7510
0.1000	0.5000	0.9000	0.2715	0.6212	0.7512
0.1000	0.5000	0.9000	0.6143	0.6305	0.7516
0.1000	0.5000	0.9000	0.1600	0.1119	0.2330
0.1000	0.5000	0.9000	0.2745	0.1380	0.3713
0.1000	0.5000	0.9000	0.3801	0.1564	0.4593
0.1000	0.5000	0.9000	0.5002	0.1815	0.5494
0.1000	0.5000	0.9000	0.2277	0.2192	0.4455
0.1000	0.5000	0.9000	0.3390	0.2192	0.5179
0.1000	0.5000	0.9000	0.4470	0.2216	0.5939
0.1000	0.5000	0.9000	0.2194	0.3227	0.5781
0.1000	0.5000	0.9000	0.3327	0.3180	0.6062
0.5000	0.9000	0.3667	0.1000	0.2232	0.3987
0.5000	0.9000	0.3667	0.2145	0.2223	0.5047
0.5000	0.9000	0.3667	0.3257	0.2220	0.5855
0.5000	0.9000	0.3667	0.4431	0.2226	0.7021
0.5000	0.9000	0.3667	0.5602	0.2220	0.7668
0.5000	0.9000	0.3667	0.2145	0.3178	0.5969

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_P$	$r_W$	$D_I$	F	$p_P$	$p_w$
0.5000	0.9000	0.3667	0.3286	0.3186	0.6512
0.5000	0.9000	0.3667	0.4431	0.3172	0.7089
0.5000	0.9000	0.3667	0.5572	0.3185	0.7897
0.5000	0.9000	0.3667	0.1000	0.3178	0.4408
0.5000	0.9000	0.3667	0.2115	0.1921	0.4557
0.5000	0.9000	0.3667	0.1574	0.3143	0.5546
0.5000	0.9000	0.3667	0.2715	0.2515	0.5549
0.5000	0.9000	0.3667	0.1000	0.4274	0.6531
0.5000	0.9000	0.3667	0.2115	0.3751	0.6531
0.5000	0.9000	0.3667	0.3257	0.3269	0.6531
0.5000	0.9000	0.3667	0.1000	0.5272	0.7530
0.5000	0.9000	0.3667	0.2145	0.5138	0.7503
0.5000	0.9000	0.3667	0.3306	0.5301	0.7514
0.5000	0.9000	0.3667	0.4431	0.4631	0.7511
0.5000	0.9000	0.3667	0.5572	0.4275	0.7514
0.5000	0.9000	0.3667	0.1574	0.2238	0.4282
0.5000	0.9000	0.3667	0.2715	0.2220	0.5025
0.5000	0.9000	0.3667	0.3857	0.2221	0.6048
0.5000	0.9000	0.3667	0.4943	0.2228	0.6917
0.5000	0.9000	0.3667	0.1574	0.3180	0.5585
0.5000	0.9000	0.3667	0.2715	0.3172	0.5897
0.5000	0.9000	0.3667	0.3857	0.3172	0.6161
0.5000	0.9000	0.3667	0.5002	0.3182	0.7027
0.5000	0.9000	0.3667	0.1000	0.1979	0.3577
0.5000	0.9000	0.3667	0.1000	0.2655	0.4573
0.5000	0.9000	0.3667	0.2145	0.1971	0.4555
0.5000	0.9000	0.3667	0.1574	0.3182	0.5542
0.5000	0.9000	0.3667	0.3286	0.1613	0.5544
0.5000	0.9000	0.3667	0.1574	0.3882	0.6520
0.5000	0.9000	0.3667	0.2686	0.3882	0.6532
0.5000	0.9000	0.3667	0.3857	0.3611	0.6525
0.5000	0.9000	0.3667	0.1000	0.1034	0.2507
0.5000	0.9000	0.3667	0.2145	0.1289	0.4433
0.5000	0.9000	0.3667	0.3231	0.1514	0.5635
0.5000	0.9000	0.3667	0.4431	0.1755	0.6617
0.5000	0.9000	0.3667	0.5572	0.2013	0.7482
0.9000	0.5000	0.3667	0.1000	0.2230	0.1783
0.9000	0.5000	0.3667	0.2145	0.2227	0.2315
0.9000	0.5000	0.3667	0.3286	0.2237	0.3053
0.9000	0.5000	0.3667	0.4431	0.2234	0.3492
0.9000	0.5000	0.3667	0.1000	0.3176	0.2444
0.9000	0.5000	0.3667	0.2145	0.3172	0.2946
0.9000	0.5000	0.3667	0.3857	0.3199	0.3473

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.9000	0.5000	0.3667	0.5002	0.3219	0.3880
0.9000	0.5000	0.3667	0.1574	0.2858	0.2595
0.9000	0.5000	0.3667	0.2715	0.1385	0.2603
0.9000	0.5000	0.3667	0.1574	0.4568	0.3574
0.9000	0.5000	0.3667	0.2715	0.3926	0.3575
0.9000	0.5000	0.3667	0.3857	0.3332	0.3574
0.9000	0.5000	0.3667	0.1574	0.5885	0.4568
0.9000	0.5000	0.3667	0.2715	0.5669	0.4561
0.9000	0.5000	0.3667	0.3857	0.5484	0.4555
0.9000	0.5000	0.3667	0.5002	0.4869	0.4557
0.9000	0.5000	0.3667	0.1574	0.1141	0.1814
0.9000	0.5000	0.3667	0.2715	0.1382	0.2715
0.9000	0.5000	0.3667	0.3857	0.1618	0.3403
0.9000	0.5000	0.3667	0.5002	0.1854	0.3970
0.1000	0.9000	0.3667	0.1574	0.2221	0.3377
0.1000	0.9000	0.3667	0.2715	0.2221	0.4047
0.1000	0.9000	0.3667	0.3857	0.2238	0.4773
0.1000	0.9000	0.3667	0.5002	0.2238	0.5550
0.1000	0.9000	0.3667	0.1545	0.3176	0.4235
0.1000	0.9000	0.3667	0.2715	0.3197	0.4649
0.1000	0.9000	0.3667	0.3857	0.3180	0.4995
0.1000	0.9000	0.3667	0.5002	0.3175	0.5499
0.1000	0.9000	0.3667	0.6143	0.3175	0.5903
0.1000	0.9000	0.3667	0.1574	0.1598	0.2596
0.1000	0.9000	0.3667	0.1574	0.2556	0.3588
0.1000	0.9000	0.3667	0.2686	0.1560	0.3590
0.1000	0.9000	0.3667	0.1574	0.3498	0.4559
0.1000	0.9000	0.3667	0.2715	0.3100	0.4571
0.1000	0.9000	0.3667	0.3857	0.1586	0.4565
0.1000	0.9000	0.3667	0.1600	0.4519	0.5551
0.1000	0.9000	0.3667	0.2715	0.4302	0.5541
0.1000	0.9000	0.3667	0.3857	0.3959	0.5546
0.1000	0.9000	0.3667	0.5002	0.3560	0.5544
0.1000	0.9000	0.3667	0.1000	0.5507	0.6531
0.1000	0.9000	0.3667	0.2145	0.5693	0.6538
0.1000	0.9000	0.3667	0.3286	0.5726	0.6525
0.1000	0.9000	0.3667	0.4431	0.5375	0.6534
0.1000	0.9000	0.3667	0.5572	0.5176	0.6525
0.1000	0.9000	0.3667	0.1000	0.1060	0.1754
0.1000	0.9000	0.3667	0.2145	0.1297	0.3094
0.1000	0.9000	0.3667	0.3286	0.1544	0.4226
0.1000	0.9000	0.3667	0.4372	0.1749	0.4809
0.1000	0.9000	0.3667	0.5572	0.1965	0.5622

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_P$	$r_W$	$D_i$	F	$p_P$	$p_w$
0.1000	0.9000	0.3667	0.1618	0.2222	0.3503
0.1000	0.9000	0.3667	0.2761	0.2222	0.4141
0.1000	0.9000	0.3667	0.3898	0.2216	0.4773
0.1000	0.9000	0.3667	0.5030	0.2223	0.4945
0.1000	0.9000	0.3667	0.2184	0.3180	0.4726
0.1000	0.9000	0.3667	0.3327	0.3180	0.4946
0.1000	0.9000	0.3667	0.4470	0.3180	0.5180
0.1000	0.9000	0.3667	0.1641	0.1261	0.2715
0.1000	0.9000	0.3667	0.2784	0.1471	0.3850
0.1000	0.9000	0.3667	0.3881	0.1711	0.4494
0.1000	0.9000	0.3667	0.1599	0.4065	0.5667
0.1000	0.9000	0.3667	0.2754	0.4073	0.5705
0.1000	0.9000	0.3667	0.3931	0.4070	0.5100
0.1000	0.9000	0.3667	0.1634	0.2236	0.4374
0.1000	0.9000	0.3667	0.2746	0.2238	0.5054
0.1000	0.9000	0.3667	0.3854	0.2238	0.5693
0.1000	0.9000	0.3667	0.1615	0.3178	0.5438
0.1000	0.9000	0.3667	0.2754	0.3178	0.5863
0.1000	0.9000	0.3667	0.3904	0.3178	0.6323
0.1000	0.9000	0.3667	0.5071	0.3184	0.6754
0.1000	0.9000	0.3667	0.2190	0.2179	0.4855
0.1000	0.9000	0.3667	0.3321	0.2228	0.5297
0.1000	0.9000	0.3667	0.4451	0.2204	0.5994
0.1000	0.9000	0.3667	0.1896	0.3160	0.5372
0.1000	0.9000	0.3667	0.2803	0.3172	0.5726
0.1000	0.9000	0.3667	0.3961	0.3166	0.6073
0.1000	0.9000	0.3667	0.4995	0.3144	0.6328
0.1000	0.9000	0.3667	0.2251	0.4012	0.6302
0.1000	0.9000	0.3667	0.3405	0.3987	0.6508
0.1000	0.9000	0.3667	0.4399	0.3994	0.6748
0.5000	0.1000	0.3667	0.2255	0.2216	0.1092
0.5000	0.1000	0.3667	0.3340	0.2192	0.1075
0.5000	0.1000	0.3667	0.4407	0.2198	0.1242
0.5000	0.1000	0.3667	0.2744	0.3180	0.1601
0.5000	0.1000	0.3667	0.3927	0.3154	0.1714
0.5000	0.1000	0.3667	0.1885	0.4024	0.2068
0.5000	0.1000	0.3667	0.2807	0.3994	0.2077
0.5000	0.1000	0.3667	0.3885	0.3920	0.2366
0.5000	0.1000	0.3667	0.1607	0.2198	0.1626
0.5000	0.1000	0.3667	0.2700	0.2192	0.2123
0.5000	0.1000	0.3667	0.3820	0.2216	0.2693
0.5000	0.1000	0.3667	0.1615	0.3123	0.2310
0.5000	0.1000	0.3667	0.2891	0.3295	0.2837

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.5000	0.1000	0.3667	0.3896	0.3135	0.2883
0.5000	0.1000	0.3667	0.1683	0.4079	0.3007
0.5000	0.1000	0.3667	0.2715	0.3987	0.3142
0.5000	0.1000	0.3667	0.3870	0.4085	0.3335
0.5000	0.1000	0.3667	0.1573	0.5158	0.3620
0.5000	0.1000	0.3667	0.2765	0.5379	0.3918
0.5000	0.1000	0.3667	0.3862	0.5189	0.4013
0.5000	0.1000	0.3667	0.1613	0.6256	0.4325
0.5000	0.1000	0.3667	0.2776	0.6298	0.4406
0.5000	0.1000	0.3667	0.3896	0.6267	0.4494
0.9000	0.5000	0.3667	0.1573	0.2130	0.2628
0.9000	0.5000	0.3667	0.2715	0.2216	0.3875
0.9000	0.5000	0.3667	0.3858	0.2216	0.4449
0.9000	0.5000	0.3667	0.1573	0.3160	0.3934
0.9000	0.5000	0.3667	0.2715	0.3160	0.4376
0.9000	0.5000	0.3667	0.3858	0.3095	0.4559
0.9000	0.5000	0.3667	0.1573	0.3987	0.4039
0.9000	0.5000	0.3667	0.2715	0.4036	0.4288
0.9000	0.5000	0.3667	0.3858	0.4043	0.4671
0.9000	0.5000	0.3667	0.1630	0.2155	0.2153
0.9000	0.5000	0.3667	0.2761	0.2135	0.2659
0.9000	0.5000	0.3667	0.3931	0.2167	0.3194
0.9000	0.5000	0.3667	0.1725	0.3135	0.2936
0.9000	0.5000	0.3667	0.2769	0.3099	0.3217
0.9000	0.5000	0.3667	0.3934	0.3086	0.3338
0.9000	0.5000	0.3667	0.2213	0.4043	0.3486
0.9000	0.5000	0.3667	0.3367	0.4055	0.3538
0.9000	0.5000	0.3667	0.4452	0.4043	0.3767
0.1000	0.1000	0.1000	0.1574	0.2230	0.3298
0.1000	0.1000	0.1000	0.2696	0.2226	0.3859
0.1000	0.1000	0.1000	0.3857	0.2242	0.4461
0.1000	0.1000	0.1000	0.5002	0.2233	0.4392
0.1000	0.1000	0.1000	0.1574	0.3177	0.3877
0.1000	0.1000	0.1000	0.2745	0.3198	0.4275
0.1000	0.1000	0.1000	0.3857	0.3190	0.4636
0.1000	0.1000	0.1000	0.5031	0.3193	0.4801
0.1000	0.1000	0.1000	0.1574	0.1576	0.2597
0.1000	0.1000	0.1000	0.1574	0.2910	0.3579
0.1000	0.1000	0.1000	0.2715	0.1907	0.3584
0.1000	0.1000	0.1000	0.1574	0.4130	0.4564
0.1000	0.1000	0.1000	0.2715	0.3822	0.4564
0.1000	0.1000	0.1000	0.3857	0.3245	0.4553
0.1000	0.1000	0.1000	0.1000	0.5232	0.5546

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.1000	0.1000	0.1000	0.2145	0.5289	0.5548
0.1000	0.1000	0.1000	0.3286	0.5134	0.5536
0.1000	0.1000	0.1000	0.4431	0.4907	0.5544
0.1000	0.1000	0.1000	0.1000	0.6236	0.6533
0.1000	0.1000	0.1000	0.2145	0.1520	0.3180
0.1000	0.1000	0.1000	0.3286	0.1499	0.3947
0.1000	0.1000	0.1000	0.5002	0.1848	0.4923
0.1000	0.5000	0.1000	0.2173	0.2249	0.4819
0.1000	0.5000	0.1000	0.3287	0.2223	0.5418
0.1000	0.5000	0.1000	0.4430	0.2231	0.6455
0.1000	0.5000	0.1000	0.2144	0.3183	0.5544
0.1000	0.5000	0.1000	0.3287	0.3191	0.6284
0.1000	0.5000	0.1000	0.4430	0.3183	0.6585
0.1000	0.5000	0.1000	0.2144	0.4070	0.6414
0.1000	0.5000	0.1000	0.3287	0.4066	0.6471
0.1000	0.5000	0.1000	0.4430	0.4055	0.7029
0.1000	0.5000	0.1000	0.2201	0.2216	0.5025
0.1000	0.5000	0.1000	0.3340	0.2216	0.5598
0.1000	0.5000	0.1000	0.4475	0.2216	0.6443
0.1000	0.5000	0.1000	0.2171	0.3184	0.5837
0.1000	0.5000	0.1000	0.3896	0.3172	0.6463
0.1000	0.5000	0.1000	0.1636	0.4055	0.6383
0.1000	0.5000	0.1000	0.2780	0.4055	0.6662
0.1000	0.5000	0.1000	0.3883	0.4068	0.7018
0.1000	0.5000	0.1000	0.2201	0.5170	0.7399
0.1000	0.5000	0.1000	0.3325	0.5158	0.7461
0.1000	0.5000	0.1000	0.4462	0.5176	0.8005
0.1000	0.1000	0.1000	0.2102	0.2221	0.2702
0.1000	0.1000	0.1000	0.3336	0.2238	0.3023
0.1000	0.1000	0.1000	0.4372	0.2222	0.3446
0.1000	0.1000	0.1000	0.2182	0.3180	0.3208
0.1000	0.1000	0.1000	0.3329	0.3194	0.3528
0.1000	0.1000	0.1000	0.4475	0.3176	0.3695
0.1000	0.1000	0.1000	0.2175	0.4072	0.3832
0.1000	0.1000	0.1000	0.3355	0.4071	0.3981
0.1000	0.1000	0.1000	0.4458	0.4065	0.4146
0.1000	0.1000	0.1000	0.2201	0.5162	0.4777
0.1000	0.1000	0.1000	0.3256	0.5196	0.4638
0.1000	0.1000	0.1000	0.4418	0.5176	0.4659
0.1000	0.1000	0.1000	0.2144	0.2228	0.2565
0.1000	0.1000	0.1000	0.3287	0.2210	0.2795
0.1000	0.1000	0.1000	0.4430	0.2216	0.3450
0.1000	0.1000	0.1000	0.2144	0.3209	0.3368

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.1000	0.1000	0.1000	0.3287	0.3142	0.3355
0.1000	0.1000	0.1000	0.4430	0.3178	0.3505
0.1000	0.1000	0.1000	0.2125	0.3889	0.3646
0.1000	0.1000	0.1000	0.3287	0.4030	0.3875
0.1000	0.1000	0.1000	0.4430	0.4049	0.4078
0.1000	0.1000	0.1000	0.2224	0.4061	0.4501
0.1000	0.1000	0.1000	0.3313	0.4036	0.4717
0.1000	0.1000	0.1000	0.1607	0.2234	0.2801
0.1000	0.1000	0.1000	0.2761	0.2210	0.3535
0.1000	0.1000	0.1000	0.3908	0.2204	0.3712
0.1000	0.1000	0.1000	0.1599	0.3178	0.3659
0.1000	0.1000	0.1000	0.2780	0.3172	0.4013
0.1000	0.1000	0.1000	0.3892	0.3180	0.4279
0.1000	0.1000	0.1000	0.1611	0.4055	0.4363
0.1000	0.1000	0.1000	0.2773	0.4043	0.4553
0.1000	0.1000	0.1000	0.3872	0.4052	0.4819
0.1000	0.1000	0.1000	0.1580	0.5140	0.5195
0.1000	0.1000	0.1000	0.2765	0.5140	0.5352
0.1000	0.1000	0.1000	0.3889	0.5109	0.5513
0.1000	0.1000	0.1000	0.1710	0.2142	0.1904
0.1000	0.1000	0.1000	0.2811	0.2155	0.2388
0.1000	0.1000	0.1000	0.3864	0.2216	0.2404
0.1000	0.1000	0.1000	0.1748	0.3050	0.2801
0.1000	0.1000	0.1000	0.2834	0.3086	0.2831
0.1000	0.1000	0.1000	0.3969	0.3123	0.2893
0.1000	0.1000	0.1000	0.1700	0.4030	0.3451
0.1000	0.1000	0.1000	0.2757	0.4043	0.3676
0.1000	0.1000	0.1000	0.3915	0.4061	0.3802
0.1000	0.1000	0.1000	0.1664	0.5121	0.4180
0.1000	0.1000	0.1000	0.2776	0.5060	0.4213
0.1000	0.1000	0.1000	0.3978	0.5140	0.4367
0.1000	0.1000	0.1000	0.2201	0.3135	0.3613
0.1000	0.1000	0.1000	0.3287	0.3172	0.3910
0.1000	0.1000	0.1000	0.4449	0.3123	0.4038
0.1000	0.1000	0.1000	0.2239	0.4006	0.4095
0.1000	0.1000	0.1000	0.3382	0.4043	0.4435
0.1000	0.1000	0.1000	0.4445	0.4018	0.4593
0.1000	0.1000	0.1000	0.2216	0.5146	0.4897
0.1000	0.1000	0.1000	0.3443	0.5134	0.4897
0.1000	0.1000	0.1000	0.4460	0.5134	0.5182
0.1000	0.1000	0.1000	0.2194	0.2339	0.2313
0.1000	0.1000	0.1000	0.3363	0.2216	0.2523
0.1000	0.1000	0.1000	0.4491	0.2223	0.3019

**7.10.4** Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_P$	$r_w$	$D_i$	F	$p_P$	$p_w$
0.1000	0.1000	0.1000	0.2226	0.3235	0.2989
0.1000	0.1000	0.1000	0.3336	0.3172	0.3155
0.1000	0.1000	0.1000	0.4426	0.3209	0.3220
0.1000	0.1000	0.1000	0.2163	0.4051	0.3513
0.1000	0.1000	0.1000	0.3296	0.4070	0.3799
0.1000	0.1000	0.1000	0.4439	0.4062	0.3783
0.1000	0.1000	0.1000	0.2205	0.5195	0.4308
0.1000	0.1000	0.1000	0.3310	0.5311	0.4360
0.1000	0.1000	0.1000	0.4449	0.5250	0.4435
0.1000	0.1000	0.1000	0.2176	0.3172	0.3361
0.1000	0.1000	0.1000	0.3317	0.3172	0.3528
0.1000	0.1000	0.1000	0.4487	0.3160	0.3748
0.1000	0.1000	0.1000	0.2218	0.4055	0.4370
0.1000	0.1000	0.1000	0.3306	0.4055	0.4367
0.1000	0.1000	0.1000	0.4452	0.4055	0.4380
0.1000	0.1000	0.1000	0.2201	0.5330	0.5208
0.1000	0.1000	0.1000	0.3313	0.5354	0.5103
0.1000	0.1000	0.1000	0.4479	0.5317	0.4989
0.1000	0.1000	0.1000	0.2209	0.2216	0.3162
0.1000	0.1000	0.1000	0.3313	0.2216	0.3541
0.1000	0.1000	0.1000	0.4418	0.2210	0.4059
0.1000	0.1000	0.1000	0.2167	0.3166	0.3646
0.1000	0.1000	0.1000	0.3325	0.3160	0.3869
0.1000	0.1000	0.1000	0.4485	0.3154	0.4183
0.1000	0.1000	0.1000	0.2222	0.4067	0.4200
0.1000	0.1000	0.1000	0.3325	0.4058	0.4221
0.1000	0.1000	0.1000	0.4433	0.4049	0.4504
0.1000	0.1000	0.1000	0.2197	0.5164	0.4966
0.1000	0.1000	0.1000	0.3294	0.5164	0.4874
0.1000	0.1000	0.1000	0.4447	0.5172	0.4989
0.1000	0.1000	0.1000	0.3915	0.3184	0.2768
0.1000	0.1000	0.1000	0.2205	0.4058	0.3311
0.1000	0.1000	0.1000	0.3352	0.4076	0.3254
0.1000	0.1000	0.1000	0.4483	0.4071	0.3297
0.1000	0.1000	0.1000	0.2159	0.5172	0.4063
0.1000	0.1000	0.1000	0.3881	0.5195	0.3846
0.1000	0.1000	0.1000	0.2144	0.2237	0.2499
0.1000	0.1000	0.1000	0.3287	0.2237	0.2922
0.1000	0.1000	0.1000	0.4439	0.2223	0.3461
0.1000	0.1000	0.1000	0.2144	0.3187	0.2861
0.1000	0.1000	0.1000	0.3287	0.3175	0.3345
0.1000	0.1000	0.1000	0.4439	0.3194	0.3776
0.1000	0.1000	0.1000	0.2182	0.4063	0.3621

7.10.4 Valores normalizados apresentados para o treinamento da rede neural para o cálculo da pressão de rejeito  $p_w$  (cont.)

*“Test Set”*

Variáveis de Entrada					Saída
$r_p$	$r_w$	$D_i$	F	$p_p$	$p_w$
0.1000	0.1000	0.1000	0.3277	0.4062	0.3767
0.1000	0.1000	0.1000	0.4481	0.4067	0.3803
0.1000	0.1000	0.1000	0.2198	0.5158	0.4313
0.1000	0.1000	0.1000	0.3325	0.5164	0.4357
0.1000	0.1000	0.1000	0.4430	0.5180	0.4276
0.1000	0.1000	0.1000	0.2144	0.4066	0.2970
0.1000	0.1000	0.1000	0.3296	0.4068	0.2938

**7.10.5** Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta

***“Learning Set”***

<b><math>P_{wexp}</math></b>	<b><math>P_{wcalc}</math></b>
0.2691	0.3770
0.3541	0.4405
0.4143	0.5067
0.5058	0.5845
0.5833	0.6530
0.3889	0.4926
0.4439	0.5329
0.4897	0.5823
0.4952	0.6310
0.5863	0.6810
0.2601	0.3629
0.3579	0.4568
0.3571	0.4388
0.4566	0.5483
0.4563	0.5461
0.4565	0.5462
0.5564	0.6365
0.5540	0.6629
0.5551	0.6493
0.4891	0.6517
0.6581	0.7117
0.6526	0.7353
0.6522	0.7491
0.6531	0.7313
0.6524	0.7274
0.7513	0.7618
0.7503	0.7839
0.7502	0.7958
0.1686	0.2625
0.2949	0.3505
0.4161	0.4560
0.5109	0.5586
0.4072	0.4051
0.4773	0.4789
0.5461	0.5472
0.5375	0.5144
0.5952	0.5575
0.6567	0.6080
0.4602	0.4737
0.5526	0.5656
0.6512	0.6554
0.7490	0.7278
0.8293	0.7794
0.5667	0.5626
0.6297	0.6320

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Learning Set”*

$P_{wexp}$	$P_{wcalc}$
0.6851	0.6958
0.7438	0.7506
0.8276	0.7921
0.2590	0.3545
0.4557	0.4850
0.5544	0.6010
0.5555	0.5703
0.5565	0.5807
0.6518	0.6848
0.6529	0.6542
0.6521	0.6778
0.7509	0.7423
0.7512	0.7842
0.7514	0.7718
0.7520	0.7820
0.3791	0.4292
0.4754	0.5205
0.5519	0.6119
0.6561	0.6937
0.5582	0.5307
0.5671	0.5959
0.6096	0.6639
0.6584	0.7255
0.2589	0.3303
0.3583	0.4131
0.4555	0.4860
0.5540	0.5467
0.5541	0.5969
0.6519	0.6559
0.6531	0.6526
0.6531	0.6940
0.6524	0.7194
0.3632	0.3866
0.5068	0.5108
0.6161	0.6301
0.7061	0.7185
0.7875	0.7926
0.2121	0.2185
0.2731	0.2544
0.3272	0.3126
0.3730	0.3888
0.2757	0.2596
0.3294	0.3077
0.3744	0.3659
0.2596	0.2566

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Learning Set”*

$P_{wexp}$	$P_{wcalc}$
0.2588	0.2409
0.3573	0.3573
0.3613	0.3324
0.3576	0.3316
0.3579	0.3584
0.4559	0.4386
0.4557	0.4435
0.4553	0.4274
0.2433	0.2109
0.3046	0.2669
0.3647	0.3430
0.2997	0.3698
0.3663	0.4329
0.4325	0.5038
0.5159	0.5764
0.3898	0.4711
0.4465	0.5092
0.4852	0.5598
0.5231	0.6128
0.5574	0.6646
0.2594	0.3515
0.3582	0.4344
0.3573	0.4352
0.4568	0.5249
0.4561	0.5203
0.4565	0.5412
0.5525	0.6143
0.5532	0.6246
0.5538	0.6209
0.5550	0.6388
0.5551	0.6555
0.6534	0.7148
0.6519	0.7350
0.6544	0.7240
0.6535	0.7145
0.6524	0.7320
0.2543	0.3224
0.3522	0.4117
0.4555	0.5155
0.4559	0.5971
0.6072	0.6697
0.3823	0.4339
0.4431	0.5066
0.4970	0.5785
0.4680	0.4899

**7.10.5** Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Learning Set”*

$P_{wexp}$	$P_{wcalc}$
0.4750	0.5352
0.5180	0.5873
0.5648	0.6407
0.3304	0.3751
0.4180	0.4732
0.4946	0.5644
0.5683	0.5922
0.5210	0.6183
0.5037	0.6521
0.5109	0.4358
0.5445	0.5082
0.6327	0.5803
0.5614	0.5108
0.6086	0.5621
0.6512	0.6142
0.4671	0.4068
0.5025	0.4670
0.5477	0.5305
0.6317	0.6112
0.5415	0.5057
0.6027	0.5608
0.6204	0.6099
0.6197	0.5753
0.6417	0.5990
0.6666	0.6330
0.1075	0.1384
0.1000	0.1629
0.1085	0.1993
0.1495	0.1818
0.1887	0.2135
0.1724	0.2426
0.2015	0.2398
0.2176	0.2591
0.2336	0.2807
0.1930	0.1483
0.2431	0.1800
0.2994	0.2242
0.2579	0.1893
0.2755	0.2122
0.3021	0.2455
0.3044	0.2408
0.3214	0.2576
0.3468	0.2839
0.3784	0.3367
0.3947	0.3524

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Learning Set”*

$P_{wexp}$	$P_{wcalc}$
0.4006	0.3484
0.4409	0.4164
0.4396	0.4356
0.4573	0.4355
0.3266	0.2324
0.4226	0.2808
0.4805	0.3488
0.4217	0.2698
0.4701	0.3072
0.5461	0.3655
0.4141	0.3179
0.4435	0.3443
0.4714	0.3897
0.2402	0.2346
0.2962	0.2853
0.3469	0.3494
0.3011	0.2683
0.3135	0.3063
0.3397	0.3643
0.3476	0.3322
0.3594	0.3684
0.2868	0.2178
0.3602	0.2446
0.4167	0.2789
0.4434	0.3259
0.3651	0.2826
0.4093	0.3043
0.4431	0.3252
0.4813	0.3526
0.2590	0.2074
0.3573	0.2815
0.3576	0.2621
0.4558	0.3535
0.4566	0.3388
0.4566	0.3249
0.4562	0.3299
0.5546	0.4436
0.5550	0.4651
0.5555	0.4473
0.5566	0.4095
0.6535	0.5008
0.1599	0.1534
0.2622	0.1948
0.3649	0.2276
0.4355	0.2869

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Learning Set”*

$P_{wexp}$	$P_{wcalc}$
0.4520	0.4359
0.5143	0.4945
0.5732	0.5604
0.5375	0.5296
0.5856	0.5661
0.6371	0.6061
0.6267	0.6192
0.6379	0.6350
0.6813	0.6546
0.4661	0.4330
0.5297	0.4943
0.6056	0.5643
0.5614	0.5296
0.6194	0.5862
0.6754	0.6308
0.6456	0.6277
0.6921	0.6454
0.7177	0.6653
0.7357	0.7172
0.7789	0.7160
0.2439	0.2303
0.2867	0.2609
0.3281	0.3047
0.3042	0.2938
0.3354	0.3154
0.3640	0.3383
0.3845	0.3621
0.3913	0.3760
0.4124	0.3835
0.4807	0.4426
0.4659	0.4602
0.4652	0.4584
0.2493	0.2326
0.2680	0.2600
0.3053	0.3025
0.3116	0.2913
0.3456	0.3130
0.3492	0.3392
0.3692	0.3556
0.3849	0.3753
0.4042	0.3825
0.4318	0.3593
0.4606	0.3753
0.4760	0.3829
0.3224	0.2455

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Learning Set”*

$P_{wexp}$	$P_{wcalc}$
0.3561	0.2821
0.3892	0.3273
0.3866	0.3031
0.4137	0.3260
0.4458	0.3535
0.4517	0.3694
0.4774	0.3800
0.4864	0.3866
0.5339	0.4524
0.5424	0.4552
0.5624	0.4461
0.2143	0.2440
0.2313	0.2829
0.2742	0.3272
0.2958	0.3035
0.3027	0.3233
0.2775	0.3482
0.3515	0.3702
0.3754	0.3779
0.3843	0.3848
0.4252	0.4565
0.4232	0.4546
0.4370	0.4452
0.3679	0.3089
0.3889	0.3378
0.3954	0.3612
0.4272	0.3725
0.4519	0.3810
0.4835	0.4431
0.4969	0.4582
0.5123	0.4548
0.2143	0.2364
0.2379	0.2643
0.2742	0.3044
0.2879	0.2995
0.3076	0.3165
0.3197	0.3376
0.3453	0.3598
0.3579	0.3755
0.3717	0.3834
0.4255	0.4380
0.4266	0.4646
0.4396	0.4628
0.3312	0.2946
0.3764	0.3141

**7.10.5** Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Learning Set”*

$P_{wexp}$	$P_{wcalc}$
0.3649	0.3385
0.4373	0.3616
0.4488	0.3758
0.4435	0.3866
0.5349	0.4493
0.5192	0.4712
0.4940	0.4552
0.2765	0.2294
0.3322	0.2632
0.3790	0.3053
0.3512	0.2934
0.3692	0.3147
0.4078	0.3398
0.4254	0.3613
0.4160	0.3761
0.4370	0.3835
0.5084	0.4407
0.4891	0.4580
0.5162	0.4540
0.2355	0.3048
0.3283	0.3634
0.3294	0.3769
0.3265	0.3834
0.4122	0.4420
0.4029	0.4592
0.2316	0.2286
0.2736	0.2623
0.3156	0.3027
0.2687	0.2942
0.3228	0.3143
0.3484	0.3376
0.3555	0.3634
0.3744	0.3763
0.3852	0.3835
0.4357	0.4411
0.4295	0.4591
0.4403	0.4538
0.2993	0.3633
0.2987	0.3762
0.2972	0.3836

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Test Set”*

$P_{wexp}$	$P_{wcalc}$
0.3124	0.4071
0.3877	0.4740
0.4612	0.5484
0.5490	0.6199
0.6221	0.6832
0.4194	0.5122
0.4676	0.5552
0.5093	0.6034
0.5444	0.6563
0.6254	0.7044
0.2594	0.3439
0.3581	0.4463
0.3596	0.4231
0.4570	0.5594
0.4564	0.5408
0.4574	0.5526
0.5546	0.6546
0.5540	0.6589
0.5540	0.6432
0.5565	0.6605
0.6526	0.7171
0.6531	0.7501
0.6530	0.7445
0.6524	0.7321
0.6522	0.7368
0.7510	0.7765
0.7512	0.7963
0.7516	0.7930
0.2330	0.3077
0.3713	0.4118
0.4593	0.5067
0.5494	0.6050
0.4455	0.4430
0.5179	0.5144
0.5939	0.5865
0.5781	0.5405
0.6062	0.5814
0.3987	0.4288
0.5047	0.5182
0.5855	0.6096
0.7021	0.6940
0.7668	0.7569
0.5969	0.5961
0.6512	0.6647
0.7089	0.7249
0.7897	0.7731

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Test Set”*

$P_{wexp}$	$P_{wcalc}$
0.4408	0.5303
0.4557	0.4926
0.5546	0.5588
0.5549	0.5852
0.6531	0.6535
0.6531	0.6437
0.6531	0.6677
0.7530	0.7470
0.7503	0.7557
0.7514	0.7812
0.7511	0.7733
0.7514	0.7926
0.4282	0.4729
0.5025	0.5656
0.6048	0.6550
0.6917	0.7242
0.5585	0.5625
0.5897	0.6302
0.6161	0.6958
0.7027	0.7508
0.3577	0.4045
0.4573	0.4724
0.4555	0.4990
0.5542	0.5627
0.5544	0.5798
0.6520	0.6330
0.6532	0.6788
0.6525	0.7148
0.2507	0.3262
0.4433	0.4502
0.5635	0.5695
0.6617	0.6783
0.7482	0.7517
0.1783	0.2086
0.2315	0.2331
0.3053	0.2808
0.3492	0.3492
0.2444	0.2535
0.2946	0.2693
0.3473	0.3348
0.3880	0.4002
0.2595	0.2432
0.2603	0.2363
0.3574	0.3512
0.3575	0.3222

**7.10.5** Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Test Set”*

$P_{wexp}$	$P_{wcalc}$
0.3574	0.3387
0.4568	0.4584
0.4561	0.4492
0.4555	0.4447
0.4557	0.4396
0.1814	0.1899
0.2715	0.2363
0.3403	0.3030
0.3970	0.3857
0.3377	0.3990
0.4047	0.4673
0.4773	0.5411
0.5550	0.6108
0.4235	0.4871
0.4649	0.5347
0.4995	0.5854
0.5499	0.6389
0.5903	0.6889
0.2596	0.3501
0.3588	0.4284
0.3590	0.4255
0.4559	0.5213
0.4571	0.5275
0.4565	0.5134
0.5551	0.6285
0.5541	0.6224
0.5546	0.6266
0.5544	0.6513
0.6531	0.7160
0.6538	0.7334
0.6525	0.7328
0.6534	0.7145
0.6525	0.7218
0.1754	0.2755
0.3094	0.3698
0.4226	0.4694
0.4809	0.5558
0.5622	0.6363
0.3503	0.4015
0.4141	0.4703
0.4773	0.5428
0.4945	0.6120
0.4726	0.5114
0.4946	0.5607
0.5180	0.6142

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*"Test Set"*

$P_{wexp}$	$P_{wcalc}$
0.2715	0.3313
0.3850	0.4278
0.4494	0.5203
0.5667	0.5814
0.5705	0.6045
0.5100	0.6350
0.4374	0.4036
0.5054	0.4703
0.5693	0.5410
0.5438	0.4898
0.5863	0.5350
0.6323	0.5875
0.6754	0.6424
0.4855	0.4317
0.5297	0.5064
0.5994	0.5769
0.5372	0.4984
0.5726	0.5367
0.6073	0.5896
0.6328	0.6376
0.6302	0.5883
0.6508	0.6148
0.6748	0.6459
0.1092	0.1502
0.1075	0.1797
0.1242	0.2228
0.1601	0.1999
0.1714	0.2304
0.2068	0.2355
0.2077	0.2476
0.2366	0.2639
0.1626	0.1377
0.2123	0.1601
0.2693	0.1981
0.2310	0.1777
0.2837	0.2087
0.2883	0.2288
0.3007	0.2361
0.3142	0.2457
0.3335	0.2727
0.3620	0.3107
0.3918	0.3538
0.4013	0.3485
0.4325	0.3874
0.4406	0.4302

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Test Set”*

$P_{wexp}$	$P_{wcalc}$
0.4494	0.4396
0.2628	0.2148
0.3875	0.2537
0.4449	0.3123
0.3934	0.2580
0.4376	0.2849
0.4559	0.3319
0.4039	0.3083
0.4288	0.3286
0.4671	0.3646
0.2153	0.2169
0.2659	0.2536
0.3194	0.3159
0.2936	0.2591
0.3217	0.2843
0.3338	0.3357
0.3486	0.3193
0.3538	0.3476
0.3767	0.3897
0.3298	0.2294
0.3859	0.2604
0.4461	0.3034
0.4392	0.3528
0.3877	0.2935
0.4275	0.3160
0.4636	0.3384
0.4801	0.3690
0.2597	0.1943
0.3579	0.2741
0.3584	0.2468
0.4564	0.3666
0.4564	0.3582
0.4553	0.3408
0.5546	0.4239
0.5548	0.4612
0.5536	0.4559
0.5544	0.4320
0.6533	0.4692
0.3180	0.2098
0.3947	0.2559
0.4923	0.3490
0.4819	0.4654
0.5418	0.5270
0.6455	0.5940
0.5544	0.5465

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Test Set”*

$P_{Wexp}$	$P_{Wcalc}$
0.6284	0.5859
0.6585	0.6286
0.6414	0.6277
0.6471	0.6442
0.7029	0.6646
0.5025	0.4642
0.5598	0.5298
0.6443	0.5961
0.5837	0.5474
0.6463	0.6076
0.6383	0.6185
0.6662	0.6357
0.7018	0.6546
0.7399	0.7158
0.7461	0.7162
0.8005	0.7166
0.2702	0.2425
0.3023	0.2831
0.3446	0.3246
0.3208	0.3046
0.3528	0.3271
0.3695	0.3532
0.3832	0.3714
0.3981	0.3806
0.4146	0.3874
0.4777	0.4534
0.4638	0.4606
0.4659	0.4485
0.2565	0.2440
0.2795	0.2802
0.3450	0.3269
0.3368	0.3060
0.3355	0.3233
0.3505	0.3521
0.3646	0.3566
0.3875	0.3775
0.4078	0.3864
0.4501	0.3711
0.4717	0.3781
0.2801	0.2305
0.3535	0.2618
0.3712	0.3044
0.3659	0.2940
0.4013	0.3150
0.4279	0.3388

7.10.5 Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*"Test Set"*

$P_{wexp}$	$P_{wcalc}$
0.4363	0.3615
0.4553	0.3748
0.4819	0.3825
0.5195	0.4389
0.5352	0.4567
0.5513	0.4499
0.1904	0.2276
0.2388	0.2610
0.2404	0.3029
0.2801	0.2874
0.2831	0.3108
0.2893	0.3382
0.3451	0.3612
0.3676	0.3747
0.3802	0.3833
0.4180	0.4400
0.4213	0.4510
0.4367	0.4511
0.3613	0.3019
0.3910	0.3250
0.4038	0.3508
0.4095	0.3670
0.4435	0.3789
0.4593	0.3851
0.4897	0.4525
0.4897	0.4551
0.5182	0.4453
0.2313	0.2515
0.2523	0.2833
0.3019	0.3297
0.2989	0.3093
0.3155	0.3260
0.3220	0.3530
0.3513	0.3696
0.3799	0.3802
0.3783	0.3871
0.4308	0.4558
0.4360	0.4686
0.4435	0.4527
0.3361	0.3040
0.3528	0.3256
0.3748	0.3530
0.4370	0.3705
0.4367	0.3792
0.4380	0.3869

**7.10.5** Valores da pressão de rejeito  $p_w$  experimentais e calculados pela rede neural com sete neurônios na camada oculta (cont.)

*“Test Set”*

$p_{wexp}$	$p_{wcalc}$
0.5208	0.4649
0.5103	0.4716
0.4989	0.4565
0.3162	0.2452
0.3541	0.2814
0.4059	0.3263
0.3646	0.3034
0.3869	0.3251
0.4183	0.3528
0.4200	0.3715
0.4221	0.3796
0.4504	0.3864
0.4966	0.4535
0.4874	0.4581
0.4989	0.4478
0.2768	0.3395
0.3311	0.3707
0.3254	0.3809
0.3297	0.3879
0.4063	0.4535
0.3846	0.4558
0.2499	0.2445
0.2922	0.2813
0.3461	0.3275
0.2861	0.3045
0.3345	0.3251
0.3776	0.3528
0.3621	0.3708
0.3767	0.3796
0.3803	0.3877
0.4313	0.4531
0.4357	0.4580
0.4276	0.4486
0.2970	0.3705
0.2938	0.3801

**7.10.6** Pesos da rede neural para o cálculo da pressão de rejeito  $p_w$  com sete neurônios na camada interna

**Pesos da camada oculta**

2.16E+00	1.92E+00	-3.17E+00	9.53E-02	-3.02E+00	-6.69E-01	3.98E-01
-1.59E+00	-8.21E-01	4.59E-01	-1.27E+00	5.08E+00	-1.03E+00	1.18E+00
-6.09E-01	6.95E-02	1.57E-01	-5.35E-01	2.04E+00	-4.39E-01	5.25E-02
9.14E-01	-2.02E+00	-8.82E-01	-5.12E-01	-3.63E-01	1.22E+00	3.16E+00
3.61E-01	-1.18E+00	-1.90E-01	3.29E-01	-1.31E+00	-9.61E-01	-3.61E+00
5.63E-01	2.03E-01	8.59E-01	2.65E-02	4.74E-01	7.34E-01	8.99E-01

**Pesos da camada de saída**

1.96E+00  
 -4.41E+00  
 -2.73E+00  
 -8.52E-01  
 4.23E+00  
 6.60E-01  
 -2.96E+00  
 2.28E-01

## 7.10.7 Valores experimentais dos ensaios de verificação

*L6-24/98*

$p_p$	F	$\delta U$	$p_w$
0.3172	0.1574	0.5909	0.4439
0.3172	0.2164	0.6433	0.4445
0.3172	0.2715	0.7434	0.4659
0.3172	0.3286	0.7884	0.4811
0.3172	0.3857	0.8065	0.4925
0.3172	0.4431	0.8310	0.4958
0.4055	0.1584	0.5197	0.5536
0.4055	0.2145	0.6028	0.5648
0.4055	0.2715	0.6696	0.5408
0.4055	0.3286	0.7536	0.5441
0.4055	0.3857	0.7824	0.5438
0.4055	0.4431	0.8367	0.5516
0.5158	0.1574	0.4136	0.6693
0.5158	0.2145	0.5018	0.6679
0.5158	0.2715	0.6104	0.6428
0.5158	0.3286	0.6884	0.6337
0.5158	0.3857	0.7421	0.6273
0.5158	0.4431	0.7621	0.6469

## 7.10.8 Valores experimentais dos ensaios de verificação (cont.)

*L1-16/98*

$p_p$	F	$\delta U$	$p_w$
0.2216	0.1000	0.5295	0.1720
0.2216	0.2715	0.7491	0.2093
0.2216	0.4431	0.7470	0.2303
0.3172	0.1574	0.6667	0.2732
0.3172	0.2145	0.7649	0.2698
0.3172	0.2715	0.7550	0.2726
0.3172	0.3286	0.7668	0.2722
0.3172	0.3857	0.8537	0.2694
0.3172	0.4431	0.7889	0.2637
0.4055	0.1000	0.4623	0.3689
0.4055	0.1584	0.6122	0.3518
0.4055	0.2145	0.7090	0.3416
0.4055	0.2715	0.7530	0.3357
0.4055	0.3286	0.7959	0.3435
0.4055	0.3876	0.8718	0.3325
0.4055	0.4431	0.8624	0.3308
0.5158	0.1574	0.5286	0.4510
0.5158	0.2145	0.6421	0.4418
0.5158	0.2706	0.7242	0.4213
0.5158	0.3286	0.7592	0.4050
0.5158	0.3857	0.7870	0.3881
0.5158	0.4421	0.8156	0.3840

## 7.11 Referências

- [7.1] ROSS, P.J. *Aplicação das Técnicas Taguchi na Engenharia da Qualidade*. São Paulo, SP: Makron Books – McGraw-Hill, 1991.

## 8 CONCLUSÃO

A aplicação da técnica de modelagem de processos por redes neurais ao desempenho separativo de ultracentrífugas se mostrou uma poderosa ferramenta a ser aplicada no desenvolvimento deste tipo de equipamento. Foram usadas redes neurais com três camadas do tipo “feedforward”, treinadas com o algoritmo de retro-propagação.

A modelagem dos parâmetros separativos e operacionais de um tipo de centrífuga, com sua configuração de montagem definida, foi altamente satisfatória. Esta foi a situação estudada, para cortes fixos, no segundo caso do Capítulo 4 e no Capítulo 5 onde se verificou desvios da ordem de 1% entre a previsão e os dados de experimentos de verificação. Considerando a operação com cortes diversos, no Capítulo 6 foi criado um modelo numérico com grande capacidade de previsão, cujos resultados foram reproduzidos com erros menores que 10%, valor este aceitável face os erros experimentais usualmente observados nesses ensaios. Este modelo é uma ferramenta muito valiosa nos cálculos de cascata, onde os parâmetros separativos das centrífugas são calculados a cada iteração em cada estágio que compõe a cascata até a convergência do sistema. Este modelo, além de ser rápido, fornece resultados muito próximos aos valores reais, diminuindo significativamente possíveis perdas de eficiência por misturas de correntes de composições diferentes, na operação dos arranjos em cascata.

Maior interesse existe na modelagem de centrífugas com diferentes características, representadas pelos parâmetros de montagem. Este caso foi inicialmente avaliado no Capítulo 4, no primeiro estudo, com resultados coerentes e aparentemente satisfatórios, porém sem possibilidade de verificação experimental. O Capítulo 7 tratou do estudo do maior conjunto de dados experimentais disponível, onde várias configurações de montagem de um modelo de centrífuga haviam sido avaliadas. Os dados disponíveis não

possuíam a qualidade desejada, tanto em termos da distribuição das variáveis de entrada como em termos dos erros experimentais avaliados, mas após uma exaustiva análise, foram selecionados os ensaios mais confiáveis, a partir dos quais foi definido o modelo numérico dos parâmetros desejados. Foram treinadas duas redes neurais independentes, uma para o cálculo do poder de separação  $\delta U$  e outra para a pressão na linha de retirada do rejeito  $p_w$ . A previsão obtida para a pressão  $p_w$  apresentou bons resultados, principalmente tendo em mente as deficiências do conjunto de dados experimentais, usado na geração do modelo. Este se mostrou um excelente modelo para avaliação qualitativa dos níveis de pressão esperados na operação de uma centrífuga. O modelo para o cálculo do poder de separação  $\delta U$ , por sua vez, não foi capaz de prever satisfatoriamente o desempenho separativo de uma centrífuga operando com baixos fluxos de alimentação, mas para valores intermediários apresentou desvios razoáveis. Uma vez que os maiores valores do poder de separação  $\delta U$  usualmente se apresentam em fluxos de alimentação intermediários, este modelo pode ser usado como uma ferramenta para a continuidade ou confirmação da otimização do equipamento. As superfícies de resposta e a análise de sensibilidade do modelo encontrado se apresentaram coerentes com as expectativas teóricas. Assim sendo, o modelo obtido foi considerado satisfatório para a finalidade de orientar a continuidade de um programa de otimização desta centrífuga.

No entanto, para o sucesso da tarefa de modelagem de uma centrífuga alguns aspectos devem ser ressaltados:

- é imprescindível o profundo conhecimento do processo a ser modelado, tanto de seus aspectos teóricos como de seus aspectos práticos, com relação aos ensaios onde os dados experimentais são gerados;
- as variáveis de entrada e as respostas do sistema devem ser cuidadosamente identificadas e analisadas; a partir daí deve ser procurado o melhor arranjo para a apresentação à rede neural na etapa de treinamento;

- deve ser observada também a distribuição dos dados experimentais no domínio das variáveis; baixas concentrações próximas aos limites do domínio podem acarretar problemas no treinamento; deve-se ter atenção também à distribuição dos dados entre os conjuntos de treinamento e de teste;
- como critério de escolha do número de neurônios da camada interna da rede neural optou-se pela rede que apresentasse menor erro total com relação ao conjunto de teste, procurando escolher redes com o menor número de neurônios e o menor número de apresentações durante o treinamento para evitar super-ajuste do modelo aos dados experimentais;
- é sempre aconselhável a análise do modelo obtido através da análise de resíduos, verificando a coerência de suas respostas e, quando possível, realizando ensaios de verificação;
- a análise de sensibilidade é facilmente executada, mas deve ser cuidadosamente interpretada; as derivadas parciais normalizadas indicam a importância relativa entre as variáveis estudadas mas não têm significado físico e seus valores absolutos devem considerar cuidadosamente as unidades das variáveis envolvidas.

Os modelos numéricos obtidos através da técnica de redes neurais se apresentam como rotinas de cálculo extremamente rápidas, permitindo a exploração de toda a superfície de resposta. Os cálculos de cascata, onde os parâmetros das centrífugas são calculados até a convergência do sistema, se tornam muito mais eficientes com a utilização dos modelos obtidos por redes neurais. Modelos considerando diferentes configurações das variáveis internas representam uma ferramenta poderosíssima no desenvolvimento, análise e otimização de ultracentrífugas.

Como proposta para continuidade deste estudo seria interessante o aprimoramento do modelo descrito no Capítulo 7 com a realização de novos ensaios de separação, com o desenho da centrífuga consolidado, de modo a termos dados experimentais mais confiáveis. A longo prazo, com a disponibilidade de dados de diferentes tipos de centrífugas, sugerimos a aplicação desta técnica de modelagem para as futuras gerações de centrífugas, com a criação inclusive de um modelo mais abrangente, considerando então as variáveis externas das centrífugas. Com isso seria possível realizar a estimativa do desempenho de centrífugas na fase de concepção do projeto, antes mesmo dos testes dos primeiros protótipos.

A técnica de redes neurais também pode ser facilmente empregada para a interpolação e conseqüente análise de resultados gerados por modelos fenomenológicos, que normalmente consomem considerável tempo de CPU para o cálculo de um caso específico.

## REFERÊNCIAS BIBLIOGRÁFICAS

(em ordem alfabética, com referências às citações)

- AVERY,D.G.; DAVIS,E. *Uranium Enrichment by Gas Centrifuges*. London: Mills and Boon, 1973. [2.7]
- BHAT,N.; McAVOY,T. Use of neural nets for dynamic modeling and control of chemical process systems. *Comput. Chem. Eng.*, v.14, n.4/5, p.573-583, 1990. [3.6]
- BHAT,N.V.; MINDERMAN Jr,P.A.; McAVOY,T.; WANG,N.S. Modeling chemical process systems via neural computation. *IEEE Control Systems Magazine*, v.4, p.24-30, 1990. [3.5]
- BENEDICT,M.; PIGFORD,T.H.; LEVI,H.W. *Nuclear Chemical Engineering*. 2.ed., New York, NY: McGraw-Hill, 1981. [2.2]
- BEVERIDGE,G.S.G.; SCHECHTER,R.S. *Optimization: Theory and Practice*. Tokyo: McGraw-Hill Kogakusha,, 1970. [3.27]
- BOX,G.E.P.; HUNTER,W.G; HUNTER,J.S. *Statistics for Experimenters: An Introduction to Design, Data Analysis and Model Building*. New York, NY: Wiley, 1978. [3.24]
- CHAN,W.M.; NASCIMENTO,C.A.O. Use of neural networks for modeling of olefin polymerization in high pressure tubular reactors. *J. Appl. Polymer Sci.*, v.53, p.1277-1289, 1994. [3.10]
- COHEN,K. *The Theory of Isotope Separation as Applied to the Large Scale Production of U<sup>235</sup>*. New York, NY: McGraw-Hill, 1951. [2.1]
- CUTTS,D.; HOFTUN,J.S.; NESIC,D.; SOMBORGER,A.; JONHSON,C.R.; ZELLER,R.T. Applications of neural networks in high energy physics. In: CONFERENCE ON COMPUTING IN HIGH ENERGY PHYSICS, Apr. 1990, Santa Fe, NM. **Proceedings...**[sl.:sn] 1990. (CONF-9004190-AIP). [3.13]

- DENBY,B. Tutorial on neural network applications in high energy physics: A 1992 perspective. In: INTERNATIONAL WORKSHOP ON SOFTWARE ENGINEERING, ARTIFICIAL INTELLIGENCE (AI) AND NEURAL NETS FOR HIGH ENERGY AND NUCLEAR PHYSICS, 2., 13-18 Jan. 1992, L'Agelonde (France). *Proceedings...* (CONF-920172-7). [3.12]
- DRAPER,N.R.; SMITH,H. *Applied Regression Analysis*. 2. ed. New York, NY: Wiley, 1981. [3.25]
- ERYÜREK,E.; TÜRCKAN,E. Neural networks for sensor validation and plant-wide monitoring., Netherlands Energy Research Foundation (ECN), Aug., 1991. Petten. (ECN-RX-91-089). [3.19]
- ERYÜREK,E.; UPADHYAYA,B.R.; KAVAKLIOGLU,K. Hybrid digital processing and neural networks applications in PWRs. Tennessee Univ., Dept. of Nuclear Engineering Knoxville, 1991. Knoxville, TN. (CONF-9109110-10). [3.20]
- FURRY,W.H.; JONES,R.C.; ONSAGER,L. On the theory of isotope separation by thermal diffusion. *Phys. Rev.*, v.55, p.1083-1095, 1939. [2.6]
- GUO,Z.; UHRIG,R.E. Use of artificial neural networks to analyze nuclear power plant performance. *Nucl. Technol.*, v.99, p.36-42, 1992. [6.4]
- HIMMELBLAU,D.M. *Process Analysis by Statistical Methods*. New York, NY: Wiley, 1970. [3.26]
- HOSKINS,J.C.; HIMMELBLAU,D.M. Artificial neural network models of knowledge representation in chemical engineering. *Comput. Chem. Eng.*, v.12, n.9/19, p.881-890, 1988. [3.1]
- HOSKINS,J.C.; HIMMELBLAU,D.M. Fault detection and diagnosis using artificial neural networks, In: MAVROVOUNIOTS,M.L. (ed.) *Artificial Intelligence in Process Engineering*. New York, NY: Academic Press, 1990, p.123-160. [3.2]
- HORNIK,K.; STINCHOMBE.M.; WHITE,H. Multilayer feedforward networks are universal approximators. *Neural Networks*, v.2, p.359-366, 1989. [4.4], [5.2]

- PETERSON,C. Neural networks and high energy physics. In: PERRET-GALLIX,D.; WOJCIK,W. (eds.). *New computing techniques in physics research*. Paris: Institut National de Physique Nucleaire et de Physique des Particules (IN2P3), 1990. p.465-480. (ISBN 2-222-04514-2). [3.14]
- POLLARD,J.F.; BROUSSARD,M.R.; GARRISON,D.B.; SAN,K.Y. Process identification using neural networks. *Comput. Chem. Eng.*, v.16, n.4, p.253-270, 1992. [3.21], [4.3]
- PSICHOGIOS,D.C.; UNGAR,L.H. Direct and indirect model based control using artificial neural networks. *Ind. Eng. Chem. Res.*, v.30, p.2564-2573, 1991. [3.8]
- RÄTZ,E. Uranium isotope separation in the gas centrifuge. Rhode Saint Genese: Von Karman Institute For Fluid Dynamics, Jul. 1978 (Pres. at VKI Lecture series entitled: Aerodynamic Separation of Gases and Isotopes, May,29 – Jun.,2, 1978). [2.4]
- ROSS, P.J. *Aplicação das Técnicas Taguchi na Engenharia da Qualidade*. São Paulo, SP: Makron Books – McGraw-Hill, 1991. [7.1]
- RUMELHART,D.; McCLELLAND,J. Parallel distributed processing explorations in the microstructure of cognition. Cambridge, Mass.: MIT, v.1, cap.8, 1986. [3.22]
- SOUBBARAMAYER Centrifugation. In: VILLANI,S., (ed.) *Uranium Enrichment*. Berlin: Springer Verlag, 1979. p.183- 243. [2.9]
- SU,H.T.; McAVOY,T.; WERBOS,P. Long-term predictions of chemical processes using recurrent neural networks: A parallel training approach. *Ind. Eng. Chem. Res.*, v.31, p.1338-1352, 1992. [3.9]
- TANABE,A.; YAMAMOTO,T.; SHINFUKU,K.; NAKAMAE,T. Neural network application to the survey of enrichment and local power. In: INTERNATIONAL CONFERENCE ON STRUCTURAL MECHANICS IN REACTOR TECHNOLOGY, 11. 1991, **Proceedings...** Tokyo: Atomic Energy Society of Japan, 1991. p.127-132. [3.18]
- UNGAR,L.H.; POWEL,B.A.; KAMENS,S.N. Adaptive networks for fault diagnosis and process control. *Comput. Chem. Eng.*, v.14, n.4/5, p.572-651,1990. [3.7]

- UHRIG,R.E. Application of neural networks to the operation of nuclear power plants. In: JSME/ASME JOINT INTERNATIONAL CONFERENCE ON NUCLEAR ENGINEERING, 4-7 Nov. 1991, Tokyo. **Proceedings...** Tokyo: Japan Society of Mechanical Engineers, 1991. v.2, p.365-369. [3.15]
- UHRIG,R.E. Neural networks and their potential application in nuclear power plants. In: NASER,J.A. *Expert Systems Applications for Electric Power Industry*. New York, NY, Hemisphere, 1991. p.1435-1446. (CONF-8900634). [3.16]
- UHRIG,R.E. Neural networks and their potential applications to nuclear power plants. In: INTERNATIONAL CONFERENCE ON FRONTIERS IN INNOVATIVE COMPUTING FOR THE NUCLEAR INDUSTRY, Jackson, WY, 15-18 Sep., 1991. **Proceedings...** Washington, DC: USDOE, 1991. (CONF-9109110-16). [3.17]
- VENKATASUBRAMANIAM,V.; VAIDYANATHAN,R.; YAMAMOTO,Y. Process fault detection and diagnosis using neural networks – I: Steady state process. *Comput. Chem. Eng.*, v.14, n.7, p.699-712, 1990. [3.3]
- VON HALLE,E. Procedure for the calculation of a the separative performance of a countercurrent gas centrifuge. In: WORKSHOP ON GASES IN STRONG ROTATION, Aug. 24-27, 1981. Oxford. **Proceedings...** USDOE, 1981. (K/OA-5013). [2.10]
- WATANABE,K.; MATSUDA,I.; KUBOTA,M.; HIMMELBLAU,D.M. Incipient fault diagnosis of chemical processes via artificial neural networks. *AIChE Journal*, v.35, n.11, p.1803-1812, 1989. [3.4]
- YIFTAH,S. Neural networks - Potential application in the nuclear industry: Preliminary comments and reflections. In: ISRAEL NUCLEAR SOCIETY ANNUAL MEETING, 1989. Yavne. **Proceedings....**, Mar. 13, 1989. Beer-Sheva. p.56-62. (INIS-mf-11503). [3.11]
- ZIPPE,G. *The development of short bowl ultra-centrifuges*. Charlottesville, VI: University of Virginia, research Laboratories for the Engineering Science, 1960. (ORO-315). [3.23], [4.2]

- JORDAN, I. *Separação dos isótopos de urânio pelo processo da centrifugação em fase gasosa*. São Paulo, SP: Instituto de Pesquisas Energéticas e Nucleares, 1980. (IPEN-Inf-3). [2.3], [4.1]
- JORDAN, I.; BUCHMANN, J.H. *Teoria de separação isotópica na centrifuga a contracorrente e cálculo dos parâmetros de separação*. São Paulo, SP: Instituto de Pesquisas Energéticas e Nucleares, Jul. 1983. (IPEN-Pub. C-5). [2.11]
- KAHANER, D.; MOLER, C.; NASH, S. *Numerical Methods and Software*. New Jersey, NJ: Prentice-Hall, 1989. [3.28], [6.1]
- KAI, T. Theoretical research on gas-centrifugal separation for uranium enrichment. *J. Nucl. Sci. Technol.*, v.26, n.1, p.157-160, 1989. [2.5], [4.5]
- LAHARGUE, J.P. & SOUBBARAMAYER A numerical model for the investigation of the flow and isotope concentration field in an ultracentrifuge. *Comp. Meth. in Appl. Mech. and Eng.*, v.15, n.2, p.259-273, 1978. [2.14]
- MAKIHARA, H. & ITO, T. Separation characteristics of gas centrifuges - Approximate analyses of separation performance. *J. Nucl. Sci. Technol.*, v.25, n.8, p.649-666, 1988. [2.16]
- MIGLIAVACCA, S.C.P. *Cálculo dos parâmetros de separação de uma centrífuga a contracorrente com variação axial do fluxo interno*. São Paulo, SP, 1991. Dissertação (Mestrado) - Instituto de Pesquisas Energéticas e Nucleares. [2.13], [6.3]
- NAKAYAMA, W. & TORII, T. Numerical analysis of separative power of isotope centrifuges (I). *J. Nucl. Sci. Technol.*, v.11, n.11, p.495-504, 1974. [2.15]
- NASCIMENTO, C.A.O.; OLIVEROS, E. & BRAUN, A.M. Neural network modeling for photochemical processes. *Chem. Eng. Proc.*, v.33, p.319-324, 1994. [5.1], [6.2]
- OLANDER, D.R. Technical basis of the gas centrifuge. *Adv. Nucl. Sci. Tech.*, v.6, p.105-174, 1972. [2.8]
- OLANDER, D.R. The theory of uranium enrichment by the gas centrifuge. *Prog. Nucl. Energy*, v.8, p.1-33, 1981. [2.12]