

## 4 Resultados

Conforme mencionado no Capítulo 3, a metodologia utilizada no presente trabalho para modelar a qualidade do PEBD baseou-se em três etapas: coleta dos dados operacionais, pré-processamento dos dados operacionais e determinação do modelo neural. O desenvolvimento das duas primeiras etapas foi detalhado nas Seções 3.2.1 e 3.2.2, respectivamente. Neste capítulo, serão descritas as atividades realizadas durante a terceira etapa, conforme ilustra a Figura 10.

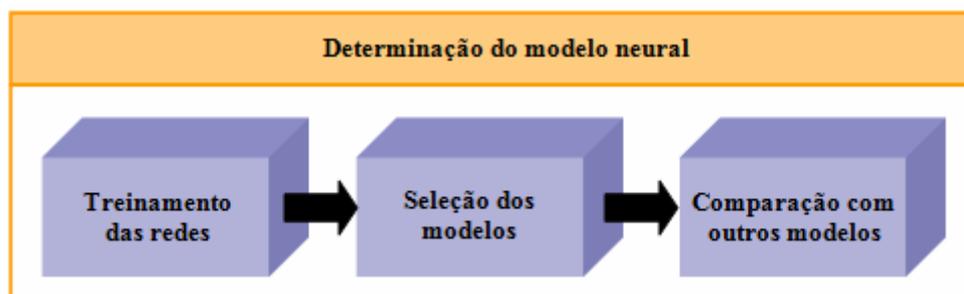


Figura 10 – Atividades realizadas durante o desenvolvimento do modelo neural da qualidade do PEBD

### 4.1. Treinamento das redes neurais artificiais

Após terem sido submetidos à etapa de pré-processamento, os dados operacionais correspondentes às variáveis de processo do sistema reacional de produção de PEBD foram empregados como dados de entrada das redes neurais artificiais testadas neste estudo. É importante salientar que a métrica aplicada para determinação dos erros de treinamento e de validação foi o erro médio absoluto percentual (MAPE – *mean absolute percent error*). O cálculo do MAPE foi realizado através da equação (4.1), onde  $N$  representa a quantidade de dados de entrada apresentados à rede neural artificial,  $d_i$  representa o valor do índice de fluidez medido no laboratório e  $Y_i$  representa o valor do índice de fluidez gerado

pela rede neural artificial. Convém mencionar que, para o cálculo do MAPE, ambos os valores do índice de fluidez ( $d_i$  e  $Y_i$ ) devem ser não-normalizados.

$$MAPE = \frac{\sum_{i=1}^N (d_i - Y_i)d_i}{N} \times 100\% \quad (4.1)$$

O treinamento das redes neurais artificiais foi feito utilizando-se a técnica de validação cruzada descrita na seção 3.2.3. De forma a considerar o efeito da inicialização randômica dos pesos no desempenho da rede, cada configuração de rede neural foi inicializada e treinada cinco vezes. Após cada inicialização e treinamento, o MAPE da rede foi calculado tanto para os dados de treinamento, quanto para os dados de validação. Ao final das cinco rodadas, o erro de cada configuração foi considerado como sendo a média do MAPE de validação das cinco inicializações, conforme o cálculo apresentado na equação (4.2).

$$Erro = \frac{\sum_{i=1}^5 MAPE_i}{5} \quad (4.2)$$

## 4.2. Seleção dos modelos

O desempenho dos modelos neurais foi avaliado com base nos valores do erro de validação, cujo cálculo foi feito através da equação (4.2). De fato, o desempenho de cada modelo foi calculado como sendo a média dos valores do erro de validação das cinco tentativas de treinamento, conforme o cálculo apresentado na equação (4.3). Neste contexto, considerou-se que a melhor rede era aquela que apresentava o menor valor de desempenho ao final das cinco tentativas.

$$Desempenho = \frac{\sum_{i=1}^5 Erro_i}{5} \quad (4.3)$$

As Tabelas 7 a 10 apresentam o erro de validação, calculado através da equação (4.2), para cada configuração de rede neural considerada neste estudo. A Tabela 7 está relacionada às redes neurais que possuem função de ativação sigmóide na camada de saída, e cujo algoritmo de treinamento não fez uso da otimização de Levenberg-Marquardt. Por outro lado, a Tabela 8 apresenta os resultados relativos às redes neurais que possuem função de ativação linear na camada de saída, e cujo algoritmo de treinamento também não fez uso da otimização de Levenberg-Marquardt. Analogamente, os resultados referentes às redes neurais cujo treinamento fez uso da otimização de Levenberg-Marquardt encontram-se apresentados nas Tabelas 9 e 10. Neste caso, o erro de validação das redes com função de ativação sigmóide na camada escondida está apresentado na Tabela 9, enquanto que o erro de validação das redes com função de ativação linear na camada de saída encontra-se na Tabela 10.

O desempenho dos modelos neurais considerados neste estudo, cujo cálculo foi feito através da equação (4.3), está apresentado nas Tabelas 11 a 14. A Tabela 11 está relacionada às redes neurais que possuem função de ativação sigmóide na camada de saída, e cujo algoritmo de treinamento não fez uso da otimização de Levenberg-Marquardt. Por outro lado, a Tabela 12 apresenta o desempenho das redes neurais que possuem função de ativação linear na camada de saída, e cujo algoritmo de treinamento também não fez uso da otimização de Levenberg-Marquardt. Analogamente, os resultados referentes às redes neurais cujo treinamento fez uso da otimização de Levenberg-Marquardt encontram-se apresentados nas Tabelas 13 e 14. Neste caso, o desempenho das redes com função de ativação sigmóide na camada escondida está apresentado na Tabela 13, enquanto que o desempenho das redes com função de ativação linear na camada de saída encontra-se na Tabela 14.

As Tabelas 11 a 14 também apresentam o tempo de treinamento de cada modelo neural considerado. O tempo de treinamento foi medido em termos do número médio de épocas que foram necessárias para a convergência do modelo neural. Cabe lembrar que o critério de parada do treinamento utilizado neste estudo foi o aumento do erro de validação, já que se fez uso da técnica de validação cruzada. Desta forma, o tempo de treinamento apresentado a seguir refere-se ao número de épocas utilizadas até que o erro de validação do modelo neural começasse a aumentar.

<i>Tentativa 1</i>		<i>Tentativa 2</i>		<i>Tentativa 3</i>	
<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>
1	6,6971	1	8,1760	1	5,9734
2	6,5059	2	4,9812	2	4,6391
3	7,1485	3	4,9301	3	5,9184
4	5,7370	4	5,3999	4	4,8805
5	5,6484*	5	4,7191*	5	5,3800
6	5,9931	6	6,4023	6	4,0808
7	6,0846	7	5,2117	7	3,9334*

<i>Tentativa 4</i>		<i>Tentativa 5</i>	
<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>
1	6,1777	1	6,6572
2	4,4202	2	4,9803*
3	4,5021	3	5,7592
4	5,9716	4	5,5601
5	6,9255	5	6,4694
6	4,2270	6	5,3920
7	3,9422*	7	5,0572

\* valor mínimo do erro de validação para a tentativa em questão

Tabela 7 – Erro de validação dos modelos neurais com função de ativação sigmóide na camada escondida (treinamento sem otimização de Levenberg-Marquardt)

<i>Tentativa 1</i>		<i>Tentativa 2</i>		<i>Tentativa 3</i>	
<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>
1	6,1799	1	5,0796	1	5,0692
2	5,2905	2	6,0280	2	5,5258
3	4,8877	3	5,3164	3	6,4246
4	4,5093	4	6,6709	4	5,7709
5	5,2293	5	4,8433	5	4,1388*
6	5,4110	6	5,4233	6	4,7151
7	4.1611*	7	4,6397*	7	4,9415

<i>Tentativa 4</i>		<i>Tentativa 5</i>	
<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>
1	5,3638	1	6,8715
2	5,7540	2	5,0578*
3	5,0990	3	6,4401
4	6.5433	4	5,5710
5	4,2905*	5	6,3241
6	4,3752	6	5,3079
7	4,5404	7	5,5457

\* valor mínimo do erro de validação para a tentativa em questão

Tabela 8 – Erro de validação dos modelos neurais com função de ativação linear na camada escondida (treinamento sem otimização de Levenberg-Marquardt)

<i>Tentativa 1</i>		<i>Tentativa 2</i>		<i>Tentativa 3</i>	
<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>
1	3,9885	1	3,7185	1	3,2497
2	3,4277	2	3,1672	2	3,2375
3	3,1001	3	3,0734	3	3,0241
4	3,1732	4	3,0440	4	3,0367
5	3,1278	5	2,8766	5	2,9680*
6	3,0838*	6	2,8508*	6	3,0105
7	3,1662	7	2,9541	7	3,0773

<i>Tentativa 4</i>		<i>Tentativa 5</i>	
<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>
1	3,5649	1	3,1551
2	3,5261	2	3,2554
3	3,3755	3	3,0472
4	3,1888*	4	3,0474
5	3,2720	5	3,0097
6	3,3202	6	2,9883*
7	3,2938	7	3,0176

\* valor mínimo do erro de validação para a tentativa em questão

Tabela 9 – Erro de validação dos modelos neurais com função de ativação sigmóide na camada escondida (treinamento com otimização de Levenberg-Marquardt)

<i>Tentativa 1</i>		<i>Tentativa 2</i>		<i>Tentativa 3</i>	
<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>
1	3,7217	1	3,2716	1	3,2499
2	3,3770	2	3,5834	2	3,1950
3	3,1757	3	3,0954	3	3,1263
4	3,1568	4	3,0482	4	3,0394*
5	3,0731*	5	2,9630*	5	3,0604
6	3,1013	6	2,9651	6	3,0462
7	3,1234	7	2,9682	7	3,0534

<i>Tentativa 4</i>		<i>Tentativa 5</i>	
<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>	<i>Número de neurônios na camada escondida</i>	<i>Erro de validação (%)</i>
1	3,6418	1	3,1573
2	3,5897	2	3,0179
3	3,5083	3	3,0621
4	4,2030	4	3,0554
5	3,4381	5	3,0444
6	3,1770*	6	3,0172*
7	3,2912	7	3,0311

\* valor mínimo do erro de validação para a tentativa em questão

Tabela 10 – Erro de validação dos modelos neurais com função de ativação linear na camada escondida (treinamento com otimização de Levenberg-Marquardt)

<i>Número de neurônios na camada escondida</i>	<i>Desempenho do modelo neural (%)</i>	<i>Tempo de treinamento (número médio de épocas)</i>
1	6,7363	185
2	5,1053	171
3	5,6517	184
4	5,5098	193
5	5,8285	181
6	5,2190	175
7	4,8458	196

Tabela 11 – Desempenho dos modelos neurais com função de ativação sigmóide na camada escondida (treinamento sem otimização de Levenberg-Marquardt)

<i>Número de neurônios na camada escondida</i>	<i>Desempenho do modelo neural (%)</i>	<i>Tempo de treinamento (número médio de épocas)</i>
1	5,7128	76
2	5,5312	74
3	5,6335	97
4	5,8131	100
5	4,9652	118
6	5,0465	123
7	4,7657	136

Tabela 12 – Desempenho dos modelos neurais com função de ativação linear na camada escondida (treinamento sem otimização de Levenberg-Marquardt)

<i>Número de neurônios na camada escondida</i>	<i>Desempenho do modelo neural (%)</i>	<i>Tempo de treinamento (número médio de épocas)</i>
1	3,5353	27
2	3,3228	29
3	3,1241	34
4	3,0980	36
5	3,0508	35
6	3,0507	27
7	3,1018	26

Tabela 13 – Desempenho dos modelos neurais com função de ativação sigmóide na camada escondida (treinamento com otimização de Levenberg-Marquardt)

<i>Número de neurônios na camada escondida</i>	<i>Desempenho do modelo neural (%)</i>	<i>Tempo de treinamento (número médio de épocas)</i>
1	3,4085	27
2	3,3526	33
3	3,1936	24
4	3,3005	25
5	3,1158	31
6	3,0614	31
7	3,0935	25

Tabela 14 – Desempenho dos modelos neurais com função de ativação linear na camada escondida (treinamento com otimização de Levenberg-Marquardt)

A análise dos resultados apresentados nas Tabelas 11 a 14 remete à discussão dos seguintes assuntos: a relação entre o tempo de treinamento e o tipo de algoritmo de treinamento utilizado; a relação entre as configurações das redes neurais artificiais e o desempenho das mesmas. Primeiramente, é possível verificar que o tipo algoritmo de treinamento utilizado na etapa de treinamento da rede neural artificial não influenciou diretamente o desempenho de generalização do modelo neural. Na realidade, variações no algoritmo de treinamento, tais como o inclusão da otimização de Levenberg-Marquardt, afetam a rapidez de convergência dos algoritmos, mas não têm efeito sobre a eficiência dos modelos neurais gerados.

Neste contexto, é interessante analisar o tempo de treinamento requerido por cada um dos dois algoritmos de retropropagação do erro utilizados neste trabalho. Conforme pode ser visto nas Tabelas 11 a 14, o algoritmo de treinamento sem otimização de Levenberg-Marquardt necessitou de um número de épocas sempre superior a 70 para gerar redes com erro de predição entre 4 e 7%. Por outro lado, o algoritmo de Levenberg-Marquardt utilizou menos de 40 épocas para gerar modelos neurais cuja precisão variava entre 3 e 4%. Convém salientar que esta precisão mostra-se condizente com os valores de erro de modelagem obtidos pelos modelos neurais descritos na literatura pesquisada. Por exemplo, os melhores modelos neurais desenvolvidos por Rallo e colaboradores (2002) apresentaram erro médio de aproximadamente 4%, enquanto que Abonyi e colaboradores (2003) propuseram modelos neurais com precisão de 3%.

No que diz respeito à influência da configuração da rede neural no desempenho do modelo, os resultados apresentados nas Tabelas 11 a 14 permitem detectar uma forte relação entre variações no número de neurônios na camada escondida e o erro de modelagem da rede neural. De fato, percebe-se que o aumento do número de neurônios está geralmente relacionado com a diminuição do erro de predição do modelo. Esta tendência independe da função de ativação utilizada na camada de saída.

Finalmente, é possível determinar, com base nos valores apresentados nas Tabelas 11 a 14, o modelo neural de melhor desempenho. A configuração da rede neural artificial cujo modelo apresentou maior acurácia na modelagem do índice de fluidez do PEBD a partir dos valores das variáveis de processo do sistema reacional possui seis neurônios na camada escondida e função de ativação sigmóide na camada de saída, conforme ilustrado na Figura 11. Este modelo, que se encontra na Tabela 13, foi obtido através do treinamento com o algoritmo de Levenberg-Marquardt e mostrou-se capaz de descrever o comportamento do índice de fluidez do PEBD com uma precisão de 3,0507%.

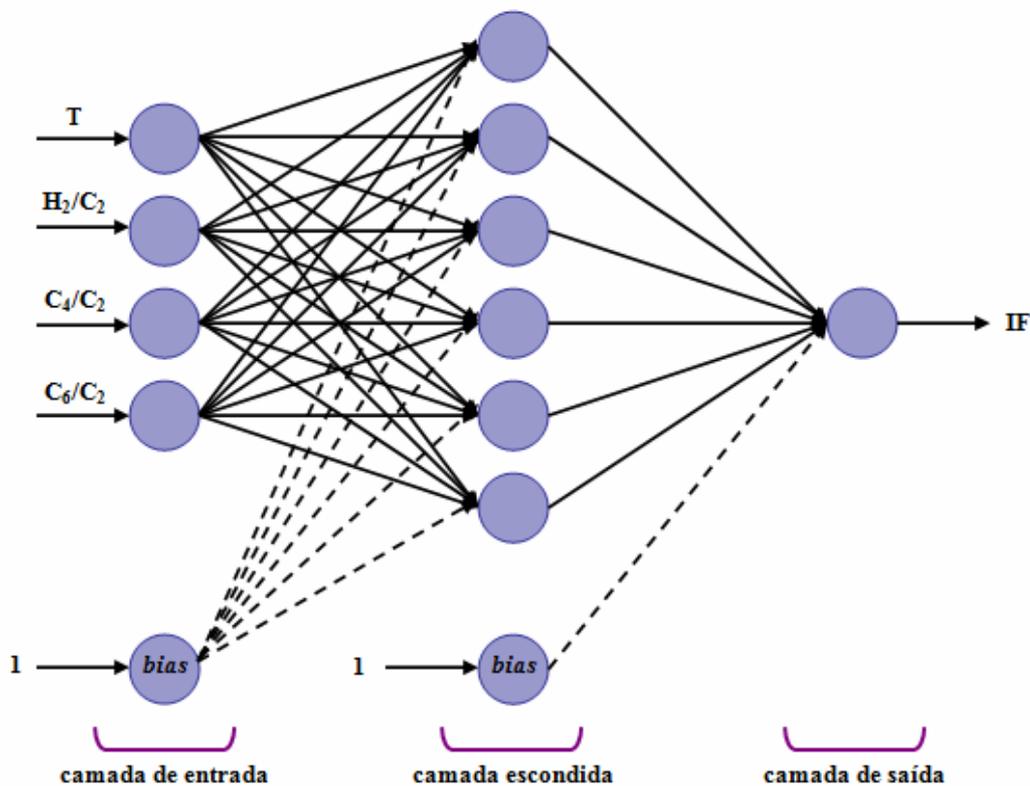


Figura 11 – Configuração da rede neural artificial cujo modelo apresentou maior acurácia na modelagem do índice de fluidez do PEBD

O modelo neural proposto neste trabalho relaciona a qualidade do polímero com as variáveis de processo através das expressões apresentadas na Tabela 15, onde  $IF$  representa o valor normalizado do índice de fluidez do PEBD,  $x_1$  representa o valor normalizado da temperatura no interior do reator,  $x_2$  representa o valor normalizado da razão  $H_2/C_2$  no reator,  $x_3$  representa o valor normalizado da razão  $C_4/C_2$  no reator e  $x_4$  representa o valor normalizado da razão  $C_6/C_2$  no reator.

<i>Modelo neural para o índice de fluidez do PEBD</i>
$IF = \frac{1}{1 + e^{-(1,1711F_1 - 1,7108F_2 - 2,2598F_3 - 0,5023F_4 + 1,7869F_5 - 6,2362F_6 + 0,3681)}}$
$F_i = \frac{1}{1 + e^{-E_i}} \text{ para } i = 1, 2, \dots, 6$
$E_1 = -17,1349x_1 - 9,1344x_2 + 26,5319x_3 - 81,1116x_4 + 14,5808$
$E_2 = 0,2048x_1 + 5,7522x_2 + 1,9312x_3 - 23,7153x_4 + 0,8817$
$E_3 = 2,4499x_1 + 7,3706x_2 - 3,3389x_3 + 28,9189x_4 - 7,1828$
$E_4 = 15,7582x_1 - 21,5277x_2 + 4,4938x_3 + 21,3054x_4 - 1,0620$
$E_5 = 1,8813x_1 + 7,8818x_2 + 5,3590x_3 - 5,5749x_4 - 5,0891$
$E_6 = -4,6111x_1 - 0,3014x_2 + 5,2301x_3 - 2,1457x_4 - 7,2881$

Tabela 15 – Modelo neural do índice de fluidez do PEBD proposto no presente trabalho

Neste ponto, cabe verificar a necessidade de incluir termos adicionais ao modelo neural proposto. Isto pode ser feito através da análise dos resíduos da rede neural artificial em questão. Cabe mencionar que o resíduo é a diferença entre o valor do índice de fluidez não-normalizado medido no laboratório ( $d_i$ ) e o valor do índice de fluidez não-normalizado gerado pela rede neural artificial ( $Y_i$ ), e o seu cálculo é feito através da equação (4.4).

$$Resíduo = d_i - Y_i \quad (4.4)$$

Primeiramente, deve-se verificar a suposição da normalidade dos resíduos da rede neural. Isto pode ser feito analisando-se o histograma da frequência dos resíduos apresentado na Figura 12. No histograma, a obtenção de uma distribuição normal do tipo  $N(0; \sigma_e^2)$  indica que os resíduos seguem uma distribuição normal e que os dados que geram altos valores de resíduos podem ser considerados como *outliers* (Montgomery e Runger, 2003). A distribuição dos resíduos apresentada na Figura 12 é uma normal do tipo  $N(0,0064; 0,0028)$ , ou seja, a média dos resíduos é 0,0064 e a sua variância é 0,0028. Desta forma, é possível concluir que os resíduos atendem aproximadamente à situação desejável de normalidade.

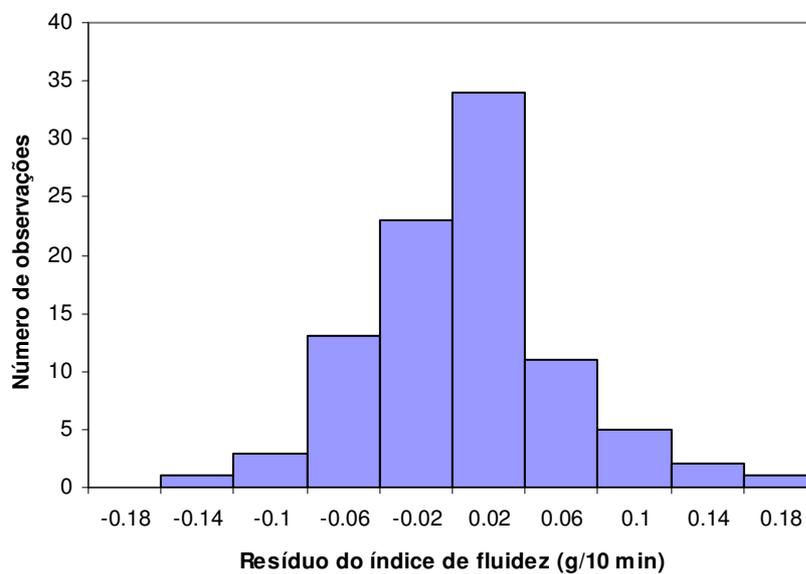


Figura 12 – Histograma dos resíduos do índice de fluidez para a rede neural artificial cujo modelo apresentou maior acurácia na modelagem do índice de fluidez do PEBD

Em seguida, deve-se verificar a suposição da variância constante dos erros. Para tal, pode-se fazer uso da Figura 13, que apresenta o gráfico do resíduo do índice de fluidez versus o valor do índice de fluidez predito pelo modelo neural.

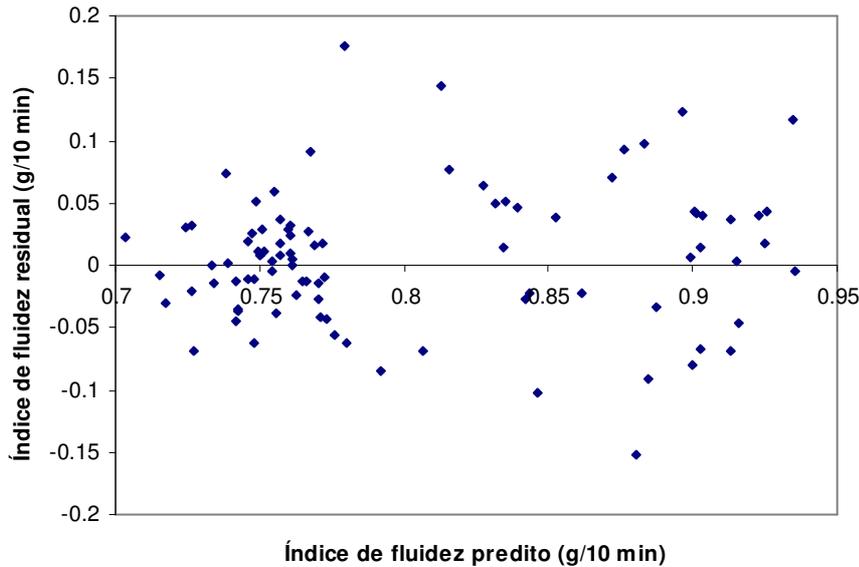


Figura 13 – Verificação da constância da variância dos erros (índice de fluidez residual versus índice de fluidez predito pelo modelo neural)

Analisando-se a Figura 13, percebe-se que os pontos estão distribuídos de forma aleatória e que o comportamento dos resíduos pode ser considerado como satisfatório (Montgomery e Runger, 2003). De fato, verifica-se por inspeção visual que o comportamento dos resíduos não é do tipo funil, nem do tipo arco duplo, nem do tipo não-linear. Desta forma, pode-se considerar que a variância dos erros é constante e igual a 0,0028, o que elimina a necessidade de adicionar termos de ordem mais elevada ao modelo neural.

#### 4.3. Comparação entre o modelo neural e modelos fenomenológicos

Com o intuito de enfatizar as vantagens associadas ao uso da modelagem neural para o índice de fluidez do PEBD, o modelo neural proposto no presente estudo foi comparado com modelos fenomenológicos existentes. O primeiro modelo fenomenológico considerado nesta comparação é baseado no modelo de McAuley e MacGregor (1991), que foi apresentado na seção 2.1. Dado que as constantes deste modelo foram previamente ajustadas para representar o sistema reacional de produção de PEBD da empresa, e que, por este motivo, estes valores são considerados sigilosos, a formulação exata deste modelo não poderá ser divulgada. O segundo modelo fenomenológico considerado neste estudo é o

modelo utilizado pelo sistema de controle avançado da empresa, que, por motivos de sigilo, também não poderá ser divulgado. Este modelo é atualmente usado na planta de PEBD para inferir os valores do índice de fluidez da resina produzida, os quais são armazenados no banco de dados. Cabe mencionar que estes valores também foram coletados e pré-processados de acordo com o procedimento descrito no Capítulo 3.

As Figuras 14 a 16 ilustram a capacidade de inferência de cada um dos três modelos considerados nesta seção. Cada figura contém duas curvas: uma descreve o comportamento do índice de fluidez do PEBD segundo um dos modelos analisado, enquanto que a outra curva apresenta os valores do índice de fluidez calculados no laboratório de controle de qualidade da empresa. Convém mencionar que os valores do índice de fluidez apresentados nos gráficos a seguir foram calculados alimentando-se todos os modelos com os valores das variáveis de processo correspondentes ao conjunto de dados de teste. Por motivos de sigilo de dados, todos os valores de índice de fluidez apresentados encontram-se normalizados.

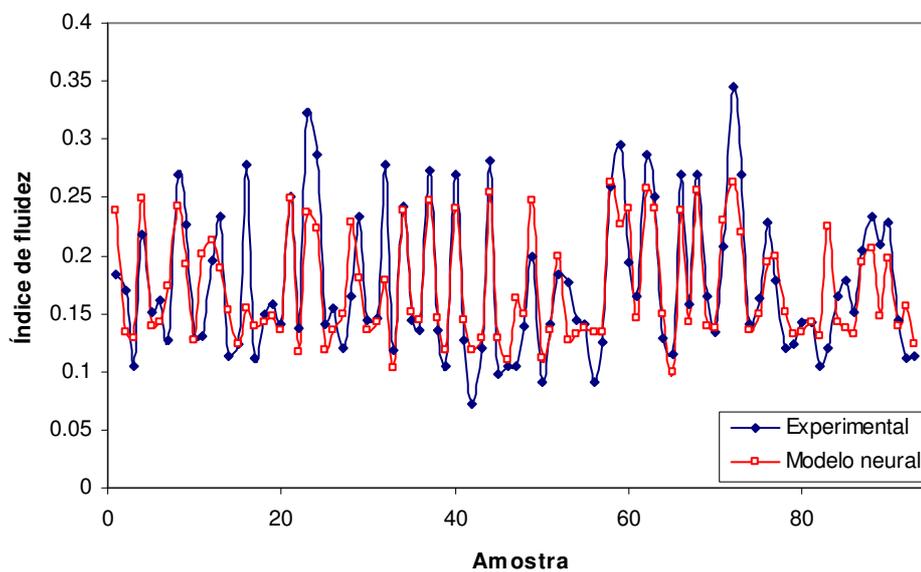


Figura 14 – Inferência do índice de fluidez do PEBD através do modelo neural proposto neste trabalho

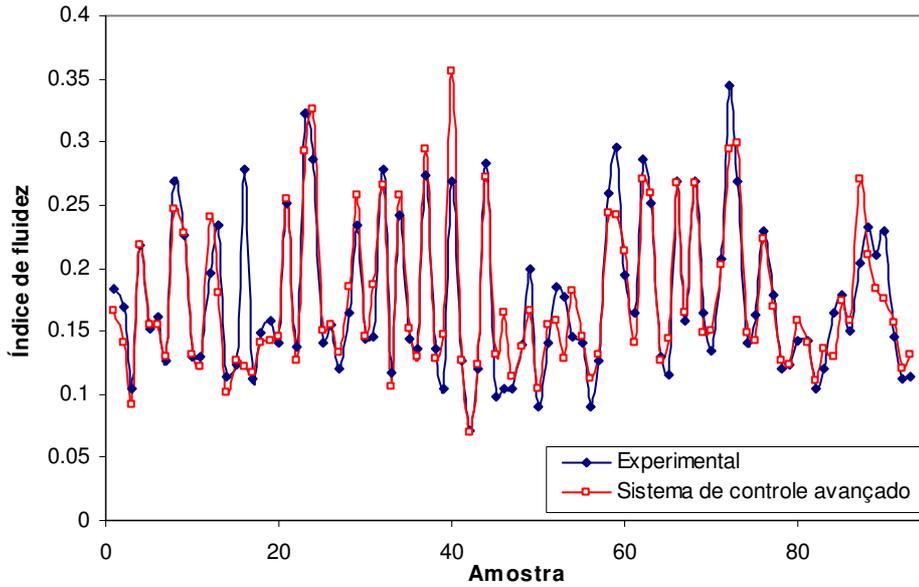


Figura 15 – Inferência do índice de fluidez do PEBD através do modelo fenomenológico utilizado pelo sistema de controle avançado da empresa

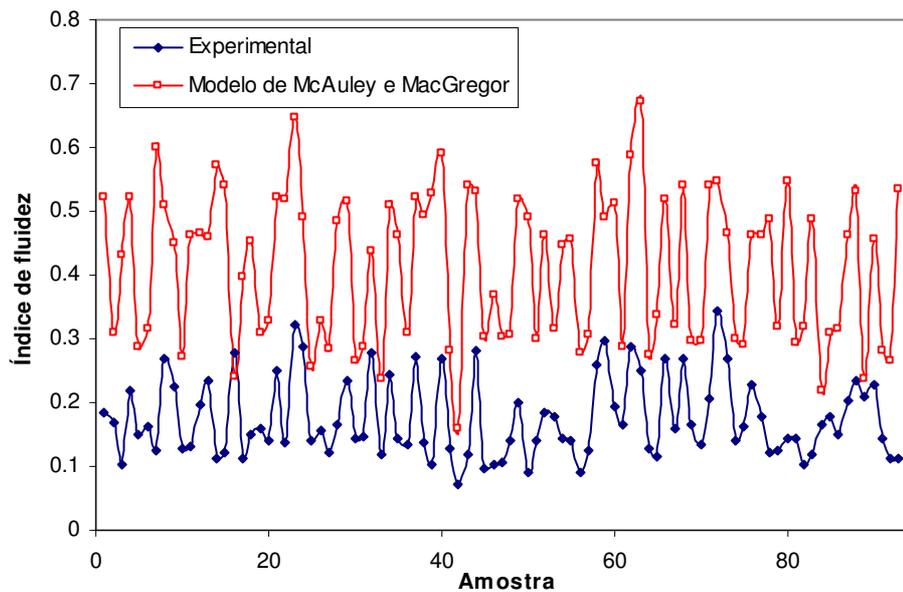


Figura 16 – Inferência do índice de fluidez do PEBD através do modelo fenomenológico baseado no modelo de McAuley e MacGregor (1991)

A inspeção visual das Figuras 14 a 16 permite concluir que, dentre os modelos analisados, o modelo atualmente implementado no sistema de controle avançado da planta mostrou-se como o mais adequado para representar o comportamento do índice de fluidez do PEBD. No entanto, o modelo neural também se mostrou capaz de modelar adequadamente o comportamento do índice

de fluidez, apesar de fazê-lo com uma precisão um pouco inferior. Cabe ainda a ressalva de que o modelo adaptado de McAuley e MacGregor (1991) também é capaz de representar a tendência do comportamento do índice de fluidez do PEBD, isto é, a curva gerada pelo modelo apresenta picos positivos e negativos em concordância com o perfil dos dados experimentais (Figura 16). Porém, os valores inferidos pelo modelo em questão são, em sua grande maioria, bastante superiores aos valores obtidos em laboratório.

A comparação quantitativa entre a acurácia do modelo neural e dos dois modelos fenomenológicos foi feita, em um primeiro momento, através dos valores do MAPE calculado para os dados de teste (Tabela 16). O cálculo do erro de teste foi novamente feito através da equação (4.1), onde os valores de  $Y_i$  corresponderam aos valores do índice de fluidez gerado por cada um dos modelos considerados nesta comparação, os valores de  $d_i$  corresponderam aos valores do índice de fluidez medido no laboratório e  $N$  é a quantidade de dados presentes no conjunto de teste.

<i>Modelagem do índice de fluidez do PEBD</i>	<i>MAPE de teste (%)</i>
Modelo neural	2,8037
Modelo fenomenológico do sistema de controle da planta	1,9274
Modelo fenomenológico baseado no modelo de McAuley e MacGregor (1991)	59,5461

Tabela 16 – Comparação entre a acurácia dos modelos do índice de fluidez do PEBD

Analisando-se os valores apresentados na Tabela 16, percebe-se que a acurácia do modelo neural proposto neste estudo aproxima-se da acurácia do modelo fenomenológico atualmente utilizado pelo sistema de controle avançado da planta. Esta observação é condizente com a análise qualitativa do desempenho dos modelos, que foi feita com base nos gráficos apresentados nas Figuras 14 a 16. De fato, o modelo fenomenológico utilizado pelo sistema de controle apresentou o melhor gráfico de predição do comportamento do índice de fluidez (Figura 15), enquanto que o gráfico gerado pelo modelo neural (Figura 14) pode ser considerado como o segundo melhor. Neste sentido, verifica-se também a concordância dos resultados em relação ao modelo fenomenológico adaptado de

McAuley e MacGregor (1991), já que este modelo apresentou o maior erro de modelagem, bem como o pior gráfico (Figura 16).

Contudo, é importante destacar que o modelo fenomenológico utilizado pelo sistema de controle possui um módulo de atualização de parâmetros em tempo real. Devido a isto, este sistema é capaz de apresentar baixos erros de modelagem de maneira consistente. Neste contexto, a inclusão de técnicas de atualização *on-line* dos parâmetros do modelo neural, tais como o filtro recursivo de Kalman, seria capaz de reduzir significativamente o erro de predição do modelo neural proposto.

Após a análise do erro de modelagem, avaliou-se o desempenho dos três modelos aqui considerados tendo como referência o coeficiente de correlação (R) dos resultados gerados pelos mesmos. A Figura 17 apresenta o gráfico do índice de fluidez medido no laboratório de controle de qualidade versus o índice de fluidez predito pelo modelo neural. Analogamente, as Figuras 18 e 19 apresentam os gráficos do índice de fluidez medido no laboratório de controle de qualidade versus o índice de fluidez predito pelos modelos fenomenológicos do sistema de controle e adaptado de McAuley e MacGregor (1991), respectivamente.

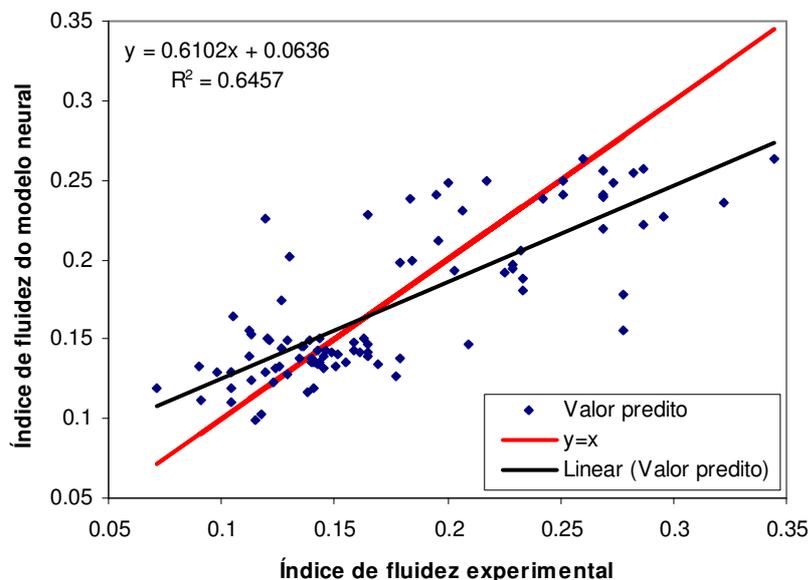


Figura 17 – Análise da correlação entre o valor experimental do índice de fluidez e o valor predito pelo modelo neural proposto no presente trabalho

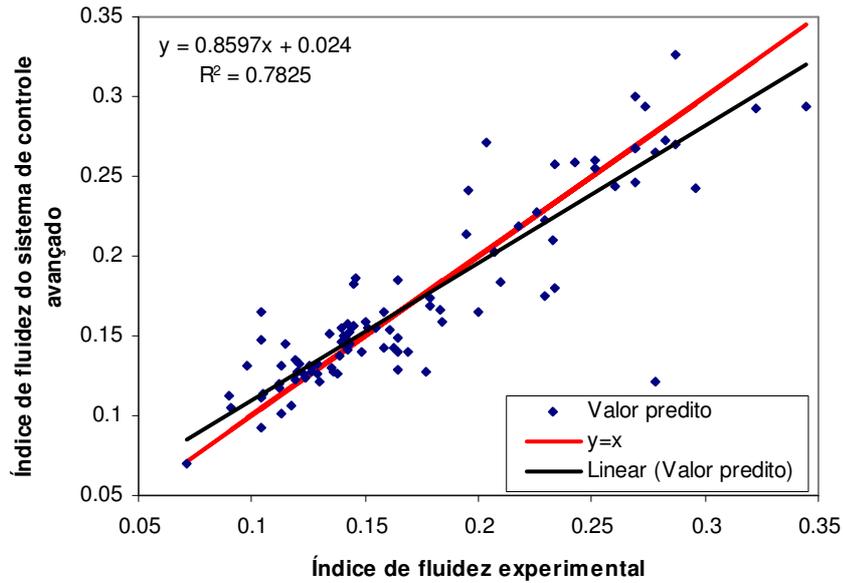


Figura 18 – Análise da correlação entre o valor experimental do índice de fluidez e o valor predito pelo modelo fenomenológico utilizado pelo sistema de controle avançado

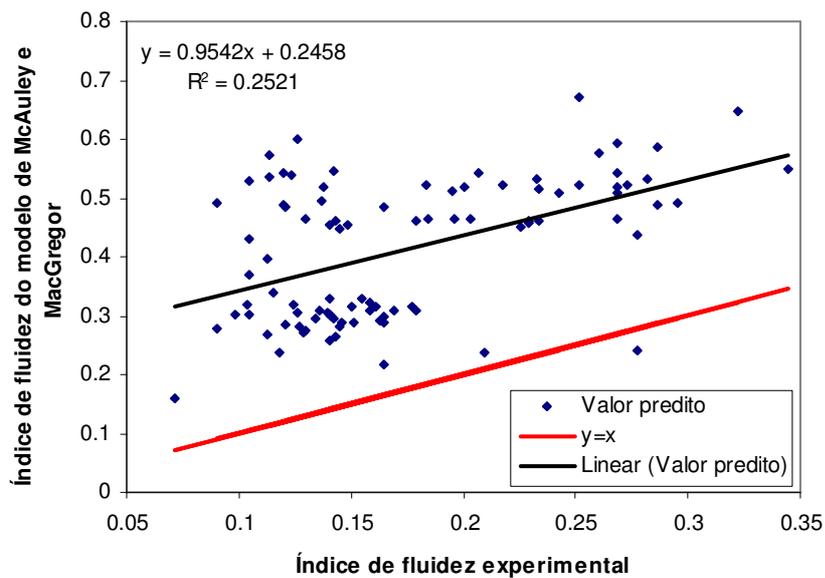


Figura 19 – Análise da correlação entre o valor experimental do índice de fluidez e o valor predito pelo modelo fenomenológico adaptado de McAuley e MacGregor (1991)

Conforme pode ser visto nas Figuras 17 e 18, os coeficientes de correlação do modelo neural ( $R = 0,803$ ) e do modelo fenomenológico utilizado pelo sistema de controle ( $R = 0,884$ ) são valores altos e próximos uns dos outros. Por outro lado, o modelo fenomenológico adaptado de McAuley e MacGregor (1991)

apresentou coeficiente de correlação muito inferior aos dois outros modelos ( $R = 0,502$ ).

Em suma, com base nos resultados gráficos e numéricos apresentados, pode-se considerar o modelo neural desenvolvido no presente trabalho como uma eficiente alternativa aos modelos fenomenológicos existentes para o sistema reacional de produção de PEBD. Convém salientar que, além de demonstrar alta acurácia na inferência da qualidade do PEBD a partir das variáveis de processo, o modelo neural em questão também pode ser facilmente automatizado, visto que as equações que o descrevem encontram-se apresentadas de maneira explícita.