



UNIVERSIDADE FEDERAL DE SERGIPE  
PROEE – PROGRAMA DE PÓS-  
GRADUAÇÃO  
EM ENGENHARIA ELÉTRICA  
DEPARTAMENTO DE ENGENHARIA  
ELÉTRICA



# **ESTUDO DE TÉCNICAS DE PREVISÃO DE CONSUMO EM SISTEMAS DE DISTRIBUIÇÃO DE GÁS NATURAL**

GUSTAVO LIMA CRUZ

São Cristovão  
2012



UNIVERSIDADE FEDERAL DE SERGIPE  
PROEE – PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA ELÉTRICA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

# **ESTUDO DE TÉCNICAS DE PREVISÃO DE CONSUMO EM SISTEMAS DE DISTRIBUIÇÃO DE GÁS NATURAL**

GUSTAVO LIMA CRUZ

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica – PROEE, da Universidade Federal de Sergipe, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientadores:

Prof. Dr. Carlos Alberto Villacorta Cardoso  
Prof. Dr. Jugurta Rosa Montalvão Filho

SÃO CRISTOVÃO-SE BRASIL  
DEZEMBRO DE 2012

# **ESTUDO DE TÉCNICAS DE PREVISÃO DE CONSUMO EM SISTEMAS DE DISTRIBUIÇÃO DE GÁS NATURAL**

**GUSTAVO LIMA CRUZ**

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA –  
PROEE DA UNIVERSIDADE FEDERAL DE SERGIPE COMO PARTE  
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU  
DE MESTRE EM ENGENHARIA ELÉTRICA.

Aprovado em: \_\_\_\_/\_\_\_\_/\_\_\_\_

---

Orientador: Prof. Dr. Carlos Alberto Villacorta Cardoso

---

Orientador: Prof. Dr. Jugurta Rosa Montalvão Filho

---

Prof. Dr. Pablo Javier Alsina

---

Prof. Dr. Elyson Ádan Nunes Carvalho

SÃO CRISTOVÃO-SE BRASIL  
DEZEMBRO DE 2012

# AGRADECIMENTOS

A minha esposa Elidiane pela paciência e companheirismo durante toda a jornada acadêmica, não deixando desistir quando me faltavam forças para continuar.

Aos meus filhos Luiz e Elisa pelas horas de descontração.

Aos meus orientadores Carlos Alberto Villacorta Cardoso e Jugurta Rosa Montalvão Filho pelas palavras de incentivo e apoio ao longo do desenvolvimento deste trabalho.

A SERGAS pelo fornecimento dos dados históricos e contribuição para o desenvolvimento da ferramenta.

Aos meus colegas e amigos pela presença durante esta jornada.

Resumo da Dissertação apresentada ao PROEE/UFS como parte dos requisitos necessários para a obtenção do grau de Mestre (Me.).

## **ESTUDO DE TÉCNICAS DE PREVISÃO DE CONSUMO EM SISTEMAS DE DISTRIBUIÇÃO DE GÁS NATURAL**

Gustavo Lima Cruz

Dezembro/2012

Orientador: Prof. Dr. Carlos Alberto Villacorta Cardoso

Programa: Engenharia Elétrica

A previsão de consumo de gás tem fundamental importância para a companhia distribuidora de gás natural, uma vez que é comum que as empresas supridoras incluam em seus contratos cláusulas que obrigam a concessionária distribuidora realizar a programação do volume de gás natural a ser retirado, sendo a mesma submetida à aplicação de penalidades caso o volume programado exceda limites previamente estabelecidos.

Sendo assim, no presente trabalho tem sido estudadas as potencialidades de utilização dos modelos de previsão baseados em regressões, séries temporais e redes neurais artificiais na previsão de consumo de gás, com o objetivo de aprimorar as metodologias atualmente utilizadas pela distribuidora de gás na programação diária realizada junto ao supridor, num cenário caracterizado pela predominância de consumidores industriais com características diferentes entre si.

Neste contexto, considerando o potencial das técnicas de previsão, foram realizados estudos de previsão de consumo em médio prazo de consumidores dos segmentos industrial e automotivo. A partir destes estudos foi possível identificar tipos de comportamentos particulares, bem como a estratégia de previsão mais adequada, seja utilizando as redes neurais artificiais, séries temporais ou uma combinação de ambas.

Para realização dos estudos uma ferramenta computacional foi desenvolvida, a qual oferece as facilidades necessárias para analisar, parametrizar e validar os métodos de previsão baseado em dados históricos de consumo. Os resultados obtidos são promissores, pois apresentam condições de contorno próximo dos valores reais.

Abstract of Dissertation presented to PROEE/UFS as a partial fulfillment of the requirements for the degree of Master.

## **STUDY OF CONSUMPTION FORECASTING SYSTEMS NATURAL GAS DISTRIBUTION**

Gustavo Lima Cruz

December / 2012

Advisor: Dr. Carlos Alberto Cardoso Villacorta

Program: Electrical Engineering

The forecasting of gas consumption has a fundamental importance for the natural gas distribution company, since it is common for supply companies include clauses in their contracts that force the distributor companies to perform the volume programming of the natural gas to be withdrawn, these same companies are subjected to the application of penalties if the volume exceeds programmed limits previously established.

Thus, in the present work has been studied the potentialities to use of predictive models based on regression, time series and artificial neural networks in forecasting gas consumption, with the intend to improved the methodologies currently used by gas distributor in the daily schedule to send to the supplier, in a scenario characterized by the predominance of industrial consumers with dissimilar characteristics.

In this context, considering the potential of forecasting techniques, has been studied the gas consumption forecasting in the medium term of both the industrial consumers and the automotive segments. From these studies it was possible to identify particular types of behaviors, and the forecasting strategy most suitable approach using artificial neural networks, time series or a combination of both.

To perform these studies was developed a computational tool to analyzing, parameterize and validate methods of forecasting based on historical data consumption. The results are promising because it presents boundary conditions close to actual values.

# SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>1</b>
<b>1.1 CADEIA DE ABASTECIMENTO DE GÁS NATURAL.....</b>	<b>2</b>
<b>1.2 O MERCADO DO GÁS NATURAL.....</b>	<b>3</b>
<b>1.3 O PROBLEMA DA PREVISÃO DE CONSUMO.....</b>	<b>4</b>
<b>1.4 METODOLOGIA ATUAL .....</b>	<b>5</b>
<b>1.5 OBJETIVOS .....</b>	<b>8</b>
<b>2. ESTADO DA ARTE.....</b>	<b>9</b>
<b>3. TÉCNICAS DE PREVISÃO .....</b>	<b>12</b>
<b>3.1 ANÁLISE DE REGRESSÃO.....</b>	<b>12</b>
<b>3.1.1 Regressão linear simples .....</b>	<b>12</b>
<b>3.1.2 Regressão linear múltipla.....</b>	<b>13</b>
<b>3.1.3 Regressão não linear .....</b>	<b>13</b>
<b>3.2 ANÁLISE DE SÉRIES TEMPORAIS.....</b>	<b>13</b>
<b>3.2.1 Ruído branco.....</b>	<b>16</b>
<b>3.2.2 Processo estacionário .....</b>	<b>16</b>
<b>3.2.3 Função de autocorrelação.....</b>	<b>17</b>
<b>3.2.4 Função de autocorrelação parcial.....</b>	<b>18</b>
<b>3.2.5 Modelos de previsão.....</b>	<b>19</b>
<b>3.3 REDES NEURAIS ARTIFICIAIS.....</b>	<b>24</b>
<b>3.3.1 Modelo de neurônio artificial.....</b>	<b>24</b>
<b>3.3.2 Redes multilayer perceptron.....</b>	<b>25</b>
<b>3.3.3 O algoritmo backpropagation .....</b>	<b>26</b>
<b>4. METODOLOGIA.....</b>	<b>30</b>
<b>4.1 ÍNDICES DE DESEMPENHO.....</b>	<b>30</b>
<b>4.2 DESCRIÇÃO DOS DADOS .....</b>	<b>32</b>
<b>4.3 PROCEDIMENTOS PARA OS MODELOS DE REGRESSÃO.....</b>	<b>32</b>
<b>4.4 PROCEDIMENTOS PARA OS MODELOS DE SÉRIES TEMPORAIS .....</b>	<b>36</b>
<b>4.5 PROCEDIMENTOS PARA OS MODELOS DE REDES NEURAIS ARTIFICIAIS .....</b>	<b>38</b>
<b>5. RESULTADOS.....</b>	<b>41</b>
<b>5.1 CONSUMIDOR INDUSTRIAL A .....</b>	<b>41</b>
<b>5.1.1 Modelo de regressão .....</b>	<b>41</b>
<b>5.1.2 Modelo de série temporal .....</b>	<b>44</b>
<b>5.1.3 Modelo de rede neural Artificial.....</b>	<b>47</b>
<b>5.1.4 Comparação dos resultados.....</b>	<b>48</b>
<b>5.2 CONSUMIDOR INDUSTRIAL B.....</b>	<b>50</b>
<b>5.2.1 Modelo de regressão .....</b>	<b>50</b>
<b>5.2.2 Modelo de série temporal .....</b>	<b>53</b>

5.2.3	<i>Modelo de rede neural Artificial</i> .....	55
5.2.4	<i>Comparação dos resultados</i> .....	57
5.3	<b>CONSUMIDOR GNV A</b> .....	58
5.3.1	<i>Modelo de regressão</i> .....	58
5.3.2	<i>Modelo de série temporal</i> .....	61
5.3.3	<i>Modelo de rede neural artificial</i> .....	63
5.3.4	<i>Comparação dos resultados</i> .....	66
6.	<b>CONCLUSÃO</b> .....	67
6.1	<b>SUGESTÕES PARA TRABALHOS FUTUROS</b> .....	68
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	69
	<b>APÊNDICE A - FERRAMENTA COMPUTACIONAL</b> .....	72

# Capítulo 1

## 1. Introdução

O gás natural é um combustível fóssil encontrado no subsolo, por acumulações em rochas porosas, isoladas do exterior por rochas impermeáveis, associadas ou não a depósitos de petrolíferos. Sua composição é função de uma série de fatores naturais que determinaram o seu processo de formação e as condições de acumulação do seu reservatório de origem [1].

O gás natural encontrado na natureza é uma mistura diversificada de hidrocarbonetos saturados, cujo componente preponderante é o Metano e em menores quantidades, o Propano e o Butano, entre outros [2].

De acordo com a Lei n. 9.578/97 – Lei do Petróleo, o gás natural é definido como sendo a porção do petróleo que existe na fase gasosa ou em solução no óleo, nas condições originais do reservatório, e que permanece no estado gasoso nas condições atmosféricas de pressão e temperatura.

A composição comercial do gás natural é variada e depende da composição do gás natural bruto, do mercado atendido, do uso final e do produto gás que se deseja. No mercado Brasileiro, segundo a resolução da ANP n. 16, de 17 de junho de 2008, a especificação do gás natural deve seguir o especificado no Quadro 1.1.

**Quadro 1.1 Especificação para o Gás Natural Comercializado no Brasil.**

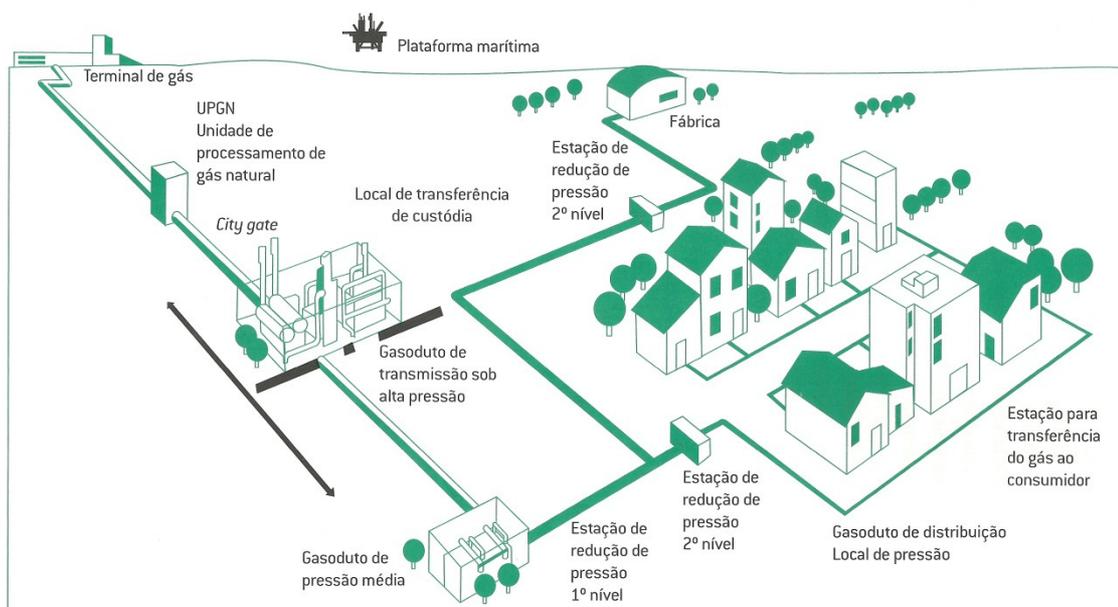
[2]

Características	Unidade	Limite		
		Norte	NE	CO, SE, SUL
Poder calorífico superior	kWh/m <sup>3</sup>	9,47 a 10,67	9,72 a 11,94	
Índice de Wobbe	kJ/m <sup>3</sup>	40.500 a 45.000	46.500 a 53.500	
Oxigênio, máx.	% mol	0,8	0,5	
Inertes (N <sub>2</sub> + CO <sub>2</sub> ), máx.	% mol	18,0	8,0	6,0
CO <sub>2</sub> , máx.	% mol	3,0		
Enxofre total, máx.	mg/m <sup>3</sup>	70		
Gás sulfídrico (H <sub>2</sub> + S), máx.	mg/m <sup>3</sup>	10	13	10
Ponto de orvalho de água a 1 atm, máx.	°C	-39	-39	-45
Ponto de orvalho de hidrocarbonetos a 4,5 Mpa, máx.	°C	15	15	0

# 1.1 Cadeia de abastecimento de gás natural

A cadeia de abastecimento de gás natural pode ser dividida em basicamente quatro etapas, exemplificadas na Figura 1.1.

- Exploração: etapa inicial realizada em duas fases. A primeira fase é a de pesquisa na qual se verifica a existência de bacias sedimentares de rochas reservatórias. Caso positivo o resultado da pesquisa, inicia-se a fase de perfuração [2].
- Processamento: esta etapa é realizada por meio de uma instalação industrial denominada Unidade de Processamento de Gás Natural (UPGN), cujo objetivo é separar as frações pesadas ou ricas (propano e hidrocarbonetos pesados) existentes no gás natural úmido ou rico gerando o gás natural seco ou pobre (metano e etano) e o líquido de gás natural (composto por frações mais pesadas que o propano). [2].
- Transporte: o transporte do gás natural é realizado por meio de dutos. O gasoduto é uma rede de distribuição que leva o gás natural das fontes produtoras até os centros consumidores e tem a capacidade de transportar grandes volumes, em função dos grandes diâmetros de tubulação e a alta pressão na qual opera e somente se aproxima das cidades para entregar gás às companhias distribuidoras, fazendo parte de um sistema integrado de transporte de gás natural [2].
- Distribuição: o gás é comercializado por meio de contratos de fornecimento com as companhias distribuidoras de cada estado, detentoras da concessão de distribuição. Nas estações de transferência de custódia (*city gates*) ocorre a transferência de propriedade entre a transportadora e a companhia distribuidora, além da regulagem de pressão e da medição dos volumes transferidos [2].



[2].

**Figura 1.1 Cadeia de Abastecimento de Gás Natural.**

## 1.2 O mercado do gás natural

O gás natural tem um amplo espectro de aplicações. Dentre elas pode-se destacar a sua utilização como combustível industrial, comercial, domiciliar e residencial, e na recuperação secundária de petróleo em campos petrolíferos, através de sua reinjeção.

Na indústria petroquímica, o gás natural é utilizado como matéria-prima para produção de plásticos, tintas, fibras sintéticas e borracha.

O uso do gás natural em residências, seja para cocção, seja para aquecimento de água, além da segurança e praticidade, tem a vantagem de substituir o gás liquefeito de petróleo, mais popularmente conhecido com GLP ou gás de cozinha (derivado de petróleo importado pelo Brasil), que exige complexa infraestrutura de transporte e armazenamento.

Outra forma que vem ganhando destaque é a utilização de gás natural como combustível na geração de eletricidade, seja em usinas termelétricas, seja em unidades industriais, instalações comerciais e de serviços, em regime de cogeração (produção combinada de vapor e eletricidade) [1].

### 1.2.1 Reservas brasileiras de gás natural

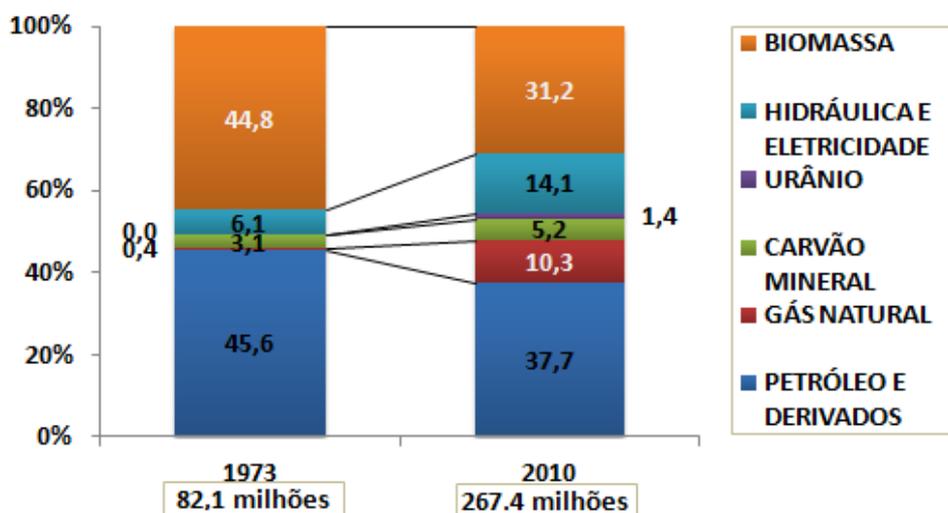
A Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) divulgou nota retificando os valores das reservas provadas de petróleo e gás natural do Brasil em 2010.

As reservas provadas de gás natural tiveram aumento de 15,23% na comparação entre 2009 e 2010, passando de 367.095 milhões de metros cúbicos para 423.003 milhões de metros cúbicos. Este crescimento é inferior apenas comparado como registrado em 2004 em relação a 2003, que foi de 32,91%. No que diz respeito às reservas totais de gás natural, no mesmo período, a elevação foi de 37,11%, de 601.518 milhões de metros cúbicos para 824.723 milhões de metros cúbicos, foi a maior desde 2004, quando o aumento foi de 41,68% frente ao ano anterior [3].

Os dados de 2010 incluem também as reservas referentes ao pré-sal da Bacia de Santos (antigas áreas exploratórias de Tupi e Iracema no Bloco BM-S-11), descobertas nos campos de Barracuda, Caratinga, Marlim, Marlim Leste e Pampo na Bacia de Campos, além de projetos de aumento de recuperação de petróleo nos campos de Albacora Leste, Maromba, Marimbá, Marlim Sul, Marlim Leste e Roncador na Bacia de Campos e na concessão de Leste de Urucu na Bacia do Solimões [3].

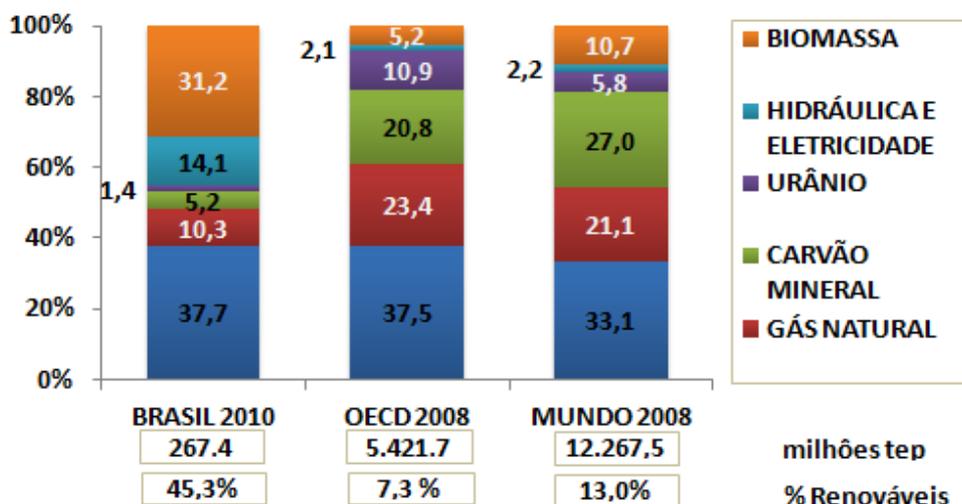
Na Figura 1.2 é possível observar um aumento de 0,4% a 10,3% de consumo de gás no período que vai de 1973 até 2010, o que demonstra não apenas um crescimento absoluto, mas também uma maior participação desta fonte de energia na matriz energética nacional. Por outro lado, na Figura 1.3 é possível observar a

participação do gás como fonte de energia no Brasil, representado por 10,3% (2010), ainda é baixa quando comparada com a média de consumo mundial de gás natural, que atinge 23,4%, segundo a OECD (*Organisation for Economic Cooperation and Development*).



[Fonte: Ministério de Minas e Energia, Balanço Energético Nacional, 2010]

**Figura 1.2 Comparativo da matriz energética brasileira de 1973 e de 2010.**



[Fonte: Ministério de Minas e Energia, Balanço Energético Nacional, 2010]

**Figura 1.3 Matriz energética do Brasil e do mundo**

## 1.3 O problema da previsão de consumo

Com o aumento da participação do gás natural na matriz energética, inúmeros são os desafios que se impõem às pesquisas no campo das previsões de consumo, uma vez que a produção do gás natural esta diretamente ligada ao consumo, ou seja, o supridor ajusta a sua capacidade produtiva em função da disponibilidade dos dutos de transporte e das demandas dos centros consumidores.

O supridor, figura responsável por suprir a demanda de gás natural das distribuidoras locais, inclui em seus contratos cláusula que obriga a concessionária realizar a programação de volume a ser retirado de gás natural, sendo a mesma submetida à aplicação de penalidades caso o volume programado exceda limites previamente estabelecidos [4].

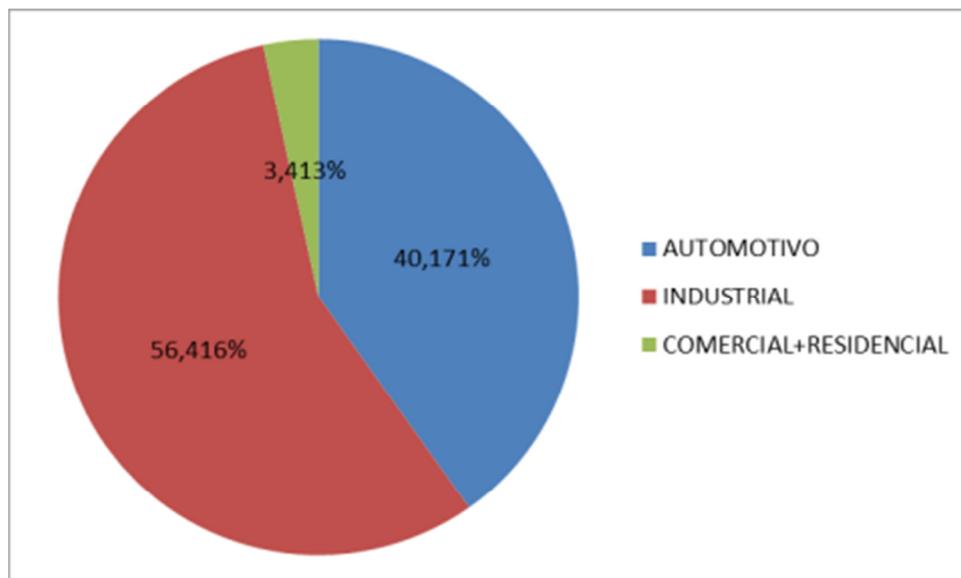
Motivados pela necessidade de não ser penalizado, as distribuidoras de gás natural têm tratado o assunto com muita seriedade, sendo para área de Medição um grande desafio, pois neste problema procura-se determinar o volume de gás a ser consumido em cada ponto da rede com certa antecedência, dentro da menor margem de erro possível.

Semelhante aos sistemas de distribuição de energia elétrica, onde o desafio é a previsão de carga, em redes de distribuição de gás natural o problema reside na programação de volume, onde o grande desafio é tentar antecipar com a menor margem de erro possível a variabilidade da curva de demanda, devido às diferentes condições de operação encontradas no diversos segmentos de consumo, e na dificuldade de se estabelecer um modelo bem definido do comportamento da carga dado à irregularidade no seu aspecto [5].

Devido a essas irregularidades, a utilização de uma ferramenta capaz de identificar todas essas sinuosidades da carga seria de grande ajuda no planejamento e determinação dos volumes demandados nas redes de distribuição e conseqüentemente na redução de penalidades aplicada as companhias de distribuição de gás natural, em função de desvios acentuados.

## **1.4 Metodologia atual**

A companhia de distribuição em estudo SERGAS atende, majoritariamente, clientes industriais, com uma parcela equivalente a 56,4% do volume distribuído, conforme demonstrado na Figura 1.4, este conjunto abrange diferentes tipos de indústrias, como por exemplo, fabricantes de bebidas, cerâmicas, processamento de alimentos, têxtil e mineração. Adicionalmente, os postos de gás natural veicular constituem aproximadamente 40,1% deste mesmo volume. Em forma minoritária e sem muita expressividade encontram-se os clientes residenciais e comerciais. Em cidades com clima temperado, como por exemplo, cidades localizadas na Europa, o consumo residencial teria uma expressividade maior, uma vez que o gás natural é utilizado para sistemas de calefação.



**Figura 1.4. Consumo de gás natural por segmento**

Com o intuito de realizar a programação de volumes a ser retirado pelos consumidores, ou seja, a previsão de consumo de gás natural foi desenvolvida pela companhia uma planilha eletrônica que separa os consumidores em dois grandes segmentos: Consumidores industriais e automotivos (GNV – Gás Natural Veicular). O método matemático aplicado em cada segmento é diferenciado.

Para os consumidores automotivos, que representam aproximadamente 40,1% do consumo de gás natural, foi ajustada uma função polinomial de 3º grau ( 1 ), e aplicado um índice de correção em função do dia da semana, conforme demonstrado na Tabela 1.1.

$$\hat{Y} = Ic(-14,0531x^3 + 560,5443x^2 - 272,854x + 1825,371) \quad (1)$$

em que  $x$ , representa o horário para o qual deseja-se realizar a previsão;  $\hat{Y}$  representa o valor estimado de consumo para um dado horário;  $Ic$  representa o índice de correção, conforme Tabela 1.1.

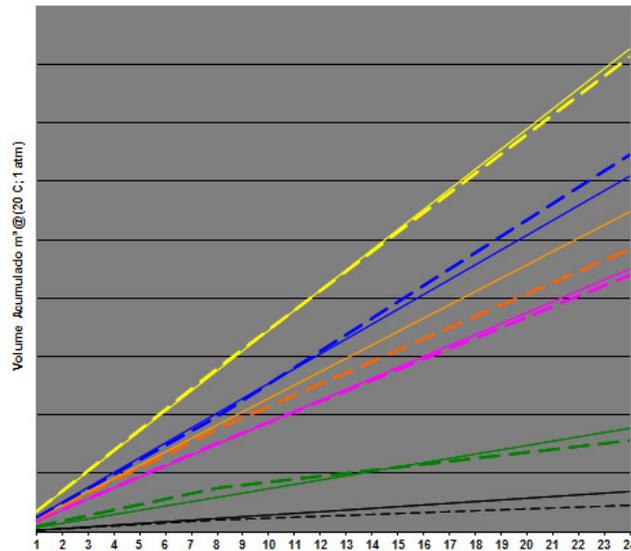
**Tabela 1.1 Índices de Correção para Consumidores Automotivos (GNV).**

DOMINGO	FERIADOS	SEXTA-FEIRA	SÁBADO	DEMAIS DIAS
0,6	0,6	0,95	0,90	0,95

Outro aspecto importante esta relacionado à forma como os dados disponíveis são trabalhados. Neste segmento não é realizada a previsão de consumo por consumidor e sim de forma coletiva ou aglutinada, ou seja, uma única previsão para todo o segmento.

Para os consumidores industriais, que representam aproximadamente 56,4% do consumo de gás natural, foi ajustada uma equação linear simples baseada em

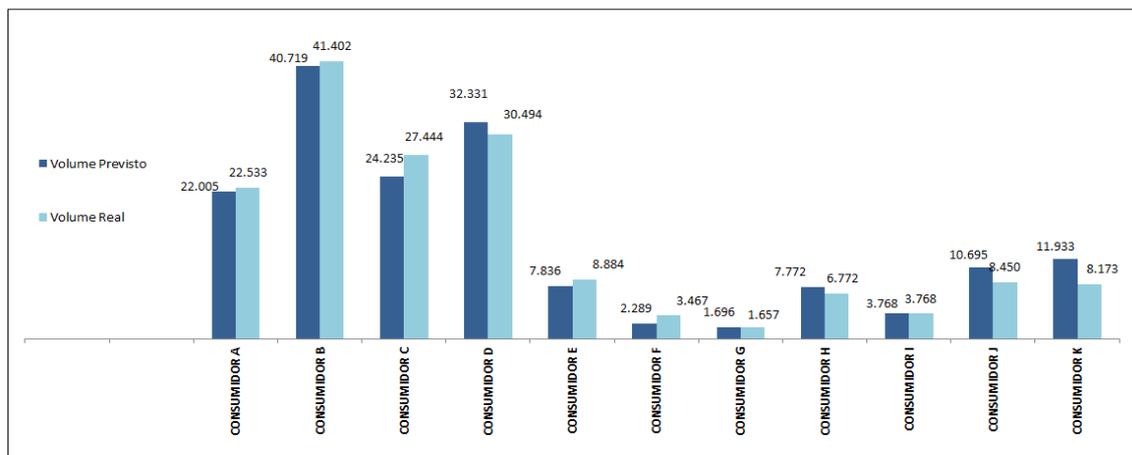
dois pontos de consumo medidos diariamente, geralmente às 08:00 e 11:00. A previsão de consumo é feita de forma individualizada, conforme exemplificado na Figura 1.5, onde a linha pontilhada representa a reta prevista e a linha cheia a reta realizada.



**Figura 1.5 Previsão de Consumo para o Segmento Industrial (Prevista x Realizada)**

A previsão de consumo a ser informada ao supridor é uma composição dos consumos previstos nos segmentos industrial, automotivo, comercial e residencial, sendo este dois últimos incluídos no equacionamento por intermédio de uma constante e representam apenas 3,41% do consumo de gás natural.

A eficiência da metodologia é avaliada com ajuda do gráfico apresentado na Figura 1.6, o qual evidencia a fragilidade do método, quando observados os resultados obtidos de forma individualizada, com diferenças entre o volume previsto e o real na ordem dos 40%.



**Figura 1.6 Avaliação da Eficiência da Metodologia**

Outro ponto negativo da metodologia aplicada esta na aglutinação dos consumidores automotivos, pois situações individuais como desabastecimento de uma região não são observadas para realização da previsão de consumo.

## 1.5 Objetivos

O objetivo principal deste trabalho é estudar as potencialidades das técnicas de previsão, sejam elas, regressão, séries temporais, redes neurais ou as mesmas de forma associada na previsão de consumo de gás natural, num cenário caracterizado pela predominância de grandes consumidores industriais, diferentes entre si, com vistas a melhorar os atuais métodos de previsão utilizados pela companhia distribuidora em estudo.

Como objetivos específicos pode-se mencionar:

- Desenvolver um modelo quantitativo utilizando como referências os dados disponibilizados pela companhia distribuidora de gás natural do estado de Sergipe - SERGAS do período de 01 de janeiro de 2011 a 31 de agosto de 2011. Os dados são tomados em base horária e correspondem às medições de volume em metros cúbicos (m<sup>3</sup>).
- Desenvolver uma ferramenta integrada que permita: mudar as parametrizações das técnicas de previsão, bem como definir diferentes períodos de treinamento e validação, executar e avaliar o desempenho das técnicas de previsão utilizadas.

# Capítulo 2

## 2. Estado da arte

Em 1994 AZZAM-UL-ASAR *et al* [5] publicaram o artigo denominado *A Specification of Neural Network Applications in the Load Forecasting Problem*. Neste artigo os autores investigam a eficácia da Rede Neural Artificial (RNA) para a previsão de curto prazo de carga em sistemas elétricos de potência. São demonstrados o processo de aprendizagem e a capacidade de uma rede neural na previsão do pico diário de carga com a utilização de exemplos. Diferentes abordagens para normalização dos dados e padrões de entrada são utilizadas para explorar a correlação entre a carga histórica, temperaturas e os padrões de carga esperados. As redes foram treinadas com dados reais de carga usando um algoritmo de *backpropagation*. As perspectivas para a aplicação de uma solução combinada utilizando redes neurais artificiais e sistemas especialistas, chamada de rede híbrida, também são discutidas. Sendo estas apontadas como uma solução mais completa para o problema de previsão em face de utilização de um sistema simples.

Em 1995 BROWN *et al* [6] publicaram o artigo denominado *Development of Artificial Neural Network Models to Predict Daily Gas Consumption*. Modelos Redes Neurais Artificiais (RNA) para prever o consumo diário de gás natural são o tema deste artigo. A metodologia baseada no conhecimento da rede e na intuição dos controladores para previsão de consumo é discutida. Resultados mostram que a Rede Neural Artificial pode reduzir o erro de previsão (RMSE – *Root Mean Square Error*) em mais de metade, quando comparado com os modelos de regressão linear e que quando comparados com previsões feitas pelos controladores da companhia de gás, os erros de previsão da Rede Neural Artificial são 20% a 30% menores.

Em 1995 MOHAMMED *et al* [7] publicaram no IEEE o artigo denominado *Practical Experiences with An Adaptive Neural Network Short-Term Load Forecasting System*. Neste artigo é apresentado um sistema baseado em uma rede neural adaptativa para previsão de carga elétrica em curto prazo. O sistema foi desenvolvido e implementado para a *Florida Power Company and Light* (FPL). Experiências práticas com o sistema são discutidas, como a capacidade de previsão de carga com um tempo de espera de uma hora a sete dias. O mecanismo adaptativo é usado para treinar as redes neurais quando o sistema esta on-line. Os resultados indicam que o sistema de previsão de carga apresenta previsões robustas e mais precisas, permitindo uma maior

adaptabilidade às bruscas mudanças climáticas em comparação com métodos estatísticos.

Em 1999 KHOTANZAD *et al* [8] publicaram o artigo denominado *Natural Gas Load Forecasting with Combination of Adaptive Neural Networks*. O foco deste trabalho é a combinação de redes neurais artificiais (RNA) para previsão de consumo diário de gás natural realizado pelas concessionárias de gás. Um sistema de duas fases é proposto. A primeira fase com três previsores baseados em redes neurais artificiais, sendo o primeiro é um previsor multicamada *feedforward* treinado com o algoritmo *backpropagation*, o segundo é outro multicamada *feedforward* treinado com o algoritmo *levenberg-Marquadt*, e o terceiro é uma camada de rede de ligação funcional. Estes três previsores separados são combinadas de forma não linear na segunda etapa usando uma ligação funcional RNA. Um esquema é introduzido para fazer a adaptação das RNAs, com os seus pesos mudando a cada fase de previsão. O desempenho é testado com dados reais de quatro distribuidoras de gás durante vários meses. Os resultados mostram que a abordagem proposta com a combinação de previsores não resultar em previsões mais precisas em comparação com o uso de um único previsor.

Em 2001 PEHARDA *et al* [9] publicaram o artigo denominado *Short term hourly forecasting of gas consumption using neural networks*. Este trabalho apresenta um modelo baseado em rede neural para previsão de consumo de gás nos segmentos residenciais e comerciais. Neste trabalho foi proposta uma rede neural *feedforward* com função de ativação sigmoide, uma camada escondida e treinada com o algoritmo *backpropagation*. O modelo foi validado com dados reais de uma área de distribuição que cobrem 7% do consumo total, na Croácia, região onde estão concentrados os consumidores residenciais e comerciais. Segundo os autores, o método proposto provou ser muito simples e viável. O erro de previsão foi pequeno, embora as condições climáticas estivessem instáveis e excepcionalmente quentes para a época do ano. O desvio padrão das previsões é pequena. O modelo unificado para todos os dias da semana foi bem ajustado e o erro para o fim de semana foi semelhante ao erro para todos os outros dias. Durante o treinamento, a exclusão de alguns dados demonstrou ser bastante útil, porque eles impediram a generalização. O método também pode ser modificado para servir para outras necessidades de previsão de curto prazo.

Em 2003 VIET *et al* [10] publicaram o artigo denominado *Neural And Fuzzy Neural Networks For Natural Gas Consumption Prediction*. Neste trabalho várias abordagens para a previsão de consumo de gás natural com redes neurais e redes fuzzy neurais para uma determinada região da Polônia são analisadas e testadas. Estratégias de previsão testadas incluem: um único módulo de rede neural, a combinação de três módulos neurais, método baseado no agrupamento por temperatura e aplicação de redes neurais nebulosas. Os resultados indicam a superioridade do método baseado no agrupamento por temperatura em face às abordagens modulares e fuzzy neurais. Uma das questões interessantes observada pelo autor no artigo é o desempenho relativamente bom dos métodos testados, no caso de uma predição de longo prazo (quatro semanas) em relação à predição médio prazo (uma semana). Geralmente, os resultados são

significativamente melhores do que os obtidos por meio de métodos estatísticos, atualmente utilizados na companhia distribuidora de gás.

Em 2008 KIZILASLAN *et al* [11] publicaram o artigo denominado *Comparison Neural Networks Models for Short Term Forecasting of Natural Gas Consumption in Istanbul* cujo objetivo é identificar o modelo de rede neural artificial mais adequado para previsão de consumo diário de gás natural, considerado pelo autor importante, tanto para as distribuidoras quanto para os consumidores. Neste estudo também foram analisados os fatores que influenciam o consumo e os resultados aplicados na rede neural artificial. As razões para escolha desta metodologia se deve a sua capacidade de modelar a relação não linear existente nos dados históricos com a utilização de mais de uma variável ao mesmo tempo.

Em 2010 XU *et al* [12] publicaram o artigo denominado *Forecasting China's natural gas consumption based on a combination model*. Neste estudo, foram utilizadas curva polinomial e Projeção Combinada de Média Móvel para estimar o consumo de gás natural na China no período de 2009-2015. O novo modelo proposto apresentou resultados mais confiáveis e precisos quando comparado a outras metodologias, tais como: modelo auto-regressivo integrado e de média móvel (ARIMA), modelo de correção de erros (ECM), modelo de séries temporais e regressão por mínimos quadrados parcial (PLSR), seu erro percentual médio absoluto (MAPE) é menor do que os de todos os modelos anteriores dentro da faixa investigada.

Em 2012 ABREU [13] *et al* publicaram o artigo denominado *Metodologia híbrida utilizando os modelos ARIMA e redes neurais artificiais para previsão de cargas elétricas*. O objetivo deste trabalho foi desenvolver um modelo híbrido utilizando os modelos ARIMA de *Box e Jenkins* e Redes Neurais Artificiais com treinamento realizado pelo algoritmo de *Levenberg-Marquardt*. Este modelo foi utilizado com a finalidade de melhorar a precisão dos resultados com relação à previsão de cargas elétricas em curto prazo. Os resultados obtidos através da metodologia proposta, modelo híbrido de regressão com redes neurais artificiais, foram comparados com outros trabalhos da literatura. A autora concluiu que o modelo proposto foi capaz de realizar previsões para períodos distintos que também envolveram dias atípicos e finais de semana com confiança e alto desempenho.

# Capítulo 3

## 3. Técnicas de previsão

Determinar uma relação entre o consumo de gás e os fatores que influenciam o seu comportamento trata-se de um processo bastante complexo. No segmento industrial fatores como condições climáticas (período chuvoso e período seco), finais de semana e feriados podem ser determinantes para o planejamento e controle da produção [4]. O mesmo ocorre para o segmento de gás natural veicular, pois tais fatores influenciam na demanda por transporte automotivo e conseqüentemente o consumo de gás natural.

Neste aspecto, diversas abordagens têm sido aplicadas, tais como regressão, processos estocásticos, redes neurais artificiais e sistemas especialistas [14].

No campo da previsão de consumo, outra dificuldade a ser vencida é a de estimar e ajustar os parâmetros do modelo, que dependem de dados históricos, que por sua vez podem tornar-se obsoletos ou não refletir as variações do consumo.

### 3.1 Análise de regressão

A análise de regressão é definida como sendo a técnica na qual se deseja quantificar a relação de dependência entre duas ou mais variáveis [16]. Com este objetivo pode-se modelar esta relação através de regressões lineares simples, lineares múltiplas e não lineares [17].

#### 3.1.1 Regressão linear simples

A existência de uma relação linear implícita entre duas variáveis, sendo uma independente  $Y$  e outra dependente  $X$ , pode ser modelada através de uma regressão linear simples [16].

A fórmula é dada por [17]:

$$\hat{Y} = \alpha + \beta X \quad (2)$$

Em que  $\alpha$  e  $\beta$  são conhecidos como coeficientes da regressão e especificam, respectivamente, o ponto onde a reta intercepta o eixo  $Y$  e a inclinação da reta. Para estimação dos coeficientes pode-se utilizar o método dos mínimos quadrados.

### 3.1.2 Regressão linear múltipla

A extensão de uma regressão linear simples, onde existe única variável dependente  $Y$  e mais de uma variável independente  $X_1, X_2, \dots, X_n$ , é chamada de regressão linear múltipla, descrita como [18]:

$$\hat{Y} = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (3)$$

em que  $b_0$  é uma constante, e representa o valor de  $Y$  quando todos os valores de  $X_i$  são zero e  $b_i$  é o coeficiente de regressão para cada  $X$ . Estabelece a quantia que  $Y$  varia com cada mudança unitária de  $X_i$ .

Pode-se inferir que, assim como na regressão linear simples, a resposta da regressão deve ser contínua, ou seja, não se pode utilizar regressão linear para prever uma variável ordinal.

### 3.1.3 Regressão não linear

O modelo linear múltiplo pode ser transformado, através da adição de termos polinomiais, em um regressor polinomial [17].

Outros modelos de regressão não linear, tais como logarítmica, exponencial e potência, podem ser modelados com a utilização de regressores lineares, para isso é necessário definir as transformações de variáveis, aplicá-las aos dados existentes, obter a regressão linear correspondente e, por fim, substituir as variáveis originais.

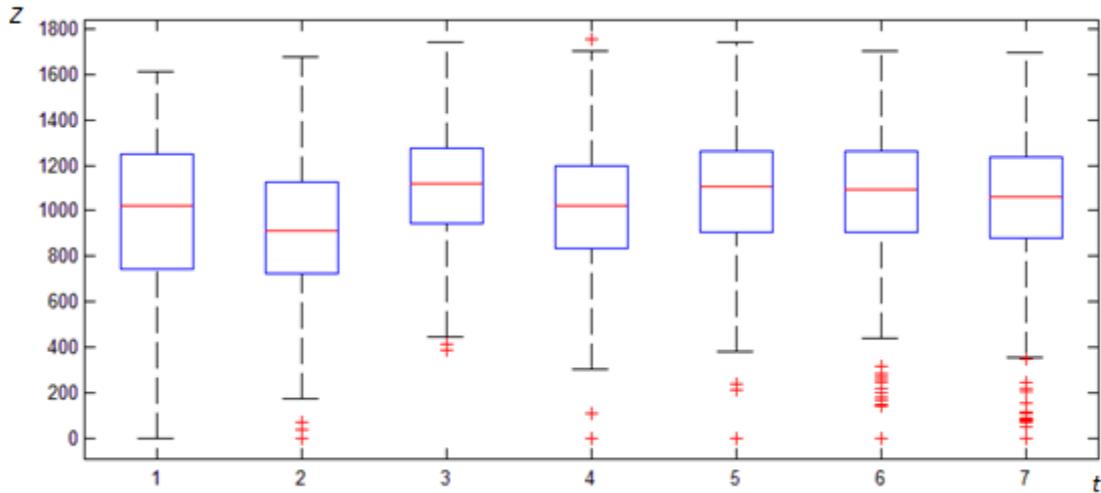
Alguns modelos de regressão não podem ser convertidos em uma função linear. Nestes casos, por intermédio de cálculos adicionais sobre fórmulas mais complexas, pode ser possível obter as estimativas de erro quadrático mínimo [17].

## 3.2 Análise de séries temporais

Um conjunto de valores passíveis de ordenação cronológica é denominado Série Temporal [19], em outros termos, pode-se defini-la uma como sendo um conjunto de observações de uma determinada variável, geralmente distribuídas de maneira equidistante no tempo, e que possuem como característica central a presença de uma dependência serial entre elas [20].

A série temporal, definida como um conjunto de observações de uma determinada variável, é denotada por  $Z_t$ , onde  $t = \{1, 2, 3, 4, \dots, n\}$  são os intervalos de

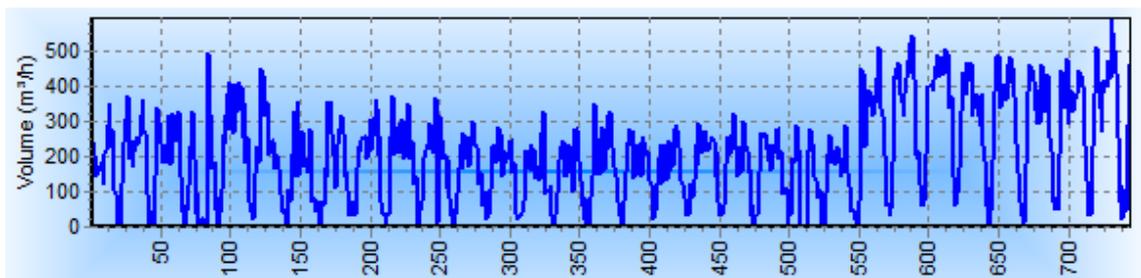
amostragem, e  $\rho(Z_t)$  a função densidade de probabilidade para cada  $t$ , conforme mostrado na Figura 3.1 [20].



**Figura 3.1 Série Temporal e Características de Distribuição de Probabilidade Típica**

Na Figura 3.1 observa-se que a variação não é pontual, mas sim segue uma curva de probabilidade para cada tempo, sendo que para cada tempo  $t$  existe uma distribuição de probabilidade que pode não ser necessariamente a mesma para os demais.

São exemplos de séries temporais pedidos, demandas, valores diários dos preços de ações de uma empresa na bolsa de valores. A Figura 3.2 exemplifica uma série temporal que representa o consumo horário de gás natural em um Posto de combustível.



**Figura 3.2 Consumo Horário de Gás Natural**

Podendo também ser vista como a realização de um processo estocástico, que é definido como uma sequência de observações regidas por leis probabilísticas. A série temporal pode ser considerada como uma amostra de um determinado processo estocástico [20].

O principal objetivo da modelagem das séries temporais é realizar previsões, sendo assim, seu estudo trabalha o comportamento dos dados no passado e presente para que estes forneçam uma ideia das possíveis variações no futuro [21].

O objeto fundamental da análise de uma série temporal é determinar suas componentes básicas buscando identificar um padrão de comportamento da série que possibilite fazer previsões, podendo ser traduzido em [22]:

- Modelagem do fenômeno sob consideração;
- Conclusões em termos estatísticos;
- Avaliação da adequação do modelo para previsão.

Para iniciar a análise de qualquer série temporal é necessária a elaboração de um gráfico, a fim de obter uma visão qualitativa geral do seu comportamento [23]. Entretanto esta ação é apenas um direcionador, sendo necessárias análises estatísticas para uma conclusão mais verdadeira sobre o comportamento da série.

As curvas obtidas pelas séries temporais podem conter [24]:

- **Tendência:** aponta a direção dos dados estudados. Sua principal característica é o movimento suave num período longo de tempo, direcionando os dados de modo constante, crescente ou decrescente. Pode-se dizer que existe um padrão de tendência quando há um aumento ou diminuição, em longo prazo, do valor médio dos dados [22].

- **Sazonalidades:** flutuações que se repetem periodicamente, acompanhando um padrão temporal (relacionadas ao fator tempo), por exemplo influências climáticas, ou ainda mudanças ou variações cíclicas de curto prazo bastante parecidas com os fenômenos cíclicos, com a diferença de que estes são caracterizados por variações que oscilam em torno da tendência a intervalos aproximadamente regulares de tempo e em longo prazo.

- **Variações irregulares:** alterações na demanda passada resultante de fatores excepcionais, como greves ou catástrofes climáticas, que não podem ser previstos e, portanto, incluídos no modelo [24].

- **Aleatoriedade (ou Erro):** uma sequência de variáveis aleatórias independentes e identicamente distribuídas, geralmente com média zero e variância constante igual a  $\sigma^2$  caracterizadas por sua duração curta e intensidade variável [25].

Outra forma de classificar as séries temporais é baseando-se no número de séries temporais envolvidas na modelagem. Esta classificação divide-se em [22]:

- **Modelos Univariados:** métodos que se baseiam em uma única série histórica, ou seja, a série temporal é explicada (prevista) apenas por seus valores passados. Este modelo será utilizado no presente trabalho.

- **Modelos Multivariados ou Causais:** métodos que modelam simultaneamente duas ou mais séries temporais permitindo relações de interdependência e causalidade, mas sem qualquer exigência com relação à direção da causalidade entre elas. A série temporal é explicada (prevista) pelos seus valores passados e também pelos valores passados de outras variáveis.

Séries temporais podem ser descritas com a utilização de modelos estatísticos, que podem ser classificados em duas classes, segundo o número de parâmetros envolvidos [26].

- Modelos paramétricos: número de parâmetros finito. Os modelos mais comumente usados são os modelos AR, ARMA, ARIMA e os modelos não lineares.
- Modelos não paramétricos: número infinito de parâmetros. Podem ser exemplificados pela função de auto-covariância (ou autocorrelação) e modelos de redes neurais.

### 3.2.1 Ruído branco

O ruído branco caracteriza-se por possuir média zero, variância constante  $\sigma^2$  e ser não autocorrelacionado. Ao definir-se um modelo de regressão, é conveniente assumir que o erro seja um ruído branco [27].

A inclusão de uma perturbação (ruído branco) no modelo de regressão é necessária na análise por três importantes razões: [28].

- Generalizar e simplificar o modelo de regressão. Como exemplo pode-se citar os processos econômicos que, geralmente, incluem somente os termos determinísticos de primeira ordem para o estudo, significando que outras variáveis com efeitos de segunda ordem ou superiores não passam a compor o termo erro.
- Considerar o efeito de possíveis erros de medida da variável dependente ou da variável a ser explicada;
- Captar o fator humano que difira de forma aleatória sob circunstâncias idênticas.

O ajuste adequado do modelo pode ser observado quando a estrutura residual é um ruído branco, isto é, o erro é uma variável aleatória independente e identicamente distribuída, com distribuição normal, média zero e desvio padrão  $\sigma$ - $N(0;\sigma)$  [29].

### 3.2.2 Processo estacionário

Define-se Processo Estacionário como sendo um processo estocástico no qual as características estatísticas não se alteram com o decorrer do tempo, ou seja, os dados flutuam ao redor de uma média constante, conforme apresentado na Figura 3.3 [22].

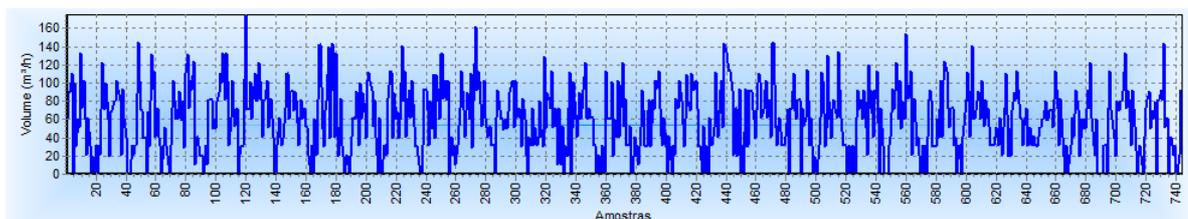


Figura 3.3. Processo estacionário.

Em termos formais, a distribuição de probabilidade conjunta de um processo estacionário nos instantes  $t_1, t_2, \dots, t_m$  é mesma que a distribuição nos instantes  $t_{1+k}, t_{2+k}, \dots, t_{m+k}$  para qualquer  $k$ , ou seja, um deslocamento de  $k$  unidades de tempo não afetará a distribuição de probabilidade conjunta.

Um das suposições básicas feitas na análise de séries temporais é que o processo estocástico gerador dos dados seja um processo estacionário [30].

### 3.2.3 Função de autocorrelação

Uma série temporal  $Z_t$  pode ser representada estatisticamente pelas seguintes equações: [20].

$$\text{Média ou valor esperado: } \mu_z = E[Z_t] \quad (4)$$

$$\text{Variância: } \sigma^2 = E[(Z_t - \mu)^2] \quad (5)$$

$$\text{Autocovariância: } \gamma_k = E[(Z_t - \mu_z)(Z_{t+k} - \mu_z)] \quad (6)$$

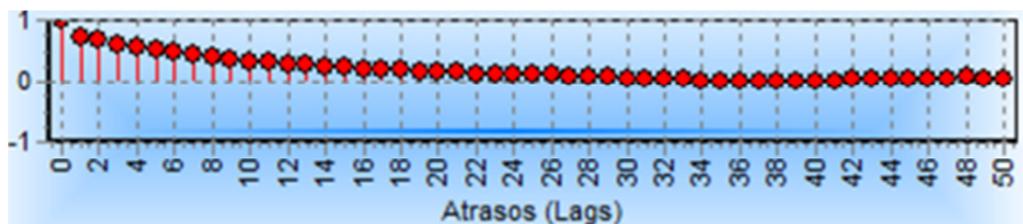
A autocovariância: é a medida de dependência entre duas observações separadas por  $k$  intervalos de tempo.

$$\text{Autocorrelação: } \rho_k = \frac{E[(Z_t - \mu)(Z_{t+k} - \mu)]}{\sqrt{E[(Z_t - \mu)^2]E[(Z_{t+k} - \mu)^2]}} \quad (7)$$

A autocorrelação possui a finalidade de medir a intensidade com que um valor observado no tempo  $t$  é influenciado por aquele observado no tempo  $t-k$ .

A função de autocorrelação (*Autocorrelation Function – ACF*), que nada mais é do que a representação gráfica da autocorrelação em função do deslocamento  $k$ , apresentada na Figura 3.4, pode ser utilizada para identificar a ordem de um modelo auto-regressivo, mas não é suficiente, pois todos os modelos auto regressivos têm uma *ACF* que decresce exponencialmente e, portanto apenas o correlograma não traz informação sobre o grau do polinômio auto regressivo.

A observação da forma da função de autocorrelação pode definir o modelo a ser utilizado para o ajuste através da modelagem *Box e Jenkins*, além de determinar sazonalidade na série temporal e o período de ocorrência [26].



**Figura 3.4. Autocorrelação da Série Temporal**

Por definição, autocorrelação é a correlação existente entre dois valores da mesma variável nos instantes  $x_i$  e  $x_{i+k}$ . Em que  $k$  é chamado de atraso (*lag*) [31].

O valor de  $\rho_k$  pode variar de  $-1$  a  $1$  e quanto mais próximo de  $1$  ou de  $-1$  estiver, maior será a correlação existente entre a reta e os dados [24].

### 3.2.4 Função de autocorrelação parcial

A função de autocorrelação parcial (*Partial Autocorrelation Function – PACF*) mede a correlação entre duas amostras  $x_t$  e  $x_{t+k}$ , separadas por um intervalo de tempo  $k$ , excluindo a dependência dos valores intermediários  $w_{t+1}, w_{t+2}, \dots, w_{t+k-1}$  [31].

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-2} \\ & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & 1 \end{bmatrix} \cdot \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} \quad (8)$$

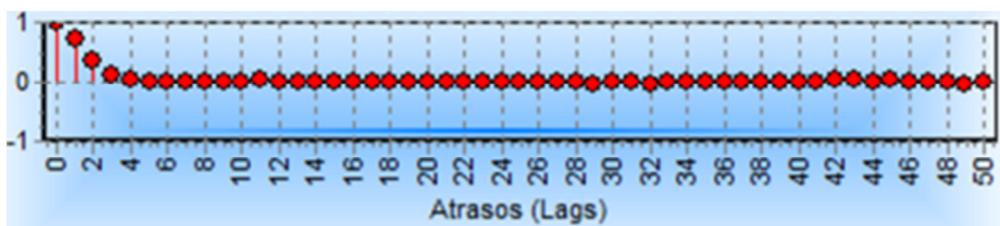
Resolvendo a (8) para  $k = 1, 2, 3, \dots$ , tem-se:

$$\phi_{11} = \rho_1 \quad (9)$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} \quad (10)$$

$$\phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} \quad (11)$$

Onde  $\phi_{kk}$  representa a Função de Autocorrelação parcial para o atraso  $k$ .



**Figura 3.5. Autocorrelação Parcial da Série Temporal**

Por definição, autocorrelação parcial, apresentada na Figura 3.5, é a correlação entre duas amostras  $x_t$  e  $x_{t+k}$ , separadas por um intervalo de tempo  $k$ , excluindo a dependência dos valores intermediários  $w_{t+1}, w_{t+2}, \dots, w_{t+k-1}$ . Em que  $k$  é chamado de atraso (*lag*) [31].

O valor de  $\phi_{kk}$  pode variar de  $-1$  a  $1$  e quanto mais próximo de  $-1$  ou de  $1$  estiver, maior será a correlação parcial existente entre a reta e os dados [31].

### 3.2.5 Modelos de previsão

A previsão de demanda utilizando métodos quantitativos pode ser feita através de vários modelos de regressão. O emprego de cada modelo depende basicamente do comportamento da série temporal que se deseja analisar [32].

#### Modelo auto-regressivo (AR)

Quando uma variável dependente  $x_t$  em um dado momento  $t$  depende apenas do seu próprio valor no período anterior ( $t-1$ ) e de um termo aleatório (ruído branco),  $\varepsilon_t$ , não correlacionado com  $x_t$ , com média zero e variância constante diz-se que esta variável segue um processo auto-regressivo de primeira ordem [28].

Se uma observação  $x_t$  é gerada pela média ponderada de somente as  $p$  primeiras observações próximas anteriores da variável acrescida de um erro aleatório  $\varepsilon_t$ , então ela pode ser modelada por um processo AR( $p$ ), dado por [28]:

$$x_t = \phi_1 \cdot x_{t-1} + \phi_2 \cdot x_{t-2} + \dots + \phi_p \cdot x_{t-p} + \xi + \varepsilon_t \quad (12)$$

em que:

$$\varepsilon_t = x_t - \hat{x}_t \quad (13)$$

$\hat{x}_t$  é a estimativa de  $x_t$ ,  $\xi$  é um valor constante e  $\phi_i$  são os coeficientes constantes auto-regressivos que descrevem como um valor corrente  $x_t$  relaciona-se com valores passados  $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ .

A média de um AR( $p$ ) é dada pelo valor estimado  $E[x_t]$  [28]:

$$E[x_t] = \frac{\xi}{(1 - \phi_1 - \phi_2 - \dots - \phi_p)} = \mu \quad (14)$$

Se o processo é estacionário, a média é constante.

A condição necessária e não suficiente de estacionariedade é representada por:

$$\phi_1 + \phi_2 + \dots + \phi_p < 1 \quad (15)$$

O modelo é auto-regressivo de ordem 1, indicado por AR(1), versão mais simples de um modelo AR, é aquele em que  $x_t$  depende somente de  $x_{t-1}$ , de  $\varepsilon_t$  e de uma constante  $\xi$  [33].

$$x_t = \phi \cdot x_{t-1} + \xi + \varepsilon_t \quad (16)$$

em que  $\phi$  é um parâmetro a ser estimado e  $E[\varepsilon_t] = 0$ ;  $E[\varepsilon_t^2] = \sigma^2$ ; e  $E[\varepsilon_t \varepsilon_s] = 0$ ; para  $t \neq s$ .

#### Modelo de médias móveis (MA)

Quando uma observação  $x_t$  é gerada pela média ponderada do valor presente e dos  $q$  primeiros valores passados de um processo de ruído branco  $\varepsilon_t$  mais a

média  $\mu$ , então ela pode ser modelada por um processo MA (*Moving Average*) ( $q$ ), dado por [28]:

$$x_t = \mu + \varepsilon_t - \theta_1 \cdot \varepsilon_{t-1} - \theta_2 \cdot \varepsilon_{t-2} - \dots - \theta_q \cdot \varepsilon_{t-q} \quad (17)$$

em que  $\varepsilon_t = x_t - \hat{x}_t$  é o erro aleatório ou ruído branco,  $\hat{x}_t$  é a estimativa de  $x_t$ ,  $\theta_i$  são os coeficientes de média móvel que descrevem como um valor corrente  $x_t$  relaciona-se com valores passados  $x_{t-1}, x_{t-2}, \dots, x_{t-q}$ .

A condição necessária e não suficiente de estacionariedade é representada por [28]:

$$\theta_1 + \theta_2 + \dots + \theta_q < 1 \quad (18)$$

Um MA( $q$ ) com  $q$  finito será sempre estacionário. O modelo de médias móveis de primeira ordem, MA(1), é dado por [33]:

$$x_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} \quad (19)$$

De forma geral, a média móvel MA( $q$ ) usa um número  $q$  predeterminado de períodos passados, normalmente os mais recentes, para gerar sua previsão. A cada novo período de previsão o dado mais antigo é substituído pelo mais recente [24].

### **Modelo auto-regressivo de média móvel (ARMA)**

Quando o processo estacionário apresenta características simultaneamente de um processo AR e de um processo MA, então ele pode ser modelado por um processo misto ARMA, descrito por seus  $p$  valores passados e pelos  $q$  ruídos brancos correntes e passados, dados por [33]:

$$x_t = \phi_1 \cdot x_{t-1} + \dots + \phi_p \cdot x_{t-p} + \xi + \varepsilon_t - \theta_1 \cdot \varepsilon_{t-1} - \dots - \theta_q \cdot \varepsilon_{t-q} \quad (20)$$

A média é dada pela parcela do processo AR.

As condições de estacionariedade também são dadas pela parcela do processo AR.

O modelo ARMA (1,1) é a especificação mais simples que um processo dessa natureza pode apresentar [28]:

$$x_t = \phi_1 \cdot x_{t-1} + \xi + \varepsilon_t - \theta_1 \cdot \varepsilon_{t-1} \quad (21)$$

Na prática, os valores de  $p$  e  $q$  são geralmente menores que 2 para séries temporais estacionárias [31]. A condição de estacionariedade estabelecida para os processos AR( $p$ ) e MA( $q$ ) se mantém nos modelos ARMA ( $p, q$ ).

Um processo estocástico estacionário, ou seja, um processo que possui média, variância e autocorrelação constantes em relação ao tempo, pode ser melhor representado por um modelo auto-regressivo e/ou médias móveis – ARMA( $p,q$ ) [20].

### **Modelo auto-regressivo integrado e de média móvel (ARIMA)**

Caso geral dos modelos propostos por *Box et al* [31], o modelo ARIMA é apropriado para descrever séries não estacionárias, ou seja, séries que não possuem média constante no período de análise, nas quais os parâmetros quase sempre são pequenos e que, na prática, geralmente apresentam tendência e/ou sazonalidade [29].

Quando série original dos dados não é estacionária, será necessária diferenciá-la a  $d$  vezes até obter uma série estacionária (média e variância constantes no tempo). Posteriormente, a série obtida pode ser modelada por um processo ARMA( $p,q$ ) [28].

O modelo ARIMA considera a tendência da série temporal, tem ordem ( $p,d,q$ ) e pode ser representado por [29]:

$$\phi(B)\Delta^d . x_t = \theta(B) . \varepsilon_t \quad (22)$$

onde:  $\Delta^d = (1 - B)^d$ ,  $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$  o polinômio auto-regressivo de ordem  $p$ ;  $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$  o polinômio de médias móveis de ordem  $q$ ;  $B$  o operador de retardo, tal que  $B^j . x_t = x_{t-j}$  e  $d$  é o número de diferenças necessárias para retirar a tendência da série e transformá-la em estacionária.

A metodologia para se prever uma série temporal através dos modelos ARIMA consiste de quatro etapas: identificação, estimativa, checagem e previsão [34].

A etapa de identificação consiste em descobrir os valores apropriados de  $p$ ,  $d$  e  $q$  dentre as várias versões dos modelos de *Box e Jenkins*, sejam eles sazonais ou não, que melhor descrevem o comportamento da série.

O primeiro parâmetro a ser identificado é o grau de diferenciação  $d$  realizado através do diagrama da função de autocorrelação (ACF), no qual são apresentados os valores das autocorrelações em relação aos atrasos  $k$ .

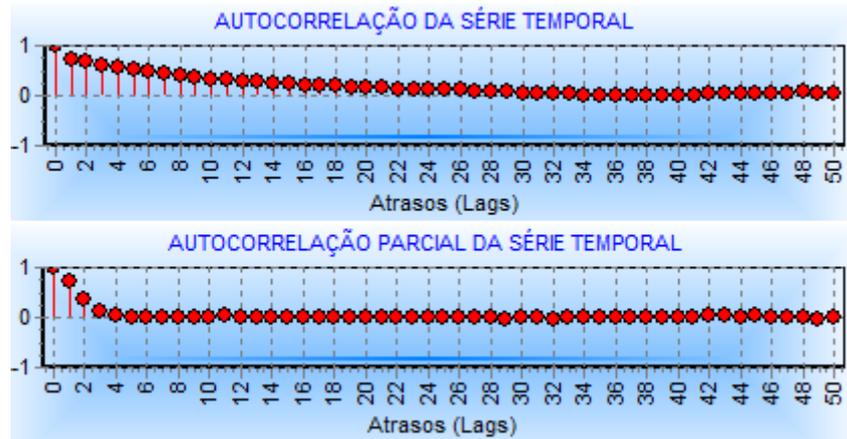
Se as autocorrelações decrescerem de forma exponencial, realizam-se diferenciações na série, até que o diagrama apresente um corte abrupto para um valor qualquer de autocorrelação, quando a série será considerada estacionária [22].

A análise do comportamento das ACFs e PACFs e seus respectivos correlogramas irão auxiliar na identificação do modelo a ser estimado.

A ordem auto-regressiva  $p$  é determinada pela verificação da função de autocorrelação (ACF) e autocorrelação parcial (PACF) da série estudada. Se a série for unicamente auto-regressiva ARIMA ( $p,d,0$ ), sua função de autocorrelação  $\rho_k$  sofrerá

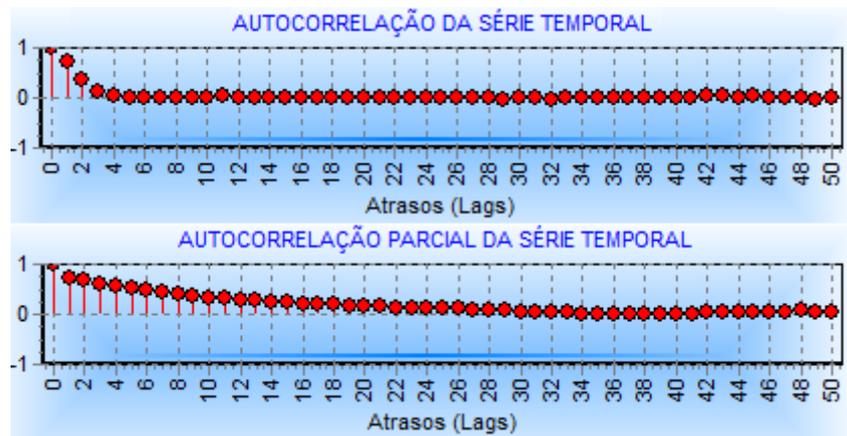
uma queda exponencial gradativa e sua função de autocorrelação parcial  $\phi_{kk}$  sofrerá uma queda repentina após o lag  $k$ , conforme pode ser visto na Figura 3.6.

Caso contrário, efetua-se a análise dos estimadores para verificar até que ordem de defasagem do correlograma desta função é estatisticamente significativa. Essa será sua ordem auto-regressiva [20].



**Figura 3.6. ACF e PACF para um Modelo AR(1)**

Para o caso de uma série ser unicamente de média móvel ARIMA  $(0,d,q)$ , sua função de autocorrelação  $\rho_k$  sofrerá uma queda repentina após o lag  $k$  e sua função de autocorrelação parcial  $\phi_{kk}$  sofrerá uma queda exponencial gradativa, conforme pode ser visto na Figura 3.7 [20].



**Figura 3.7. ACF e PACF para um modelo MA (1)**

Uma vez identificados os valores apropriados de  $p$  e  $q$ , a próxima etapa é estimar os parâmetros dos termos auto-regressivo e de média móvel incluídos no modelo, que pode ser feito pelo método dos mínimos quadrados.

Escolhido o modelo ARIMA em particular e estimados seus parâmetros, parte-se para a terceira etapa que é verificar se o modelo escolhido é adequado para ajustar os dados, pois é possível que outro modelo ARIMA possa desempenhar o mesmo papel.

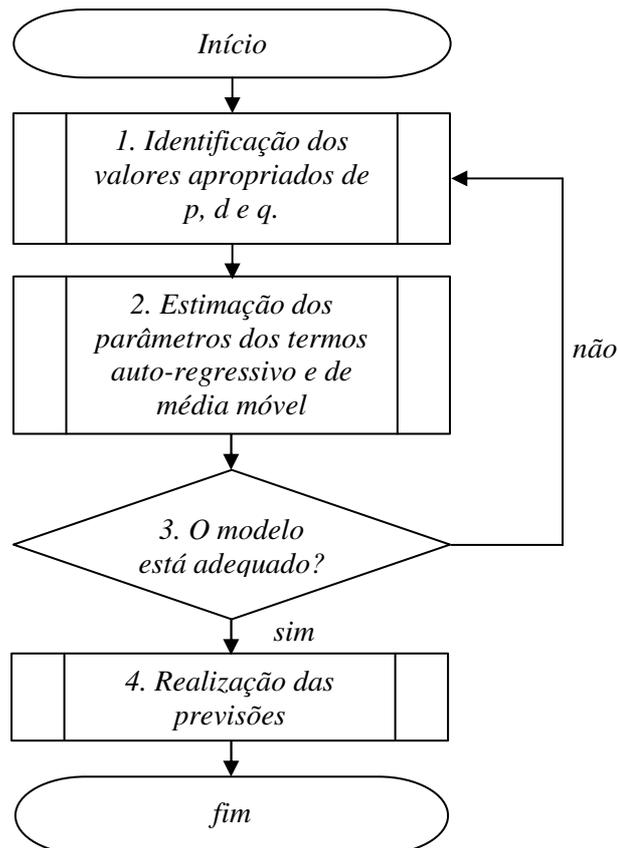
Um teste simples para avaliar o modelo escolhido é analisar os resíduos estimados, pois estes devem ser ruídos brancos. Caso positivo pode-se aceitar o ajuste específico. Caso negativo deve-se repetir processo.

Na última etapa, de previsão, são realizadas as previsões e verificada a eficácia do modelo escolhido.

A teoria da utilização de componentes auto-regressivos e de médias móveis na modelagem de séries temporais utiliza duas ideias básicas na criação de sua metodologia de construção de modelos:

- Parcimônia, que consiste na utilização do menor número possível de parâmetros para obter uma representação adequada no fenômeno em estudo.
- Construção iterativa do modelo em que a informação empírica é analisada teoricamente sendo, o resultado deste estágio confrontado com a prática e assim sucessivamente até a obtenção de um modelo satisfatório.

O ciclo iterativo utilizado para a análise de uma série temporal através da metodologia de *Box e Jenkins* está representado na Figura 3.8:



**Figura 3.8. Fluxograma do Modelo ARIMA de *Box e Jenkins* [31]**

Caso o modelo não seja adequado, o ciclo é repetido, voltando-se à fase de identificação. Quando se obtém um modelo satisfatório, passa-se para a última etapa da metodologia de *Box e Jenkins*, que trata da realização de previsões.

### 3.3 Redes neurais artificiais

Novas descobertas no campo das redes neurais têm atraído cada vez mais atenção nos últimos anos. Desde 1943, quando Warren McCulloch e Walter Pitts apresentaram o primeiro modelo de neurônios artificiais, novo e mais sofisticado, diversas proposições foram feitas de década para década. A análise matemática tem resolvido alguns dos mistérios apresentados pelos novos modelos, mas deixou muitas perguntas em aberto para futuras investigações [35].

Pode-se ilustrar a importância destes estudos quando se aponta para o período compreendido entre 1901 e 1991, onde cerca de dez por cento dos Prêmios Nobel de Fisiologia e Medicina foram concedidos a cientistas que contribuíram para a compreensão do cérebro. Não é um exagero dizer que nós aprendemos mais sobre o sistema nervoso nos últimos 50 anos do que nunca [35].

Ao longo das últimas décadas o homem tem fomentado o desejo de fazer com que as máquinas tenham capacidades similares aos seres humanos como, por exemplo, aprendizado, tomada de decisões e reconhecimento de padrões, o surgimento de algoritmos como o das redes neurais tornou estes objetivos alcançáveis.

Assim como ensina-se a uma criança a reconhecer um dado objeto, como por exemplo uma cadeira. Mostra-se a ela exemplos deste objeto e espera-se o seu aprendizado. Neste momento é importante a apresentação de diversos exemplos para que se torne possível a correta identificação do objeto.

Além disso, é esperado que, com a apresentação de novos objetos diferentes dos utilizados no aprendizado, que estes sejam reconhecidos corretamente quanto a tratar-se ou não do objeto em questão, considerando que tenha sido submetido a esta criança muitos exemplos de casos positivos e negativos de reconhecimento do objeto.

Este mesmo procedimento natural pode ser espelhado para o ensino de uma rede neural.

#### 3.3.1 Modelo de neurônio artificial

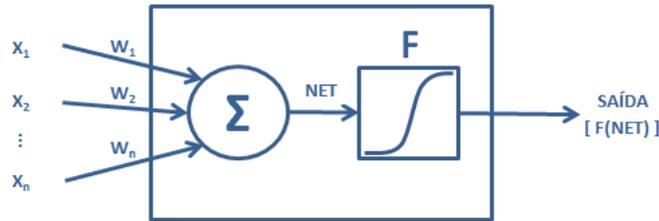
Inspirado no funcionamento de um neurônio biológico, que consiste de muitas entradas, correspondente aos dendritos conectados através das junções sinápticas. O modelo de um neurônio é apresentado na Figura 3.9 e é matematicamente descrito por [36]:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (23)$$

$$y_k = \varphi(u_k + b_k) \quad (24)$$

em que  $x_i$  são os sinais de entrada,  $w_{kj}$  são os pesos sinápticos do neurônio  $k$ ,  $u_k$  é a saída do combinador linear devido aos sinais de entrada,  $b_k$  é o bias,  $\varphi(.)$  é a função de ativação e  $y_k$  é o sinal de saída do neurônio  $k$ .

Apesar da sua contribuição, McCulloch e Pitts não apresentaram nenhum modelo que permitisse a adaptação dos pesos sinápticos em processo de aprendizado.



**Figura 3.9. Neurônio artificial projetado por McCulloch e Pitts**

Somente em 1949, Donald Hebb propôs uma lei de aprendizado para ajuste das sinapses dos neurônios, demonstrando que o aprendizado está ligado a alteração da eficiência sináptica, ou seja, a conexão somente é reforçada quando as células pré-sinápticas e as pós-sinápticas estão excitadas, postulando assim uma fórmula matemática simples que permitisse a alteração dos pesos sinápticos dos neurônios proporcionalmente para as ativações do neurônio [36].

$$\Delta w_{kj}(n) = F(y_k(n), x_j(n)) \quad (25)$$

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n) \quad (26)$$

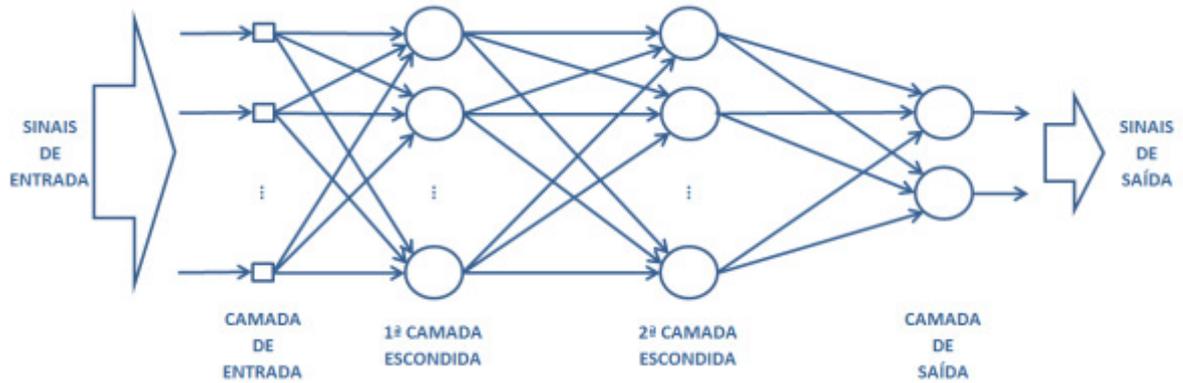
em que  $\eta$  é uma constante positiva que determina a taxa de aprendizagem.

### 3.3.2 Redes multilayer perceptron

Com amplo espectro de aplicação, as redes *Multilayer Perceptron* têm tido sucesso na classificação de padrões, controle e processamento de sinais e na previsão de valores.

As redes *Multilayer Perceptron* são constituídas por um conjunto de nós fonte que formam a camada de entrada, as camadas escondidas e a camada de saída da rede. Com exceção da primeira, as demais camadas são dotadas de neurônios e, portanto, apresentam capacidade computacional [36].

Exemplificada por intermédio da Figura 3.10 temos a arquitetura de uma rede neural artificial *Multilayer Perceptron* com camada de entrada, duas camadas escondidas e camada de saída.



**Figura 3.10. Arquitetura de uma rede neural artificial *multilayer perceptron* com duas camadas escondidas**

Conceitualmente diz-se que uma rede neural artificial é progressiva (*feedforward*) quando não são definidos laços de realimentação, ou seja, as saídas dos neurônios em quaisquer camadas estão, exclusivamente, ligadas as entradas da camada subsequente. Como resultado tem-se que o sinal de entrada propaga-se em sentido progressivo através de todas as camadas da rede. A rede *multilayer perceptron* é uma rede progressiva [36].

Outro aspecto a ser observado está relacionado à conectividade, ou seja, a rede pode ser ou não completamente conectada. A rede é dita completamente conectada quando cada nó de uma camada está conectado a todos os outros nós da camada adjacente. Em caso contrário algumas sinapses podem estar faltando. Em termos práticos a ausência de uma sinapse pode ser emulada com um peso constante e igual a zero [36].

### 3.3.3 O algoritmo *backpropagation*

O algoritmo *backpropagation* é conhecido como o mais popular algoritmo utilizado no contexto do aprendizado de uma rede neural artificial *multilayer perceptron*, título adquirido em função da sua facilidade de implementação e pelo fato do seu grande potencial em armazenar o conteúdo das informações, adquirido por intermédio do conjunto de dados, nos pesos sinápticos da rede [36].

A utilização deste algoritmo em uma rede *multilayer perceptron* fará com que ela desenvolva a capacidade de generalizar, ou seja, capacidade de apresentar um desempenho satisfatório quando é alimentada com dados de teste retirados do mesmo espaço de entrada que os dados de treinamento, mas que não foram previamente apresentados. Para isso é preciso na etapa de treinamento apresentar a rede um conjunto grande o suficiente de dados que represente o ambiente no qual a rede está inserida [36].

Na etapa de treinamento, aplicação do algoritmo pode ser dividida em duas etapas: Passo direto e passo reverso [36].

### Passo direto

Nesta etapa os pesos sinápticos não são alterados e o sinal na camada de entrada é propagado através das camadas escondidas até a camada de saída, neurônio a neurônio [36].

O sinal obtido como resultado na saída do neurônio  $j$  é equacionado por

$$y_j(n) = \varphi(v_j(n)) \quad (27)$$

onde  $v_j(n)$  é o potencial de ativação do neurônio  $j$ , equacionado por

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n) \quad (28)$$

em que  $m$  é o número total de entradas (excluindo a polarização) aplicadas ao neurônio  $j$ ,  $w_{ji}(n)$  é o peso sináptico conectando a saída do neurônio  $i$  ao neurônio  $j$ ,  $y_i(n)$  é o sinal de entrada do neurônio  $j$ , ou equivalentemente, o sinal na saída do neurônio  $i$ .

Nos casos em que o neurônio  $j$  encontra-se na primeira camada escondida, o índice  $i$  remete ao  $i$ -ésimo nó de entrada da rede, escreve-se:

$$y_i(n) = x_i(n) \quad (29)$$

onde  $x_i(n)$  é o  $i$ -ésimo componente do vetor de entrada do neurônio  $j$ .

Por outro lado, quando o neurônio  $j$  está na camada de saída, o índice  $j$  refere-se ao  $j$ -ésimo nó de saída da rede, escreve-se:

$$y_j(n) = o_j(n) \quad (30)$$

sendo  $o_j(n)$  o  $j$ -ésimo componente do vetor de saída.

A saída obtida  $o_j(n)$  é então comparada com a resposta desejada  $d_j(n)$  e esta diferença será definida como sinal de erro  $e_j(n)$  para o  $j$ -ésimo neurônio de saída [36].

Contudo pode-se delimitar que o passo direto começa na apresentação do vetor de entrada a primeira camada escondida e termina com a obtenção do sinal de erro na camada de saída [36].

### Passo reverso

Iniciando-se na camada de saída, os sinais de erro serão propagados na direção contrária através da rede, neurônio a neurônio, recursivamente computando os gradientes locais para cada neurônio e corrigindo os pesos sinápticos de acordo com a Regra Delta (31) [36].

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (31)$$

em que  $\Delta w_{ji}(n)$  é a correção aplicada a  $i$ -ésima sinapse do neurônio  $j$ ,  $y_i(n)$  é o sinal de entrada no  $i$ -ésimo nó de entrada do neurônio  $j$ ,  $\delta_j(n)$  é o gradiente local do neurônio  $j$  e  $\eta$  é a razão de aprendizado, esta fator será discutido mais adiante.

Para os casos em que o neurônio encontra-se na camada de saída, o gradiente local é simplesmente o sinal de erro do neurônio multiplicado pela primeira derivada de sua não linearidade ( 32 ) [36].

$$\delta_j(n) = \varphi'_j(v_j(n))e_j(n), \text{ neurônio } j \text{ é de saída.} \quad ( 32 )$$

em que  $\delta_j(n)$  é o gradiente local do neurônio  $j$ ,  $e_j(n)$  é sinal de erro  $j$ -ésimo nó de saída do neurônio  $j$ ,  $\varphi'_j(v_j(n))$  é primeira derivada da função de ativação associada ao neurônio  $j$ .

Uma vez obtido o gradiente local de cada neurônio da camada de saída faz-se o uso da ( 31 ) para corrigir os pesos sinápticos que alimentam a camada de saída.

Obtidos os gradientes locais para os neurônios da camada de saída, usa-se a ( 33 ) para calcular o gradiente local de cada neurônio na camada à esquerda.

Calculado o gradiente local de cada neurônio da camada à esquerda, usa-se a ( 31 ) para corrigir os pesos sinápticos que alimentam esta camada.

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n), \text{ neurônio } j \text{ é escondido.} \quad ( 33 )$$

Recursivamente este procedimento é realizado, propagando as correções nos pesos sinápticos camada por camada, até a camada de entrada.

Observa-se que durante cada ciclo ( passo direto - passo reverso ) ao longo da apresentação do conjunto de dados para treinamento, o vetor de entrada para cada ciclo é mantido fixo.

### **Razão de aprendizado e fator de momento**

A utilização do algoritmo *backpropagation* proporciona uma aproximação da trajetória de movimento na direção de descida sobre a superfície de erro no espaço de pesos sinápticos. Sendo assim quanto menor for feita a razão de aprendizado  $\eta$ , menores serão as correções aplicadas aos pesos sinápticos em cada iteração e mais suave será a trajetória no espaço de pesos. Como consequência tem-se uma lenta convergência do algoritmo até um valor de erro suficientemente pequeno e aceitável [37].

Por outro lado, quando temos a razão de aprendizado muito grande, com o intuito de acelerar a convergência, a correção nos pesos sinápticos também será grande, deste modo o algoritmo torna-se instável (oscilatório).

Para acelerar a convergência e manter estabilidade na trajetória pode-se acrescentar à Regra de Delta ( 31 ) o chamado Fator de Momento. Assim tem-se [35]:

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (34)$$

em que a constante  $\alpha$  é denominada de Constante de Momento com  $0 < \alpha < 1$ . Seu efeito é aumentar a velocidade da trajetória no espaço de pesos na direção da descida mais íngreme.

Situação observada quando a correção aplicada ao peso sináptico matem seu sinal algébrico após várias iterações, caracterizando uma trajetória na superfície de erro ao longo de uma descida acentuada, a correção do peso sináptico é acelerada pelo fator de momento, já que o mínimo global ainda deve estar longe.

No caso de um eventual mínimo local ao longo desta descida acelerada, este pode ser facilmente transpassado.

Por outro lado, quando observa-se a troca de sinal após algumas iteração, caracterizando uma trajetória na superfície de erro próxima ao mínimo global, a correção do peso sináptico é freada pela redução do valor absoluto médio do fator de momento, já que um mínimo (provavelmente global) está próximo e uma alta velocidade poderia desestabilizar o algoritmo em torno do mínimo.

# Capítulo 4

## 4. Metodologia

Este Capítulo apresenta a metodologia utilizada para a modelagem dos dados de consumo de gás natural para consumidores dos segmentos industrial e automotivo da Sergipe Gás S/A - SERGAS.

No decorrer deste Capítulo serão abordados os principais índices de desempenho que são utilizados para avaliar o quão satisfatório são os resultados das previsões dos modelos.

Uma vez que no presente trabalho é explorada a combinação de várias técnicas de previsão, neste capítulo serão introduzidos os procedimentos para obtenção de modelos REGRESSÃO (linear simples, linear múltipla e não linear transformada – polinomial, exponencial, logarítmica e potência), SÉRIE TEMPORAL (auto-regressivo, média móvel, auto-regressivo de média móvel e auto-regressivo integrado e de média móvel) e REDES NEURAIS ARTIFICIAIS (redes *Multilayer Perceptron* com aprendizado através do algoritmo *backpropagation*).

### 4.1 Índices de desempenho

A avaliação da qualidade da previsão é uma importante tarefa a ser realizada, pois permite, por exemplo, comparar diversos algoritmos e diversas estruturas de modelos utilizando índices de desempenho. A seguir são apresentados alguns dos índices de desempenho mais utilizados em problemas de previsão

- O erro médio (ME do inglês *mean error*):

$$ME = \frac{1}{N} \sum_{k=1}^N y(k) - \hat{y}(k) \quad (35)$$

- O erro absoluto médio (MAE do inglês *mean absolute error*):

$$MAE = \frac{1}{N} \sum_{k=1}^N |y(k) - \hat{y}(k)| \quad (36)$$

- O erro quadrático médio (MSE do inglês *mean squared error*):

$$MSE = \frac{1}{N} \sum_{k=1}^N (y(k) - \hat{y}(k))^2 \quad (37)$$

- O erro percentual médio (MPE do inglês *mean percentage error*):

$$MPE = \frac{1}{N} \sum_{k=1}^N \frac{y(k) - \hat{y}(k)}{y(k)} 100 \quad (38)$$

- O erro percentual absoluto médio (MAPE do inglês *mean absolute percentage error*):

$$MAPE = \frac{1}{N} \sum_{k=1}^N \left| \frac{y(k) - \hat{y}(k)}{y(k)} 100 \right| \quad (39)$$

Com o intuito de comparar dois previsores pode-se utilizar os índices de desempenho mostrados nas ( 35 ) a ( 39 ), além de tais índices é necessário também levar em consideração as características dos dados. Por exemplo, uma série de dados com um alto nível de parcela estocástica, um MAPE de 10% pode ser avaliado como um excelente desempenho. Por outro lado, uma série de dados puramente determinística e estacionária com um MAPE de 1% pode indicar um péssimo predictor. Com o objetivo de avaliar a eficiência de um predictor frente aos dados analisados, define-se a raiz do erro quadrático médio normalizado (RMSE do inglês *root mean square error*).

$$RMSE = \frac{\sqrt{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}}{\sqrt{\sum_{k=1}^N (y(k) - \bar{y})^2}} \quad (40)$$

em que  $\bar{y}$  é o valor médio de  $y(k)$ , sendo que a média é calculada na janela de identificação.

Neste índice de desempenho, o erro do predictor é normalizado pelo erro do predictor trivial (valor médio dos dados). Sendo assim, valores próximos de 1 significam que o predictor não é significativamente melhor que simplesmente usar o valor médio dos dados como previsão. Nota-se que a utilidade do índice RMSE aumenta à medida que a componente estocástica da série  $y(k)$  se torna dominante.

Para os casos em que a componente determinística é dominante, outros índices devem ser usados. Uma alternativa interessante é

$$U_{Theil} = \frac{\sqrt{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}}{\sqrt{\sum_{k=1}^N (y(k) - y(k-1))^2}} \quad (41)$$

Conhecido como estatística *U de Theil* [38], este índice utiliza-se da mesma metodologia aplicada na ( 40 ) substituindo-se como predictor trivial o valor

médio dos dados pelo valor anterior da série. Da mesma forma, valores menores do que as unidades indicam um melhor desempenho em relação ao previsor trivial.

Observa-se que o preditor trivial no *U de Theil* é apenas a diferença de um passo à frente, tornando o previsor trivial difícil de ser superado quando se deseja fazer a previsão de médio e longo prazo.

## 4.2 Descrição dos dados

Os dados de consumo foram disponibilizados pela companhia de distribuição de gás natural do Estado de Sergipe, a Sergipe Gás S/A - SERGAS, e compreendem o consumo horário de gás natural dos meses de janeiro de 2011 a agosto de 2011. Os arquivos foram disponibilizados em formato *adobe acrobat* e convertidos no formato *Excel*, totalizando 5808 amostras. Assim, as amostras de consumo horário relativas ao citado período foram carregadas na ferramenta computacional desenvolvida.

## 4.3 Procedimentos para os modelos de regressão

Neste item serão descritos as técnicas de regressão utilizadas neste trabalho para a previsão de consumo de gás natural.

Linear: Nas regressões lineares simples existe uma relação linear implícita entre as duas variáveis, chamadas de variável dependente e independente [16].

$$\hat{Y} = \alpha + \beta \cdot x \quad (42)$$

em que  $\alpha$  e  $\beta$  são os coeficientes da regressão e especificam, respectivamente, o ponto onde a reta intercepta o eixo Y e a inclinação da reta. Estes coeficientes foram estimados pelo método dos mínimos quadrados.

Polinomial: As regressões polinomiais podem ser modeladas adicionando os termos polinomiais ao modelo linear. Isso é feito transformando as variáveis de modo que a equação resultante seja uma equação linear. Neste contexto tem-se

$$\hat{Y} = \beta_0 + \beta_1 \cdot x_1^1 + \beta_2 \cdot x_2^2 + \dots + \beta_b \cdot x_n^n \quad (43)$$

sendo transformada em

$$\hat{Y} = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_n \cdot X_n \quad (44)$$

fazendo

$$X_n = x_n^n \quad (45)$$

Função Exponencial: A função exponencial  $Y = a \cdot e^{bX}$  foi transformada na função linear  $\ln(y) = \ln(a) + b \cdot x$ .

$$\hat{Y} = \alpha \cdot e^{\beta X} \quad (46)$$

sendo transformada em

$$\ln(\hat{Y}) = \ln(\alpha) + \beta \cdot x \quad (47)$$

fazendo  $\varphi = \ln(\hat{Y})$  e  $\eta = \ln(\alpha)$ , a equação pode ser reescrita como:

$$\varphi = \eta + \beta \cdot x \quad (48)$$

na qual serão calculados os valores de  $\eta$  e  $\beta$  com a utilização de mínimos quadrados e substituídos na (46) com a seguinte transformação:

$$\alpha = e^\eta$$

Função Logarítmica: A função logarítmica  $Y = a + b \cdot \ln(x)$  foi transformada na função linear  $Y = a + b \cdot \bar{x}$ .

$$\hat{Y} = \alpha + \beta \cdot \ln(x) \quad (49)$$

fazendo  $\bar{x} = \ln(x)$  então:

$$\hat{Y} = \alpha + \beta \cdot \bar{x} \quad (50)$$

Os valores de  $\alpha$  e  $\beta$  são calculados com a utilização de mínimos quadrados.

Função Potência: A função Potência  $Y = a \cdot x^b$  foi transformada na função linear  $\ln(y) = \ln(a) + b \cdot \ln(x)$ .

$$\hat{Y} = \alpha \cdot x^\beta \quad (51)$$

transformada em:

$$\ln(\hat{Y}) = \ln(\alpha) + \beta \cdot \ln(x) \quad (52)$$

fazendo  $\varphi = \ln(\hat{Y})$ ,  $\eta = \ln(\alpha)$  e  $\bar{x} = \ln(x)$  então a equação pode ser reescrita como:

$$\varphi = \eta + \beta \cdot \bar{x} \quad (53)$$

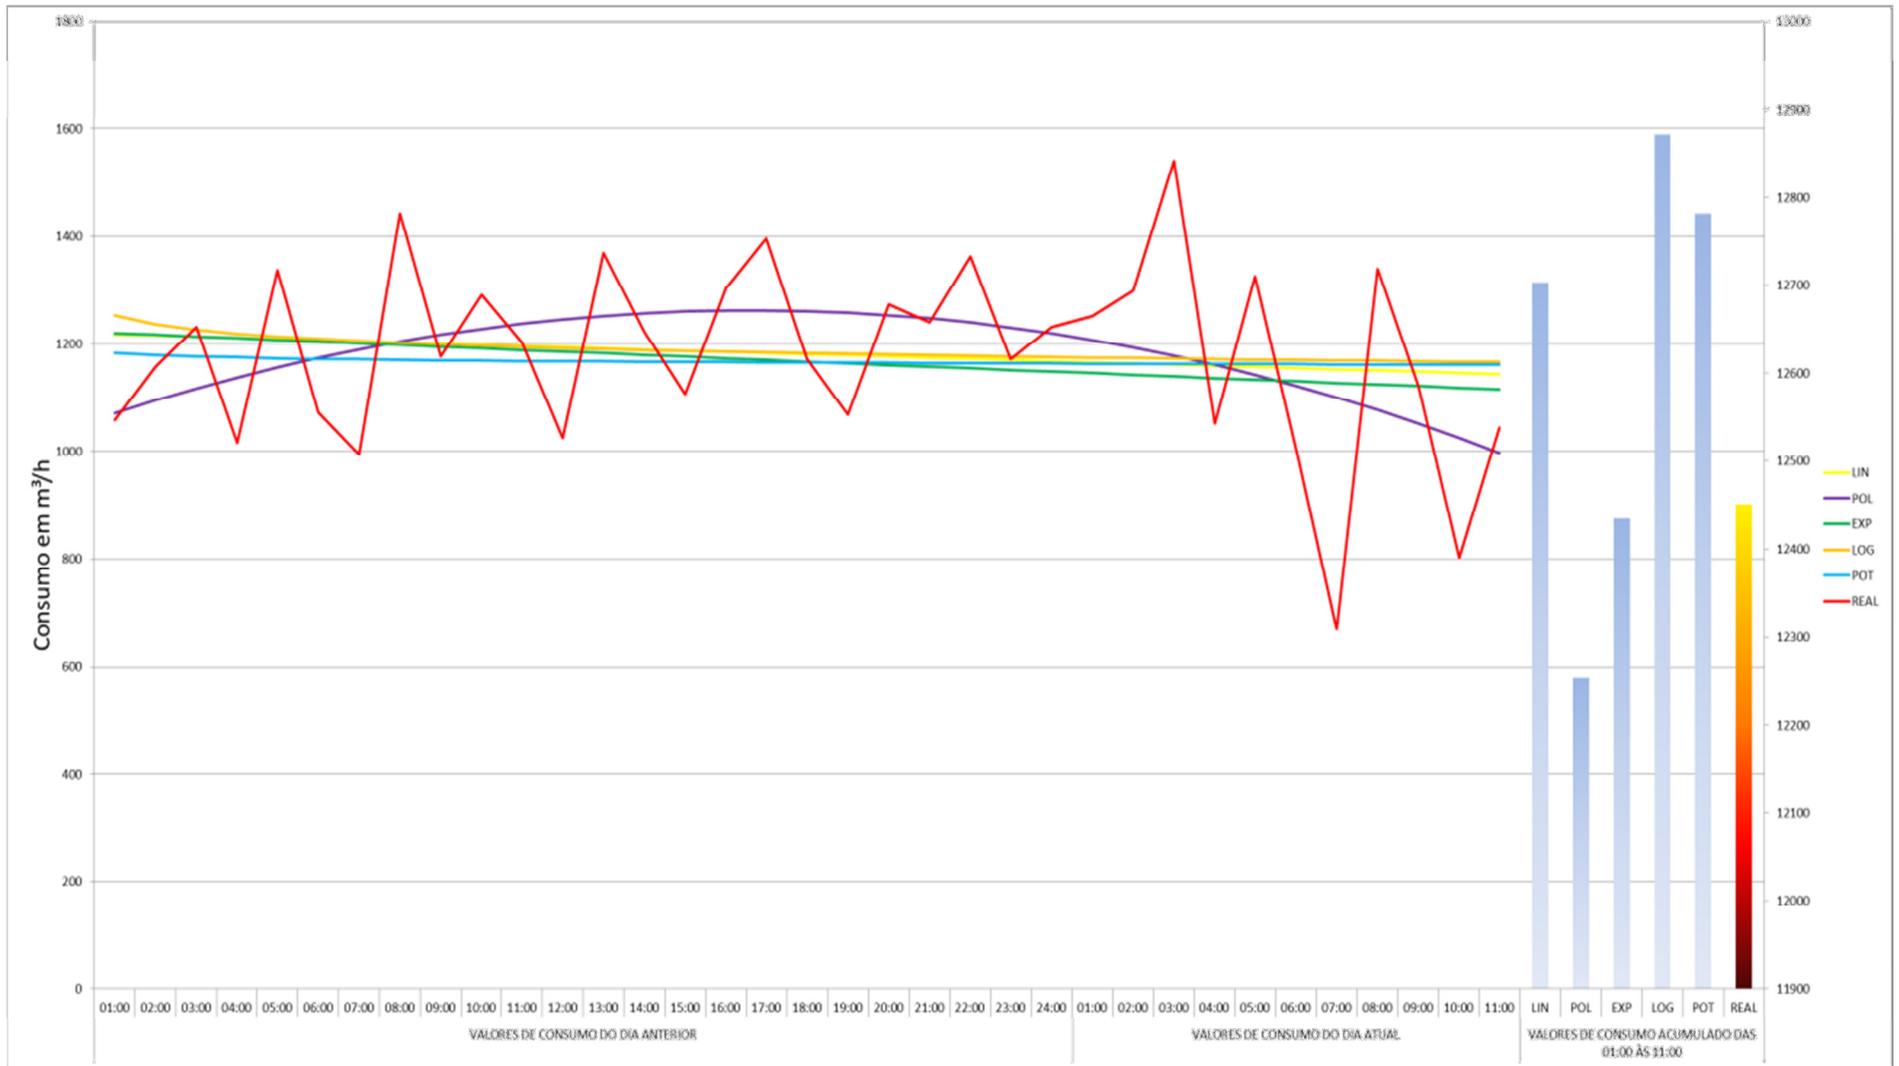
na qual serão calculados os valores de  $\eta$  e  $\beta$  com a utilização de mínimos quadrados e substituídos na (51) com a seguinte transformação:

$$\alpha = e^\eta$$

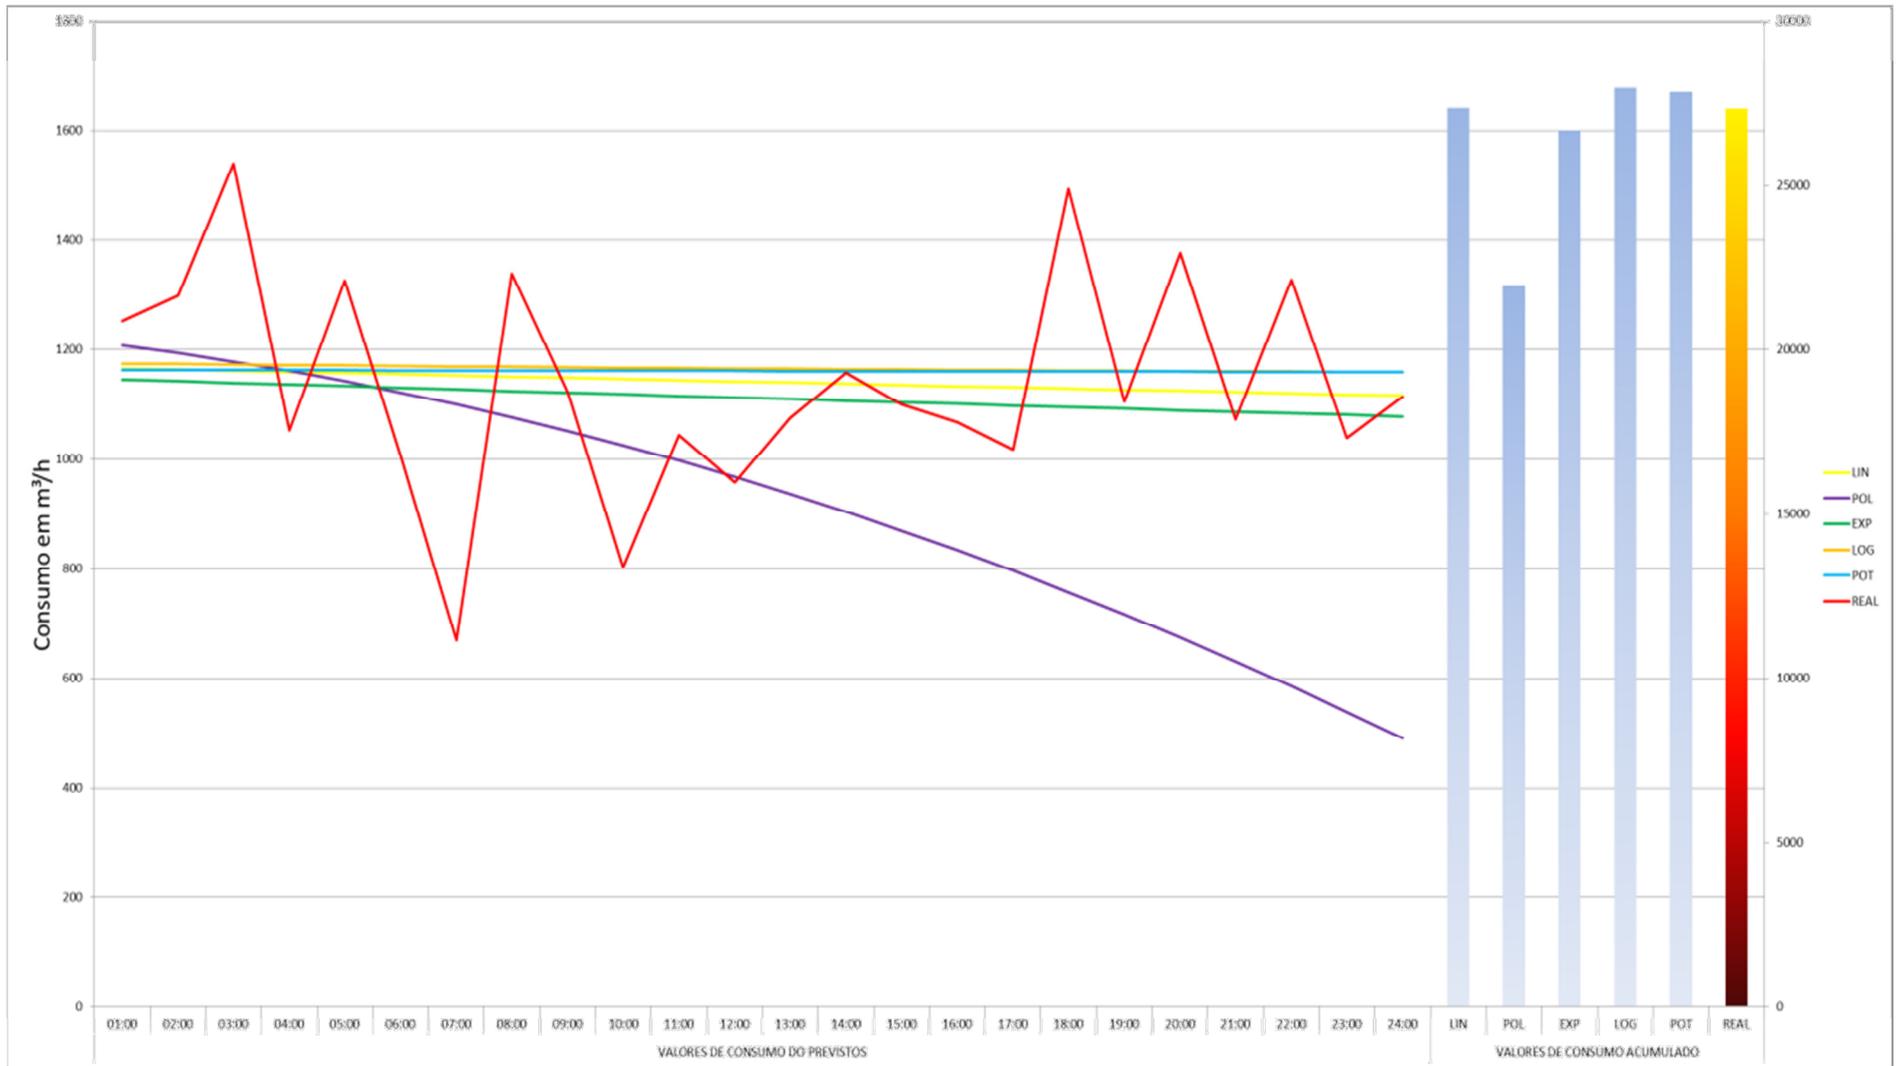
Para o ajuste dos modelos foram utilizados os dados diários das 01:00 às 11:00 do dia em análise e os 24 valores horários do dia anterior, conforme ilustrado na Figura 4.1.

A escolha deste período se dá pelo fato de que estes são os dados que estão disponíveis no sistema de telemetria para realização da previsão.

Para validação do modelo utiliza-se a equação calculada e estimam-se os valores para um dia inteiro, ou seja, das 01:00 até as 24:00, conforme ilustrado na Figura 4.2.



**Figura 4.1. Análise dos Ajustes da Regressão**



**Figura 4.2. Análise dos Resultados da Regressão**

A fim de analisar os resultados obtidos e comparar a eficiência dos métodos serão utilizado os Índices de Desempenho apresentados neste capítulo e exemplificado na Tabela 4.1.

**Tabela 4.1. Índices de Desempenho aplicados as Regressões**

TIPO	ME	MAE	MSE	MPE	MAPE	RMSE	PERÍODO DE AJUSTE / VALIDAÇÃO
LINEAR	0,50	2,05	7,42	3,77	18,19	0,85	01/08/2011 - 30/08/2011
POLINOMIAL	0,23	2,63	11,21	17,84	34,46	1,05	01/08/2011 - 30/08/2011
EXPONENCIAL	- 0,42	2,18	9,30	- 24,36	36,51	0,95	01/08/2011 - 30/08/2011
LOGARITMICA	0,09	1,92	5,92	- 4,69	19,78	0,76	01/08/2011 - 30/08/2011
POTÊNCIA	- 0,24	1,93	8,04	- 23,79	34,97	0,89	01/08/2011 - 30/08/2011

A ordem da equação polinomial ajustada nos estudos de caso apresentados no capítulo 5 é igual a dois.

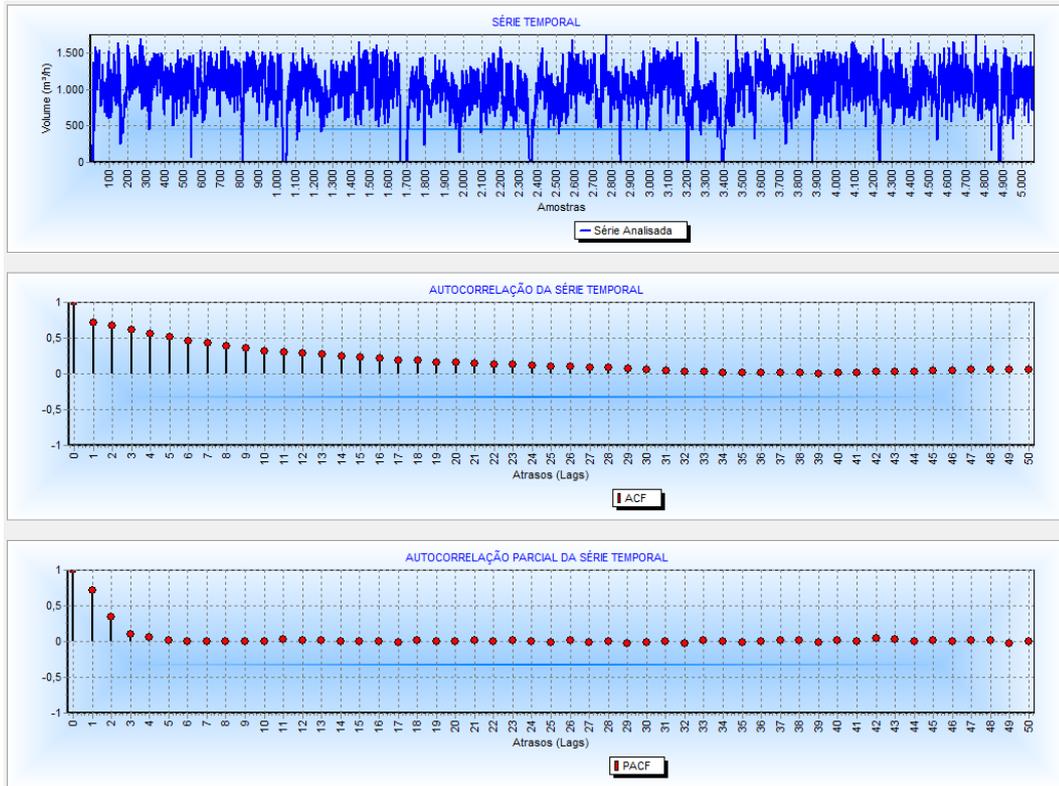
## 4.4 Procedimentos para os modelos de séries temporais

O presente trabalho seguiu a metodologia de *Box e Jenkins* na modelagem das Séries Temporais. Na Figura 3.8 foi esquematizado o fluxograma desta metodologia. Esta metodologia, segundo a maioria dos autores, se baseia na análise dos dados através de uma estratégia interativa.

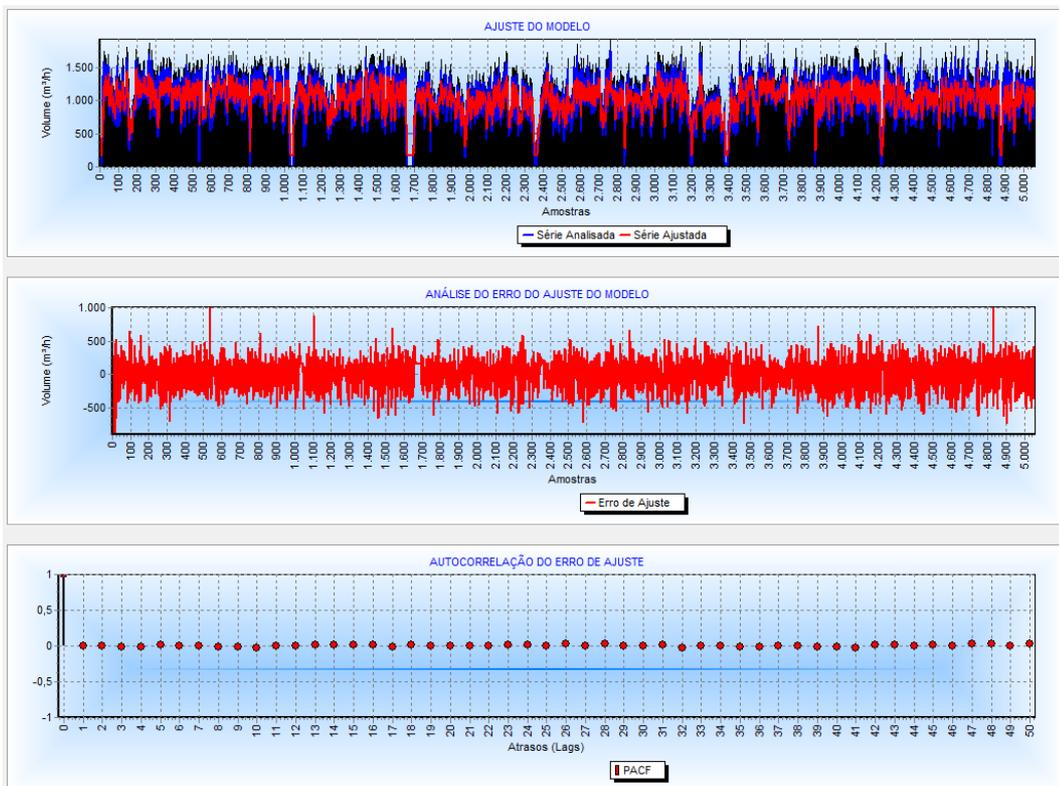
Os estágios do ciclo iterativo da metodologia *Box e Jenkins* são identificação, estimação, verificação e previsão.

No primeiro estágio é realizada a identificação do modelo, escolhido com base na análise de autocorrelações, autocorrelações parciais e outros critérios. Nessa etapa, é identificada a necessidade de diferenciar os dados para tornar a série estacionária e calculada a ordem do processo auto-regressivo ( $p$ ) e do processo de médias móveis ( $q$ ). Tradicionalmente, as principais ferramentas nessa fase são as funções de autocorrelação e autocorrelações parciais, conforme Figura 4.3.

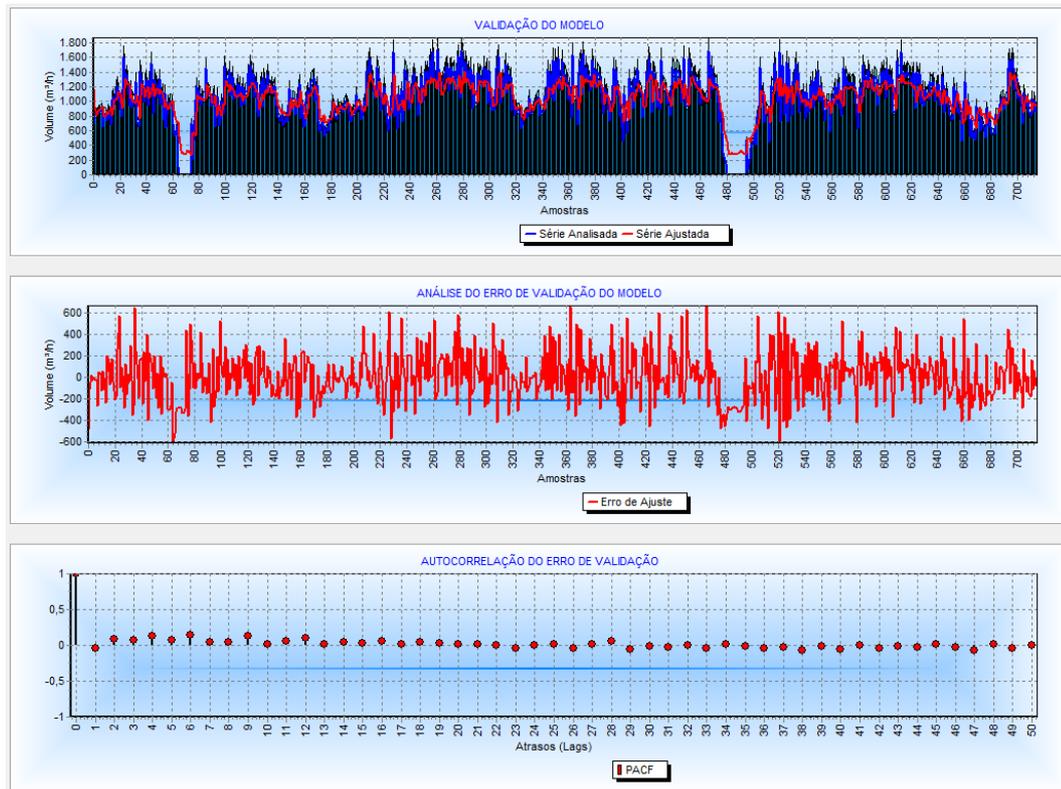
O próximo estágio será a estimação dos valores dos coeficientes auto-regressivo ( $p$ ) e de médias móveis ( $q$ ), utilizando o método de mínimos quadrados. Seguido pelo estágio de verificação da adequação do modelo proposto a série temporal em análise. Caso o modelo não seja adequado, o ciclo é repetido, voltando-se à fase de identificação. Quando se obtém um modelo satisfatório, passa-se para o último estágio da metodologia de *Box e Jenkins*, que trata da realização de previsões, demonstrada na Figura 4.5.



**Figura 4.3. Exemplo de Série Temporal (gráfico superior), Função de Autocorrelação (gráfico central) e Função de Autocorrelação Parcial (gráfico inferior).**



**Figura 4.4. Exemplo de Ajuste do Modelo (gráfico superior), Erro de Ajuste do Modelo (gráfico central) e Autocorrelação do Erro de Ajuste (gráfico inferior).**



**Figura 4.5. Exemplo de Previsão do Modelo (gráfico superior), Erro de Previsão do Modelo (gráfico central) e Autocorrelação do Erro de Previsão (gráfico inferior).**

A fim de comparar a eficiência das diversas configurações possíveis do modelo em estudo serão utilizados os Índices de Desempenho apresentados neste capítulo, conforme demonstrado na Tabela 4.2.

**Tabela 4.2. Índices de Desempenho aplicados as Séries Temporais**

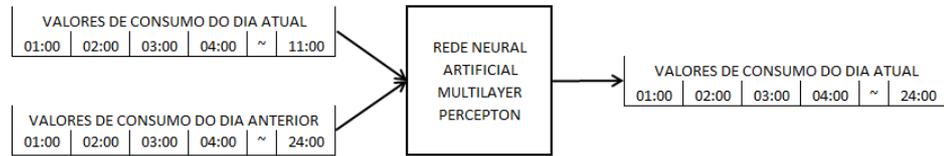
ARIMA	p Lags	q Lags	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE AJUSTE	PERÍODO DE VALIDAÇÃO
(2,0,2)	(1 2)	(3 4)	5,34	193,3	6,02E+04	-5,7	20,52	0,73	0,92	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(2,1,2)	(1 2)	(3 4)	-2,75	182,9	5,63E+04	21,61	114,9	0,89	0,51	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(2,0,0)	(1 2)	()	3,84	177,8	5,14E+04	-5,11	18,83	0,68	0,85	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(0,0,2)	()	(1 2)	15,25	269,8	1,22E+05	-7,06	28,45	1,04	1,31	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011

## 4.5 Procedimentos para os modelos de redes neurais artificiais

Para os procedimentos da RNA devem ser levados em conta à escolha das entradas do modelo, escolha do número de camadas escondidas, escolha do número de neurônios na camada escondida, escolha das saídas, porcentagem de dados para treinamento e validação. Algumas considerações sobre a escolha da topologia da rede são feitas a seguir.

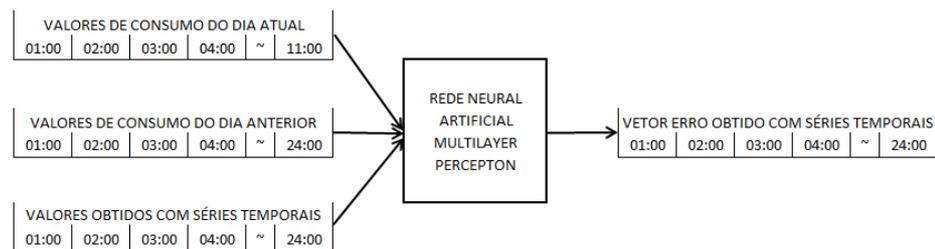
Na metodologia proposta, a escolha das entradas da Rede Neural Artificial pode ser realizada de duas formas distintas:

- **Rede Neural Artificial Padrão:** neste modelo têm-se como entradas da rede os valores reais de consumo das 01:00 às 11:00 do dia atual, além dos valores dos 24 valores horários do dia anterior, formando uma rede com um vetor de 35 entradas e um de 24 saídas conforme ilustrado na Figura 4.6.



**Figura 4.6. Entradas da Rede Neural Artificial Padrão.**

- **Rede Neural Artificial auxiliada por Séries Temporais:** neste modelo mantem-se as entradas da Rede Neural Artificial Padrão, adiciona-se um vetor contendo os valores estimados utilizando as Séries Temporais, totalizando ao todo 59 entradas, sendo o vetor de saída modificado de forma a conter os erros obtidos no ajuste da Série Temporal, conforme demonstrado na Figura 4.7.



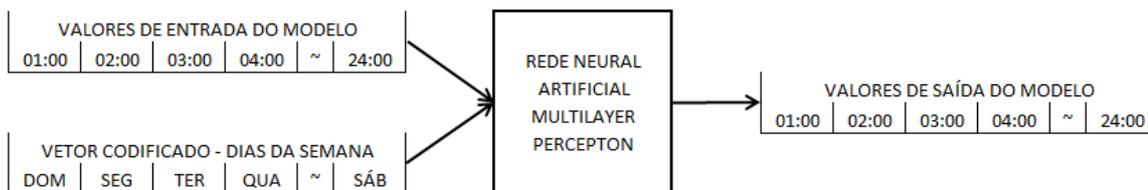
**Figura 4.7. Entradas da Rede Neural Artificial auxiliada por Séries Temporais.**

Neste último caso para conseguir prever o valor do consumo o erro será somado ao valor previsto a partir das séries temporais, conforme demonstrado na ( 54 ).

$$\hat{Y} = \tilde{Y} + \tilde{e}_r \quad ( 54 )$$

em que  $\hat{Y}$  é o valor da saída prevista utilizando rede neural artificial auxiliada por séries temporais,  $\tilde{Y}$  é o valor da saída prevista utilizando séries temporais e  $\tilde{e}_r$  é o valor do erro previsto utilizando redes neurais artificiais.

Adicionalmente os modelos apresentados de redes neurais pode-se inserir, aos já existentes vetores de entradas, um vetor contendo informações sobre os dias da semana codificados em números binários, mostrado na Figura 4.8. Esta prática visa aumentar a eficiência da rede neural para os casos em que são observadas características particulares associadas aos dias da semana, ou seja, a existência de um comportamento típico para cada dia da semana.



**Figura 4.8. Inserção do vetor codificado dos dias da semana.**

O número de camadas escondidas assim como o número de neurônios por camada escondida depende da complexidade da série de dados em análise, podendo variar de apenas uma camada escondida com um neurônio até varias camadas escondidas com vários neurônios.

O número de neurônios da camada escondida normalmente é obtido por tentativas. Para cada tentativa foram realizadas várias simulações, inicializando a rede em condições iniciais diferentes para tentar evitar que o algoritmo de treinamento alcançasse um mínimo local. Para cada caso foi escolhida a simulação correspondente ao número de neurônios da camada que apresentou melhor desempenho, em função dos índices de desempenho.

Como forma de evitar que o treinamento alcance um mínimo local e acelerar a convergência e manter a trajetória estável foi incluído o Fator de Momento à Regra Delta. Também foi implementada a possibilidade de escolha da função de ativação.

Uma questão importante foi a composição dos dados para treinamento e validação, isto é, quais os dados serão usados para treinar os modelos, e quais serão utilizados para validá-los. A literatura sugere que pelo menos 20% da base de dados seja separada para validar os modelos obtidos na fase de treinamento [37].

A fim de comparar a eficiência das diversas configurações possíveis do modelo em estudo foram utilizados os Índices de Desempenho apresentados neste capítulo, conforme demonstrado na Tabela 4.3.

**Tabela 4.3. Índices de Desempenho aplicados as Redes Neurais Artificiais**

DADOS R.N.A.	TIPO R.N.A.	VETOR DIA	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE AJUSTE	PERÍODO DE VALIDAÇÃO
Tan. Hip.(1,4)	PADRÃO	SIM	0,14	1,38	2,88	-8,69	18,38	0,53	0,41	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Tan. Hip.(1,4)	PADRÃO	NÃO	0,13	1,41	2,98	-9,23	19,11	0,54	0,41	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Tan. Hip.(1,4)	PADRÃO + ST	SIM	0,31	1,39	2,89	-7,71	18,6	0,53	0,4	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Tan. Hip.(1,4)	PADRÃO + ST	NÃO	0,16	1,34	2,85	-8,32	18,1	0,53	0,4	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011

Na Tabela 4.3 observa-se na primeira coluna a codificação utilizada para identificar a topologia da rede neural artificial, composta pela função de ativação (i.e. Tan. Hip – tangente hiperbólica) seguida por parênteses contendo o número de camadas escondidas e o número de neurônios por camada escondida.

# Capítulo 5

## 5. Resultados

Neste capítulo serão apresentados os resultados das previsões de consumo de gás utilizando os modelos descritos no capítulo 4. Estes resultados também são analisados e discutidos utilizando os índices de desempenho, comentados também no capítulo anterior, bem como a luz das possíveis penalidades no caso da previsão de consumo exceder os limites de +5% e -10% normalmente utilizados pelos fornecedores na programação diária junto às distribuidoras.

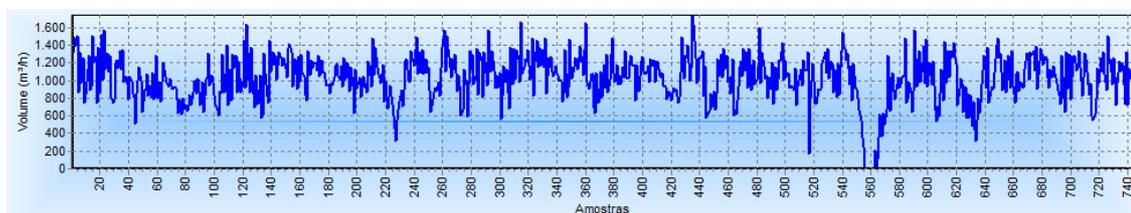
Neste contexto serão comparados os melhores resultados obtidos em cada modelo frente às diferentes configurações utilizadas e, em seguida, comparado o melhor resultado frente ao modelo adotado atualmente na companhia distribuidora em análise.

Nos estudos de caso deste trabalho utilizaram-se os dados dos dias compreendidos entre 01/01/2011 e 31/07/2011 para treinamento e entre 01/08/2011 e 31/08/2011 para validação.

Os resultados serão apresentados nas seções a seguir.

### 5.1 Consumidor industrial A

A Figura 5.1 mostra o perfil de consumo do CONSUMIDOR INDUSTRIAL A.



**Figura 5.1. Perfil de consumo do CONSUMIDOR INDUSTRIAL A.**

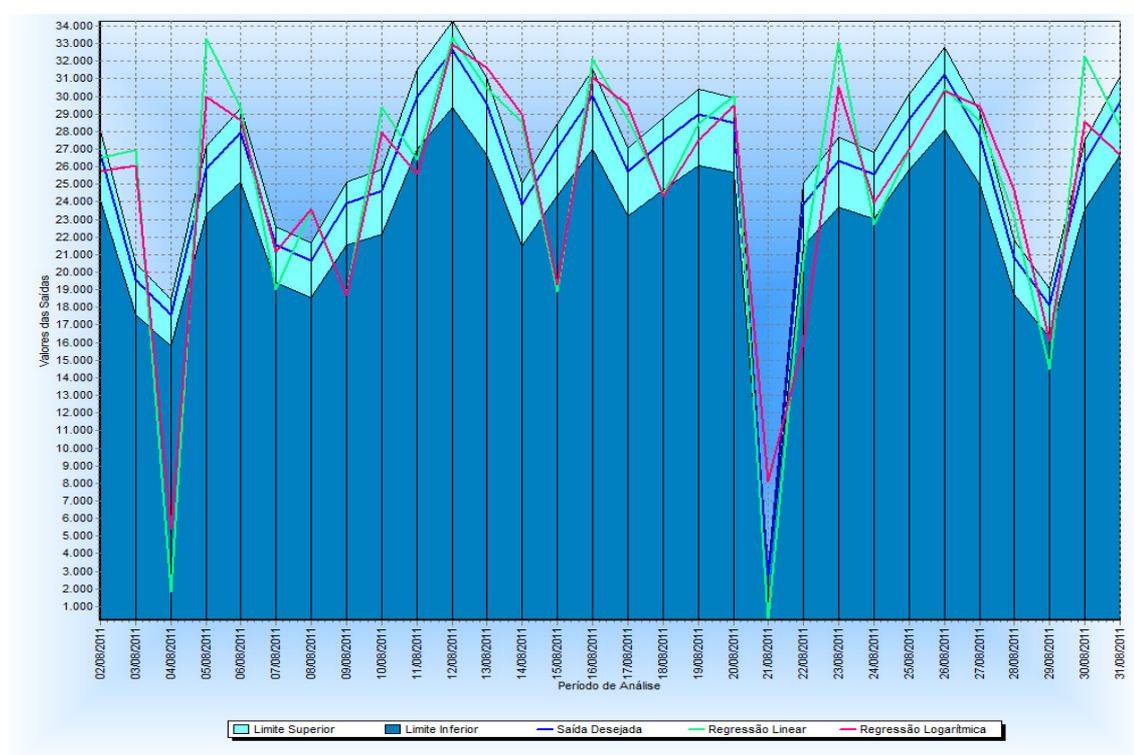
#### 5.1.1 Modelo de regressão

Para os modelos de regressão foram obtidos os resultados apresentados na Tabela 5.1.

**Tabela 5.1. Resultados obtidos com Regressões.**

MODELO	ME	MAE	MSE	MPE	MAPE	RMSE	PERÍODO DE AJUSTE / VALIDAÇÃO
LINEAR	0,50	2,05	7,42	3,77	18,19	0,85	01/08/2011 - 30/08/2011
POLINOMIAL	0,23	2,63	11,21	17,84	34,46	1,05	01/08/2011 - 30/08/2011
EXPONENCIAL	-0,42	2,18	9,30	-24,36	36,51	0,95	01/08/2011 - 30/08/2011
LOGARITMICA	0,09	1,92	5,92	-4,69	19,78	0,76	01/08/2011 - 30/08/2011
POTÊNCIA	-0,24	1,93	8,04	-23,79	34,97	0,89	01/08/2011 - 30/08/2011

Na Tabela 5.1 é possível observar que os melhores resultados, do ponto de vista dos índices de desempenho, são da Regressão Logarítmica (melhores ME, MAE, MSE e RMSE), seguido pela Regressão Linear (melhores MPE e MAPE). A Figura 5.2 apresenta os resultados das citadas regressões frente ao resultado desejado, além disso, os limites superior e inferior desejado para a previsão, que são de +5% e -10% respectivamente.



**Figura 5.2. Análise das Curvas de Regressão – Melhores Resultados**

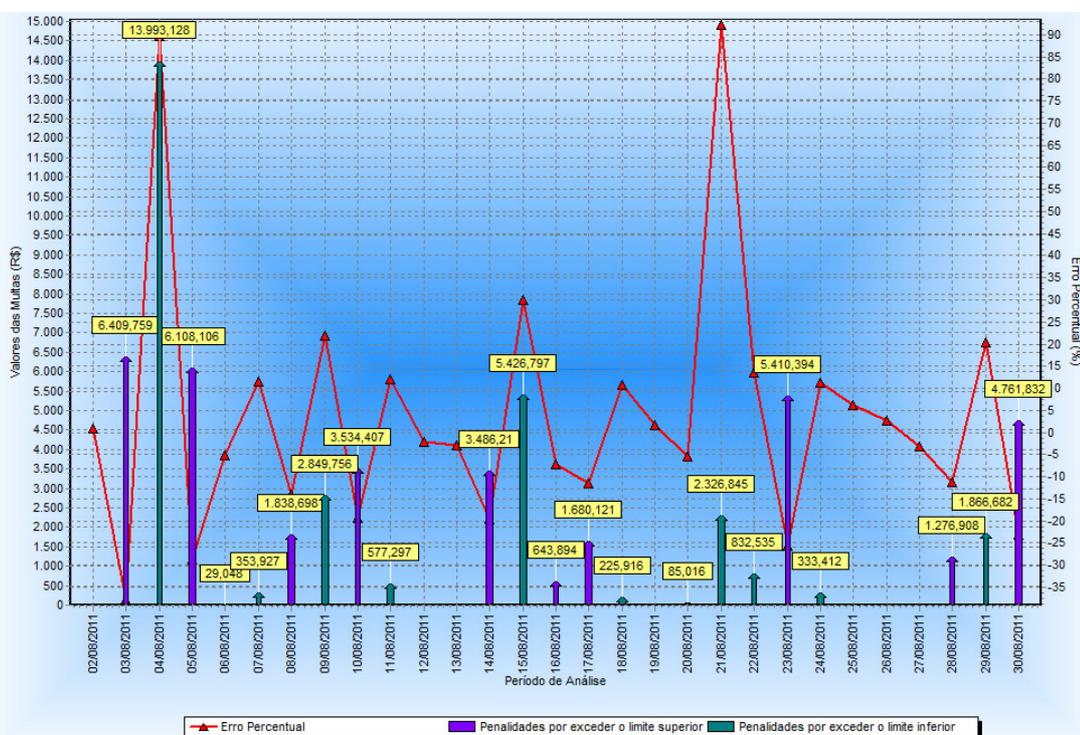
Nas Figura 5.3 e Figura 5.4 pode ser verificado o erro percentual para cada amostra, assim como, a aplicação de penalidades em função da extrapolação dos limites superiores e inferiores.

A Tabela 5.2 mostra os resultados do ponto de vista de aplicação das penalidades, onde mais uma vez foi constatado que a regressão Logarítmica obteve o melhor desempenho quando da aplicação de penalidades, destacando-se na redução das penalidades por erros a menor, ou seja, penalidades aplicadas por exceder o limite inferior desejado de -10%.

**Tabela 5.2. Aplicação de Penalidades - Regressão**

MODELO DE REGRESSÃO	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
LINEAR	24,14%	75,86%	41,38%	34,45%	01/08/2011 - 30/08/2011
LOGARITMICA	34,49%	65,51%	41,37%	24,14%	01/08/2011 - 30/08/2011

Diante das observações realizadas, seja ela do ponto de vista dos índices de desempenho, seja do ponto de vista da aplicação de penalidades, o modelo de regressão logarítmica apresentou o melhor desempenho para o conjunto de dados em questão, por ele amortecer a curva de previsão evitando que sejam realizadas programações de volumes excessivas e que não serão atingidas, reduzindo assim a aplicação de penalidades por erros a menor.



**Figura 5.3. Aplicação de Penalidades – Regressão Linear**

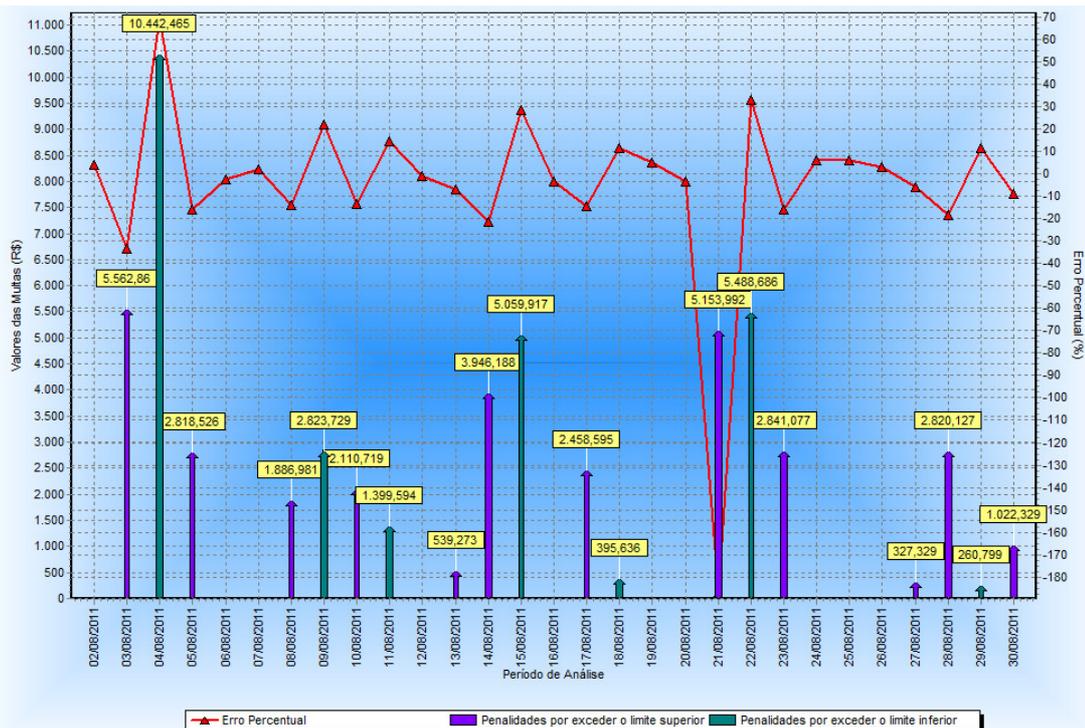


Figura 5.4. Aplicação de Penalidades – Regressão Logarítmica

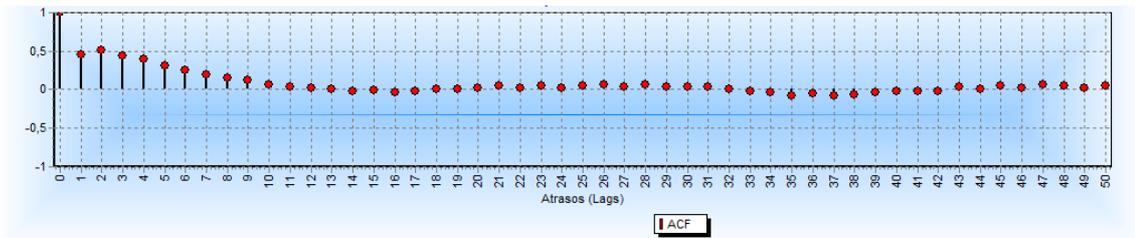
## 5.1.2 Modelo de série temporal

Para o modelo de séries temporais, as parametrizações que obtiveram os melhores resultados estão contidas na Tabela 5.3.

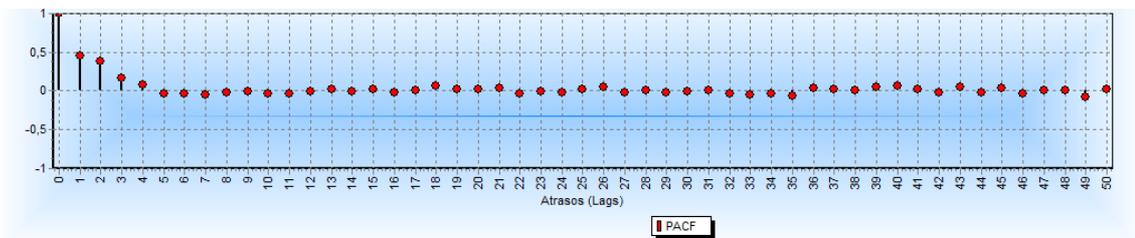
Tabela 5.3. Resultados obtidos com Séries Temporais

ARIMA	p Lags	q Lags	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE AJUSTE	PERÍODO DE VALIDAÇÃO
(4,0,2)	(1 2 3 4)	(5 6)	0,00	0,10	0,02	-4,61	18,18	0,66	0,84	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(4,0,4)	(1 2 3 4)	(5 6 7 8)	0,00	0,10	0,02	-4,72	18,26	0,66	0,84	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(4,0,0)	(1 2 3 4)	()	0,00	0,10	0,02	-4,90	18,51	0,67	0,84	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(3,0,0)	(1 2 3)	()	0,00	0,10	0,02	-4,94	18,59	0,67	0,85	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011

A partir dos dados da Tabela 5.3 é possível observar que, no âmbito das séries temporais, o modelo que melhor se adequa a série em estudo é predominantemente auto-regressivo com pequenas variações nos índices de desempenho quando utilizado uma parametrização com Médias Móveis. Este comportamento, por sua vez, já poderia ser previsto analisando os gráficos da Autocorrelação (ACF) e da Autocorrelação Parcial (PACF), pois para uma série unicamente auto-regressiva ARIMA  $(p,0,0)$ , sua função de autocorrelação sofrerá uma queda exponencial gradativa, conforme pode ser visto na Figura 5.5 e sua função de autocorrelação parcial sofrerá uma queda repentina após o lag  $k$ , conforme pode ser visto na Figura 5.6 [20].

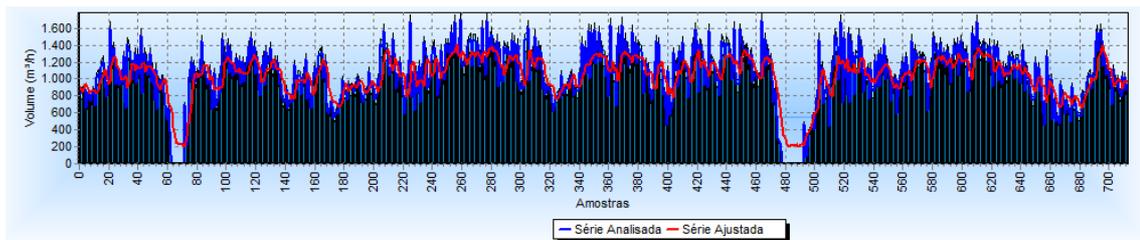


**Figura 5.5. Autocorrelação (ACF) da Série Temporal**



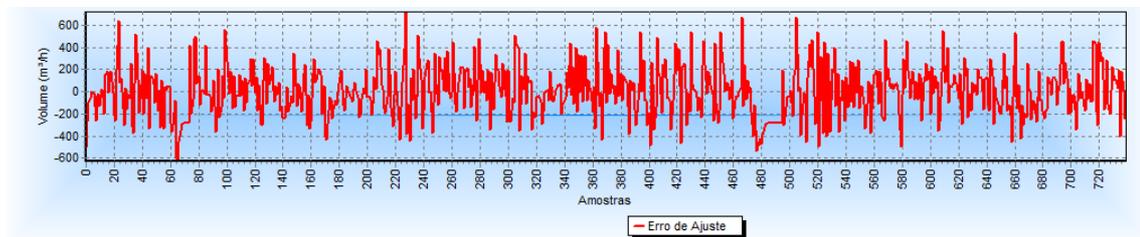
**Figura 5.6. Autocorrelação Parcial (PACF) da Série Temporal**

A Figura 5.7 apresenta os resultados obtidos na validação do modelo ARIMA(4,0,0).

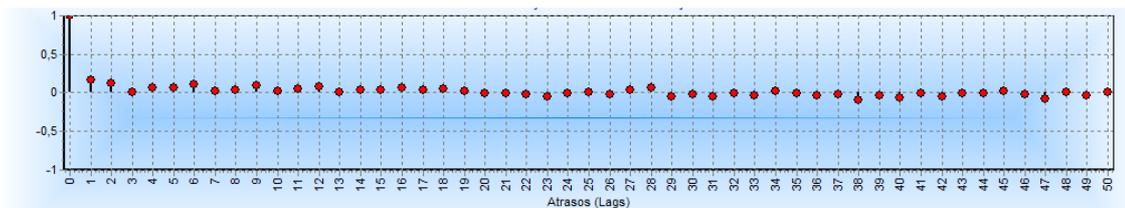


**Figura 5.7. Validação do modelo – Séries Temporais.**

É importante ressaltar que, conforme citado no capítulo 3 no texto referente à etapa 3 da metodologia de *Box e Jenkins*, um teste simples para verificar o ajuste e validação do modelo é analisar se o erro é um ruído branco, caracterizado por possuir média zero, variância constante  $\sigma^2$  e não ser autocorrelacionado, características estas que podem ser confirmadas por intermédio das Figura 5.8 e Figura 5.9.



**Figura 5.8. Análise do erro de validação do modelo**



**Figura 5.9. Autocorrelação do erro de validação**

A Tabela 5.4 apresenta os resultados do ponto de vista de aplicação das penalidades, onde pode-se destacar o melhor desempenho para um modelo unicamente auto-regressivo [ARIMA (4,0,0)], sendo evidenciado para este modelo uma redução das penalidades aplicadas, por exceder o limite inferior desejado, frente outras configurações.

**Tabela 5.4. Aplicação de Penalidades – Séries Temporais**

MODELO DE SÉRIES TEMPORAIS	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
(4,0,2)	51,74%	48,26%	24,13%	24,13%	01/08/2011 - 30/08/2011
(4,0,4)	51,74%	48,26%	24,13%	24,13%	01/08/2011 - 30/08/2011
(4,0,0)	55,17%	44,82%	24,13%	20,68%	01/08/2011 - 30/08/2011
(3,0,0)	51,74%	48,26%	24,13%	24,13%	01/08/2011 - 30/08/2011

Na Figura 5.10 pode ser verificado o erro percentual para cada amostra, assim como, a aplicação de penalidades em função da extrapolação dos limites superiores e inferiores.



**Figura 5.10. Aplicação de Penalidades – Série Temporal**

Diante das observações realizadas o modelo ARIMA unicamente auto-regressivo apresentou um melhor desempenho, pois conforme dito anteriormente, através da análise dos correlogramas ACF e PACF, havia um forte indicio de que a série seria modelada com um modelo ARIMA( $p,0,0$ ) confirmado por intermédio dos gráficos e tabelas apresentadas nesta seção.

### 5.1.3 Modelo de rede neural Artificial

Na Tabela 5.5 estão apresentados os melhores resultados obtidos após a utilização de diferentes configurações de Rede Neural Artificial.

**Tabela 5.5. Resultados obtidos com Redes Neurais**

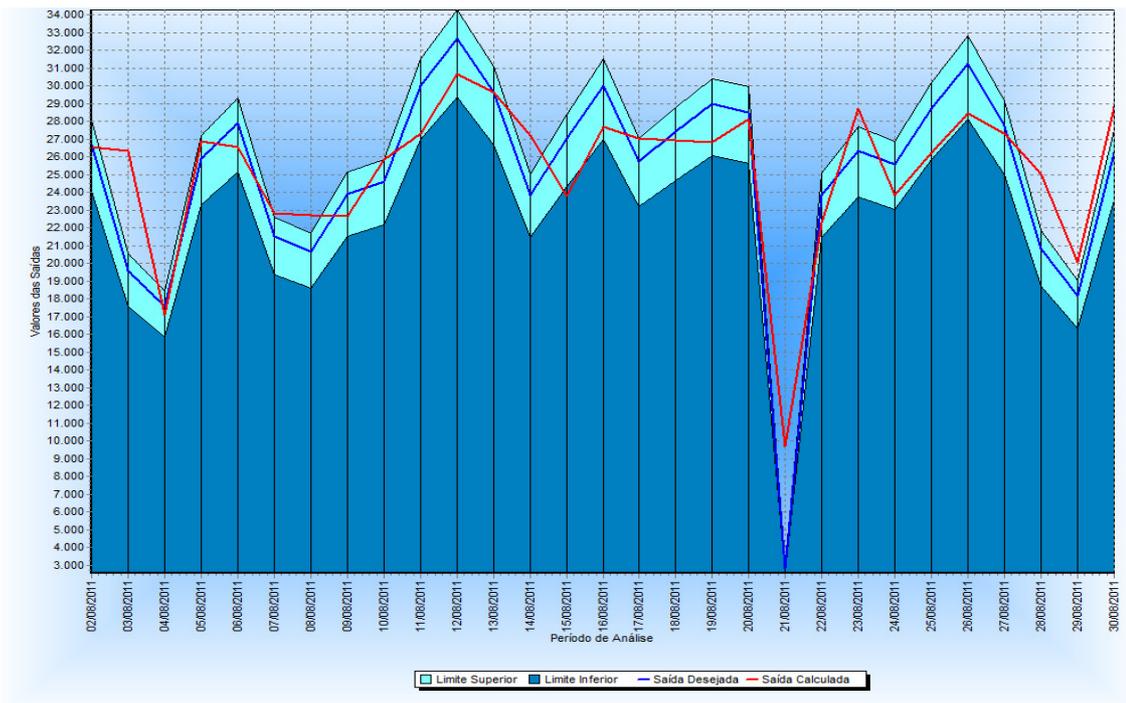
DADOS R.N.A.	TIPO R.N.A.	VETOR DIA	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE AJUSTE	PERÍODO DE VALIDAÇÃO
Sigmoide(2,2)	PADRÃO	SIM	0,23	1,31	2,76	-6,82	17,06	0,52	0,40	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Tan. Hip.(3,2)	PADRÃO	NÃO	-0,33	1,32	3,01	-11,69	18,14	0,54	0,42	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Sigmoide(2,3)	PADRÃO + ST	SIM	0,30	1,28	2,35	-4,82	14,79	0,48	0,37	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Sigmoide(1,1)	PADRÃO + ST	NÃO	-0,17	1,18	2,29	-9,17	15,49	0,47	0,36	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011

Na Tabela 5.5 é possível observar que os melhores resultados, do ponto de vista dos índices de desempenho, são da configuração da rede neural artificial com função de ativação sigmoide, com uma camada escondida e um neurônio por camada, auxiliada por séries temporais e sem a inserção do vetor codificado dias da semana (melhores ME, MAE, MSE, RMSE e UTHEIL), seguida pela configuração com função de ativação sigmoide, com duas camadas escondida e três neurônios por camada, auxiliada por séries temporais e com a inserção do vetor codificado dias da semana (melhores MPE e MAPE).

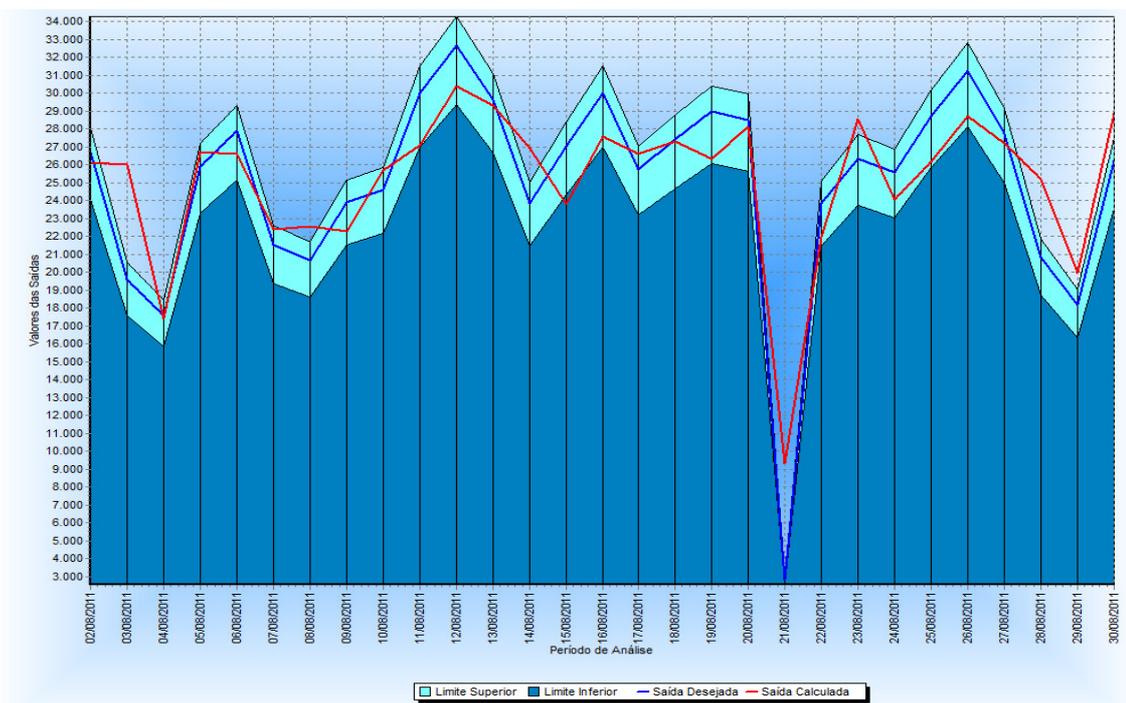
Ao analisar as Figura 5.11 e Figura 5.12, em que são apresentados os resultados das configurações com melhor desempenho frente ao resultado desejado, constata-se que os resultados obtidos estão muito próximos, com diferenças não significativas para alguns dias, e do ponto de vista de aplicação de penalidades, por intermédio da Tabela 5.6, verifica-se que a configuração com mais camadas escondidas apresentou um desempenho 3% superior à outra configuração, também não significativa, sendo assim não pode-se concluir que o melhor desempenho esta associado ao número maior de camadas, restando apenas à hipótese de que o melhor desempenho esta associado ao auxílio das séries temporais frente aos modelos que não utilizam o citado auxílio.

**Tabela 5.6. Aplicação de Penalidades – Redes Neurais Artificiais**

MODELO DE RNA	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
Sigmoide(2,3)	68,96%	31,03%	27,58%	3,44%	01/08/2011 - 30/08/2011
Sigmoide(1,1)	65,51%	34,48%	31,03%	3,44%	01/08/2011 - 30/08/2011



**Figura 5.11. Análise das Curvas das Redes Neurais Artificiais – SIGMOIDE (1,1)**



**Figura 5.12. Análise das Curvas das Redes Neurais Artificiais – SIGMOIDE (2,3)**

### 5.1.4 Comparação dos resultados

Nas Tabela 5.7 e Tabela 5.8 são apresentados, respectivamente, o comparativo entre os melhores resultados do ponto de vista dos índices de desempenho e da aplicação de penalidades.

**Tabela 5.7. Quadro comparativo dos índices de desempenho**

MODELO	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE VALIDAÇÃO
REGRESSÃO	0,09	1,92	5,92	-4,69	19,78	0,76	-	01/08/2011 - 30/08/2011
SÉRIE TEMPORAL	0,00	0,10	0,02	-4,90	18,51	0,67	0,84	01/08/2011 - 30/08/2011
RNA	0,23	1,31	2,76	-6,82	17,06	0,52	0,40	01/08/2011 - 30/08/2011
RNA + ST	0,30	1,28	2,35	-4,82	14,79	0,48	0,37	01/08/2011 - 30/08/2011

**Tabela 5.8. Quadro comparativo da aplicação de penalidade**

MODELO	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
REGRESSÃO	34,49%	65,51%	41,37%	24,14%	01/08/2011 - 30/08/2011
SÉRIES TEMPORAIS	55,17%	44,82%	24,13%	20,68%	01/08/2011 - 30/08/2011
RNA	51,72%	48,27%	24,13%	24,13%	01/08/2011 - 30/08/2011
RNA + ST	68,96%	31,03%	27,58%	3,44%	01/08/2011 - 30/08/2011

Analisando as Tabela 5.7 e Tabela 5.8 é possível afirmar que:

- Os melhores índices de desempenho não significam necessariamente que o modelo é o mais adequado para redução da aplicação de penalidade, objetivo principal deste trabalho;
- O modelo que apresentou o melhor MAPE foi também o que apresentou os melhores resultados sob a ótica da aplicação de penalidades;
- Para o conjunto de dados analisado, o modelo que obteve a menor índice de aplicação de penalidade foi à rede neural artificial auxiliada por séries temporais;

Entre os modelos propostos e analisados, a rede neural artificial auxiliada por séries temporais obteve os melhores resultados, consequência da divisão do processo de previsão em duas etapas. Na primeira etapa, o modelo ARIMA foi responsável por gerar os parâmetros do consumo (o melhor modelo) e realizar a previsão desejada. Na segunda etapa a rede neural artificial realizou a previsão do erro substituindo-o no modelo ARIMA para enfim realizar a previsão.

Quando comparado com a metodologia atual, o modelo de rede neural artificial auxiliada por série temporal apresenta uma redução de 27,02% na aplicação de penalidades, conforme demonstrado na Tabela 5.9. Isto se deve ao fato da metodologia proposta demonstrar grande robustez na modelagem do perfil de consumo e consequentemente uma melhor previsão de médio prazo do consumo de gás natural.

**Tabela 5.9. Quadro comparativo com a metodologia atual.**

MODELO	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
METODOLIGIA ATUAL	41,94%	58,06%	45,16%	12,90%	01/08/2011 - 30/08/2011
RNA + ST	68,96%	31,03%	27,58%	3,44%	01/08/2011 - 30/08/2011

## 5.2 Consumidor industrial B

Na Figura 5.13 é apresentado o perfil de consumo do CONSUMIDOR INDUSTRIAL B.

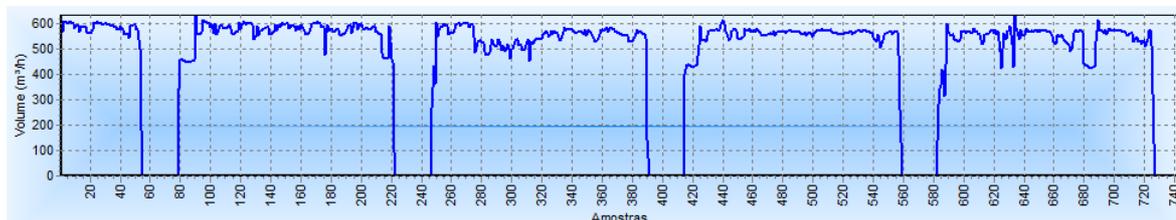


Figura 5.13. Perfil de consumo do CONSUMIDOR INDUSTRIAL B.

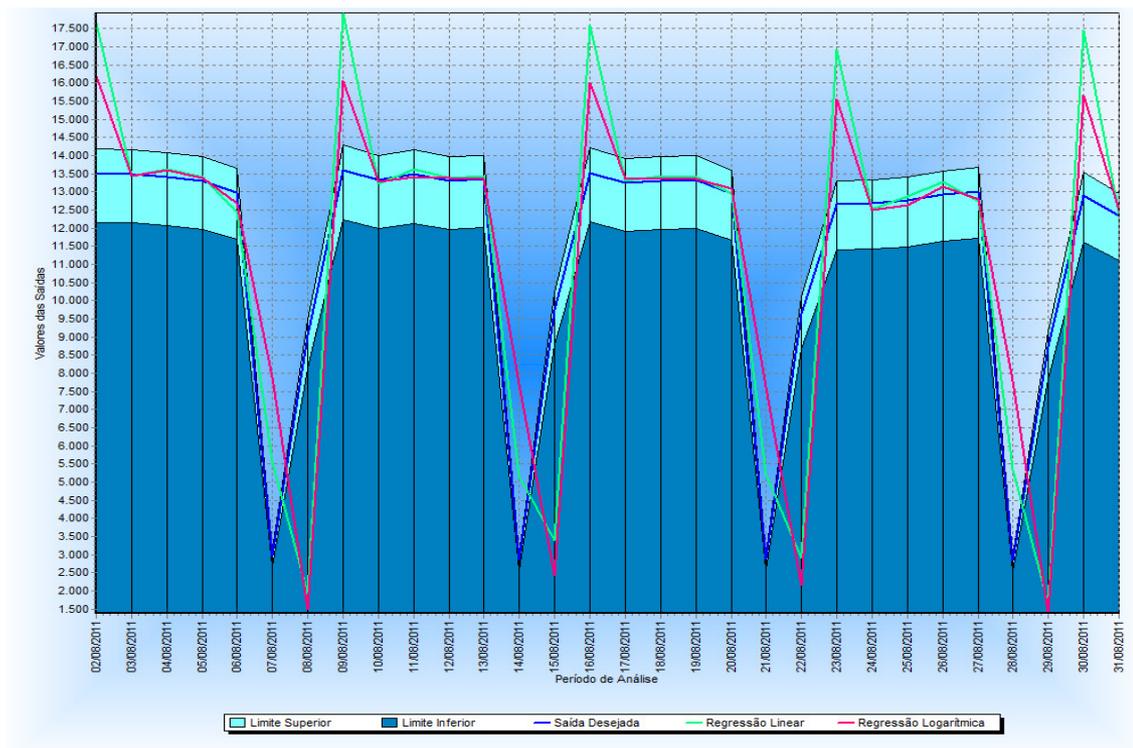
### 5.2.1 Modelo de regressão

Para os modelos de regressão foram obtidos os resultados apresentados na Tabela 5.10:

Tabela 5.10. Resultados obtidos com Regressões.

TIPO	ME	MAE	MSE	MPE	MAPE	RMSE	PERÍODO DE AJUSTE / VALIDAÇÃO
LINEAR	-0,09	1,33	4,29	-6,90	27,14	0,89	01/08/2011 - 30/08/2011
POLINOMIAL	0,12	1,85	7,33	19,08	46,35	1,14	01/08/2011 - 30/08/2011
EXPONENCIAL	-2,76	3,40	35,53	-102,70	110,10	2,57	01/08/2011 - 30/08/2011
LOGARITMICA	-0,07	1,40	4,99	-15,20	37,09	0,96	01/08/2011 - 30/08/2011
POTÊNCIA	-2,82	3,30	36,31	-91,34	96,96	2,60	01/08/2011 - 30/08/2011

Na Tabela 5.10 é possível observar que os melhores resultados, do ponto de vista dos índices de desempenho, são da Regressão Linear (melhores MAE, MPE, MAPE e RMSE), seguido pela Regressão Logarítmica (melhores ME e MSE). Na Figura 5.14 são apresentados os resultados das citadas regressões frente ao resultado desejado, além disso, os limites superior e inferior desejado para a previsão, que são de +5% e -10% respectivamente.



**Figura 5.14. Análise das Curvas de Regressão – Melhores Resultados**

Nas Figura 5.15 e Figura 5.16 pode ser verificado o erro percentual para cada amostra, assim como, a aplicação de penalidades em função da extrapolação dos limites superiores e inferiores.

Na Tabela 5.11, que apresenta os resultados do ponto de vista de aplicação das penalidades, é possível observar que os dois modelos foram equivalentes.

**Tabela 5.11. Aplicação de Penalidades - Regressão**

MODELO DE REGRESSÃO	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
LINEAR	55,17%	44,82%	31,03%	13,79%	01/08/2011 - 30/08/2011
LOGARITMICA	55,17%	44,82%	31,03%	13,79%	01/08/2011 - 30/08/2011

Diante das observações realizadas do ponto de vista da aplicação de penalidades, os modelos de regressão linear e logarítmica apresentam desempenho equivalente para o conjunto de dados em questão, isto se deve ao fato de que esta série possui um comportamento crescente e constante podendo o mesmo ser modelado tanto por uma equação linear quanto por uma equação logarítmica.

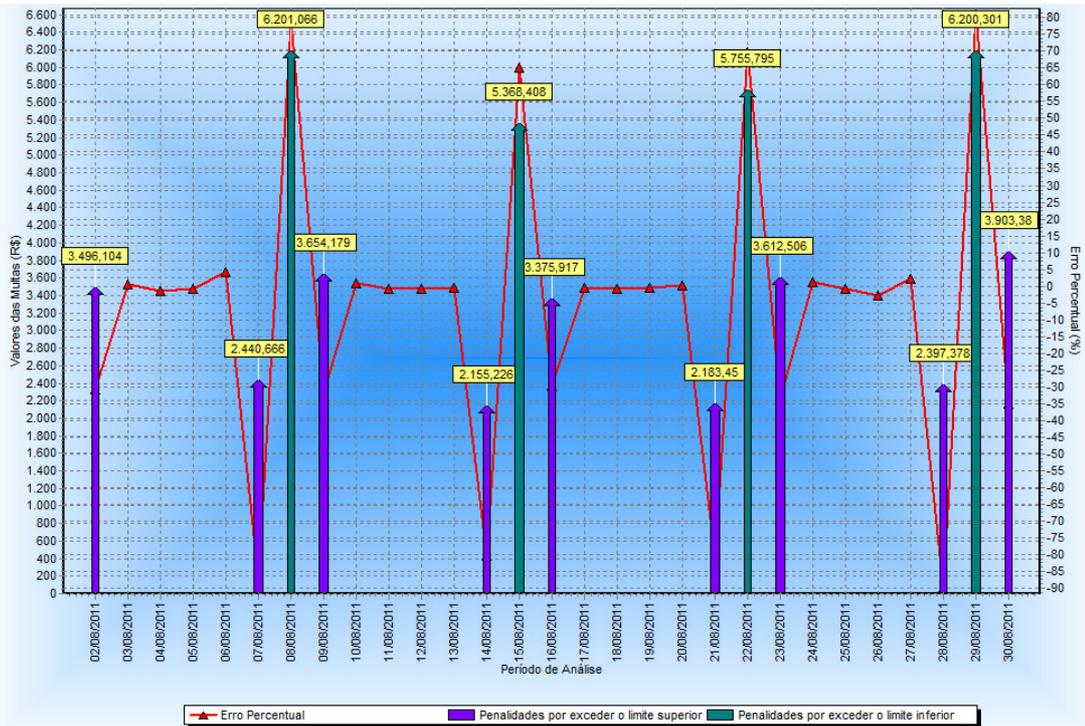


Figura 5.15. Aplicação de Penalidades – Regressão Linear

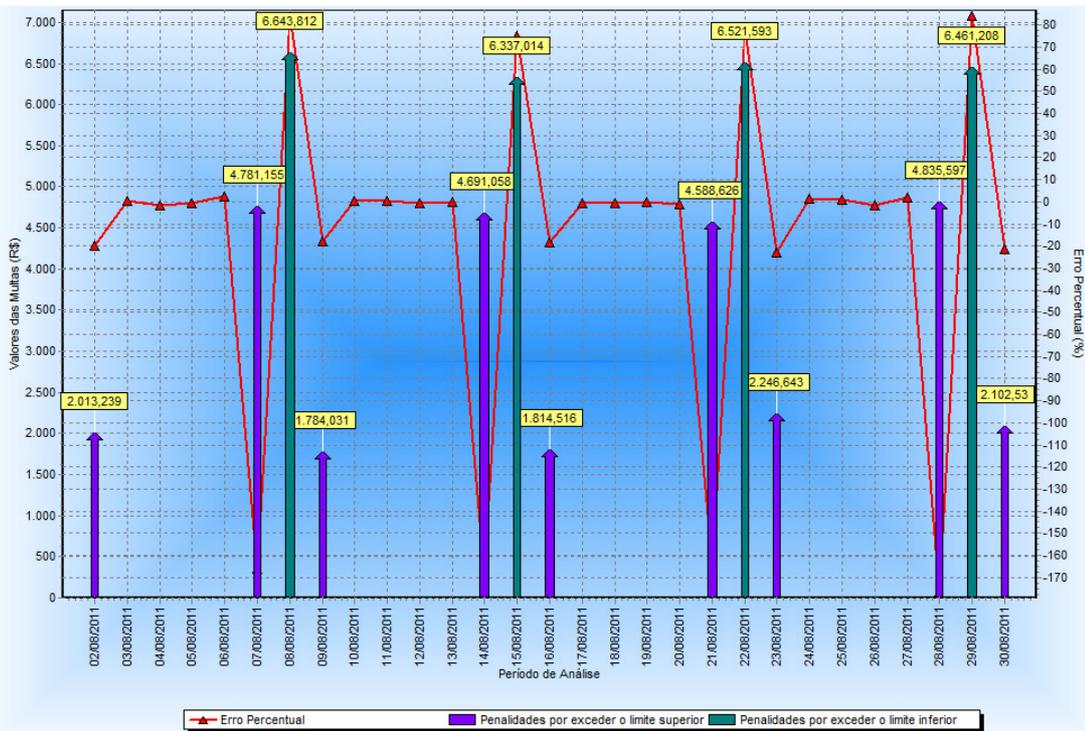


Figura 5.16. Aplicação de Penalidades – Regressão Logarítmica

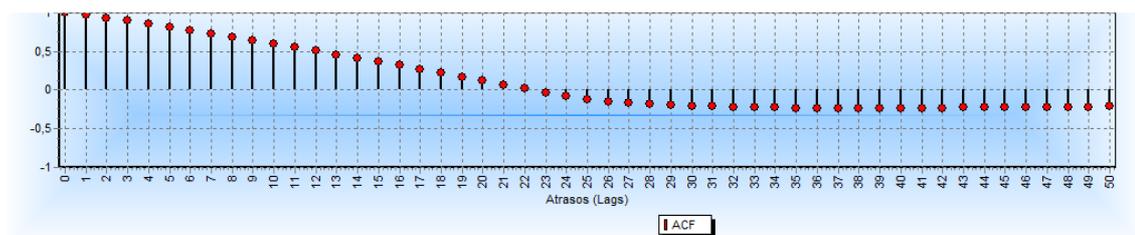
## 5.2.2 Modelo de série temporal

Para o modelo de séries temporais, as parametrizações que obtiveram os melhores resultados estão contidas na Tabela 5.12.

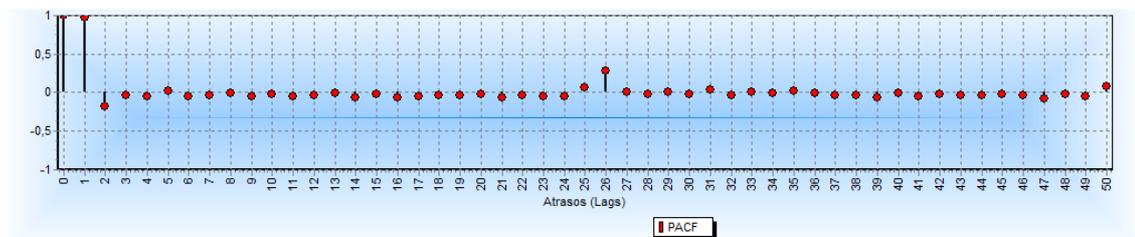
**Tabela 5.12. Resultados obtidos com Séries Temporais**

ARIMA	p Lags	q Lags	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE AJUSTE	PERÍODO DE VALIDAÇÃO
(1,0,0)	(1)	()	0	0,01	0	-0,24	4,45	0,25	0,99	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(2,0,0)	(12)	()	0	0,01	0	-0,34	4,55	0,25	0,97	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(3,0,0)	(123)	()	0	0,01	0	-0,33	4,56	0,25	0,97	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(4,0,0)	(1234)	()	0	0,01	0	-0,35	4,56	0,25	0,97	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011

A partir dos dados da Tabela 5.12 é possível observar que, no âmbito das series temporais, o modelo que melhor se adéqua a série em estudo é estritamente auto-regressivo. Este comportamento, por sua vez, já poderia ser previsto analisando os gráficos da Autocorrelação (ACF) e da Autocorrelação Parcial (PACF), pois para uma série unicamente auto-regressiva ARIMA  $(p,0,0)$ , sua função de autocorrelação sofrerá uma queda exponencial gradativa, conforme pode ser visto na Figura 5.17 e sua função de autocorrelação parcial sofrerá uma queda repentina após o lag  $k$ , conforme pode ser visto na Figura 5.18 [20].

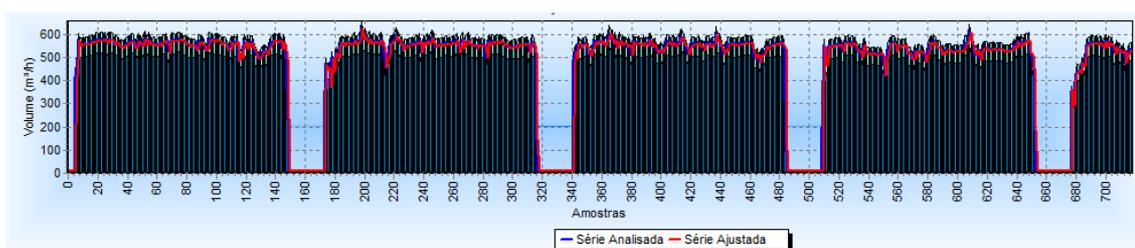


**Figura 5.17 . Autocorrelação (ACF) da Série Temporal**



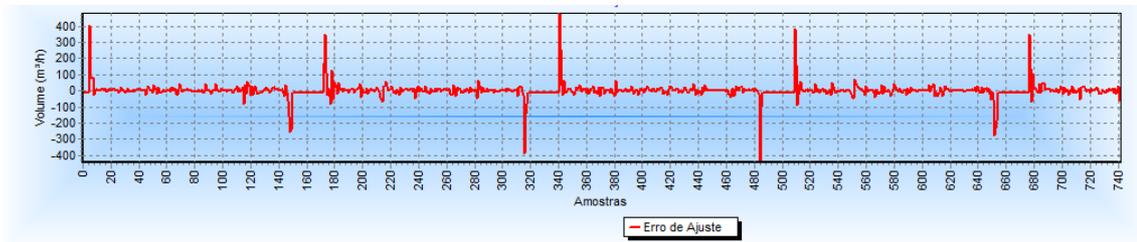
**Figura 5.18. Autocorrelação Parcial (PACF) da Série Temporal**

A Figura 5.19 apresenta os resultados obtidos na validação do modelo ARIMA(1,0,0).

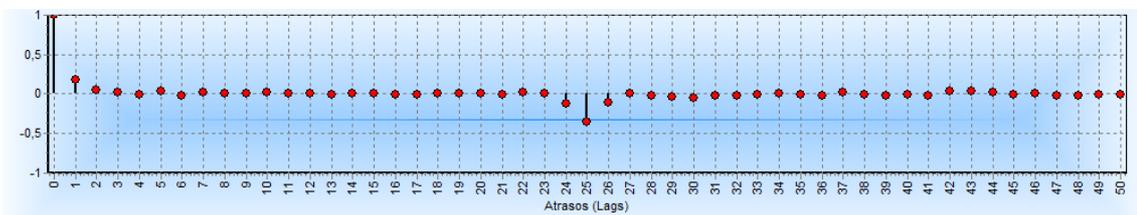


**Figura 5.19. Validação do modelo – Séries Temporais.**

Analisando o correlograma dos resíduos, ilustrado na Figura 5.20, nota-se que não há valores significativos para os coeficientes de autocorrelação, e que, portanto, os resíduos são um ruído branco, apresentado na Figura 5.21. Pela metodologia de *Box e Jenkins* chega-se a um modelo apropriado para descrever o perfil de consumo.



**Figura 5.20. Análise do erro de validação do modelo**



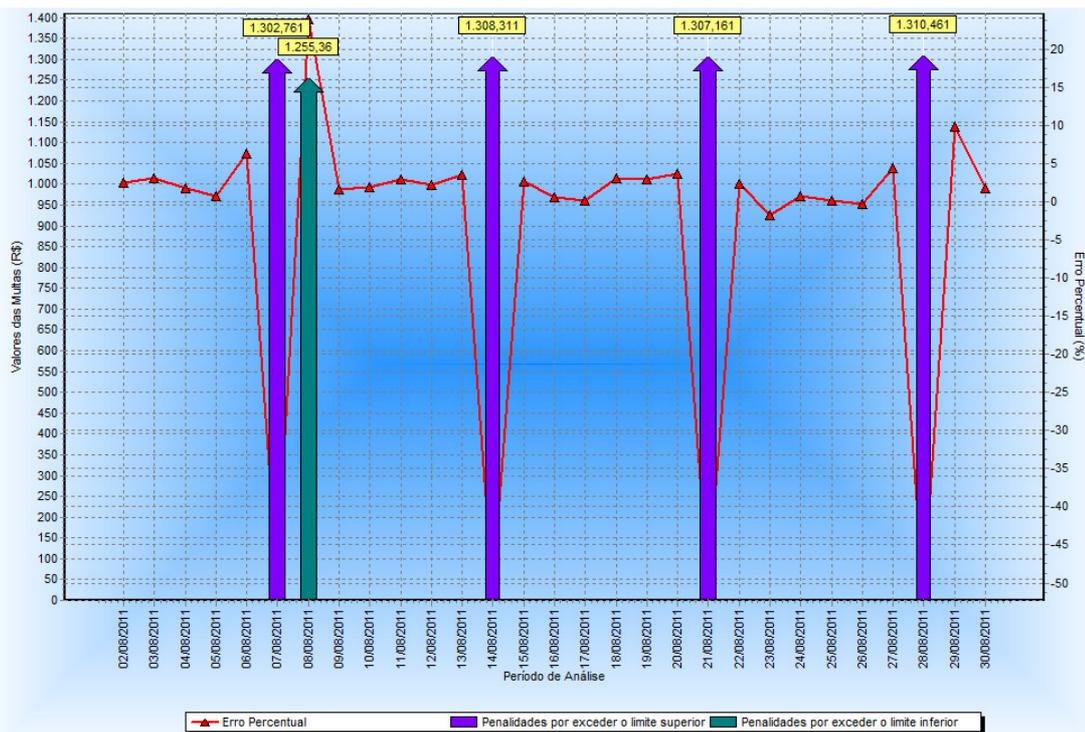
**Figura 5.21. Autocorrelação do erro de validação**

Na Tabela 5.13, que apresenta os resultados do ponto de vista de aplicação das penalidades, é possível observar desempenho equivalente para os modelos estritamente auto-regressivo e destacar o melhor desempenho do modelo ARIMA (4,0,0), sendo evidenciado, para este modelo, uma redução das penalidades por erros a menor frente outras configurações.

**Tabela 5.13. Aplicação de Penalidades – Séries Temporais**

MODELO DE SÉRIES TEMPORAIS	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
(1,0,0)	79,31%	20,68%	13,79%	6,89%	01/08/2011 - 30/08/2011
(2,0,0)	79,31%	20,68%	13,79%	6,89%	01/08/2011 - 30/08/2011
(3,0,0)	79,31%	20,68%	13,79%	6,89%	01/08/2011 - 30/08/2011
(4,0,0)	82,75%	17,24%	13,79%	3,44%	01/08/2011 - 30/08/2011

Na Figura 5.22 pode ser verificado erro percentual para cada amostra, assim como, a aplicação de penalidades em função da extrapolação dos limites superiores e inferiores.



**Figura 5.22. Análise Financeira dos Resultados – Série Temporal**

Finalizada as observações a cerca do modelo ARIMA pode-se confirmar, por intermédio dos gráficos e tabelas apresentadas nesta seção, que o modelo unicamente auto-regressivo obteve o melhor desempenho, pois através da análise dos correlogramas ACF e PACF, já tinha-se indicativos de que a série seria modelada com um ARIMA( $p,0,0$ ).

### 5.2.3 Modelo de rede neural Artificial

Na Tabela 5.14 são apresentados os melhores resultados obtidos com a utilização de diferentes configurações da Rede Neural Artificial.

**Tabela 5.14. Resultados obtidos com Redes Neurais**

DADOS R.N.A.	TIPO R.N.A.	VETOR DIA	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE AJUSTE	PERÍODO DE VALIDAÇÃO
Tan. Hip.(2,2)	PADRÃO	SIM	-0,04	0,09	0,01	-0,59	1,14	0,05	0,04	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Tan. Hip.(2,2)	PADRÃO	NÃO	-0,07	0,10	0,02	-0,92	1,44	0,06	0,04	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Tan. Hip.(1,2)	PADRÃO + ST	SIM	-0,05	0,10	0,02	-0,61	1,35	0,05	0,04	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Tan. Hip.(2,2)	PADRÃO + ST	NÃO	-0,08	0,15	0,04	-0,83	2,29	0,09	0,07	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011

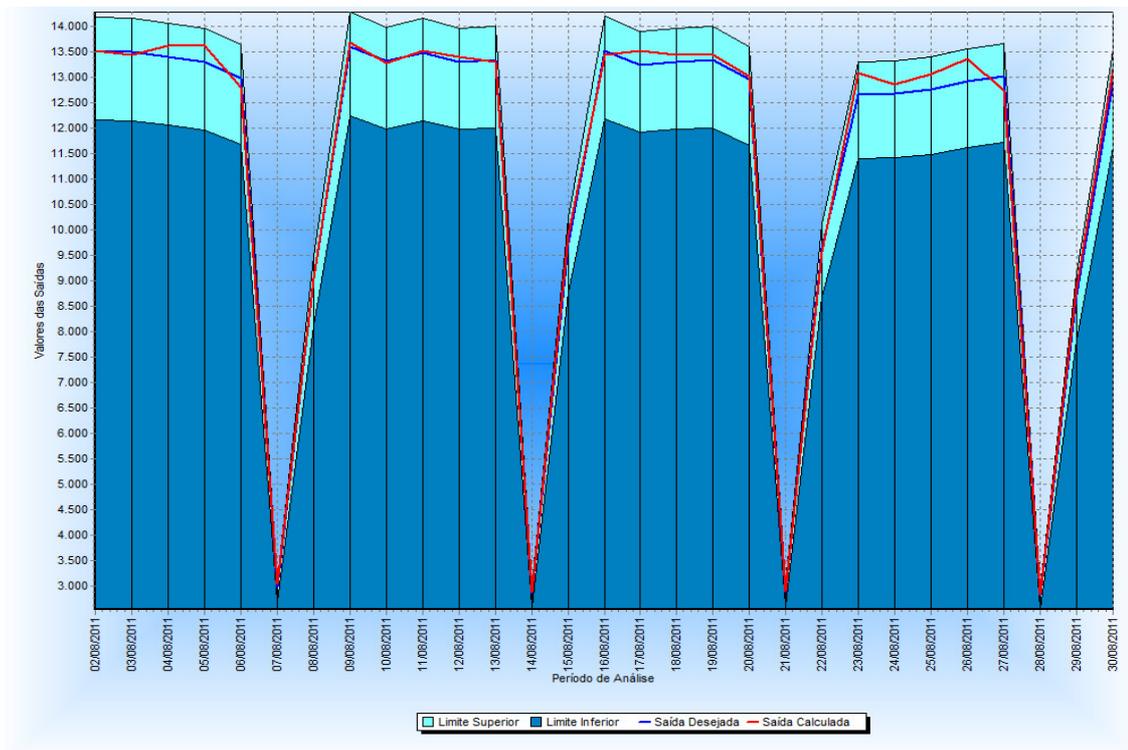
Na Tabela 5.14 é possível observar que o melhor resultado é da configuração da rede neural artificial com função de ativação tangente hiperbólica, com duas camadas escondida e dois neurônios por camada, sem o auxílio por séries temporais e com a inserção do vetor codificado dias da semana em todos os índices de desempenho, seguida pela configuração com função de ativação tangente hiperbólica, com uma camada escondida e dois neurônios, com o auxílio por séries temporais e com a inserção do vetor codificado dias da semana.

Nas Figura 5.23 e Figura 5.24, que apresentam os resultados das configurações com melhor desempenho frente ao resultado desejado, constata-se que os resultados obtidos estão muito próximos, com diferenças não significativas para alguns dias.

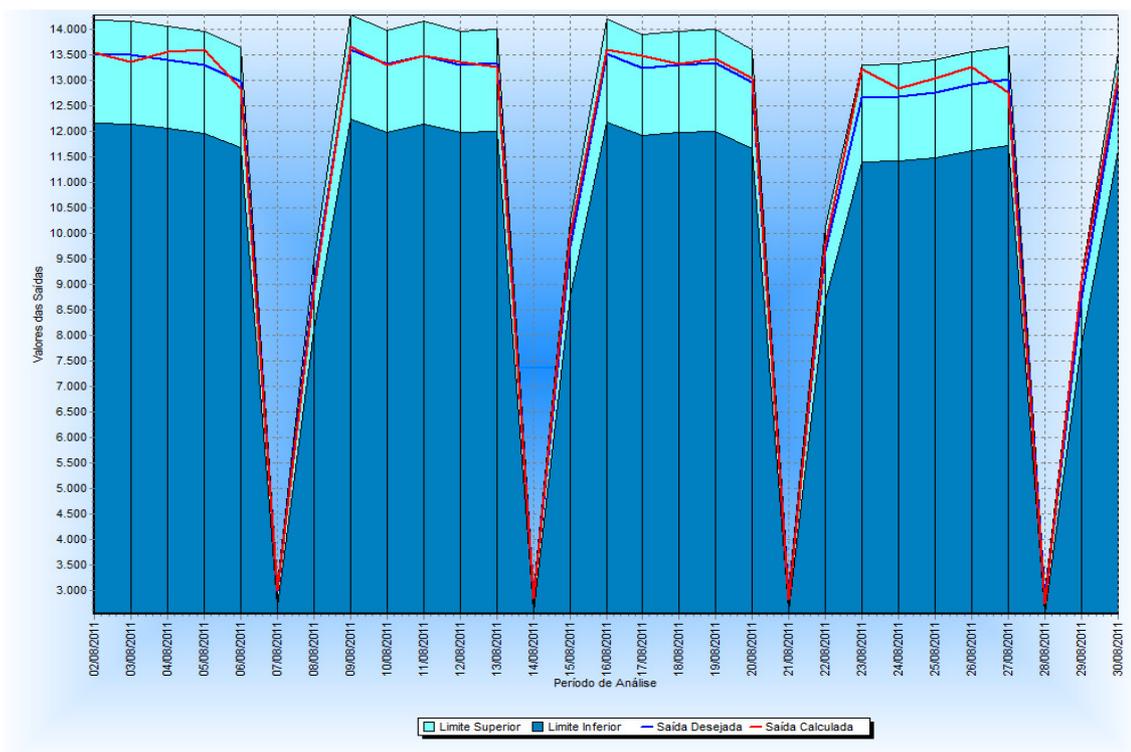
**Tabela 5.15. Aplicação de Penalidades – Redes Neurais Artificiais**

MODELO DE RNA	TIPO R.N.A.	VETOR DIA	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
Tan. Hip.(2,2)	PADRÃO	SIM	100,00%	0,00%	0,00%	0,00%	01/08/2011 - 30/08/2011
Tan. Hip.(1,2)	PADRÃO + ST	SIM	100,00%	0,00%	0,00%	0,00%	01/08/2011 - 30/08/2011

No tocante a aplicação de penalidades, apresentada na Tabela 5.15, verifica-se que as duas configurações reduzem a aplicação de penalidades a zero, sendo assim pode-se concluir o modelo redes neurais artificiais, auxiliado ou não por séries temporais, resolve o problema da previsão de consumo para o consumidor em questão, tal fato se deve as características de linearidade e sazonalidade semanal facilmente generalizada pelo algoritmo de aprendizado da rede neural artificial.



**Figura 5.23. Análise das Curvas das Redes Neurais Artificiais – TAN H (2,2)**



**Figura 5.24. Análise das Curvas das Redes Neurais Artificiais – TAN H (1,2)**

## 5.2.4 Comparação dos resultados

As Tabela 5.16 e Tabela 5.17 apresentam, respectivamente, o comparativo entre os melhores resultados do ponto de vista dos índices de desempenho e da aplicação de penalidades.

**Tabela 5.16. Quadro comparativo dos modelos**

MODELO	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE VALIDAÇÃO
REGRESSÃO	-0,09	1,33	4,29	-6,90	27,14	0,89	-	01/08/2011 - 30/08/2011
SÉRIE TEMPORAL	0,00	0,01	0,00	-0,35	4,56	0,25	0,97	01/08/2011 - 30/08/2011
REDE NEURAL ARTIFICIAL	-0,04	0,09	0,01	-0,59	1,14	0,05	0,04	01/08/2011 - 30/08/2011
RNA + ST	-0,05	0,10	0,02	-0,61	1,35	0,05	0,04	01/08/2011 - 30/08/2011

**Tabela 5.17. Quadro comparativo da aplicação de penalidade**

MODELO	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
REGRESSÃO	55,17%	44,82%	31,03%	13,79%	01/08/2011 - 30/08/2011
SÉRIES TEMPORAIS	82,75%	17,24%	13,79%	3,44%	01/08/2011 - 30/08/2011
RNA	100,00%	0,00%	0,00%	0,00%	01/08/2011 - 30/08/2011
RNA + ST	100,00%	0,00%	0,00%	0,00%	01/08/2011 - 30/08/2011

Analisando as tabelas acima é possível afirmar que:

- Os melhores índices de desempenho não significam necessariamente que o modelo é o mais adequado para redução da aplicação de penalidade, objetivo principal deste trabalho;

- O modelo que apresentou o melhor MAPE foi também o que apresentou os melhores resultados sob a ótica da aplicação de penalidades;
- Para o conjunto de dados analisado os modelos de rede neural artificial, auxiliada ou não por séries temporais, apresentam os melhores desempenhos, reduzindo a aplicação de penalidades à zero;

Entre os modelos propostos e analisados, visualmente percebe-se que o modelo de rede neural artificial, auxiliada ou não por séries temporais, consegue generalizar a dinâmica da série de consumo em estudo. Tanto a tendência da série, quanto as oscilações sazonais são absorvidas pelo modelo. Os índices de desempenho, assim como a aplicação de penalidades, revelam que o modelo apresenta bom desempenho para previsões de médio prazo.

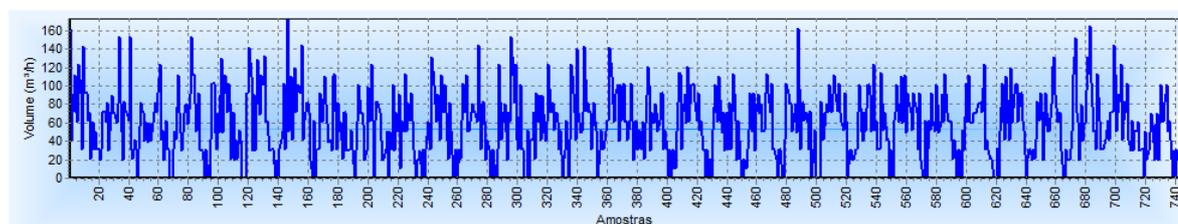
Quando comparado com a metodologia atual, o modelo de rede neural artificial apresenta uma redução de 22,58% na aplicação de penalidades, conforme demonstrado na Tabela 5.18. Isto se deve ao fato da metodologia proposta demonstrar capacidade de generalizar a dinâmica da série de consumo em estudo, tanto da tendência da série, quanto as oscilações sazonais na modelagem do perfil de consumo e consequentemente na melhor previsão de médio prazo do consumo de gás natural.

**Tabela 5.18. Quadro comparativo com a metodologia atual**

MODELO	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
METODOLIGIA ATUAL	77,42%	22,58%	22,58%	0,00%	01/08/2011 - 30/08/2011
RNA OU RNA + ST	100,00%	0,00%	0,00%	0,00%	01/08/2011 - 30/08/2011

## 5.3 Consumidor GNV A

Na Figura 5.25 **Erro! Fonte de referência não encontrada.** é apresentado o perfil de consumo do CONSUMIDOR GNV A.



**Figura 5.25. Perfil de consumo do CONSUMIDOR GNV A.**

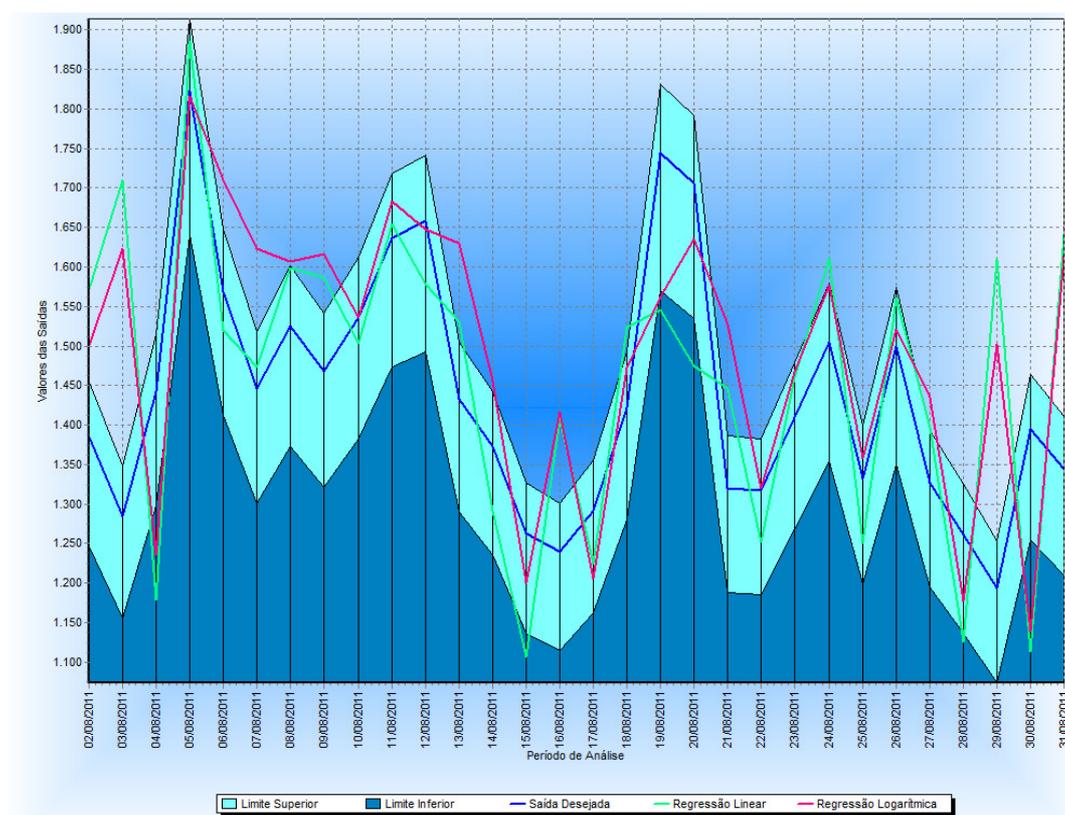
### 5.3.1 Modelo de regressão

Para os modelos de regressão foram obtidos os resultados apresentados na Tabela 5.19 **Erro! Fonte de referência não encontrada.**

**Tabela 5.19. Resultados obtidos com Regressões.**

TIPO	ME	MAE	MSE	MPE	MAPE	RMSE	PERÍODO DE AJUSTE / VALIDAÇÃO
LINEAR	-0,09	0,57	0,51	-2,05	9,96	1,12	01/08/2011 - 30/08/2011
POLINOMIAL	3,11	3,11	11,34	52,33	52,33	5,27	01/08/2011 - 30/08/2011
EXPONENCIAL	-0,76	1,49	5,20	-14,61	26,25	3,57	01/08/2011 - 30/08/2011
LOGARITMICA	-0,23	0,49	0,39	-4,25	8,70	0,98	01/08/2011 - 30/08/2011
POTÊNCIA	-0,69	1,13	2,49	-12,97	19,87	2,47	01/08/2011 - 30/08/2011

Na Tabela 5.19 é possível observar que os melhores resultados, do ponto de vista dos índices de desempenho, são da Regressão Logarítmica (melhores MAE, MSE, MAPE e RMSE), seguido pela Regressão Linear (melhores ME e MPE). Na Figura 5.26 são apresentados os resultados das citadas regressões frente ao resultado desejado, além disso, os limites superior e inferior desejado para a previsão, que são de 5% e 10% respectivamente.



**Figura 5.26. Análise das Curvas de Regressão – Melhores Resultados**

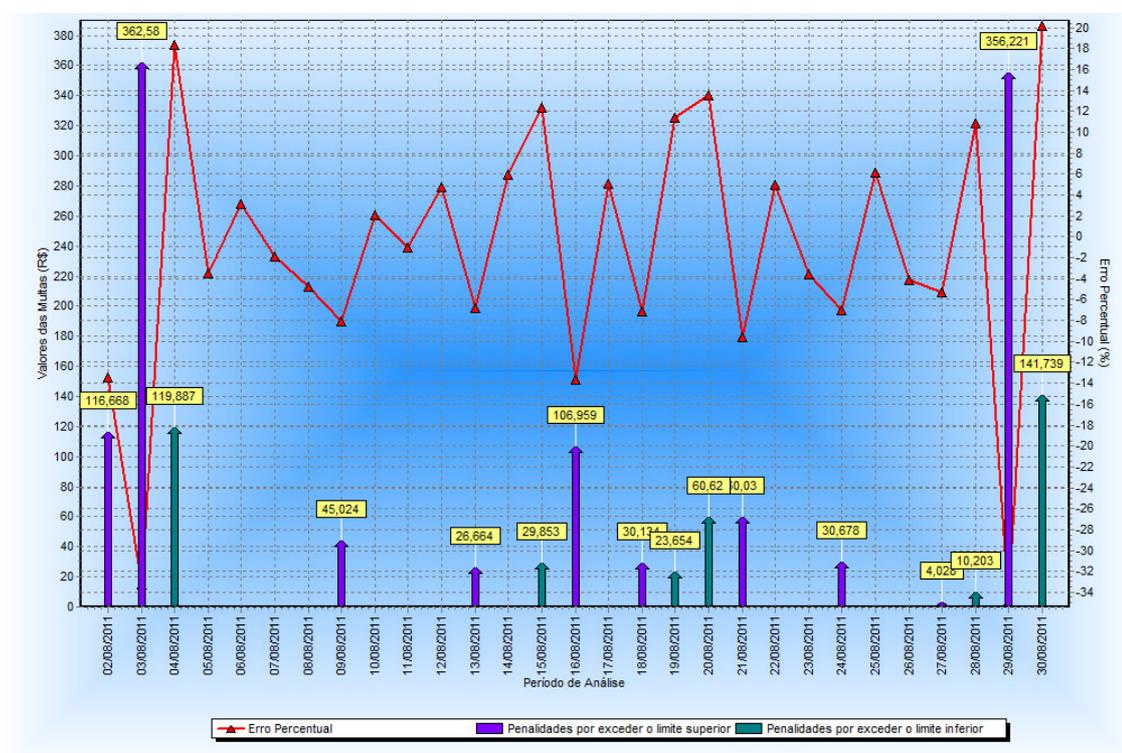
Nas Figura 5.27 e Figura 5.28 pode ser verificado o erro percentual para cada amostra, assim como, a aplicação de penalidades em função da extrapolação dos limites superiores e inferiores.

Na Tabela 5.20 são apresentados os resultados do ponto de vista de aplicação das penalidades, onde mais uma vez foi constatado que a regressão Logarítmica obteve um melhor desempenho quando da aplicação de penalidades, destacando-se na redução das penalidades por erros a menor.

**Tabela 5.20. Aplicação de Penalidades - Regressão**

MODELO DE REGRESSÃO	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
LINEAR	44,82%	55,17%	34,48%	20,68%	01/08/2011 - 30/08/2011
LOGARITMICA	48,27%	51,72%	41,37%	10,34%	01/08/2011 - 30/08/2011

Diante das observações realizadas, seja ela do ponto de vista dos índices de desempenho, seja do ponto de vista da aplicação de penalidades, o modelo de regressão logarítmica apresentou um melhor desempenho para o conjunto de dados em questão, por ele amortecer a curva de previsão evitando que sejam realizadas programações de volumes excessivas e que não serão atingidas, reduzindo assim a aplicação de penalidades por erros a menor.



**Figura 5.27. Aplicação de Penalidades – Regressão Linear**

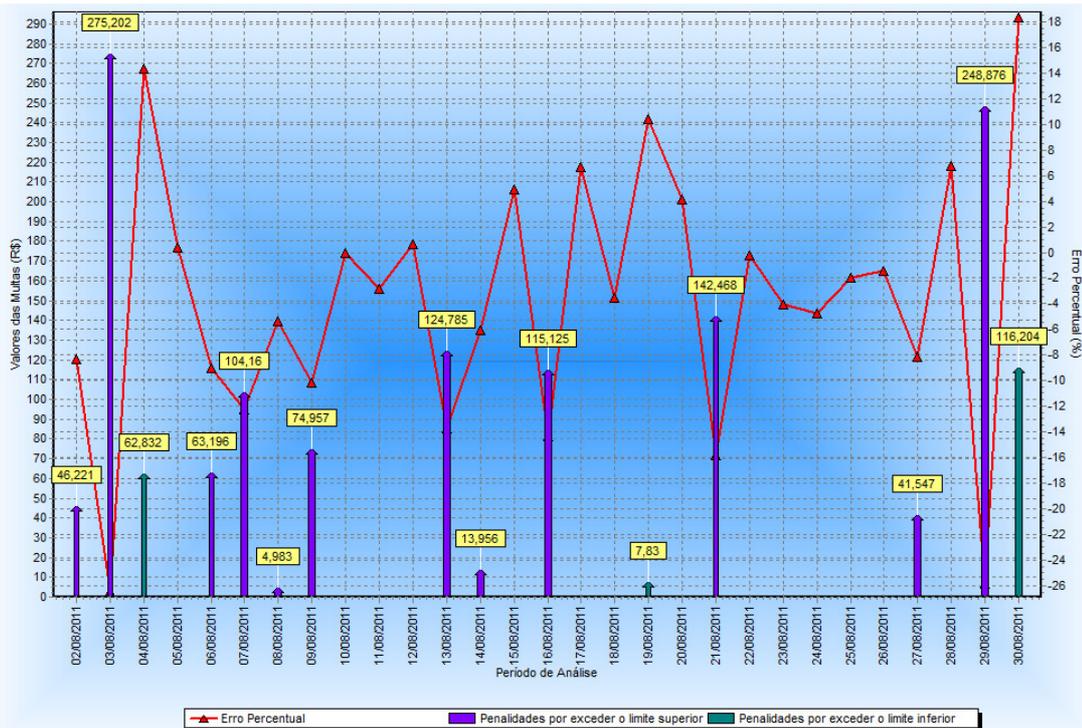


Figura 5.28. Aplicação de Penalidades – Regressão Logarítmica

### 5.3.2 Modelo de série temporal

Para o modelo de séries temporais, as parametrizações que obtiveram os melhores resultados estão contidas na Tabela 5.21.

Tabela 5.21. Resultados obtidos com Séries Temporais

ARIMA	p Lags	q Lags	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE AJUSTE	PERÍODO DE VALIDAÇÃO
(4,0,1)	(1 2 23 24)	(3)	0,00	0,10	0,01	-12,72	38,48	0,82	0,74	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(4,0,0)	(1 2 23 24)	()	0,00	0,10	0,01	-12,80	38,67	0,82	0,74	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(4,0,2)	(1 2 23 24)	(3 22)	0,00	0,10	0,02	-13,67	39,28	0,84	0,76	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
(2,0,0)	(1 24)	()	0,00	0,10	0,02	-13,80	40,46	0,86	0,78	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011

A partir dos dados da Tabela 5.21 é possível observar que, no âmbito das series temporais, o modelo que melhor se adéqua a série em estudo é o ARMA. Este comportamento, por sua vez, pode ser antecipado analisando os gráficos da Autocorrelação (ACF) e da Autocorrelação Parcial (PACF), pois para uma série auto-regressiva média móvel, ARIMA ( $p,0,q$ ), sua função de autocorrelação, assim como sua função de autocorrelação parcial sofrerão uma queda exponencial gradativa e/ou oscilações senoidais, conforme pode ser visto nas Figura 5.29 e Figura 5.30 [31].

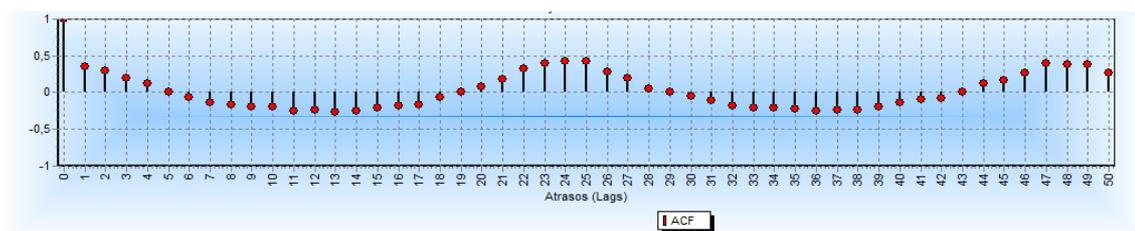
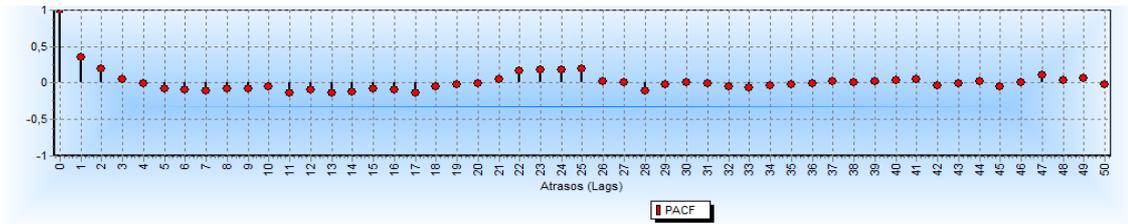
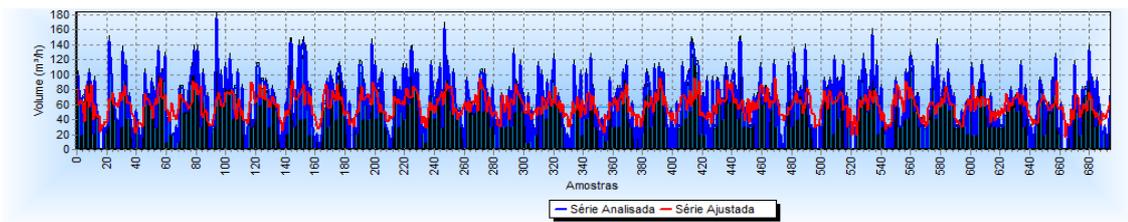


Figura 5.29. Autocorrelação (ACF) da Série Temporal



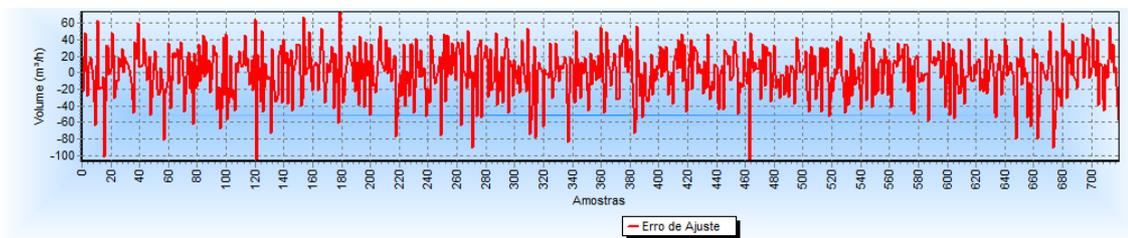
**Figura 5.30. Autocorrelação Parcial (PACF) da Série Temporal**

A Figura 5.31 apresenta os resultados obtidos na validação do modelo ARIMA(4,0,2).

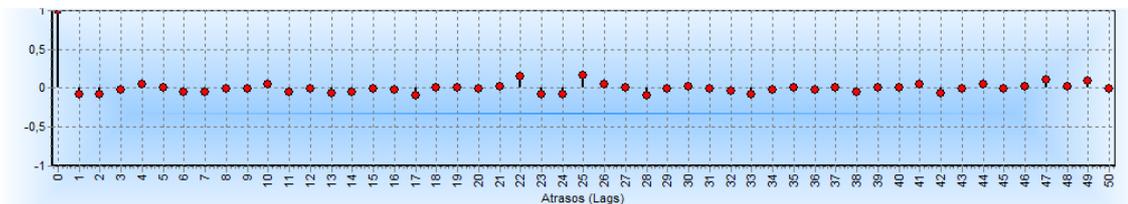


**Figura 5.31. Validação do modelo – Séries Temporais.**

É importante ressaltar que, conforme citado no capítulo 3 no texto referente à etapa 3 da metodologia de *Box e Jenkins*, um teste simples para verificar o ajuste e validação do modelo é analisar se o erro é um ruído branco, caracterizado por possuir média zero, variância constante  $\sigma^2$  e não ser autocorrelacionado, características estas que podem ser confirmadas por intermédio das Figura 5.32 e Figura 5.33.



**Figura 5.32. Análise do erro de validação do modelo**



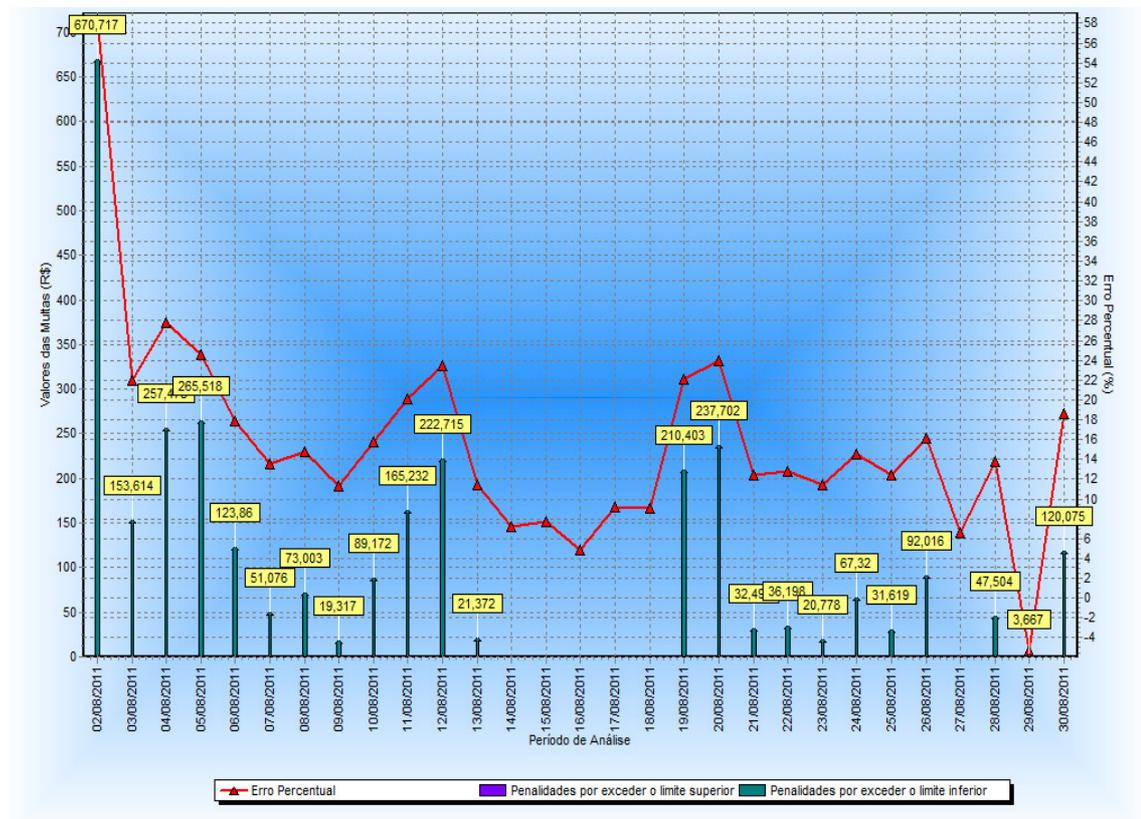
**Figura 5.33. Autocorrelação do erro de validação**

A Tabela 5.22 apresenta os resultados do ponto de vista de aplicação das penalidades, onde se pode destacar o melhor desempenho para um modelo ARMA [ARIMA (4,0,2)], sendo evidenciado para este modelo uma redução das penalidades por erros a menor frete as outras configurações.

**Tabela 5.22. Aplicação de Penalidades – Séries Temporais**

MODELO DE SÉRIES TEMPORAIS	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
(4,0,1)	24,13%	75,86%	0,00%	75,86%	01/08/2011 - 30/08/2011
(4,0,0)	24,13%	75,86%	0,00%	75,86%	01/08/2011 - 30/08/2011
(4,0,2)	31,03%	68,96%	0,00%	68,96%	01/08/2011 - 30/08/2011
(2,0,0)	27,58%	72,41%	3,44%	68,96%	01/08/2011 - 30/08/2011

Na Figura 5.34 pode ser verificado erro percentual para cada amostra do melhor ajuste, assim como, a aplicação de penalidades em função da extrapolação dos limites superiores e inferiores.



**Figura 5.34. Aplicação de Penalidades – Série Temporal**

Diante das observações realizadas o modelo ARMA auto-regressivo e média móvel apresentou um melhor desempenho, pois conforme dito anteriormente, através da análise dos correlogramas ACF e PACF, havia um forte indicio de que a série seria modelada com um modelo ARIMA( $p,0,q$ ) confirmado por intermédio dos gráficos e tabelas apresentadas nesta seção

### 5.3.3 Modelo de rede neural artificial

Na Tabela 5.23 Erro! Fonte de referência não encontrada. são apresentados os melhores resultados obtidos com a utilização de diferentes configurações da Rede Neural Artificial.

**Tabela 5.23. Resultados obtidos com Redes Neurais**

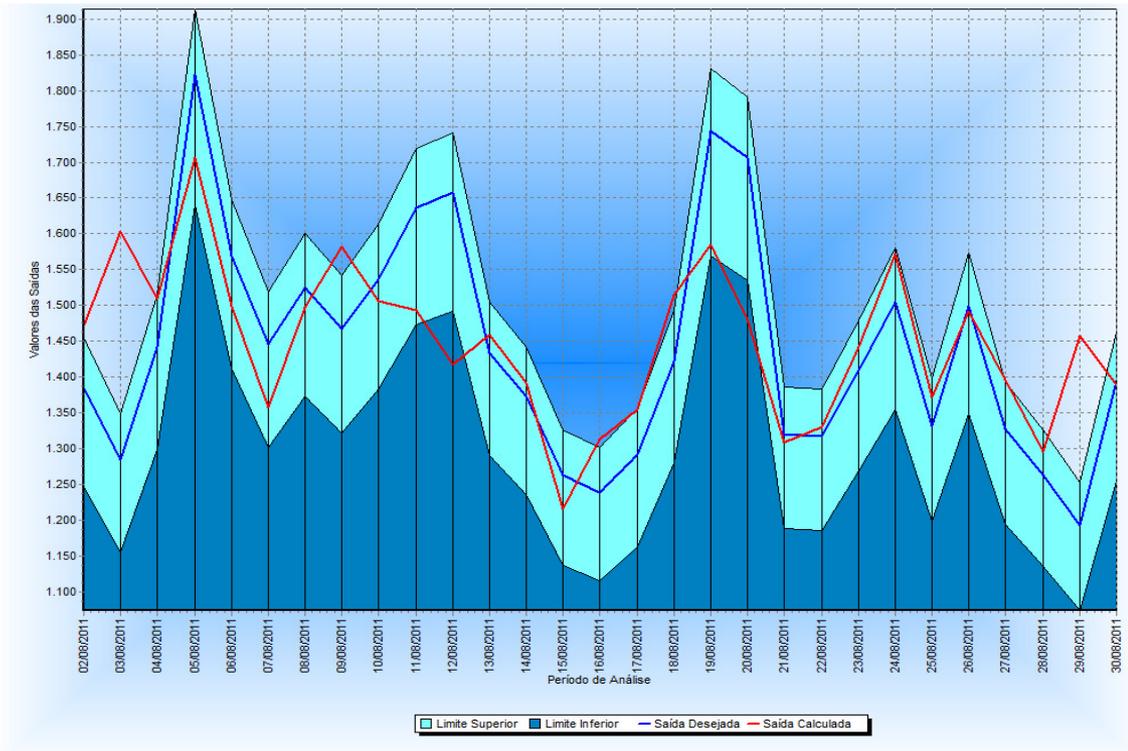
DADOS R.N.A.	TIPO R.N.A.	VETOR DIA	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE AJUSTE	PERÍODO DE VALIDAÇÃO
Sigmoide(3,2)	PADRÃO	SIM	0,10	0,36	0,22	0,90	5,87	0,73	0,70	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Sigmoide(1,3)	PADRÃO	NÃO	0,07	0,35	0,22	0,60	5,76	0,73	0,69	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Sigmoide(1,3)	PADRÃO + ST	SIM	0,09	0,35	0,23	0,77	5,73	0,75	0,71	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011
Tan. Hip.(2,2)	PADRÃO + ST	NÃO	0,03	0,33	0,23	-0,22	5,46	0,74	0,70	01/07/2011 - 31/07/2011	01/08/2011 - 30/08/2011

Na Tabela 5.23 é possível observar que os melhores resultados, do ponto de vista dos índices de desempenho, são da configuração da rede neural artificial com função de ativação tangente hiperbólica, com duas camadas escondida e dois neurônios por camada, com o auxílio por séries temporais e sem a inserção do vetor codificado dias da semana (melhores ME, MAE, MPE e MAPE), seguida pela configuração com função de ativação sigmoide, com uma camada escondida e três neurônios por camada, sem auxílio por séries temporais e sem a inserção do vetor codificado dias da semana (melhores MSE, RMSE e UTHEIL).

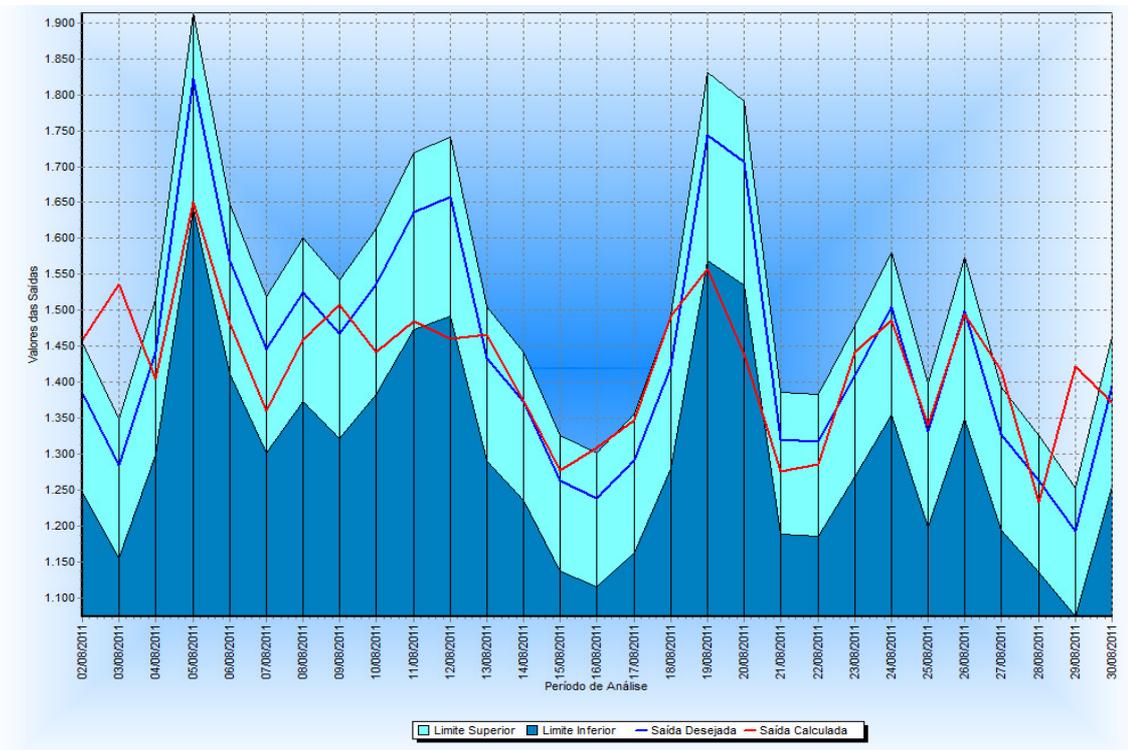
Analisando-se as Figura 5.35 e Figura 5.36, na qual são apresentados os resultados das configurações com melhor desempenho frente ao resultado desejado, constata-se que os resultados obtidos estão muito próximos, com diferenças não significativas para alguns dias, e do ponto de vista de aplicação de penalidades, por intermédio da Tabela 5.24, verifica-se que a configuração não auxiliada por séries temporais apresentou um desempenho 10,35% superior à outra configuração, apontando para a hipótese de que o melhor desempenho não esta associado ao auxilio das séries temporais e sim a capacidade da rede em generalizar a dinâmica da série de consumo em estudo, tanto da tendência da série, quanto as oscilações sazonais presente no perfil.

**Tabela 5.24. Aplicação de Penalidades – Redes Neurais Artificiais**

MODELO DE RNA	TIPO R.N.A.	VETOR DIA	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
Tan. Hip.(2,2)	PADRÃO + ST	NÃO	62,06%	37,93%	27,58%	10,34%	01/08/2011 - 30/08/2011
Sigmoide(1,3)	PADRÃO	NÃO	72,41%	27,58%	17,24%	10,34%	01/08/2011 - 30/08/2011



**Figura 5.35. Análise das Curvas das Redes Neurais Artificiais – TAN H (2,2)**



**Figura 5.36. Análise das Curvas das Redes Neurais Artificiais – SIGMOIDE (1,3)**

### 5.3.4 Comparação dos resultados

Nas Tabela 5.25 e Tabela 5.26 são apresentados, respectivamente, o comparativo entre os melhores resultados do ponto de vista dos índices de desempenho e da aplicação de penalidades.

**Tabela 5.25. Quadro comparativo dos modelos**

MODELO	ME	MAE	MSE	MPE	MAPE	RMSE	UTHEIL	PERÍODO DE VALIDAÇÃO
REGRESSÃO	-0,23	0,49	0,39	-4,25	8,70	0,98	-	01/08/2011 - 30/08/2011
SÉRIE TEMPORAL	0,00	0,10	0,02	-13,67	39,28	0,84	0,76	01/08/2011 - 30/08/2011
REDE NEURAL ARTIFICIAL	0,07	0,35	0,22	0,60	5,76	0,73	0,69	01/08/2011 - 30/08/2011
RNA + ST	0,03	0,33	0,23	-0,22	5,46	0,74	0,70	01/08/2011 - 30/08/2011

**Tabela 5.26. Quadro comparativo da aplicação de penalidade**

MODELO	PERCENTUAL DE ACERTOS	PERCENTUAL APLICAÇÃO DE PENALIDADES	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MAIOR	PERCENTUAL DE APLICAÇÃO DE PENALIDADES POR ERROS A MENOR	PERÍODO DE AJUSTE / VALIDAÇÃO
REGRESSÃO	48,27%	51,72%	41,37%	10,34%	01/08/2011 - 30/08/2011
SÉRIES TEMPORAIS	31,03%	68,96%	0,00%	68,96%	01/08/2011 - 30/08/2011
RNA	72,41%	27,58%	17,24%	10,34%	01/08/2011 - 30/08/2011
RNA + ST	62,06%	37,93%	27,58%	10,34%	01/08/2011 - 30/08/2011

Analisando as tabelas acima pode-se dizer que:

- Os melhores índices de desempenho não significam necessariamente que o modelo é o mais adequado para redução da aplicação de penalidade, objetivo principal deste trabalho;
- O modelo que apresentou o melhor MAPE não foi o que apresentou os melhores resultados sob a ótica da aplicação de penalidades;
- Para o conjunto de dados analisado o que obteve a menor aplicação de penalidade foi a rede neural artificial não auxiliada por séries temporais;

Entre os modelos propostos e analisados, visualmente percebe-se que o modelo de rede neural artificial, auxiliada ou não por séries temporais, consegue generalizar a dinâmica da série de consumo em estudo. Tanto a tendência da série, quanto as oscilações sazonais são absorvidas pelo modelo. Os índices de desempenho, assim como a aplicação de penalidades, revelam que o modelo apresenta bom desempenho para previsões de médio prazo.

Para os consumidores do segmento GNV não será possível realizar um comparativo entre os resultados obtidos com a metodologia aplicada atualmente na companhia, pois esta, por sua vez, realizada a previsão de consumo para o conjunto de todos os consumidores do segmento e não para um consumidor específico, conforme explicado no capítulo 1.

# Capítulo 6

## 6. Conclusão

O presente trabalho permitiu constatar a possibilidade de melhorar de forma significativa a previsão de consumo de gás em médio prazo utilizando técnicas como as redes neurais artificiais, as séries temporais e a combinação de ambas. A metodologia do presente trabalho, utilizando estas técnicas para realização da previsão de consumo de gás natural nos segmentos industrial e GNV, é bastante promissora, trazendo vantagens em termos de versatilidade e maior precisão quando comparada a técnica usada atualmente na companhia.

Adicionalmente, tanto as redes neurais, como as séries temporais, ou a associação de ambas aplicadas aos casos de estudo deste trabalho conseguiram melhores índices de acerto, quando comparadas com as técnicas de regressão linear, polinomial, logarítmica e de potência.

No tocante ao comparativo entre as técnicas propostas, sejam elas regressão, séries temporais e redes neurais artificiais, sendo esta última associada ou não a técnica de séries temporais, é evidente que os melhores resultados são uma combinação das características dos dados históricos do consumidor em análise e a técnica que melhor modela os seus dados. Em outras palavras, não pode-se afirmar que uma técnica é superior ou inferior sem antes analisar de forma minuciosa as características da série, tais como tendências, sazonalidades, variações irregulares e randômicas.

Quando analisado o desempenho dos resultados frente aos objetivos propostos foi possível verificar a estreita relação entre o MAPE (*mean absolute percentage error*) e a aplicação de penalidades, uma vez que para todos os casos as previsões com mínimos MAPEs correspondiam as menores penalidades.

O problema da programação diária exige um grande esforço de previsão, uma vez que devem ser previstos em torno de 14 valores no futuro, neste contexto foi possível verificar que o desempenho das redes neurais melhorou à medida que foi incrementado o número de entradas utilizando-se não apenas as do dia em questão, mas também amostras do dia anterior. Além disso, dois tipos de funções de disparo se destacaram, principalmente, a função sigmoide, e em menor grau a tangente hiperbólica.

Outro objetivo proposto foi o desenvolvimento de uma ferramenta computacional para realização das previsões. Com este intuito foi desenvolvida uma ferramenta baseada em regressão, séries temporais e redes neurais artificiais que permitem as seguintes atividades:

- Banco de dados com os valores históricos para consumidores;
- A visualização dos perfis de consumo por consumidor;
- A utilização de diferentes técnicas de regressão, sendo elas: linear, polinomial, exponencial, logarítmica e potência;
- A utilização do modelo ARIMA de Box e Jenkins;
- A utilização do modelo de redes neurais artificiais Multilayer Perceptron com aprendizado baseado no algoritmo backpropagation;
- O cálculo dos índices de desempenhos apresentados no capítulo 4;
- Relatório gráfico comparativo de ajuste dos modelos

## **6.1 Sugestões para trabalhos futuros**

Para continuidades deste trabalho, algumas propostas são sugeridas, tais como:

- Analisar outros fatores, que não a série de consumo de gás natural, que possam influenciar na previsão de consumo de médio prazo;
- A utilização de novas funções de ativação, de outras arquiteturas de rede, assim como a utilização de outros algoritmos de aprendizado;
- A incorporação de sistemas especialistas aos modelos propostos;
- A criação de um comitê de preditores com os modelos propostos, fazendo as ponderações necessárias para aumentar a eficiência dos mesmos;
- Realizar as adequações necessárias aos modelos propostos para a realização de previsões de curto e longo prazo;
- A utilização das técnicas estudadas na previsão de outras variáveis, tais como: índices de ações, condições climáticas, etc.

# Referências Bibliográficas

- [ 1 ] GASNET. *O site do gás natural. Distribuidoras de Gás. Disponível em:* <<http://www.gasnet.com.br>> . Acessado em: 22 de novembro de 2011.
- [ 2 ] MONTEIRO, J. V. FREITAS; SILVA, J. R. N. M. *Gás Natural aplicado à indústria e ao grande comércio.* São Paulo: Blucher, 2010. 182p.
- [ 3 ] AGÊNCIA NACIONAL DE PETRÓLEO, GÁS NATURAL E BIOCOMBUSTIVÉIS – ANP. Disponível em: <<http://www.anp.gov.br>> . Acessado em: 22 de novembro de 2011.
- [ 4 ] KHOTANZAD, A; ELRAGAL, H; LU, T. L. *Combination of artificial neural-network forecasters for prediction of natural gas consumption.* IEEE transactions on neural networks / a publication of the IEEE Neural Networks Council, v. 11, n. 2, p. 464-73, jan 2000.
- [ 5 ] AZZAM-UL-ASAR; MCDONALD, J. R. *A Specification of Neural Network Applications in the Load Forecasting Problem.* IEEE TRANSACTIONS ON CONTROL SYSTEMS TECHNOLOGY, v. 2, p. 135-141, out 1994.
- [ 6 ] BROWN, R. H.; MATIN, I. *Development of Artificial Neural Network Models to Predict Daily Gas Consumption.* Computer Engineering, p. 1389-1394, 1995.
- [ 7 ] MOHAMMED, O. PARK, D. MERCHANT, R. et al. *Practical Experiences with An Adaptive Neural Network Short-Term Load Forecasting System The Florida Power and Light ANN Architectures and Input.* Forecast, v. 10, n. 1, p. 254-265, 1995.
- [ 8 ] KHOTANZAD, A.; ELRAGAL, H. *Natural Gas Load Forecasting with Combination of Adaptive Neural Networks.* Electrical Engineering, p. 4069-4072, 1999.
- [ 9 ] PEHARDA, D.; DELIMAR, M.; LONEARIC, S. *Short term hourly forecasting of gas consumption using neural networks.* Electrical Engineering, p. 367-371, 2001.
- [ 10 ] VIET, N. H.; MANDZIUK, J. *Neural and Fuzzy Neural Networks for Natural Gas Consumption.* Neural Networks, n. 503, p. 759-768, 2003.
- [ 11 ] KIZILASLAN, R.; KARLIK, B. *Comparison Neural Networks Models for Short Term Forecasting of Natural Gas Consumption in Istanbul.* Network, p. 448-453, 2008.
- [ 12 ] XU, G.; WANG, W. *Forecasting China's natural gas consumption based on a combination model.* Journal of Natural Gas Chemistry, v. 19, n. 5, p. 493-496, set 2010.
- [ 13 ] ABREU, THAYS; ARAÚJO ,KLAYTON A. M.; LOPES, MARA L. M.; LOTUFO, ANNA DIVA P. *Metodologia Híbrida Utilizando os Modelos ARIMA e*

- Redes Neurais Artificiais para Previsão de Cargas Elétricas*. Congresso Brasileiro de Automática, p. 2229-2236, 2012.
- [ 14 ] RUI, C. JIAN, W. LI, W. NINGJIE, Y.; PENGYAN, Z. *The Forecasting of China Natural Gas Consumption Based on Genetic Algorithm*. 2009 Fifth International Joint Conference on INC, IMS and IDC, n. 0, p. 1436-1439, 2009.
- [ 15 ] HUA, F.; FENG, W. *Based on Kalman Filtering Theory Gas Forecast System Research*. 2010 Third International Conference on Information and Computing, p. 69-72, jun 2010.
- [ 16 ] CHIU, S.; TAVELLA, D. *Data Mining And Market Intelligence For Optimal Marketing Returns*. Oxford: Butterworth-Heinemann, 2008.
- [ 17 ] HAN, J.; KAMBER, M. *Data Mining Concepts and Techniques*. San Diego: Academic Press, 2001.
- [ 18 ] SNEDECOR, G. W.; COCHRAN W. G. *Statistical methods*. 8th ed. Iowa: Iowa State University Press, 1989.
- [ 19 ] MILONE, Giuseppe; ANGELINI, Flávio. *Estatística Aplicada*. São Paulo: Atlas, 1995.
- [ 20 ] RIBEIRO; Luiz Cláudio; PAULA, Anaparecida Vieira. *Previsão de população através dos modelos ARIMA de Box e Jenkins*, 2000 – In: Encontro Nacional de Estudos Populacionais, Anais...: Universidade Federal de Minas Gerais, Caxambu, 2000. Disponível em: <http://www.abep.nepo.unicamp.br/docs/anais/pdf/2000>.
- [ 21 ] SÁFADI, Thelma; NOGUEIRA, Denismar Alves. *Previsão de preços na bovinocultura de corte*. Revista de Administração da UFLA v. 2, n. 1, p. 22-31, 2000.
- [ 22 ] MAKRIDAKIS, Spyros G.; WHEELWRIGHT, Steven C; HYNDMAN, Rob J. *Forecasting: methods and applications*. 3.ed. New York: John Wiley & Sons, 1998.
- [ 23 ] FONSECA, Jairo S.; MARTINS, Gilberto A.; TOLEDO, Geraldo L. *Estatística Aplicada*. São Paulo: Atlas, 1995.
- [ 24 ] TUBINO, Dalvio F. *Manual de Planejamento e Controle da Produção*. 2.ed. São Paulo: Atlas S.A., 2000
- [ 25 ] MENTZER, John T.; BIENSTOCK, Carol C. *Sales Forecasting Management*. Thousand Oaks: Sage, 1998.
- [ 26 ] MORETTIN, Pedro Alberto; TOLOI, Clélia M. *Séries Temporais*. 2.ed. São Paulo: Atual, 1987.
- [ 27 ] MORETTIN, Pedro Alberto; TOLOI, Clélia M. *Análise de séries temporais*. São Paulo: Edgard Blucher, 2004.
- [ 28 ] BRYSON JR, A. E.; HO, Y. C. *Applied Optimal Control*. Washington: Hemisphere Publishing Company Corporation, 1975.
- [ 29 ] STENGEL, Robert F. *Stochastic Optimal Control: Theory and Application*. 1.ed. New York: John Wiley & Sons Inc, 1986.
- [ 30 ] SÁFADI, Thelma. *Uso de séries temporais na análise de vazão de água na represa de FURNAS*. Ciências Agrotécnicas, Lavras, v.28, n.1, p. 142-148. 2004.
- [ 31 ] BOX, G. E. P., JENKINS, G. M & REINSEL, G. C. *Time Series Analysis – Forecasting And Control*. 3.ed. New Jersey: Prentice Hall, 1994.

- [ 32 ] PELLEGRINI; Fernando R.; FOGLIATTO, Flávio S.; *Passos para Implementação de Sistemas de previsão de Demanda – Técnicas e Estudo de Caso.* Revista PRODUÇÃO, v.11, n.1, Novembro de 2001.
- [ 33 ] VASCONCELLOS, M. A. S.; ALVES, D. *Manual de Econometria.* São Paulo: Atlas. 2000.
- [ 34 ] GUJARATI, D. N. *Econometria Básica.* São Paulo: Makron Books, 2004.
- [ 35 ] ROJAS, R. *Neural Networks.* *Neural Networks*, v. 42, n. A.I. Memo No. 1562, p. 509, 1996. Springer.
- [ 36 ] HAYKIN, S. *Redes Neurais Princípios e Práticas.* 2. ed. Porto Alegre: Bookman, 2001.
- [ 37 ] BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. *Redes neurais artificiais: teoria e aplicações.* Rio de Janeiro: LTC, 2000.
- [ 38 ] THEIL, H. *Economic forecasts and policy.* North-Holland Publishing Co., 1958.

# Apêndice A - Ferramenta Computacional

Nesta seção serão apresentadas as funcionalidades implementadas na ferramenta computacional, assim como o diagrama funcional, estrutura das telas e forma de utilização.

## A-1 Apresentação

Na Figura A.2 encontram-se representado o diagrama funcional da ferramenta computacional, no qual observa-se a divisão da ferramenta em basicamente duas etapas: cadastramento de consumidores e configuração dos modelos de previsão.

## A-2 Banco de dados

Na etapa de cadastramento de consumidores é realizada a identificação do consumidor por intermédio de dados cadastrais triviais, tais como: nome, logradouro, município e CNPJ, destacando-se a informação referente ao segmento ao qual ele pertence.

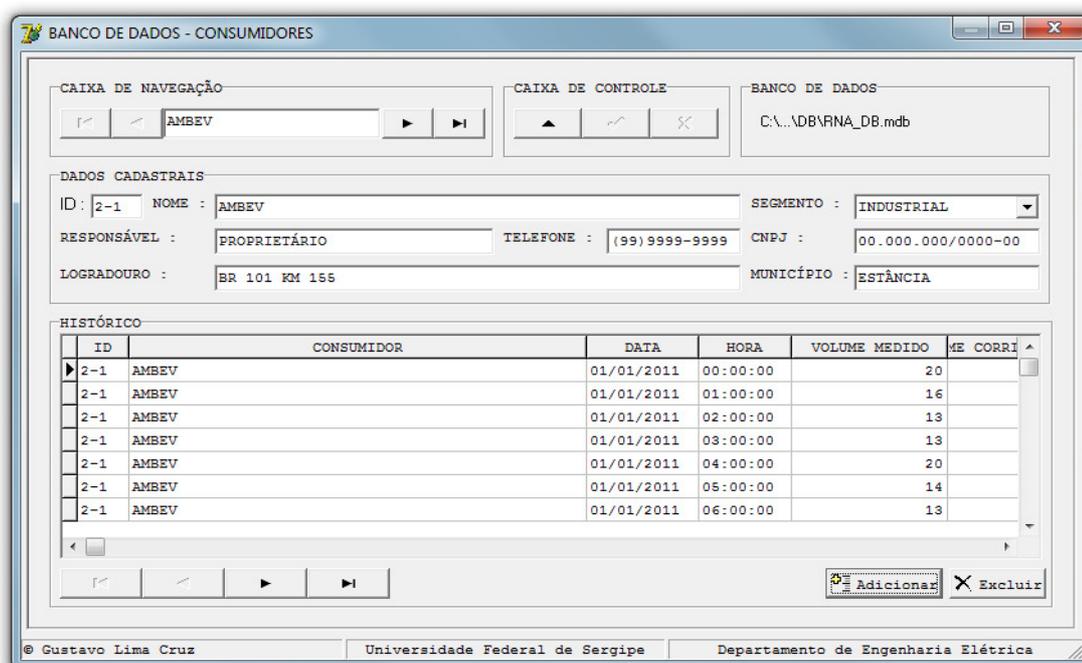
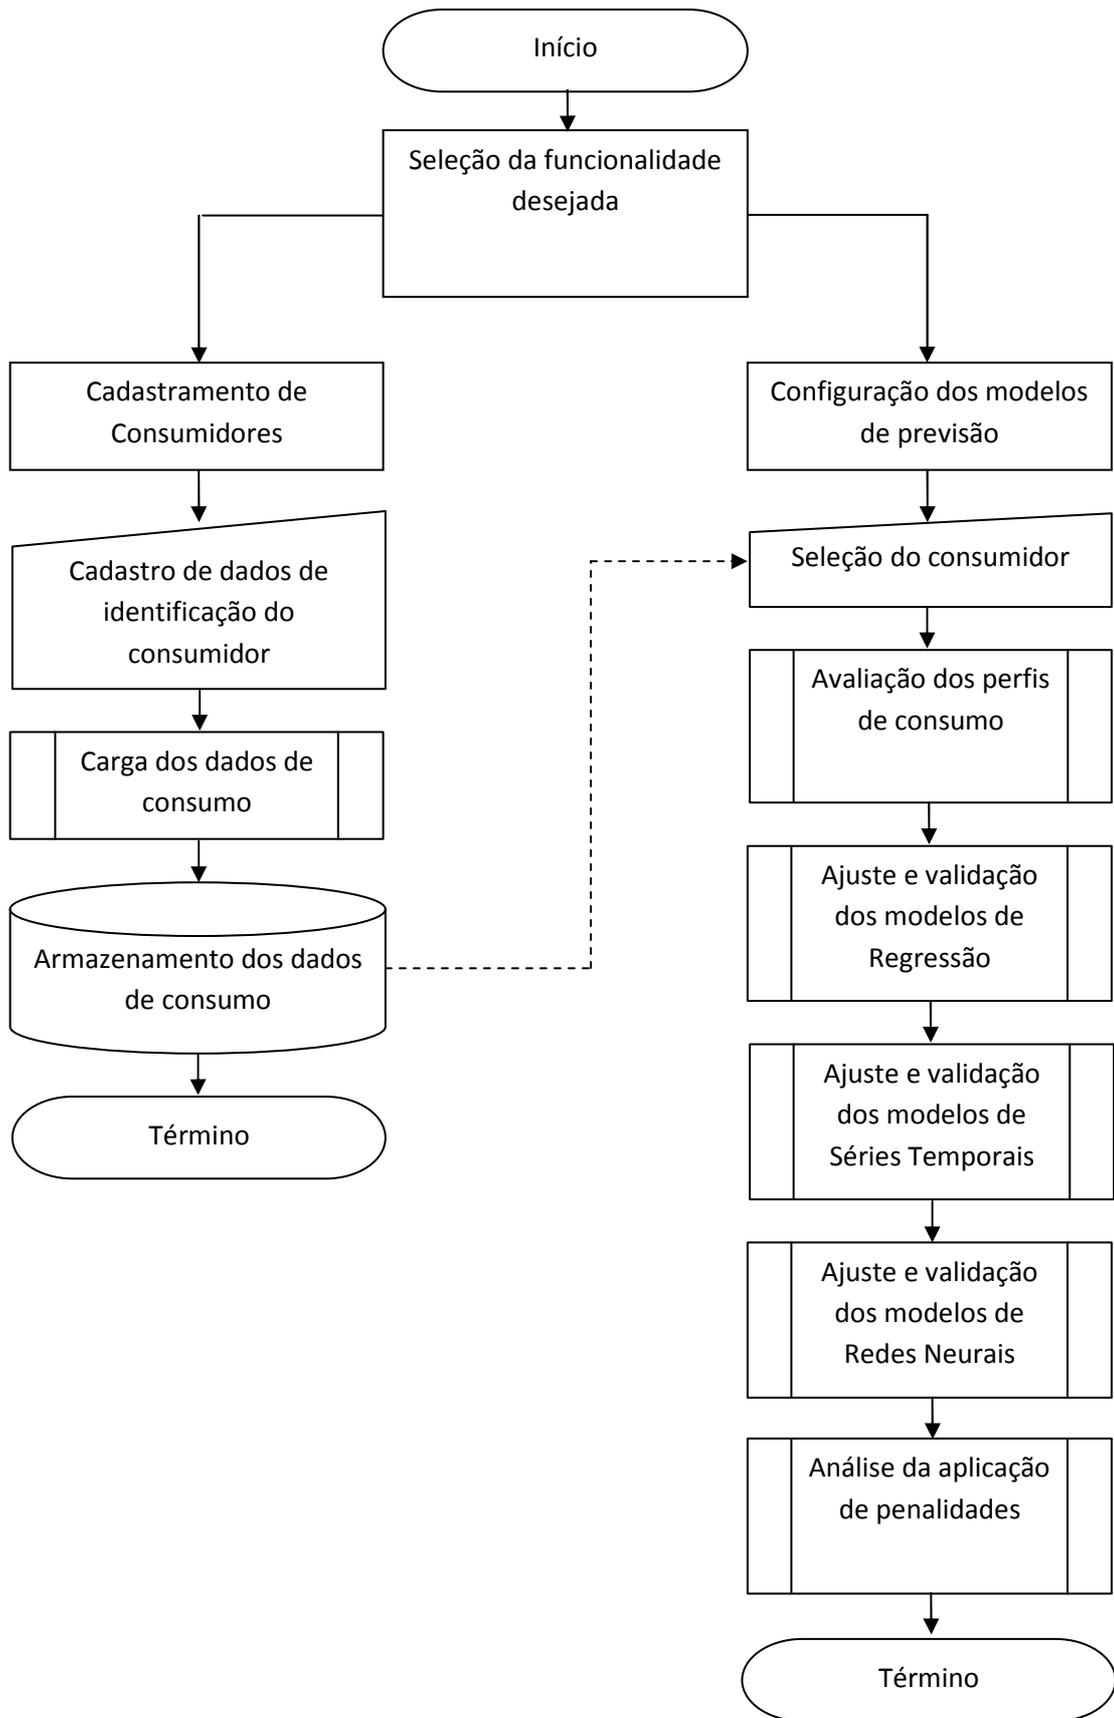


Figura A.1 Tela de acesso ao banco de dados dos consumidores



**Figura A.2 Diagrama funcional da fermenta computacional**

No tocante aos dados históricos de consumo, estes são carregados de forma automatizada na ferramenta por intermédio de arquivos padronizados no formato *Microsoft Excel*, conforme modelo demonstrado na figura A.3.

	A	B	C	D	E	F	G	H	I	J	K	L		
1	<b>Audit Trail Report (Daily Summary)</b>													
2	Report Name: MasterLink32 Audit Trail Report (Daily Summary)										Report Date: 2/8/2011			
3	Report Selections: 1 site, From 1/1/2011 To 1/31/2011													
4	Site Id: 2-1		Site Name: AMBEY										Start Time: 12:00:00AM	
5	Site Location: ESTANCIA													
6			Sum	Sum	Average	Average	Average	Average	Sum	Average	Sum	Average		
7			IncrementalVol	Co IncrementalUn	PCorPressureC	TemperatureGas	BatteryReadingVol	PreviousCorv	Inst Flow Rate	BatteryMemoryV	UncorrectedVol	CorrectionTotal		
8	Date: 1/1/2011	Records per hr	m3	m3	KGom2	C	Volts	m3	m3/HR	Volts	m3	----		
9	12:00:00AM	1	116,00	20,00	6,05	25,47	5,71	24092,00	302,56	4,48	4622091,00	5,80		
10	1:00:00AM	1	93,00	16,00	6,17	25,25	5,71	24092,00	0,00	4,48	4622107,00	5,82		
11	2:00:00AM	1	76,00	13,00	6,17	25,33	5,71	24092,00	0,00	4,48	4622120,00	5,82		
12	3:00:00AM	1	75,00	13,00	6,18	25,12	5,71	24092,00	0,00	4,48	4622133,00	5,84		
13	4:00:00AM	1	116,00	20,00	6,04	24,36	5,71	24092,00	299,23	4,48	4622153,00	5,82		
14	5:00:00AM	1	82,00	14,00	6,15	24,73	5,71	24092,00	0,00	4,48	4622167,00	5,91		
15	6:00:00AM	1	74,00	13,00	6,12	23,18	5,72	24092,00	0,00	4,48	4622180,00	5,80		
16	7:00:00AM	1	108,00	19,00	6,01	22,64	5,72	24092,00	297,80	4,48	4622199,00	5,82		
17	8:00:00AM	1	50,00	9,00	6,10	26,27	5,72	24092,00	0,00	4,48	4622208,00	5,84		
18	9:00:00AM	1	0,00	0,00	6,10	38,33	5,72	24092,00	0,00	4,48	4622208,00	5,61		
19	10:00:00AM	1	244,00	46,00	6,13	30,41	5,72	24092,00	0,00	4,48	4622254,00	5,79		
20	11:00:00AM	1	0,00	0,00	6,12	35,04	5,72	24092,00	0,00	4,48	4622254,00	5,68		
21	12:00:00PM	1	0,00	0,00	6,13	32,91	5,72	24092,00	0,00	4,48	4622254,00	5,73		
22	1:00:00PM	1	0,00	0,00	6,13	31,84	5,72	24092,00	0,00	4,48	4622254,00	5,75		
23	2:00:00PM	1	0,00	0,00	6,16	35,64	5,71	24092,00	0,00	4,48	4622254,00	5,71		
24	3:00:00PM	1	386,00	78,00	6,17	31,14	5,71	24092,00	0,00	4,48	4622332,00	5,80		
25	4:00:00PM	1	377,00	68,00	6,17	28,54	5,71	24092,00	0,00	4,48	4622400,00	5,86		
26	5:00:00PM	1	376,00	67,00	5,45	26,70	5,71	24092,00	986,07	4,48	4622467,00	5,20		
27	6:00:00PM	1	1370,00	278,00	5,15	25,52	5,71	24092,00	1144,88	4,48	4622745,00	4,93		
28	7:00:00PM	1	725,00	138,00	6,02	25,28	5,71	24092,00	400,03	4,48	4622883,00	5,78		
29	8:00:00PM	1	431,00	75,00	6,02	24,96	5,70	24092,00	396,82	4,48	4622958,00	5,79		
30	9:00:00PM	1	632,00	115,00	5,96	25,09	5,71	24092,00	911,33	4,48	4623073,00	5,73		
31	10:00:00PM	1	723,00	133,00	5,90	24,93	5,71	24092,00	995,68	4,48	4623206,00	5,67		
32	11:00:00PM	1	659,00	121,00	5,45	25,07	5,70	24092,00	1061,17	4,48	4623327,00	5,23		
33	<b>Total Records</b>		<b>Sum</b>	<b>Sum</b>	<b>Average</b>	<b>Average</b>	<b>Average</b>	<b>Average</b>	<b>Sum</b>	<b>Average</b>	<b>Sum</b>	<b>Average</b>		
34			<b>24</b>	<b>6713,00</b>	<b>1256,00</b>	<b>6,00</b>	<b>28,74</b>	<b>5,71</b>	<b>24092,00</b>	<b>6795,57</b>	<b>4,48</b>	<b>#####</b>	<b>5,69</b>	
35	2/8/2011 4:44:20 PM Page: 1													

Figura A.3 Exemplo de arquivo padronizado de entrada

## A-3 Configuração dos modelos de previsão

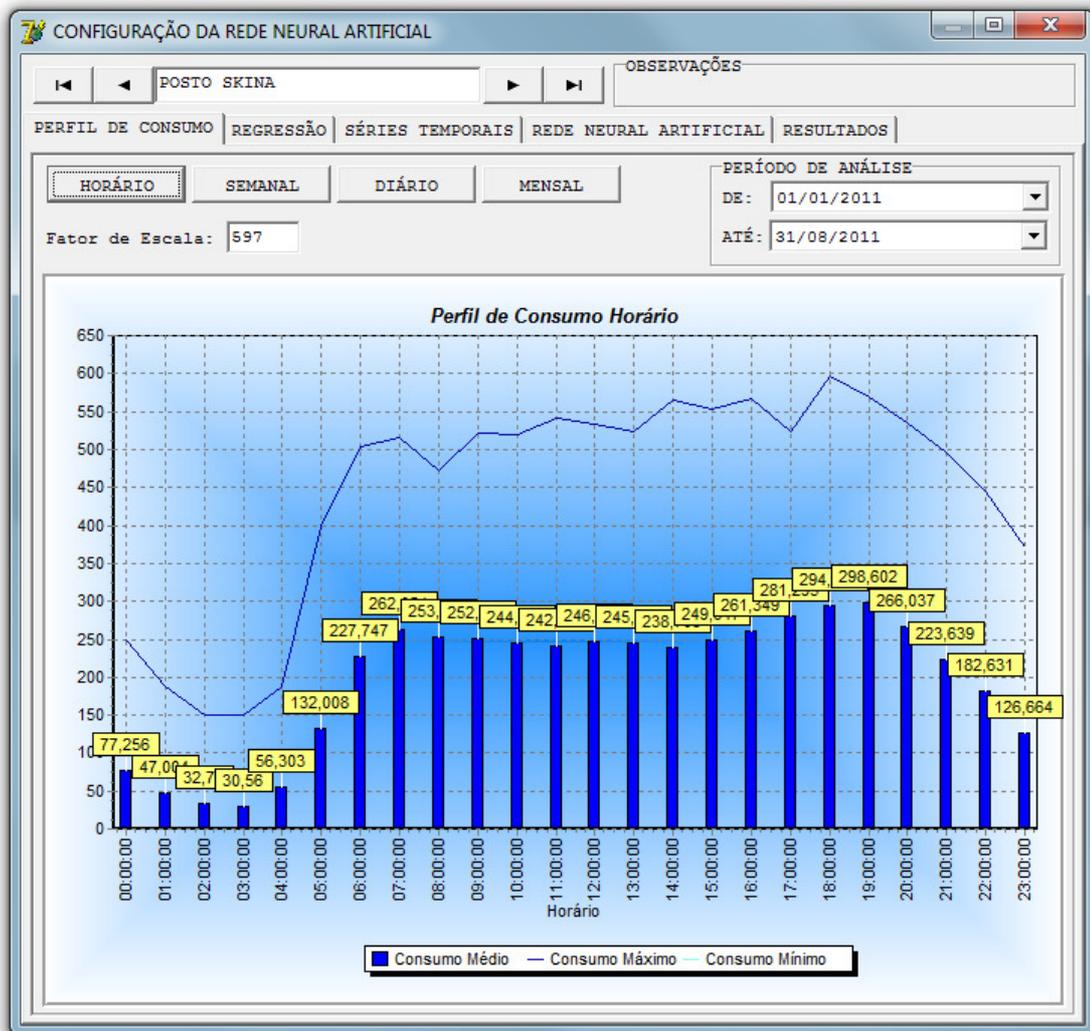
Uma vez cadastrado os consumidores, segue-se para etapa de configuração dos modelos, que foi dividida em cinco processos: avaliação dos perfis de consumo, ajuste e validação dos modelos de Regressão, ajuste e validação dos modelos de Séries Temporais, ajuste e validação dos modelos de Redes Neurais Artificiais e análise da aplicação de penalidades.

### A-3.1 Avaliação dos perfil de consumo

O primeiro processo, chamado de avaliação dos perfis de consumo, consiste em observar e avaliar os perfis de consumo de forma individualizada, por intermédio dos consumos médios, máximos e mínimos, segmentados em horário, semanal, diário e mensal, a fim de obter características típicas como tendências, sazonalidades, variações irregulares e randômicas, de fundamental importância no ajuste dos modelos que seguem.

O banco de dados irá fornecer os dados necessários para realização desta análise, podendo-se selecionar o período no qual se deseja realizar esta operação.

Na figura A.4 é apresentada a tela da ferramenta referente ao perfil de consumo horário de um consumidor do segmento veicular, no qual destaca-se um perfil com características sazonais.



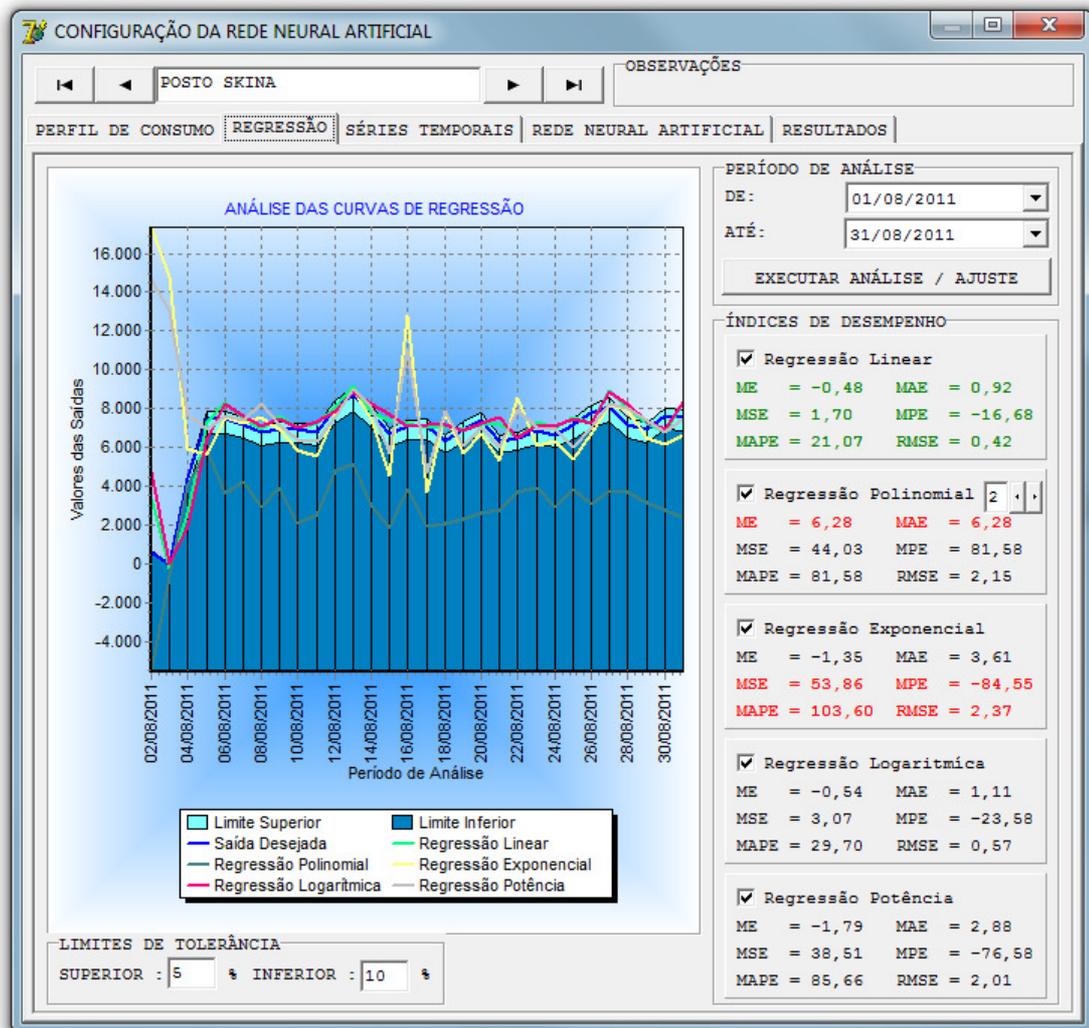
**Figura A.4 Exemplo de perfil de consumo**

Outra informação importante para a realização das previsões de consumo é obtida neste processo, chamado de Fator de Escala, ou seja, um valor numérico que servirá para normalizar os dados nos próximos processos.

### A-3.2 Ajuste e validação dos modelos de Regressão

No processo de ajuste e validação dos modelos de regressão serão realizados os ajustes das curvas de regressão linear, polinomial, exponencial, logarítmica e potência, cabendo ao usuário da ferramenta apenas selecionar o período desejado para esta tarefa. Os ajustes serão realizados e exibidos graficamente conforme figura A.5.

Com o intuito de avaliar os resultados obtidos, nesta mesma tela serão exibidos os índices de desempenho, destacando em verde os melhores índices e em vermelho os piores.



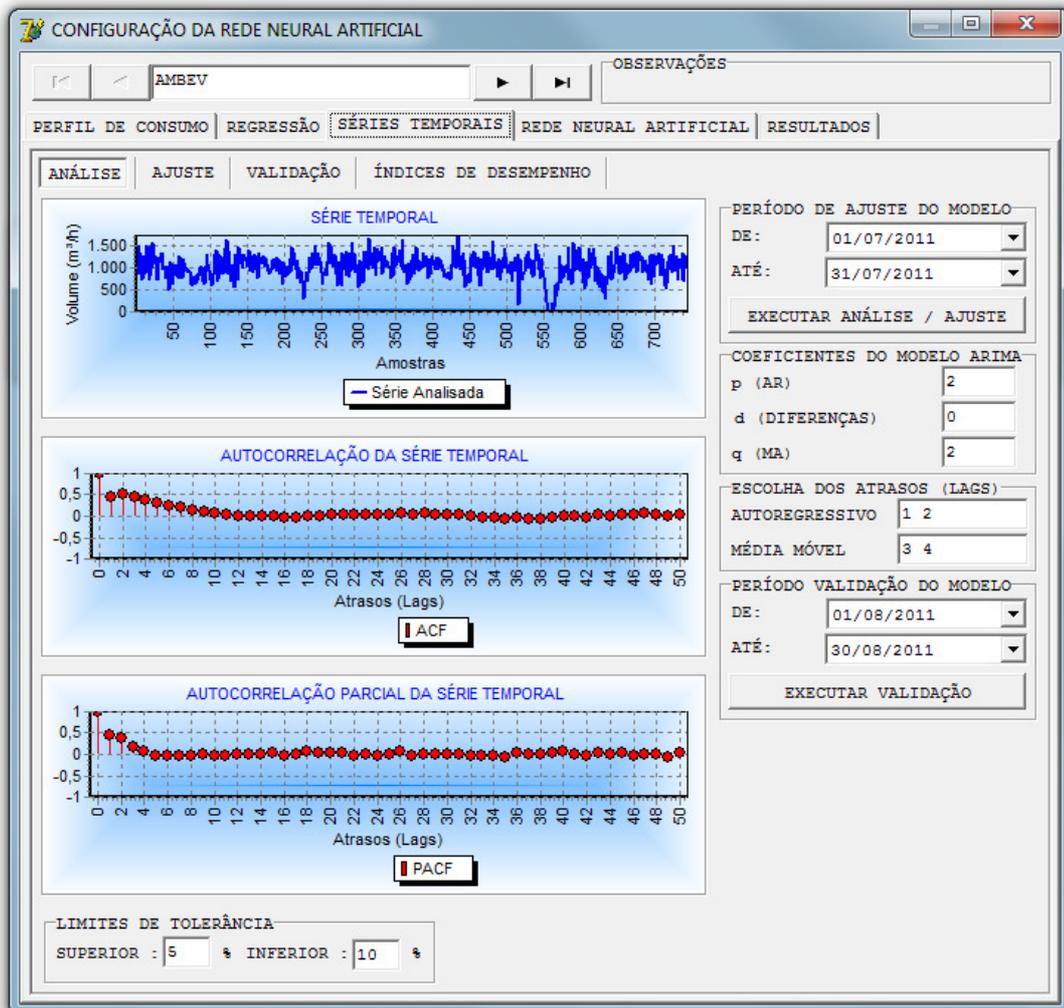
**Figura A.5 Exemplo de ajuste e validação dos modelos de regressão**

Do ponto de vista do gráfico apresentado é possível ajustar os limites máximo e mínimo de tolerância para aplicação de penalidades, devendo a curva prevista manter-se dentro destes limites, evitando assim a aplicação de penalidades.

### A-3.3 Ajuste e validação dos modelos de Séries Temporais

O processo de ajuste e validação dos modelos de Séries Temporais é iniciado com a seleção do período de ajuste, seguida pela análise da série temporal, observando-se as funções de autocorrelação e autocorrelação parcial, exemplificada na figura A.6.

De posse das observações realizadas faz-se a escolha da ordem dos processos auto-regressivo ( $p$ ) e médio móvel ( $q$ ), assim como a quantidade de diferenciações necessárias ( $d$ ), finalizando com a escolha dos atrasos ( $lags$ )



**Figura A.6 Exemplo de análise da série temporal**

Configurado o modelo desejado parte-se para o ajuste, cujo resultado é exibido graficamente, conforme figura A.7, onde destaca-se a necessidade de analisar, além do ajuste propriamente, o erro e a autocorrelação do erro.

Uma vez considerado ajustado o modelo parte-se para a validação do mesmo, no qual deve-se escolher um período, chamado período de validação e mais uma vez analisar o erro e a autocorrelação do erro, conforme figura A.8

O processo é finalizado avaliando os índices de desempenho, apresentados em forma de tabela.

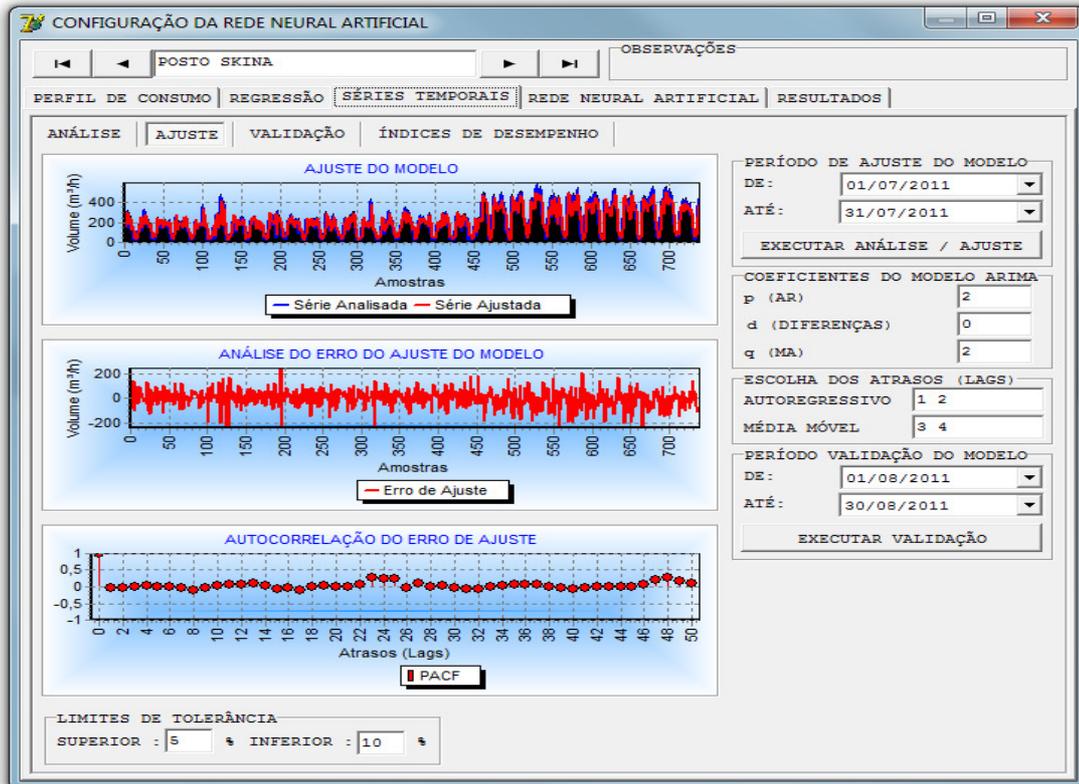


Figura A.7 Exemplo de ajuste do modelo de série temporal

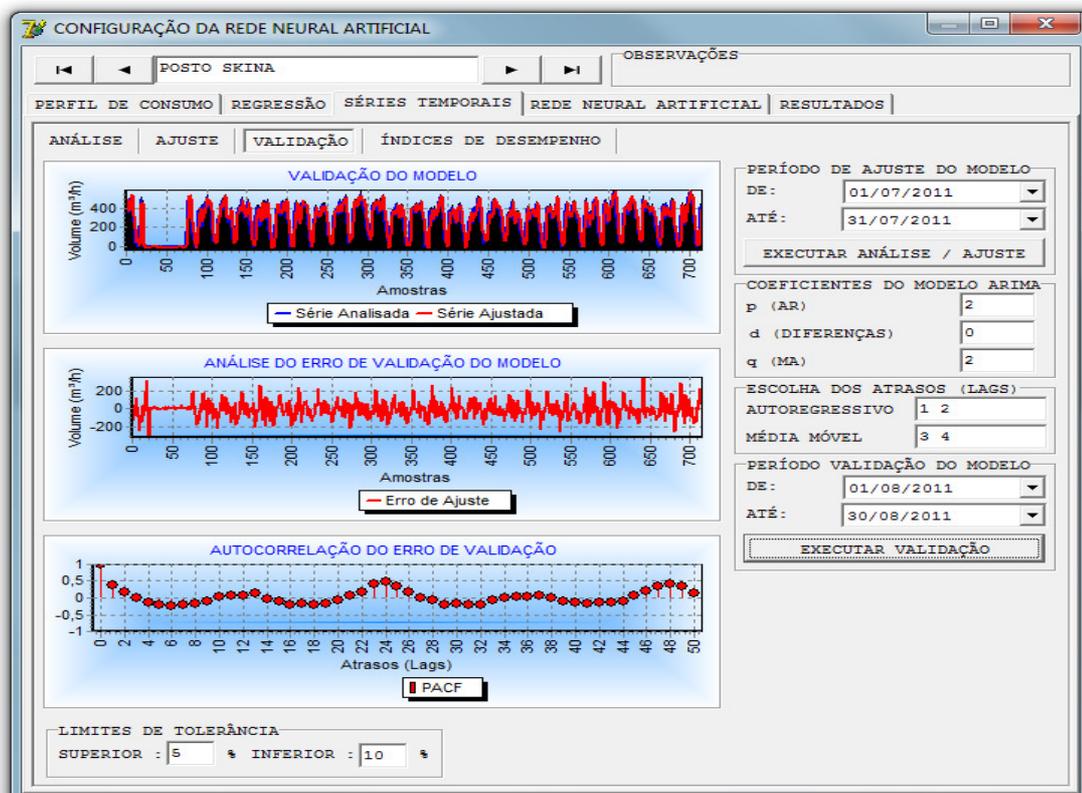


Figura A.8 Exemplo de validação do modelo de série temporal

### A-3.4 Ajuste e validação dos modelos de redes neurais artificiais

Este processo, ajuste e validação dos modelos de redes neurais artificiais, é iniciado pela seleção do período de aprendizado da rede neural artificial, seguido pela caracterização desta etapa, em que serão escolhidos o número de ciclos de aprendizado, a razão de aprendizado  $\eta$ , o erro médio máximo admissível, utilizado como critério de parada, além do fator de momento, elemento facilitador da convergência do aprendizado.

Terminada a configuração do aprendizado, segue-se para a topologia da rede, na qual serão definidos o número de camadas escondidas, o número de neurônios por camada escondida e a função de ativação, para este último foram implementadas duas funções, a tangente hiperbólica e a sigmoide. Na figura A.9 é exemplificada esta etapa.

No tocante as entradas e saídas da rede neural artificial, pode-se configurá-las com ou sem o auxílio de séries temporais, além da possibilidade de inclusão do vetor codificado dos dias da semana.

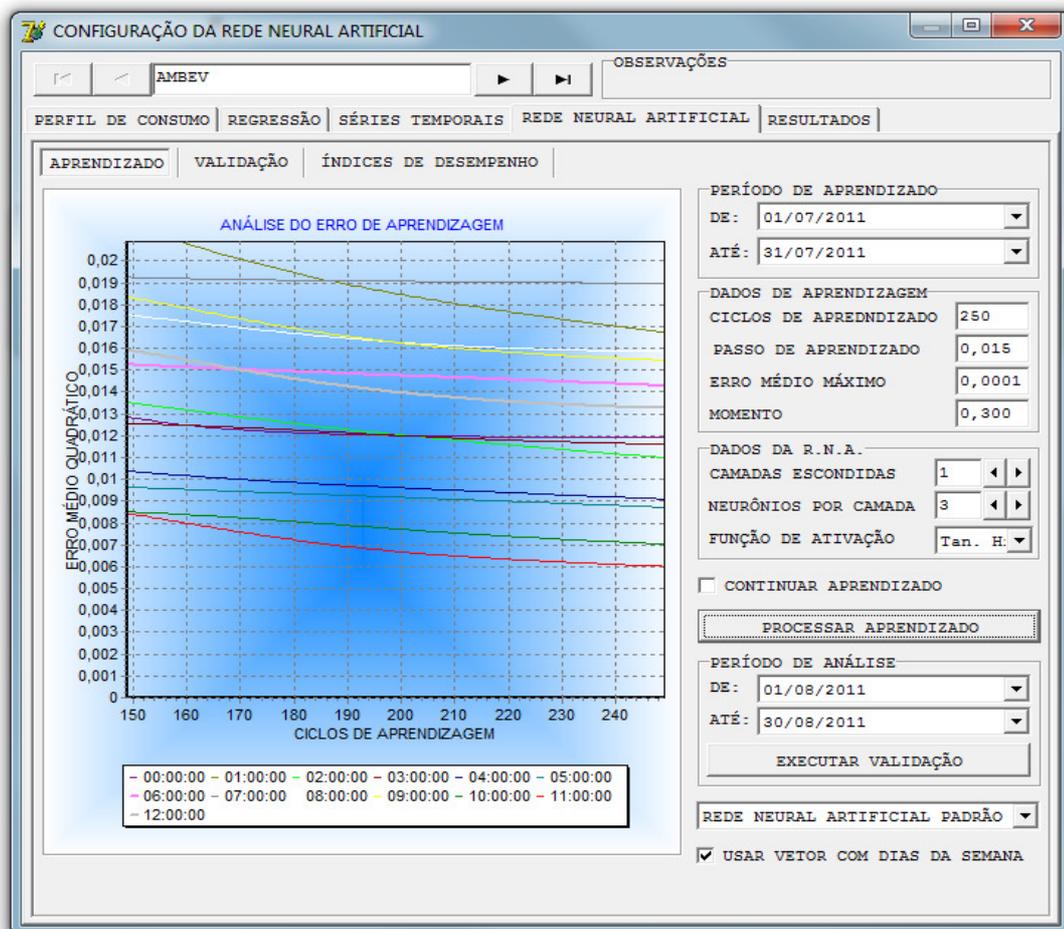
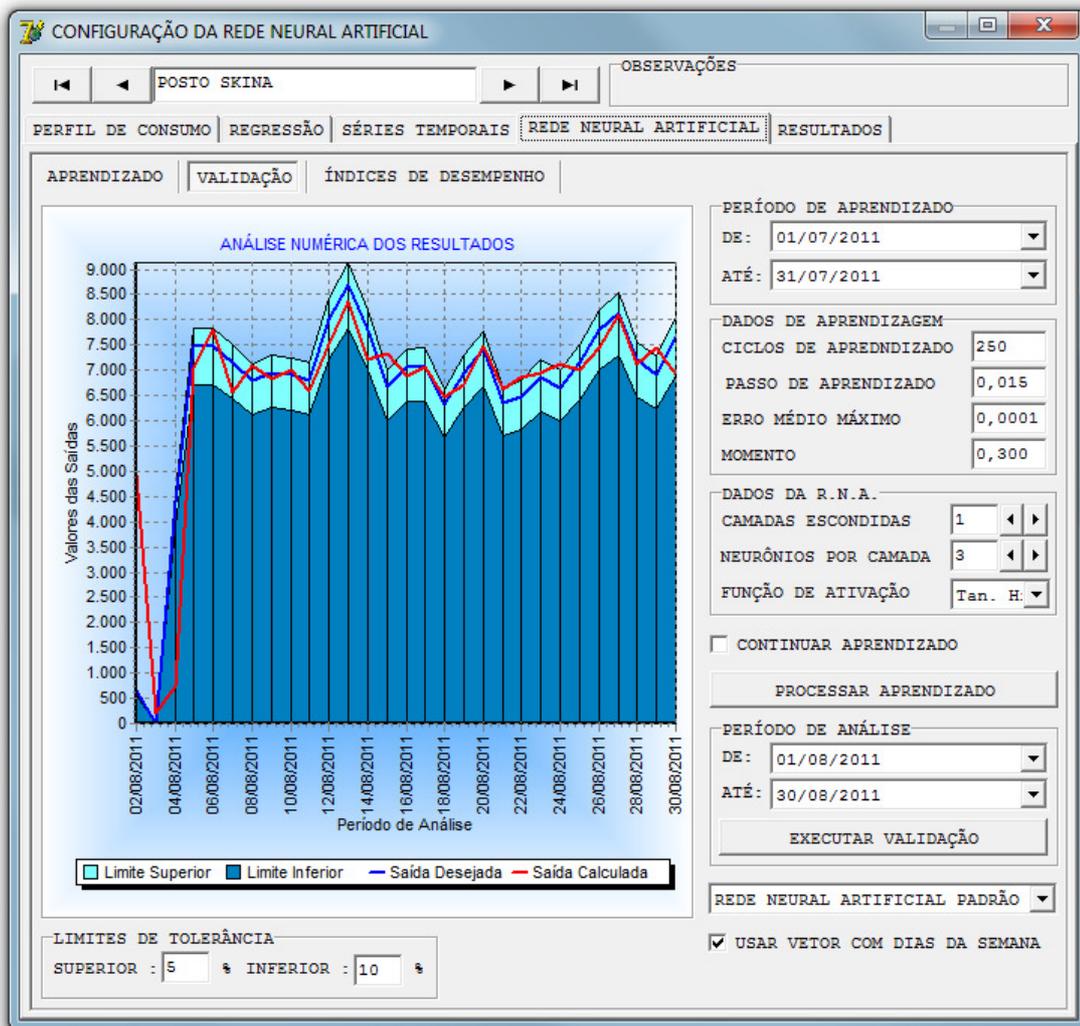


Figura A.8 Exemplo de aprendizado da rede neural artificial

Durante o andamento do processo de aprendizado é exibida, em tempo real e na forma gráfica, a evolução do erro médio de máximo de aprendizado, na qual observa-se a convergência do modelo para o mínimo global, facultando ao usuário continuar ou não o corrente aprendizado.

Concluída a etapa de aprendizado, inicia-se, com a seleção do período de validação do modelo, a etapa de análise de adequação do modelo a série em estudo, conforme figura A.9, na qual serão observados os valores previstos frente aos valores reais, respeitando-se os limites de tolerância para aplicação de penalidades.



**Figura A.9 Exemplo de validação do modelo de rede neural artificial**

O processo é finalizado avaliando os índices de desempenho, apresentados em forma de tabela.

### A-3.5 Análise da aplicação de penalidades

O último processo a ser realizado é a análise da aplicação de penalidades, no qual, para cada uma das técnicas de previsão, serão observados o erro percentual da previsão e a aplicação de penalidade por exceder os limites superior e inferior.

Na figura A.10 é apresentada a tela da ferramenta referente à análise da aplicação de penalidade, onde observa-se, graficamente, o erro percentual e a aplicação de penalidades e, na forma de tabela, o resultado consolidado do modelo de previsão, com o percentual de acertos, de erros e de aplicação de penalidades para o período selecionado para análise.

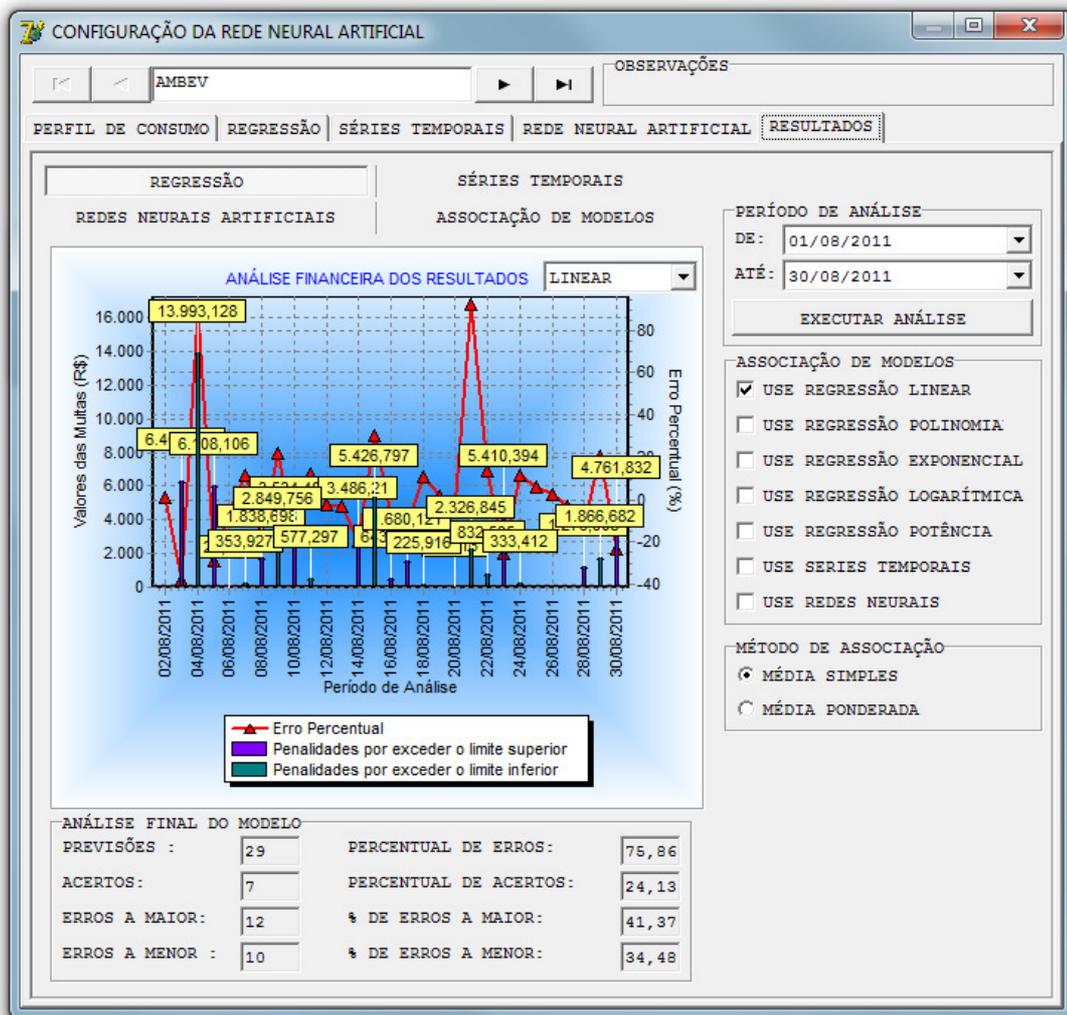


Figura A.10 Exemplo de análise da aplicação de penalidades