

**UNIVERSIDADE FEDERAL DE ALFENAS**  
**INSTITUTO DE CIÊNCIAS EXATAS**  
**BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

*Max Olinto Moreira*

**SISTEMA INTELIGENTE BASEADO EM COMBINAÇÃO DE  
PREVISORES PARA PREVISÃO DE SÉRIES TEMPORAIS DE  
CARGA ELÉTRICA À CURTO PRAZO**

Alfenas, 01 de Julho de 2010.



**UNIVERSIDADE FEDERAL DE ALFENAS**  
**INSTITUTO DE CIÊNCIAS EXATAS**  
**BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

**SISTEMA INTELIGENTE BASEADO EM COMBINAÇÃO DE  
PREVISORES PARA PREVISÃO DE SÉRIES TEMPORAIS DE  
CARGA ELÉTRICA À CURTO PRAZO**

*Max Olinto Moreira*

Monografia apresentada ao Curso de Bacharelado em  
Ciência da Computação da Universidade Federal de  
Alfenas como requisito parcial para obtenção do Título de  
Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Ricardo Menezes

Alfenas, 01 de Julho de 2010.



*Max Olinto Moreira*

**SISTEMA INTELIGENTE BASEADO EM COMBINAÇÃO DE  
PREVISORES PARA PREVISÃO DE SÉRIES TEMPORAIS DE  
CARGA ELÉTRICA À CURTO PRAZO**

A Banca examinadora abaixo-assinada aprova a monografia apresentada como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação pela Universidade Federal de Alfenas.

---

**Prof. M.e Luiz Eduardo da Silva**

**Universidade Federal de Alfenas**

---

**Profa. Dra. Thais Gama de Siqueira**

**Universidade Federal de Alfenas**

---

**Prof. Dr. Ricardo Menezes Salgado (Orientador)**

**Universidade Federal de Alfenas**

Alfenas, 01 de Julho de 2010.



Dedico este trabalho à minha família e ao meu orientador, professor Dr. Ricardo Menezes Salgado, que me acompanharam durante todo o tempo de execução do mesmo, inclusive durante as dificuldades encontradas



# AGRADECIMENTO

[Agradeço, primeiramente, a Deus por ter me concedido o dom da vida e estar sempre presente em meus caminhos, além de me fortalecer diariamente.

À minha família, que se manteve inteiramente do meu lado em todos os momentos. Agradeço pelo cuidado, pelo companheirismo, pela paciência, pelo amor e pelo carinho.

Merece destaque também meu orientador, professor Dr. Ricardo Menezes Salgado, agradeço pela paciência e pela confiança em meu potencial. Fico muito feliz ao lembrar que sua orientação não se resumia apenas à um trabalho científico mas, algumas vezes, compartilhava comigo experiências que ele já havia vivenciado ou adquirido ao longo de sua trajetória pela vida. Sempre agiu com presteza, se mostrando amigo em todo tempo.

Por último, agradeço e parabenizo à Unifal-MG pela excelência dos cursos oferecidos, em especial o curso de Bacharelado em Ciência da Computação, que tive o privilégio de acompanhar a implantação e os primeiros passos, por ter ingressado na primeira turma do mesmo, em 2006/02. É com muita alegria que posso dizer que presenciei aulas com um corpo docente extremamente competente, indispensáveis e responsáveis pelo nível de excelência do curso.] ]



"Quem retém as palavras possui o conhecimento, e o sereno de espírito é  
homem de inteligência."

Provérbios 17:27



# RESUMO

A previsão da demanda de carga é uma tarefa fundamental para um bom funcionamento dos sistemas elétricos, pois vários processos de tomada de decisão, tais como planejamento, operação, análise de segurança e decisões de mercado, são altamente influenciados por este processo. Esta previsão é importante para que uma empresa de distribuição promova um fornecimento de energia de forma segura, econômica e contínua. O presente trabalho propõe a elaboração de uma metodologia de previsão de carga elétrica à curto prazo, baseada na combinação de vários previsores distintos. A combinação proposta envolve as componentes de Programação Genética, Redes Neurais Artificiais e Regressão Linear Múltipla. Acredita-se que, esta combinação, denominada Ensemble, tende a apresentar resultados de forma a tornar a previsão mais acurada do que se fosse realizada por apenas um componente de previsão, individualmente, reduzindo os erros e suavizando os resultados. Neste modelo, a previsão da curva de demanda de carga, de um certo dia, baseia-se nas curvas de demanda de dias já conhecidos. Para a execução dos experimentos deste trabalho, serão considerados dados de medição obtidos do sistema elétrico brasileiro. Estes dados compreendem o período de 01/03/2002 a 30/08/2002, com a medição efetuada com discretização horária.

**Palavras-Chave:** Previsão de Carga, Ensemble, Inteligência Artificial, Redes Neurais Artificiais.



# ABSTRACT

The short-term load forecasting is a fundamental task for the proper functioning of electrical systems, due to many decision-making processes such as planning, operation, security analysis and market decisions are heavily influenced by it. This prediction is important for a distribution company to promote a supply of energy in a safe, economical and continuous. This paper proposes the development of a methodology for short-term load forecasting based on a combination of several different predictors. The proposal involves combining the components of Genetic Programming, Artificial Neural Networks and Multiple Linear Regression. It is believed that this combination, called Ensemble, tends to produce results in order to make the prediction more accurate than if performed by only one component of prediction, individually, reducing errors and smoother results. In this model, the forecast of the demand curve of loading, one day, based on demand curves for days already known. For the execution of experiments in this work will be considered measurement data obtained from the Brazilian electrical system. These data cover the period of 03/01/2002 to 08/30/2002, with measurements performed with hourly discretization.

**Keywords:** Load Forecast, Ensemble, Artificial Intelligence, Artificial Neural Networks



# LISTA DE FIGURAS

FIGURA 1 – SISTEMA ELÉTRICO DE POTÊNCIA (SEP).....	26
FIGURA 2 – ALGUMAS FORMAS DE ENERGIA. ....	27
FIGURA 3 – ALGUMAS TRANSFORMAÇÕES ENERGÉTICAS E SUAS APLICAÇÕES. ....	27
FIGURA 4 – MODELO DE PREVISÃO SIMPLIFICADO .....	37
FIGURA 5 – MODELO REDE NEURAL MLP. FONTE: (SILVEIRA ET AL, 2010) .....	39
FIGURA 6 – PROGRAMA $X^2+Y$ (FORMA PRÉ-FIXADA) REPRESENTADO NA ESTRUTURA DE ÁRVORE. ....	40
FIGURA 7 – ESQUEMA DE FUNCIONAMENTO DA PROGRAMAÇÃO GENÉTICA. ....	42
FIGURA 8 – ESTRUTURA DE UM <i>ENSEMBLE</i> .....	44
FIGURA 9 – MELHORES COMPONENTES SELECIONADAS. FONTE: (SALGADO ET AL. 2006) .....	45
FIGURA 10 – CURVA REAL X CURVA OBTIDA PELO <i>ENSEMBLE</i> . FONTE: (SALGADO ET AL. 2006).....	46
FIGURA 11 – HISTÓRICO DE MEDIÇÃO, APRESENTANDO AS DIVISÕES PARA OS EXPERIMENTOS.....	51
FIGURA 12 – SÉRIES DE CARGA ABRANGENDO O PERÍODO DE 01/03/2002 A 30/08/2002.....	52
FIGURA 13 – SÉRIES DE CARGA DO CONSUMO REAL DA SEMANA DE VALIDAÇÃO. ....	54
FIGURA 14 – SÉRIES DE CARGA DO CONSUMO REAL DA SEMANA DE PREVISÃO.....	54
FIGURA 15 – CURVAS DE CONSUMO DISPOSTAS EM SÉRIE. ....	55
FIGURA 16 – PREVISÃO REALIZADA POR UMA COMPONENTE INDIVIDUAL PARA UM DIA X QUALQUER, ENCONTRANDO O EPMd.....	58
FIGURA 17 – GERAÇÃO E ESCOLHA DAS COMPONENTES QUE OBTIVERAM O MENOR EPMd. ....	61
FIGURA 18 – EXEMPLO DE MUTAÇÃO.....	62
FIGURA 19 – EXEMPLO DE ERROS COMETIDOS PELO <i>ENSEMBLE</i> PELAS COMPONENTES INDIVIDUAIS DE PREVISÃO.....	64
FIGURA 20 – EXEMPLO DE ENTRADAS TREINO, SAÍDAS DESEJADAS E ENTRADAS TESTE PARA A PREVISÃO DE UMA DETERMINADA HORA DO DIA 23/08/2002.....	66
FIGURA 21 – CURVAS DO CONSUMO DE CARGA HORÁRIO, APRESENTADAS PARA TODOS OS DIAS DO HISTÓRICO DE MEDIÇÃO. ....	66
FIGURA 22 – COMPONENTES SELECIONADAS PARA COMPOR O <i>ENSEMBLE</i> DO DIA 24/08/2002.....	67
FIGURA 23 – MAIOR E MENOR ERRO COMETIDO PELAS COMPONENTES DE CADA MODELO, PARA O DIA 24.....	70
FIGURA 24 – MAIOR E MENOR ERRO COMETIDO PELAS COMPONENTES DE CADA MODELO, PARA O DIA 25.....	70
FIGURA 25 – MAIOR E MENOR ERRO COMETIDO PELAS COMPONENTES DE CADA MODELO, PARA O DIA 26.....	71
FIGURA 26 – GRÁFICO DE ERROS PARA CADA HORA DO DIA 24.....	74
FIGURA 27 – GRÁFICO DE ERROS PARA CADA HORA DO DIA 25.....	75
FIGURA 28 – GRÁFICO DE ERROS PARA CADA HORA DO DIA 26.....	75
FIGURA 29 – GRÁFICO DE ERROS PARA CADA HORA DO DIA 27.....	76
FIGURA 30 – GRÁFICO DE ERROS PARA CADA HORA DO DIA 28.....	77
FIGURA 31 – GRÁFICO DE ERROS PARA CADA HORA DO DIA 29.....	77
FIGURA 32 – GRÁFICO DE ERROS PARA CADA HORA DO DIA 30.....	78
FIGURA 33 – GRÁFICO DAS CURVAS DE PREVISÃO, OBTIDAS PELAS COMPONENTES INDIVIDUAIS, E DA CARGA REAL DO DIA 25. ....	79
FIGURA 34 – GRÁFICO DAS CURVAS DE PREVISÃO, OBTIDAS PELAS COMPONENTES INDIVIDUAIS, E DA CARGA REAL DO DIA 26. ....	79

FIGURA 35 – GRÁFICO DAS CURVAS DE PREVISÃO, OBTIDAS PELAS COMPONENTES INDIVIDUAIS, E DA CARGA REAL DO DIA 27. ....	80
FIGURA 36 – GRÁFICO DAS CURVAS DOS <i>ENSEMBLES</i> E CURVA REAL DE CARGA PARA O DIA 24. ....	81
FIGURA 37 – GRÁFICO DAS CURVAS DOS <i>ENSEMBLES</i> E CURVA REAL DE CARGA PARA O DIA 25. ....	81
FIGURA 38 – GRÁFICO DAS CURVAS DOS <i>ENSEMBLES</i> E CURVA REAL DE CARGA PARA O DIA 26. ....	82
FIGURA 39 – GRÁFICO DAS CURVAS DOS <i>ENSEMBLES</i> E CURVA REAL DE CARGA PARA O DIA 27. ....	82
FIGURA 40 – GRÁFICO DAS CURVAS DOS <i>ENSEMBLES</i> E CURVA REAL DE CARGA PARA O DIA 28. ....	83
FIGURA 41 – GRÁFICO DAS CURVAS DOS <i>ENSEMBLES</i> E CURVA REAL DE CARGA PARA O DIA 29. ....	83
FIGURA 42 – GRÁFICO DAS CURVAS DOS <i>ENSEMBLES</i> E CURVA REAL DE CARGA PARA O DIA 30. ....	84
FIGURA 43 – GRÁFICO DOS ERROS HORÁRIOS PARA OS TRÊS <i>ENSEMBLES</i> PROPOSTOS (MA, MP E RNA) VERIFICADOS PARA O DIA 24. ....	86
FIGURA 44 – GRÁFICO DOS ERROS HORÁRIOS PARA OS TRÊS <i>ENSEMBLES</i> PROPOSTOS (MA, MP E RNA) VERIFICADOS PARA O DIA 25. ....	87
FIGURA 45 – GRÁFICO DOS ERROS HORÁRIOS PARA OS TRÊS <i>ENSEMBLES</i> PROPOSTOS (MA, MP E RNA) VERIFICADOS PARA O DIA 26. ....	88
FIGURA 46 – GRÁFICO DOS ERROS HORÁRIOS PARA OS TRÊS <i>ENSEMBLES</i> PROPOSTOS (MA, MP E RNA) VERIFICADOS PARA O DIA 27. ....	89
FIGURA 47 – GRÁFICO DOS ERROS HORÁRIOS PARA OS TRÊS <i>ENSEMBLES</i> PROPOSTOS (MA, MP E RNA) VERIFICADOS PARA O DIA 28. ....	91
FIGURA 48 – GRÁFICO DOS ERROS HORÁRIOS PARA OS TRÊS <i>ENSEMBLES</i> PROPOSTOS (MA, MP E RNA) VERIFICADOS PARA O DIA 29. ....	93
FIGURA 49 – GRÁFICO DOS ERROS HORÁRIOS PARA OS TRÊS <i>ENSEMBLES</i> PROPOSTOS (MA, MP E RNA) VERIFICADOS PARA O DIA 30. ....	94
FIGURA 50 – PREVISORES QUE SE COMPORTARAM NUMERICAMENTE MELHOR QUE OS DEMAIS. ....	95

# LISTA DE TABELAS

TABELA 1 – TABELA DA ANÁLISE DE VARIÂNCIA .....	53
TABELA 2 – TESTE DE TUKEY .....	53
TABELA 3 – EXEMPLO DE COMPONENTES E SEUS RESPECTIVOS EPMD'S.....	59
TABELA 4 – PARÂMETROS DA RNA.....	62
TABELA 5 – PARÂMETROS DA PG .....	63
TABELA 6 – ERRO PERCENTUAL MÉDIO DIÁRIO E DESVIO PADRÃO VERIFICADOS PARA AS COMPONENTES SELECIONADAS NA SEMANA DE VALIDAÇÃO. ....	72
TABELA 7 – ERRO PERCENTUAL MÉDIO DIÁRIO E DESVIO PADRÃO VERIFICADOS PARA AS COMPONENTES UTILIZADAS NA SEMANA DE PREVISÃO. ....	73
TABELA 8 – ERROS PERCENTUAIS DIÁRIOS VERIFICADOS PARA OS DIAS DE PREVISÃO.....	84
TABELA 9 – TABELA DA ANÁLISE DE VARIÂNCIA PARA O DIA 24 (SÁBADO).....	86
TABELA 10 – TABELA DA ANÁLISE DE VARIÂNCIA PARA O DIA 25 (DOMINGO).....	88
TABELA 11 – TABELA DA ANÁLISE DE VARIÂNCIA PARA O DIA 26 (SEGUNDA).....	89
TABELA 12 – TABELA DA ANÁLISE DE VARIÂNCIA PARA O DIA 27 (TERÇA).....	90
TABELA 13 – TABELA DO TESTE DE TUKEY PARA O DIA 27 (TERÇA).....	90
TABELA 14 – TABELA DO TESTE DE SCOTT-KNOTT PARA O DIA 27 (TERÇA).....	91
TABELA 15 – TABELA DA ANÁLISE DE VARIÂNCIA PARA O DIA 28 (QUARTA).....	92
TABELA 16 – TABELA DO TESTE DE TUKEY PARA O DIA 28 (QUARTA).....	92
TABELA 17 – TABELA DA ANÁLISE DE VARIÂNCIA PARA O DIA 29 (QUINTA).....	93
TABELA 18 – TABELA DA ANÁLISE DE VARIÂNCIA PARA O DIA 30 (SEXTA).....	95
TABELA 19 – TABELA DA ANÁLISE DE VARIÂNCIA.....	107



# LISTA DE ABREVIACÕES

BP	BackPropagation
EPMh	Erro Percentual Médio Horário
EPMd	Erro Percentual Médio Diário
MA	Média Arimética
MP	Média Ponderada
MLP	Multi-Layer Perceptron – (Perceptron de Múltiplas Camadas)
PG	Programação Genética
PSO	Otimização por Enxame de Partículas
RLM	Regressão Linear Múltipla
RNA	Redes Neurais Artificiais
SEB	Setor Elétrico Brasileiro
SEP	Sistema Elétrico de Potência
SVM	Support Vector Machines – (Máquinas de Vetores Suporte)
CP	Classificação de Padrões
RNA	Redes Neurais Artificiais
]	



# SUMÁRIO

<b>1 INTRODUÇÃO</b>	<b>25</b>
1.1 JUSTIFICATIVA E MOTIVAÇÃO	26
1.2 PROBLEMATIZAÇÃO	30
1.3 OBJETIVOS	31
1.3.1 Gerais	31
1.3.2 Específicos	31
1.4 ORGANIZAÇÃO DA MONOGRAFIA	31
<b>2 DESCRIÇÃO DO PROBLEMA</b>	<b>33</b>
2.1 CONSIDERAÇÕES INICIAIS	33
2.2 PREVISÃO DE CARGA ELÉTRICA	33
2.2.1 Classificação da Previsão de Carga	36
2.3 MODELOS DE PREVISÃO DE CARGA	37
2.3.1 Redes Neurais Artificiais Multicamadas	38
2.3.2 Programação Genética	39
2.3.3 Regressão Linear	42
2.4 ENSEMBLES	43
2.5 TRABALHOS RELACIONADOS	44
2.6 SUMÁRIO DO CAPÍTULO	49
<b>3 BASE DE DADOS UTILIZADA</b>	<b>51</b>
<b>4 METODOLOGIA</b>	<b>57</b>
4.1 DESCRIÇÃO	57
4.2 IDEIA PRINCIPAL	57
4.3 COMPONENTES INDIVIDUAIS	60
4.3.1 Geração das componentes individuais	61
4.4 ENSEMBLES UTILIZADOS	63
4.5 CONFIGURAÇÃO DAS ENTRADAS E SAÍDAS PARA OS MODELOS INDIVIDUAIS E ENSEMBLES	65
<b>5 RESULTADOS</b>	<b>69</b>
5.1 DESCRIÇÃO	69
5.2 COMPONENTES INDIVIDUAIS	69
5.2.1 Dia 24 – Sábado	74
5.2.2 Dia 25 – Domingo	74
5.2.3 Dia 26 – Segunda	75
5.2.4 Dia 27 – Terça	76
5.2.5 Dia 28 – Quarta	76
5.2.6 Dia 29 – Quinta	77
5.2.7 Dia 30 – Sexta	78
5.2.8 Comentários Adicionais	78
5.3 ENSEMBLES	80
5.3.1 Dia 24 – Sábado	85
5.3.2 Dia 25 – Domingo	87
5.3.3 Dia 26 – Segunda	88

5.3.4 Dia 27 - Terça .....	89
5.3.5 Dia 28 - Quarta.....	91
5.3.6 Dia 29 - Quinta.....	93
5.3.7 Dia 30 - Sexta.....	94
<b>6 CONCLUSÕES.....</b>	<b>97</b>
6.1 SUMÁRIO DA MONOGRAFIA.....	97
6.2 CONCLUSÕES .....	98
<b>7 REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>101</b>
<b>8 APÊNDICES E ANEXOS.....</b>	<b>105</b>
8.1 ANÁLISE DE VARIÂNCIA .....	106
8.2 TESTE DE TUKEY PARA COMPARAÇÃO DAS MÉDIAS .....	108

# 1

## Introdução

*[Este capítulo apresenta, em seu conteúdo, uma introdução ao trabalho proposto, além de dar uma ideia geral do problema em questão e alguns detalhes sobre a organização da monografia.]*

A energia, em suas mais diversas formas, tem uma tendência positiva ao consumo. Com a energia elétrica, o contrário não acontece, pois é considerada um insumo indispensável para o desenvolvimento econômico nas sociedades atuais. “Atualmente a eletricidade corresponde a uma grande parcela do consumo total de energia do Brasil (cerca de 40%) entre todos os componentes energéticos que constituem a matriz energética nacional.” (Salgado, 2009 apud Eletrobrás, 2008).

Para que o fornecimento de energia elétrica aconteça com boa qualidade, de forma segura, econômica e contínua, uma empresa precisa dispor de técnicas que estimem, com a máxima exatidão, o nível de demanda, para que haja um equilíbrio entre a energia gerada e a consumida. “O conhecimento futuro do perfil das cargas elétricas é fator essencial no planejamento e operação dos sistemas elétricos de potência (Altran, Lopes e Minussi, 2005).”

O fornecimento de energia compreende três fases, a saber, geração, transmissão e distribuição. Na fase de geração, existe uma unidade geradora que produz a energia efetivamente. Na fase de transmissão, existem linhas de transmissão que conduzem a energia produzida para uma fonte de distribuição. Por fim, a fase de distribuição, consiste em uma unidade encarregada de fazer com que a energia alcance seus consumidores. Portanto, segundo Salgado (2009), o resultado deste planejamento deve prover uma seqüência de decisões, de forma a diminuir o custo da operação e garantir o atendimento da demanda, para que as fases de geração, transmissão e distribuição operem em harmonia dentro de seus limites operacionais. A Figura 1 ilustra este cenário, classificado como Sistema Elétrico de Potência, identificando as principais fases citadas.

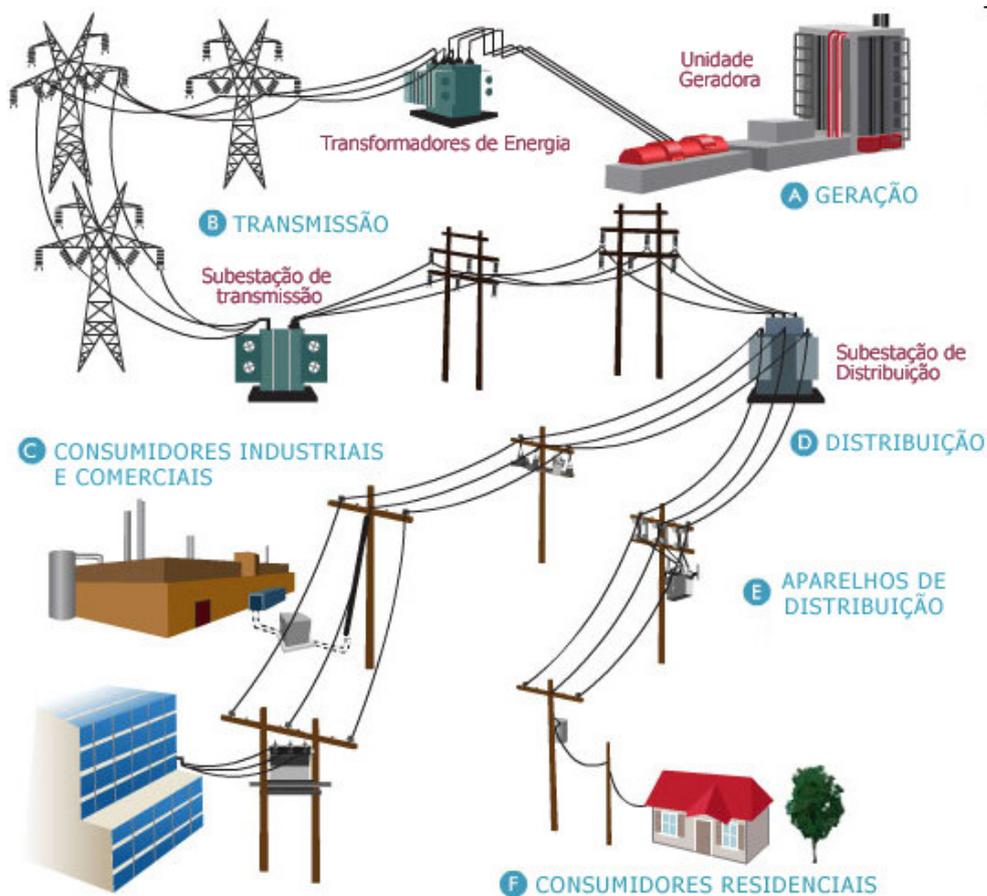


Figura 1 - Sistema Elétrico de Potência (SEP).

## 1.1 Justificativa e Motivação

Considerando as formas de energia existentes na natureza, podemos classificá-las como renováveis e não-renováveis. O homem, ao longo do tempo, tem procurado preservar e otimizar a utilização destas nos mais diferentes cenários, em âmbito mundial. Diante desta ótica, sabe-se que cada tipo de energia tem uma aplicação específica e, dependendo da necessidade, da viabilidade econômica ou da viabilidade ambiental, uma pode ser transformada em outra para suprir a demanda energética. As Figuras 2 e 3 retratam esta ideia de maneira simples, sendo que na primeira são apresentados alguns tipos de energia e na segunda são

ilustradas algumas transformações energéticas, mostrando também alguns setores em que são aplicadas.

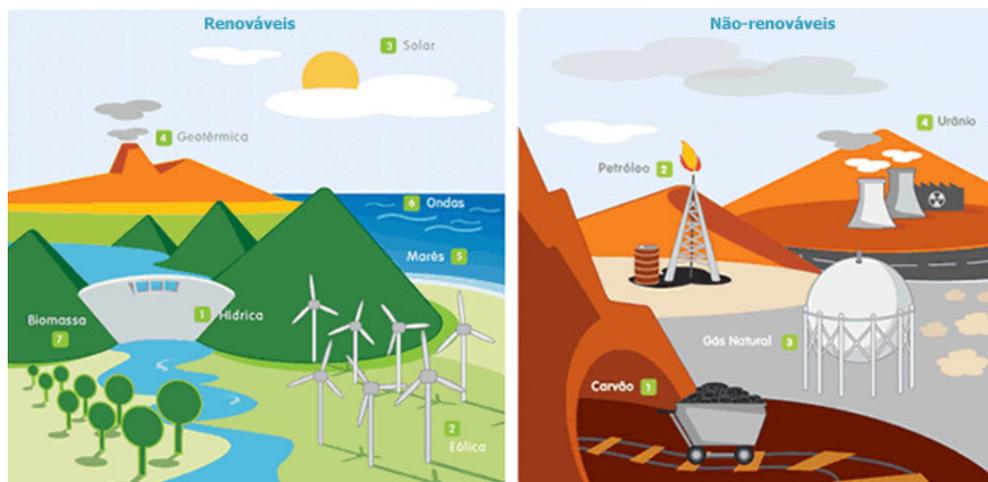


Figura 2 – Algumas formas de energia.

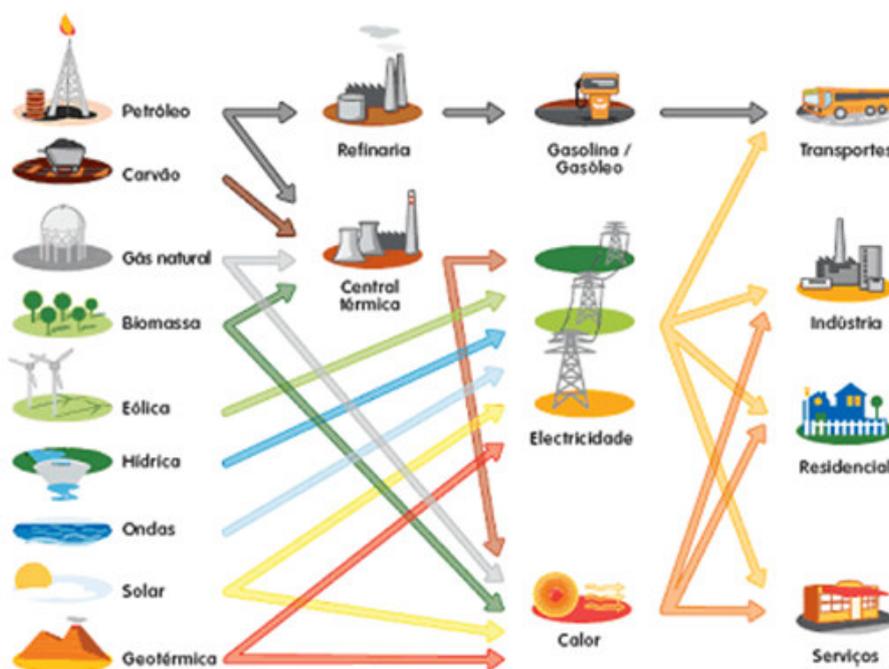


Figura 3 – Algumas transformações energéticas e suas aplicações.

Conforme citado anteriormente, a energia elétrica, por ser um bem necessário ao desenvolvimento econômico de um país, tem sido considerada pelo governo objeto de preservação, cuja meta é fazer com que seu uso se dê de forma otimizada e consciente. Da mesma maneira, existe a preocupação em garantir o

atendimento das reais necessidades da demanda de carga. Para que isto aconteça, é necessário que haja um planejamento que procure reduzir ao máximo as perdas e riscos e aumentar a segurança da energia elétrica gerada. A eficiência deste planejamento, no qual compreende e estão envolvidas as etapas de geração, transmissão e distribuição de energia, reside no fato de encontrar um ponto ideal de operação que irá promover um equilíbrio entre a energia gerada e a energia consumida.

A busca por uma solução para este problema é alvo de estudos. Vale ressaltar que todo este processo envolve uma quantidade considerável de variáveis, exigindo a análise de diversos parâmetros, fator que acaba aumentando a sua complexidade.

Objetivando fazer com que a operação do Setor Elétrico Brasileiro (SEB) aconteça de maneira sincronizada, sem que ocorra um comprometimento do suprimento energético ou da segurança do sistema como um todo, é necessário que este planejamento seja feito em etapas. Estas etapas são estabelecidas de acordo com as tarefas necessárias envolvidas no planejamento de cada fase e a medida principal para classificá-las relaciona-se com o horizonte de planejamento. No caso brasileiro, de acordo com Cicogna (2003), o setor elétrico utiliza-se das seguintes etapas para implementar o planejamento do parque gerador/transmissor de energia elétrica:

- Planejamento da Operação: nesta etapa procura-se definir o comportamento da operação do sistema para um horizonte de até cinco anos à frente. Os recursos devem ser aproveitados de maneira otimizada e racional, visando garantir qualidade, segurança e continuidade no atendimento à demanda.
- Programação da Operação: nesta etapa procura-se conciliar a operação do sistema hidráulico e elétrico em horizontes que vão de alguns dias a algumas semanas à frente. Esta operação é muito próxima com a operação em tempo real, fazendo com que as restrições elétricas sejam representadas na programação da mesma.

Associado à etapa de programação da operação, existe uma relação entre esta e o problema de previsão de carga à curto prazo. Esta forma de previsão se

mostra importante pelo fato de que a demanda futura de carga do mercado energético influencia nas formas de operação de cada unidade que constitui o sistema elétrico. Sabendo que o ideal seria que toda a energia produzida fosse consumida na sua totalidade, sem desperdícios ou escassez, é de fundamental importância que se descubra o comportamento da carga futura com a máxima precisão para que a operação de todo o sistema elétrico aconteça para atender apenas a quantidade demandada.

Quando existe alta taxa de erro nesta previsão, existe a possibilidade de se comprometer o funcionamento do sistema elétrico, uma vez que a operação e o planejamento do mesmo acontecem em função da demanda. A complexidade desta análise aumenta por existir uma série de fatores que estão diretamente relacionados com esta estimativa de previsão, dos quais destacam-se a hora do dia, o dia da semana, a temperatura, a quantidade de incidência de luz, etc.

Todo o sistema elétrico foi projetado para suportar o transporte de uma determinada quantidade de carga. Fica evidente que o conhecimento da carga que o sistema terá que transmitir é essencial para que se possa efetuar um planejamento operacional para que este aconteça de maneira segura, sem causar danos à rede.

O estudo e análise de carga elétrica acabam se tornando uma exigência fundamental durante a operação do sistema como um todo. Especificamente no contexto do planejamento da operação de curto prazo, a previsão da carga é importante na elaboração do programa de operação dos próximos dias, pois erros na previsão da carga podem ter conseqüências sérias em termos de eficiência e segurança do sistema (aumento dos custos, não atendimento da demanda).

Implementar novas técnicas que procurem garantir um fornecimento de energia com qualidade é um dos requisitos que as empresas do setor elétrico têm que executar. Estas devem buscar a resolução de vários problemas relacionados aos processos de operação e controle. A aplicação e o desenvolvimento de novas ferramentas, visando otimizar e conseguir melhorias no planejamento, têm sido alvo de interesse e de pesquisas na área, alcançando bons resultados no processo.

Em concordância com este objetivo, o conhecimento do comportamento da carga futura é o primeiro pré-requisito para um planejamento seguro e econômico do sistema de energia elétrica. Aumentar a segurança e a economia da operação de

sistemas são as motivações para a realização de previsões de cargas mais confiáveis nos sistemas elétricos de potência (Leone Filho, 2006).

Tendo em vista estas considerações, percebe-se que, um desequilíbrio, tanto da energia gerada em excesso quanto da energia gerada em quantidade menor que o necessário, pode causar problemas de sobre-tensão ou sub-tensão no sistema. Existem duas soluções possíveis para tentar amenizar este problema ou tentar promover um equilíbrio entre a escassez e o excesso de energia, das quais podemos destacar: a reprogramação das geradoras ou a transferência de energia através dos intercâmbios entre os sistemas. Entretanto, estas atividades demandam certo intervalo de tempo para serem efetivadas e daí surge a motivação de se realizar uma boa previsão (Salgado e Pereira, 2006).

O consumo diário com discretização horária pode ser representado através de uma série temporal, por exemplo, e, através de modelos de previsão de carga, pode-se estimar a carga futura. Neste sentido, a motivação deste projeto foi desenvolver metodologias que possibilitem estabelecer a previsão de carga elétrica à curto prazo buscando alcançar a máxima precisão nos resultados. ]

## 1.2 Problematização

[Promover um equilíbrio entre a energia gerada e a consumida, de forma segura e eficiente, é um grande desafio das empresas de distribuição de energia elétrica.

Portanto, a indagação a ser feita, visando alcançar um bom funcionamento de todo o sistema elétrico, é: Como estimar o consumo futuro de energia elétrica, de forma aproximada e eficaz, garantindo as reais necessidades da demanda? ]

## 1.3 Objetivos

### 1.3.1 Gerais

[Desenvolver uma metodologia capaz de realizar a previsão de séries temporais de carga elétrica, objetivando alcançar resultados mais acurados no processo. ]

### 1.3.2 Específicos

- [Realizar pesquisa bibliográfica.
- Implementar previsores individuais.
- Propor formas de combinar previsores.
- Escrever monografia.
- Publicar resultados em congressos e eventos da área.]

## 1.4 Organização da Monografia

[No Capítulo [2](#) é apresentada uma descrição mais detalhada do problema levantado neste trabalho e, além disso, são discutidos os modelos utilizados para a previsão de carga elétrica à curto prazo. Alguns trabalhos relacionados são apresentados, os quais focam, em sua maioria, na utilização de *ensembles* para a obtenção de melhorias nos resultados de previsão de carga.

No Capítulo [3](#) é apresentada a base de dados utilizada na realização dos experimentos deste trabalho, cujos dados de consumo de carga foram obtidos de uma empresa elétrica do Brasil, com discretização horária.

O Capítulo [4](#) aborda a metodologia empregada, iniciando com uma breve descrição do objetivo deste trabalho, destacando a ideia principal. Em seguida, são discutidas as componentes de previsão, individuais e *ensembles*, além de apresentar as entradas e saídas para treinamento dos modelos.

O Capítulo [5](#) traz, em sua extensão, uma descrição do comportamento dos *ensembles* para a previsão, utilizando a base de dados deste trabalho, fazendo uma breve análise dos erros cometidos pelos componentes envolvidos que participaram deste processo. É feita uma análise gráfica para alguns dos dias de previsão, exibindo as curvas de carga real e prevista.

O Capítulo [6](#) apresenta as conclusões que foram identificadas no desenvolvimento do processo de previsão, além de uma descrição sucinta do mesmo.

# 2

## Descrição do Problema

*Este capítulo apresenta, na Seção 2.2 a importância de se realizar a previsão de carga elétrica em sistemas de potência. A Seção 2.3 dá um entendimento geral sobre séries temporais. A Seção 2.4 aborda os modelos de previsão utilizados neste trabalho, dos quais citam-se as Redes Neurais Artificiais Multicamadas, a Programação Genética e a Regressão Linear Múltipla.*

### 2.1 Considerações Iniciais

Neste capítulo é possível ter um entendimento mais abrangente do problema da previsão de carga elétrica, dos fatores que influenciam a demanda, dos tipos de previsão, dos modelos de previsão e da importância de se efetuar uma estimativa em que a proximidade do resultado obtido com a carga real seja a maior possível, com a finalidade de se obter melhorias na programação e no planejamento operacional das empresas concessionárias responsáveis pela distribuição de energia elétrica. É discutida, de forma sucinta na Seção 2.5, a combinação de previsores, denominada *ensembles*.

### 2.2 Previsão de Carga Elétrica

Conforme discutido e comentado no capítulo anterior, em um sistema de potência, a energia gerada deve ser exatamente aquela demandada pelos consumidores, ou seja, o sistema deve produzir exatamente a mesma energia requerida pelos consumidores que estão ligados a ele a cada instante de tempo, continuamente, pois a energia excedente pode causar sobre-tensão, uma vez que não é possível armazená-la, e energia em escassez pode causar sub-tensão no sistema ou até mesmo a falta dela.

A preocupação com o problema de estimação da carga num dado instante vem do fato de a previsão ser fundamental para o planejamento e operação dos sistemas elétricos. As contribuições desta para o mesmo conferem um melhor gerenciamento da análise de segurança, da produção de energia, do controle e operação do sistema, dentre outras.

Observando o mercado de energia, que passou a ser regulado e fiscalizado por entidades do governo, a energia elétrica se comporta neste cenário como uma mercadoria, gerando certo nível de concorrência entre aqueles que atuam no setor. Neste sentido, é necessário que se tenha um controle maior nas transições de compra e venda de energia, evitando penalidades contratuais (Vehviläinen e Keppo, 2003).

Para que a empresa atue de maneira eficiente (fornecendo energia de maneira segura e econômica) ela precisa utilizar-se de ferramentas que proporcionem um bom planejamento, evitando a ocorrência de vários problemas técnicos e operacionais. Para que o planejamento do sistema seja eficaz, deve haver um monitoramento completo do mesmo, desde a geração da energia até a entrega ao consumidor final. Desta forma, o acompanhamento de carga é fundamental para um fornecimento de qualidade.

Visando alcançar melhorias neste contexto, novas ferramentas de otimização e controle são estudadas, desenvolvidas e aplicadas, fornecendo resultados que proporcionam redução de determinados custos relacionados. Uma das técnicas mais utilizadas é a Análise e Previsão de Séries Temporais. Esta técnica visa obter valores futuros de séries de vazões, consumo, demanda, entre outros, através de um histórico prévio destas séries. Uma descrição mais detalhada sobre séries temporais é relatada na seção 2.3.

Trazendo estas ferramentas para a realidade do problema deste trabalho, uma série de carga elétrica pode ser entendida como uma série temporal contendo as medições do consumo de carga em determinados intervalos de observância. As medições que compõem esta série de carga elétrica podem ser realizadas com vários intervalos, variando de acordo com o tipo de operação.

Em nosso país, o sistema elétrico geralmente fornece energia elétrica para vários tipos de clientes e consumidores. Tais clientes podem ser classificadas como residenciais, comerciais e industriais. Dentre as características que se pode observar

nestas classes, pode-se citar que algumas delas estão associadas às condições meteorológicas, às mudanças econômicas, às mudanças tarifárias, à sazonalidade, entre outras. De uma maneira geral, os consumidores da classe industrial são os que apresentam o menor índice de variabilidade no consumo, apresentando curvas de consumo de carga suaves e constantes.

Estas séries apresentam comportamentos que podem ser estatisticamente previstos. Desta forma é possível conhecer a forma como os clientes utilizam a energia e caracterizar o perfil de consumo, independente do seu enquadramento quanto ao tipo, nas áreas comercial, residencial ou industrial. De um modo geral, a carga sofre influências de muitos fatores como: eventos televisivos, econômicos, climáticos, dentre outros, ou seja, pode variar com o tempo.

Diversos fatores são responsáveis por influenciar o consumo elétrico. Esta oscilação do consumo, sendo para mais ou para menos, está associada às variações de alguns parâmetros que provocam alterações no costume e comportamento dos clientes. Os mais relevantes destes fatores podem ser enumerados e discutidos.

No caso de fatores climáticos, percebe-se que estes mudam o comportamento de consumo dos clientes ao longo de um curto período de tempo. Temperatura, intensidade do vento, neblina, neve, umidade do ar, chuvas, dentre outros, são exemplos de indicadores que podem se fazer participantes dos principais eventos climáticos. De acordo com Salgado (2009), dos fatores climáticos citados, o que tem maior impacto no consumo de carga é a temperatura.

Já no caso de fatores econômicos e demográficos, pode-se observar a influência destes ao longo de diversos anos. A variação da economia proporciona melhores ou piores condições para que o consumidor adquira ou deixe de adquirir aparelhos eletroeletrônicos ou que façam uso de eletricidade, por exemplo. Já no caso do fator demográfico, por exemplo, existe o aparecimento ou formação de centros urbanos e novas indústrias, demandando desta maneira mais energia para auxiliar o crescimento no geral.

Outro fator que também merece destaque é o de calendário, em que estão associados eventos que acontecem em determinadas datas comemorativas. Estes eventos tendem a provocar alterações no perfil da curva de consumo de carga.

Existem muitos outros fatores que também influenciam o consumo e não serão discutidos neste trabalho, mas pelos já citados é possível perceber que ainda podem existir diversas combinações de acontecimentos entre eles, provocando, ainda mais, um aumento na complexidade de análise da demanda futura.

## 2.2.1 Classificação da Previsão de Carga

A previsão de carga pode ser classificada em previsão a curto, médio e longo prazo. Existem algumas pequenas variações na literatura quanto à definição dessas classificações. De uma forma geral, elas podem ser entendidas da seguinte maneira:

- Previsão de curto prazo: Tipo de previsão muito importante para elaboração do programa operacional dos próximos dias. Geralmente esta classificação assume horizontes de alguns minutos ou horas até alguns dias à frente. Isto faz com que a operação se torne mais segura, além de otimizar os recursos de produção, diminuindo seus custos.
- Previsão de médio prazo: Neste processo, a importância de se realizá-la está relacionada com uma melhor programação do suprimento de combustível, operações de manutenção e de planejamento de intercâmbio. Os horizontes de previsão variam de alguns meses até um ano à frente. Esta previsão se mostra interessante para orientar a otimização dos recursos disponíveis, ajudando a definir as produções das hidrelétricas e termoeletricas.
- Previsão de longo prazo: Este tipo de previsão tem uma função diferenciada em relação aos demais tipos apresentados. Os horizontes vão desde alguns anos até alcançar em torno de dez anos à frente. Os resultados deste processo servem de base para orientar os investimentos no setor elétrico e as tomadas de decisões comerciais, além de que, no contexto da distribuição de energia, a previsão de longo prazo é essencial para auxiliar as decisões de compra ou venda de energia elétrica, uma vez que são tomadas, na maioria dos casos, com cinco anos de antecedência.

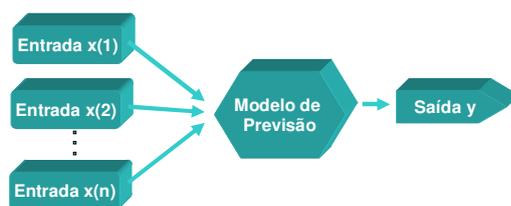
Neste trabalho o foco será dado à previsão de carga elétrica à curto prazo, sendo que a predição é realizada hora a hora, objetivando estimar o consumo do dia seguinte, mediante análise do histórico de medição.

## 2.3 Modelos de Previsão de Carga

Avaliando o problema de previsão de carga elétrica, pode-se classificá-lo como um problema de previsão de séries temporais. Neste processo, o histórico de dados de consumo de carga é utilizado para compor e representar as séries em questão.

É essencial encontrar um modelo que possa representar o comportamento da série da forma mais precisa possível ao longo do período de medição. A Figura 4 retrata o esquema clássico de um modelo de previsão de séries temporais, com várias entradas em instantes anteriores e uma saída que representa a previsão de carga no instante  $t$ .

Por possuir comportamento não-linear, o comportamento da série fica difícil de ser avaliado e previsto. A solução da previsão de séries temporais de carga elétrica não é tão simples, pelo fato de existirem diversos fatores relacionados, principalmente pelo comportamento da mesma apresentar característica não-linear, o que dificulta a previsão. A complexidade do problema pode variar de acordo com o período e número de séries a serem previstas.



**Figura 4 - Modelo de previsão simplificado**

Nas subseções seguintes são apresentados os modelos de previsão que foram utilizados neste trabalho, a saber Redes Neurais Artificiais, Programação Genética, Regressão Linear Múltipla e a técnica denominada *ensemble*.

### 2.3.1 Redes Neurais Artificiais Multicamadas

As redes neurais artificiais são inspiradas nos modelos biológicos, procurando compreender e representar o comportamento do cérebro humano, uma vez que a interação entre os neurônios produz resultados inteligentes. Tendo em vista esta informação, vale ressaltar que as redes neurais artificiais são capazes de aprender e generalizar com a experiência de dados passados.

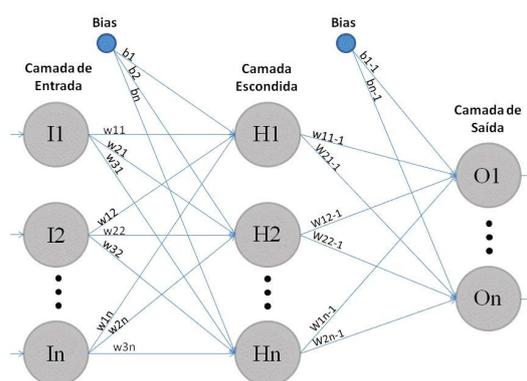
As arquiteturas do tipo multicamadas (MLP) constituem os modelos neurais artificiais mais utilizados e conhecidos atualmente. Tipicamente, esta estrutura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída, adquirindo conhecimento através de um aprendizado supervisionado. Os sinais de entrada são propagados camada a camada pela rede.

Um método amplamente utilizado para ajuste dos parâmetros é o algoritmo de retropropagação do erro (*BackPropagation*). Segundo Haykin (1994), este algoritmo se baseia na regra de aprendizagem por correção de erro. O funcionamento deste segue os seguintes princípios: primeiro, ocorre a propagação do estímulo em direção a saída da rede, provocado por um vetor de entrada; logo após, ocorre a retropropagação do erro cometido pela rede na ordem inversa, da camada de saída em direção a primeira camada da rede. Os valores dos pesos sinápticos somente são alterados durante a fase de retropropagação, com o objetivo de aproximar a resposta obtida para a resposta desejada para uma determinada entrada.

O método do gradiente de ajuste de pesos é o mais utilizado, pois apresenta facilidades de implementação e realiza busca local com base no gradiente descendente no espaço de variáveis. Porém, por ser um método que trabalha com informações de primeira ordem, sua convergência é lenta. Os métodos de segunda ordem, em geral, apresentam maior velocidade de convergência no ajuste de parâmetros.

A Figura 5 retrata um modelo neural MLP, em que  $I_j$  representa os neurônios da camada de entrada, sendo “j” um número inteiro variando de 1 a n, considerando n o total de neurônios na camada de entrada.  $H_k$  os neurônios da camada escondida, sendo k um número inteiro variando de 1 ao total de neurônios

da camada escondida e  $O_m$  os neurônios da camada de saída, tomando  $m$  variando de 1 a quantidade total de neurônios da camada de saída. A conexão entre os neurônios deste modelo matemático se dá através de um ajuste de pesos, os quais representam o conhecimento adquirido pela rede. Estes pesos são indicados na figura através do símbolo “ $w$ ”. Outro componente que merece destaque neste modelo é o peso bias, representado pelo símbolo “ $b$ ”, o qual é responsável por controlar a entrada dos valores na função de ativação do neurônio artificial.



**Figura 5 – Modelo Rede Neural MLP.** fonte: (Silveira et al, 2010)

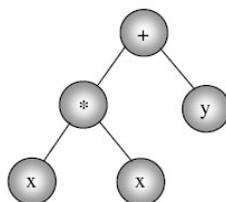
Uma das primeiras utilizações de RNAs em previsão de carga foi feita por (Park et al., 1991) onde foi utilizada uma MLP tendo como entrada da RNA dados climáticos (temperatura). Park propôs uma RNA para aprender a relação entre as temperaturas e a carga. Para calcular a carga prevista, a RNA interpola os dados carga-temperatura num conjunto de treinamento. Para isto o problema de previsão foi subdividido em três sub-problemas, isto é, foram desenvolvidas três redes neurais especializadas, uma para prever o pico de carga, uma para prever total de carga do dia e outra para o perfil horário da carga durante o dia, para horizontes de 24 horas à frente.

### 2.3.2 Programação Genética

A programação genética foi desenvolvida inspirada no processo biológico de evolução e seleção natural das espécies. Este processo biológico foi proposto por Charles Darwin (Darwin, 2000). O princípio desta teoria relata que os indivíduos que possuem maior capacidade de adaptação ao meio ambiente têm maiores chances de sobreviver. Desta forma, as características genéticas são transferidas

para as próximas gerações, sofrendo mudanças que irão contribuir para a preservação daquela espécie. Desta forma, os indivíduos que irão compor a nova geração possuirão características genéticas melhores que os da geração anterior.

Na programação genética, cada indivíduo é considerado um programa computacional e a população (ou espaço de busca) são todos os possíveis programas de computador. Cada programa é representado por expressões matemáticas compostas de funções e terminais e codificados através de estrutura de árvores (Figura 6), ao invés de linhas de código.



**Figura 6 - Programa  $x^2+y$  (forma pré-fixada) representado na estrutura de árvore.**

As funções geralmente são operadores aritméticos (+, -, \*, %, etc), funções matemáticas (sen, cos, tan, etc), operadores booleanos (and, or, not), operadores condicionais (se, então, senão), dentre outros, e são representados pelos vértices internos da árvore, possuindo aridade dois. Os terminais podem ser variáveis ou constantes e aparecem nos vértices externos da árvore, ou seja, nas folhas.

O funcionamento do algoritmo se dá de forma que, inicialmente é criada uma população aleatória de programas, ou seja, funções são escolhidas aleatoriamente no conjunto de funções, e terminais são escolhidos aleatoriamente no conjunto de terminais. Esta população deverá ter uma diversidade suficiente para tentar garantir que se encontre nos indivíduos todas as características que sejam necessárias para solucionar o problema, pois as características não existentes na população inicial dificilmente aparecem durante o processo evolutivo (Souza, 2006).

Em um segundo momento, os programas devem ser avaliados no que se refere em quão bem ele realiza ou executa sua tarefa em um ambiente específico de um determinado problema. Existe uma função, denominada função de aptidão (ou *fitness*), que é responsável por avaliar o quão bem cada programa desempenha sua tarefa. Quando esta função é bem definida, as chances de que o algoritmo apresente uma solução muito próxima da solução ótima aumentam (Souza, 2006).

Para facilitar o entendimento, pode-se citar a verificação do erro produzido pela execução de um programa. Quanto mais próximo o erro for de zero, melhor é o programa, por exemplo.

Num próximo passo, são selecionados os indivíduos que obtiveram os melhores valores, oriundos da avaliação feita pela função de aptidão. Este processo é denominado seleção.

Em seguida, são aplicados os operadores genéticos aos indivíduos selecionados, objetivando gerar uma nova população. Os operadores mais utilizados são:

- Reprodução, que preserva o indivíduo, copiando-o para a próxima geração sem nenhuma alteração.
- Cruzamento, que a partir do cruzamento de dois indivíduos escolhidos através do valor de sua função de aptidão, é gerado um novo indivíduo. Acredita-se que o operador de cruzamento visa guiar a solução através da combinação das melhores soluções na busca pela solução ótima.
- Mutação, que efetua as modificações em apenas um indivíduo, através da substituição e nenhum indivíduo novo é criado.

A população inicial é então substituída pela nova população e é verificado se o critério de parada foi alcançado. Caso isso não ocorra, o algoritmo retorna ao segundo passo e repete os procedimentos descritos anteriormente até que a condição de parada seja satisfeita. A Figura 7 esquematiza o funcionamento da programação genética, facilitando o entendimento.

Maiores informações sobre a programação genética podem ser encontradas nos trabalhos de Koza (1992), Banzhaf (1998), Chellapilla (1997) e outros.

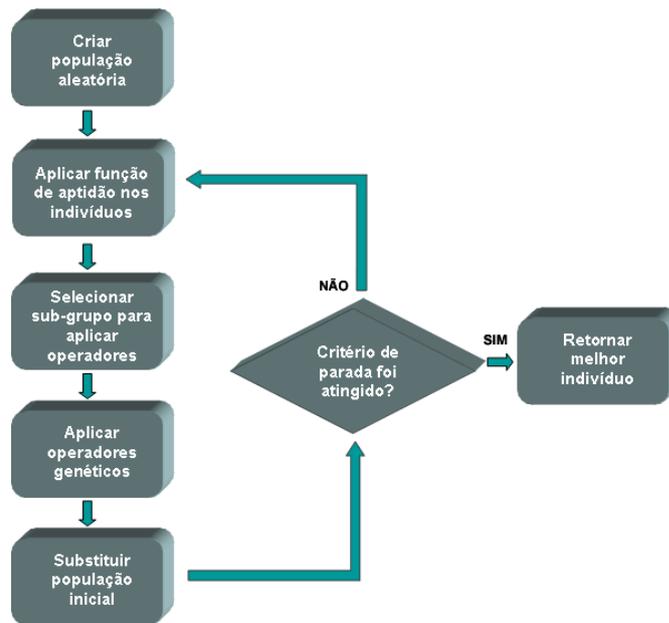


Figura 7 - Esquema de funcionamento da programação genética.

### 2.3.3 Regressão Linear

A Regressão Linear é uma técnica de modelagem supervisionada para analisar a relação entre uma variável contínua dependente  $y$  (valor real) e uma ou mais variáveis independentes  $\{x_1, x_2, \dots, x_n\}$ . O objetivo da análise de regressão é identificar uma função que descreve, da melhor maneira possível, a relação entre essas variáveis para que os valores das variáveis dependentes possam ser previstos, ou obtidos, através dos valores das variáveis independentes. A fórmula (14) expressa o modelo:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n + \varepsilon \quad (1)$$

Em que  $y$  é a variável dependente,  $x_i$  são as variáveis independentes,  $\beta_i$  são os parâmetros da regressão com seus respectivos  $x_i$  e  $\varepsilon$  é o valor do erro.

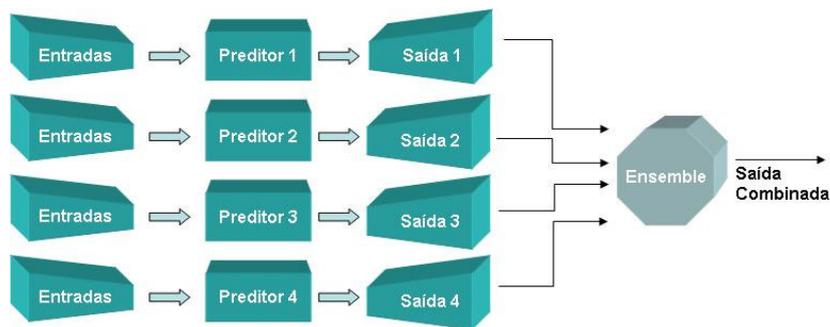
## 2.4 Ensembles

A palavra *ensembles* origina-se do inglês e significa “agrupamentos”. Esta técnica originou-se do trabalho de Hansen e Salamon (1990), que demonstrou que a habilidade de generalização pode ser significativamente melhorada por meio da composição de várias redes neurais artificiais, ou seja, a partir do treinamento independente de várias destas e posterior composição das saídas individuais. Ela consiste na combinação dos resultados de vários previsores (ou componentes) distintos para a obtenção de uma saída que seja melhor (ou mais estável) que as obtidas pelos componentes individuais.

De uma forma geral, o *ensemble* é construído em duas etapas. Na primeira, os previsores que compõem o *ensemble* são executados e, na segunda etapa, os resultados alcançados por cada componente é combinado de alguma maneira.

Neste sentido, segundo Leone Filho (2006), a utilização de múltiplos previsores tenta explorar o bom comportamento local de cada um dos previsores e, com isto, aumenta a precisão e a confiabilidade da previsão, uma vez que se um dos previsores errar muito em determinado subconjunto de dados de entrada, os outros previsores tendem a compensar o erro deste.

Para exemplificar, a Figura 8 apresenta um *ensemble* que combina as saídas de 4 previsores distintos. Algumas das principais motivações para se utilizar o *ensemble* se resumem em alguns pontos, tais como a grande ou pequena quantidade do volume de dados, a qual poderia não ser modelada de forma eficiente por apenas um único componente de previsão. A complexidade do problema, também pode interferir, pois pode ser difícil de ser tratada por apenas uma componente. Cita-se também uma diminuição do custo computacional em razão de se utilizar vários modelos simples ao invés de um único maior e com mais parâmetros a serem ajustados.



**Figura 8 - Estrutura de um *ensemble***

Apesar da falta de uma teoria de *ensemble* unificada, há muitas razões teóricas para combinar múltiplos componentes que irão compor o *ensemble*, e alguma evidência empírica da eficiência desta abordagem. Contudo, não há garantia de que, para qualquer aplicação, o *ensemble* irá de fato melhorar o desempenho da classificação se comparado com o melhor componente individual, mas existem algumas condições que devem ser seguidas para que o *ensemble* apresente bom resultado:

- As taxas de erro dos componentes devem ser baixas e menores que 50%;
- O número de componentes gerados deve ser grande;
- O índice de decorrelação entre os classificadores deve ser alto;

As condições acima nunca poderão ser totalmente atendidas, pois quanto maior o número de componentes menor será a decorrelação média entre eles, visto que todos apresentam probabilidade de erro de previsão inferior a 50%. Geralmente os componentes que compõe a saída final são selecionados dentre os que apresentam melhor desempenho e maior decorrelação.

## 2.5 Trabalhos relacionados

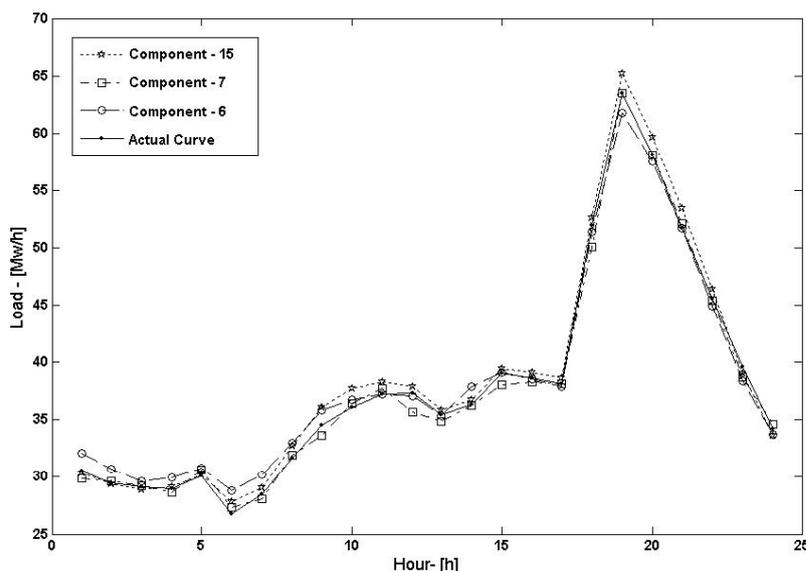
Como já dito anteriormente, a previsão de carga se mostra importante para um bom planejamento do sistema elétrico. Para isto, na literatura existem diversas técnicas sendo estudadas e desenvolvidas visando descobrir um modelo que

atenda a grande maioria dos casos para a solução deste problema. Dentre essas técnicas, existem métodos lineares e não-lineares.

A partir do trabalho de Salgado et al. (2006), é proposta uma metodologia de previsão de carga através da combinação dos resultados dos modelos de Redes Neurais Artificiais (RNA) e Máquinas de Vetores Suporte (SVM). Neste trabalho, é identificado um erro cometido pelo *ensemble* 25% menor do que o melhor resultado obtido pela melhor componente de previsão de forma individual.

O modelo foi inicializado várias vezes para confirmar que os perfis dos conjuntos de preditores tendem a produzir baixa variância. Para a construção do modelo de *ensemble*, foram utilizadas várias componentes de RNA's e SVM's, obtidas através da variação dos parâmetros de configuração dos mesmos, de forma aleatória. Este *ensemble* ficou dividido em três etapas: a geração e o treinamento das componentes, a validação e a seleção e, por último, a previsão e a combinação.

Considerando ainda o trabalho de Salgado et al. (2006), os dados utilizados para a realização dos experimentos deste processo foram obtidos da região nordeste do sistema elétrico brasileiro, compreendendo o período de 01/06/2001 a 25/09/2001 para validação e testes, e o dia 03/10/2001 para a previsão. É possível observar, a partir da Figura 9, as curvas de previsão do trabalho de Salgado et al. (2006), realizadas pelas melhores componentes que irão compor o *ensemble* e a curva real de carga medida para aquele dia.

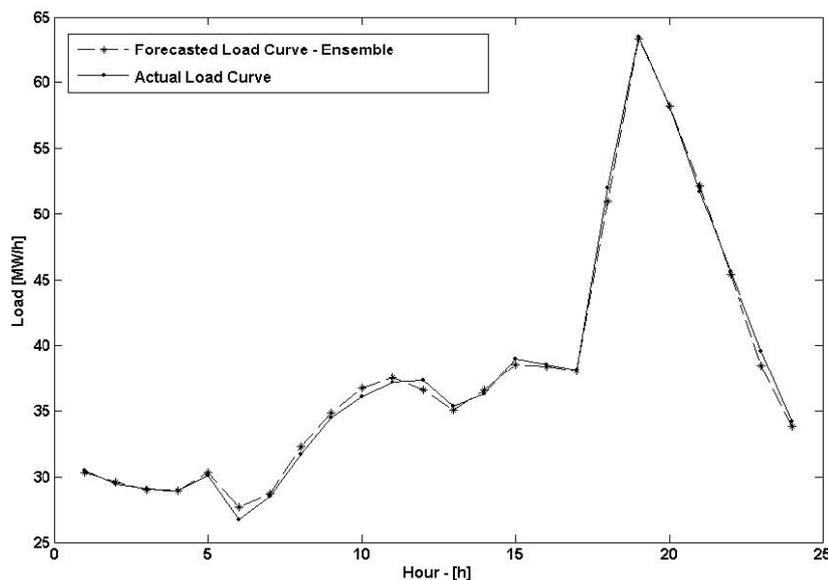


**Figura 9 – Melhores componentes selecionadas.** Fonte: (Salgado et al. 2006)

Já, na Figura 10 é possível observar a curva de carga resultante da combinação das componentes ilustradas na Figura 9 e a curva de carga real. Fica evidente que o combinador é capaz de extrair as características das componentes selecionadas e fazer com que a curva gerada pelo *ensemble* seja mais próxima da curva de demanda real.

Outro trabalho aborda a utilização dos *ensembles* para previsão de carga elétrica a curto prazo é o de Leone Filho (2006), em que são utilizados como componentes de previsão as Redes Neurais Artificiais e as Redes Neurais Nebulosas. Foi observado que este modelo foi capaz de alcançar uma grande robustez na previsão. A evolução dos parâmetros dos diferentes modelos de rede, no trabalho de Leone Filho (2006), é realizada através de uma evolução com Algoritmos Genéticos.

Tendo em vista ainda o trabalho de Leone Filho (2006), foram utilizados dados de carga obtidos de uma companhia energética de São Paulo, utilizando um histórico que compreende o período de 19 de janeiro de 1998 a 19 de dezembro de 1999, totalizando 100 semanas, com base de medição horária. Neste processo, cada modelo individual seria treinado para cada dia da semana.



**Figura 10 – Curva Real x Curva Obtida pelo *Ensemble*.** Fonte: (Salgado et al. 2006)

Uma aplicação interessante do *ensemble* acontece no trabalho de Siwek e Osowski (2007), em que são utilizadas como componentes individuais de previsão

as redes neurais MLP, as máquinas de vetores suporte, as redes de Elman e as redes de Kohonen, objetivando estimar a carga futura de 24 horas à frente. Siwek e Osowski (2007) utilizam uma forma de combinar os resultados denominada BSS (*Blind Source Separation*), em que é feita uma análise das séries temporais previstas pelas componentes, realizando uma separação daquelas que apresentam ruído e fazendo com que participem da reconstrução do resultado final apenas aquelas mais significantes, levando a resultados mais acurados de previsão. Para o trabalho de Siwek e Osowski (2007) foram utilizados dados de carga medidos no sistema elétrico polonês.

Analisando o trabalho de Drezga e Rahman (1999), é apresentado a utilização de duas redes neurais idênticas para realizar a previsão horária de carga elétrica. Os resultados oriundos das redes são combinados através da média entre eles e são utilizados para realimentar as previsões subsequentes.

Outro trabalho que propõe a utilização do *ensemble* para melhorar os resultados de previsão é o de Li et al (2009), em que são utilizadas combinações de redes neurais através de um algoritmo evolucionário discreto. Neste processo, um método de entropia é utilizado para determinar os coeficientes de treinamento da rede ao longo da execução, de acordo com a variação dos erros das seqüências de previsões que estão sendo realizadas. Os experimentos observados demonstraram que a abordagem proposta oferece resultados promissores, além de conferir uma maior precisão e estabilidade. Neste trabalho, é usado um conjunto  $S = \{f_1, f_2, \dots, f_n\}$  de redes neurais treinadas independentemente, cujo objetivo é encontrar um subconjunto de  $S$  que possa fazer a integração com a melhor performance geral. No algoritmo evolucionário discreto, a operação de seleção é realizada por uma função de *fitness*. Maiores detalhes sobre esta abordagem e metodologia podem ser encontrados no trabalho de Li et al (2009).

Merece destaque também o trabalho de Villanueva (2006), onde são aplicados comitês de máquinas para previsão de séries temporais de carga elétrica, visando aumentar ganhos em desempenho durante o processo. A ideia desta proposta consiste basicamente em duas vertentes: a primeira é a de dividir para conquistar, em que é feita a divisão das tarefas entre componentes especializadas e o processo de junção dos resultados é realizado pelo algoritmo de aprendizagem; a

segunda consiste em resolver todo o problema por cada componente envolvida e, em seguida, combinar as repostas obtidas pelas mesmas pelo *ensemble*.

No trabalho de Sapeluk et al. (1994) é proposto uma previsão de carga hora a hora via rede neural artificial, em que é feita uma combinação das camadas escondidas do modelo de rede e cada de grupo de camada é treinada separadamente. É mostrado neste trabalho que existe uma eficiência ao se utilizar uma rede neural artificial e que o modelo deve ser treinado periodicamente, utilizando dados mais recentes, visando alcançar uma maior performance na previsão e resultados mais precisos ao término da execução da mesma.

Existem também outros trabalhos que se utilizam de outras técnicas para a previsão de carga. Dentre muitos destes, citam-se aqueles em que são empregadas formas diferenciadas de se treinar uma RNA para previsão de carga. Estas formas constituem-se em uma análise comparativa dos algoritmos *BackPropagation* (BP) e Otimização por Enxame de Partículas (PSO) para a regulagem dos pesos sinápticos de uma rede neural do tipo MLP. Estes ajustes de pesos, quando bem efetuados, proporcionam à rede obter resultados mais acurados de previsão.

No trabalho de Sun et al (2006), são elencados os principais problemas ao utilizar o BP para o treinamento de uma RNA em problemas de previsão de carga à curto prazo, dos quais citam-se a baixa velocidade de convergência e a estagnação em mínimos locais. Visando diminuir estes problemas, é sugerida a aplicação do algoritmo da PSO para o treinamento desta rede, conseguindo resultados bastante satisfatórios na comparação entre os dois métodos, mesmo a PSO sendo uma técnica de busca global sem qualquer mecanismo de busca local.

Procurando conciliar os dois algoritmos, o trabalho de Caiqing et al (2008) apresenta a PSO apenas para otimização dos parâmetros iniciais do BP, sendo este último responsável por realizar a previsão de carga à curto prazo efetivamente. No trabalho proposto por Caiqing et al (2008), acredita-se que o algoritmo híbrido é eficiente e possui velocidade de convergência satisfatória, alcançando maior precisão nos resultados.

Analisando o trabalho de Sun & Zou (2007), nota-se que a capacidade de otimização global da PSO é maior em relação à capacidade do BP. De acordo com os resultados experimentais obtidos neste trabalho, observa-se que a PSO acelera a

velocidade de aprendizagem da rede e melhora a precisão dos valores previstos se comparado ao método convencional BP.

No trabalho de Bashir & El-Hawary (2007) também é feita uma análise comparativa entre os algoritmos PSO e BP. Neste é apresentada utilização do algoritmo da PSO como vantajosa no treinamento e ajuste de pesos da rede neural para previsão de carga elétrica. Observa-se que a PSO é mencionada como de fácil implementação e baixo custo computacional, obtendo resultados mais precisos em relação ao algoritmo de treinamento convencional, o BP.

Outro trabalho que foca na utilização da PSO como algoritmo efetivo para o treinamento de uma RNA é o de Grimaldi et al (2004). Neste trabalho são apresentadas as vantagens e desvantagens da utilização da PSO quando aplicada como o algoritmo de treinamento da rede para aplicações que envolvem problemas eletromagnéticos, como o problema de previsão de cargas. Assim, para a verificação do desempenho obtido, uma comparação mais acurada é feita, na qual a comparação entre os testes foi realizada utilizando também Algoritmos Genéticos e o clássico BP para o treinamento da rede.

No trabalho de Bashir & El-Hawary (2009), a técnica da PSO também é usada para o treinamento da RNA que é aplicada ao problema de previsão de cargas à curto prazo. Um diferencial observado durante o trabalho de [17] é que os dados para treinamento sofrem um pré-processamento utilizando a transformada *wavelet*, extraíndo possíveis informações redundantes do conjunto de treinamento, para serem inseridas na rede neural, combinando com dados do tempo (temperatura, umidade etc), tornando a previsão mais precisa. Nos resultados dos testes, foi realizada a comparação da PSO com o algoritmo BP, evidenciando a alta precisão de previsão conseguida pela técnica da PSO.

## 2.6 Sumário do Capítulo

Neste capítulo foi discutida a importância de se realizar uma previsão de carga elétrica com a máxima exatidão, bem como algumas técnicas de se estimar esta demanda. Além disso, foram apresentados alguns trabalhos relacionados com a

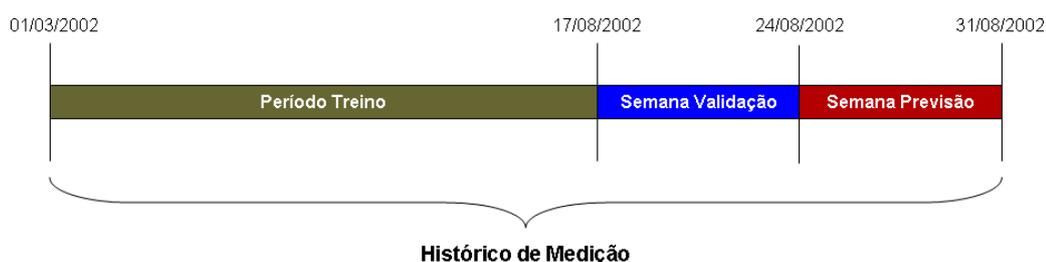
previsão de carga. No decorrer deste trabalho serão discutidas e apresentadas as formas e aplicações destas técnicas na base de dados considerada.

# 3

## Base de Dados Utilizada

*Este capítulo apresenta os dados utilizados para a realização dos experimentos deste trabalho. Esta base de dados foi obtida a partir da medição do consumo de carga adquirido de uma empresa elétrica do Brasil.*

O período do histórico de medição, utilizado na realização dos experimentos deste trabalho, compreende o intervalo que abrange as datas de 01/03/2002 a 30/08/2002, adquiridos de uma empresa elétrica do Brasil. Foram reservados para treinamento dos modelos os dados de carga dos dias anteceder o dia 17/08/2002. Para a validação dos mesmos, foi considerada a semana cujo intervalo está definido entre os dias 17/08/2002 (sábado) e 23/08/2002 (sexta-feira). Esta semana será considerada, ou mencionada, neste trabalho como semana de validação ou período de validação. O objetivo é efetuar a previsão de carga para o intervalo de 24/08/2002 (sábado) a 30/08/2002 (sexta-feira) e realizar uma análise comparativa dos resultados obtidos pelos componentes envolvidos nesta previsão. Este último período é considerado neste trabalho como semana de previsão ou período de previsão. A Figura 11 retrata este cenário de forma mais clara.



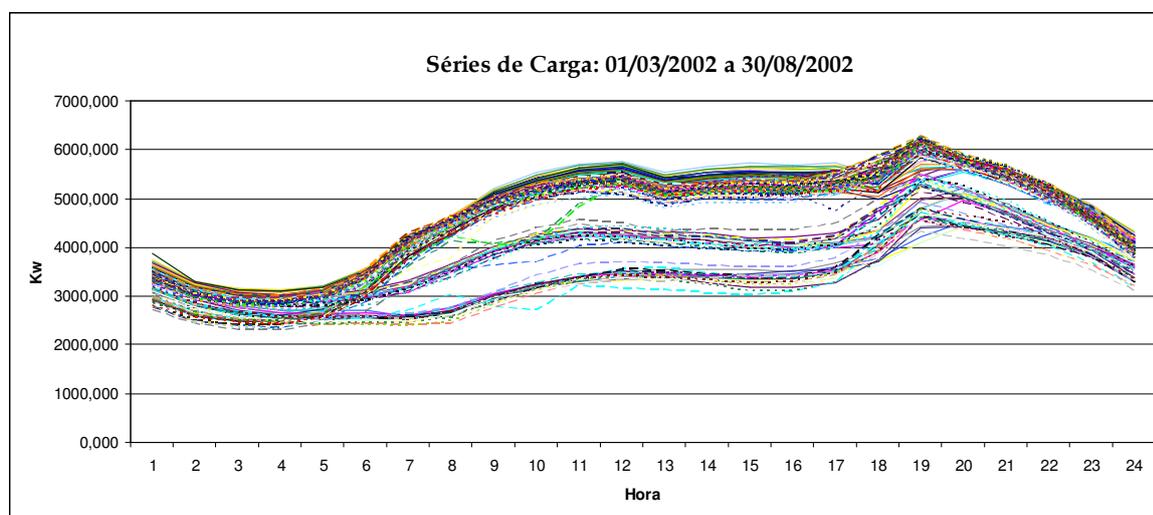
**Figura 11 - Histórico de medição, apresentando as divisões para os experimentos.**

Os dados foram tratados previamente, fazendo a normalização através da divisão de todos os valores de carga pelo máximo global. Este processo é importante para que os dados não apresentem um desvio elevado. Sendo assim,

eles ficam incluídos no intervalo entre 0 e 1. É importante lembrar que após a normalização as séries não perdem suas características originais e a relação entre elas é mantida. A Figura 12 apresenta as séries de dados utilizadas nos experimentos deste trabalho, de forma não normalizada.

Ao analisar o gráfico da Figura 12, observa-se que estas séries apresentam um consumo elevado por volta das 19 horas, caracterizando um pico nas curvas. Este fato acontece em função de um aumento no consumo elétrico neste horário. Este consumo elevado identificado é caracterizado como horário de ponta.

Como forma de verificar se existe alguma semelhança estatística entre os dados do consumo de carga da base utilizada, foi utilizado o teste "F" da análise de variância e o teste de Tukey para tal processo, através do *software* Sisvar. Esta análise estatística se fez da seguinte forma: primeiro é verificada a média de consumo diário para todos os dias do histórico. Os dias contidos no histórico são agrupados de forma que os dias do período de treino, de validação e de teste ficassem separados. Em seguida, são aplicados os testes estatísticos nos grupos mencionados.



**Figura 12 – Séries de carga abrangendo o período de 01/03/2002 a 30/08/2002.**

A partir da análise de variância, apresentada na Tabela 1, é possível concluir que as médias dos consumos diários do histórico de medição são estatisticamente semelhantes. Visando reforçar esta afirmação, é realizado o teste de Tukey, o qual agrupa as médias que se apresentam de forma estatisticamente semelhantes, para

verificar a relação entre elas. Neste teste, mostrado na Tabela 2, é possível verificar e reforçar a afirmação anterior, em que as médias dos consumos dos dias são estatisticamente semelhantes.

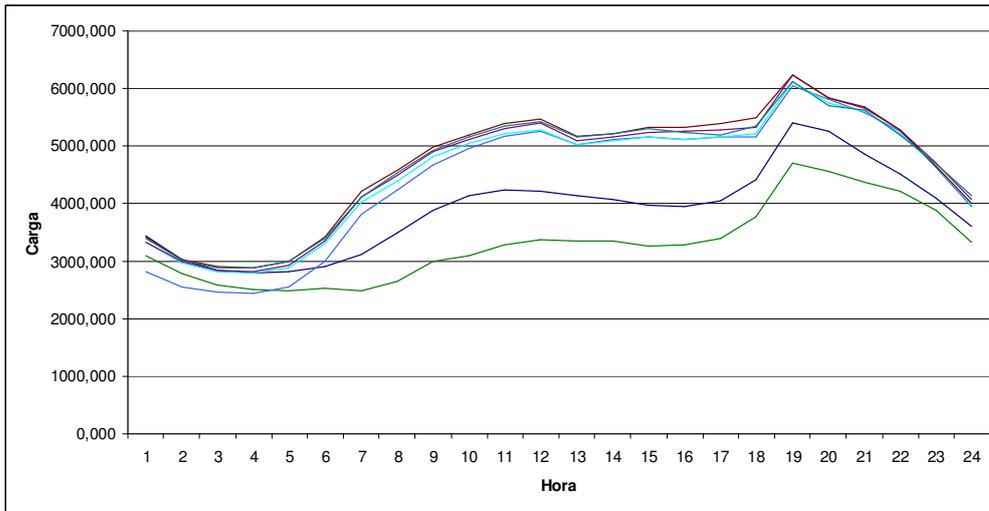
**Tabela 1 - Tabela da análise de variância**

FV	GL	SQ	QM	Fc	Pr > Fc
Grupo	2	3324.133670	1662.066835	0.007	0.9932
erro	152	36972915,895457	243242.867733		
Total Corrigido	154	36976240.029127			
CV (%) =	11.45	36976240.029127			
Média Geral	4307.8245283		Número de observações:	155	

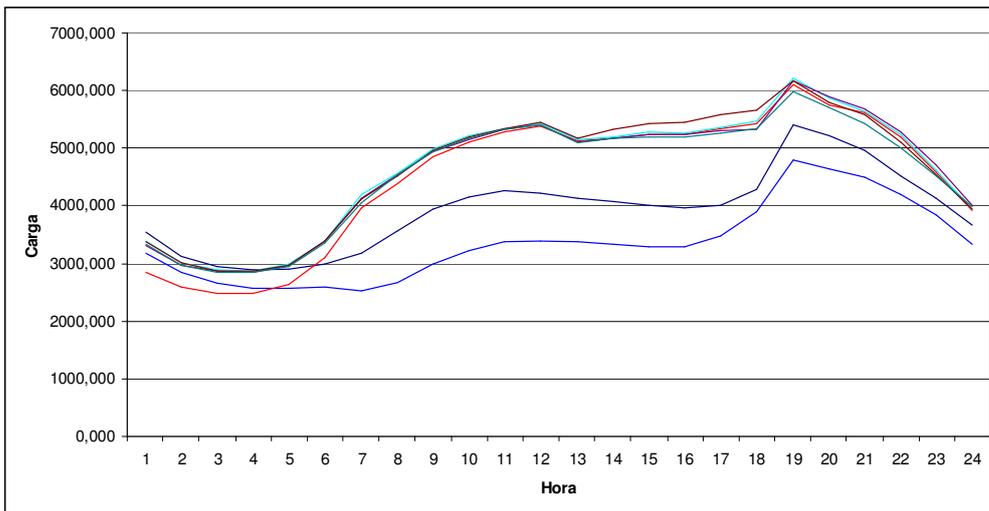
**Tabela 2 - Teste de Tukey**

Tratamentos	Médias	Resultados
Período Validação	4293.859048	a
Período Treino	4307.687917	a
Período Previsão	4324.541755	a

As Figuras 13 e 14 abordam o consumo de carga real das semanas de validação e previsão, respectivamente. Nestas, é possível perceber um comportamento similar entre as suas curvas.



**Figura 13 - Séries de carga do consumo real da semana de validação.**



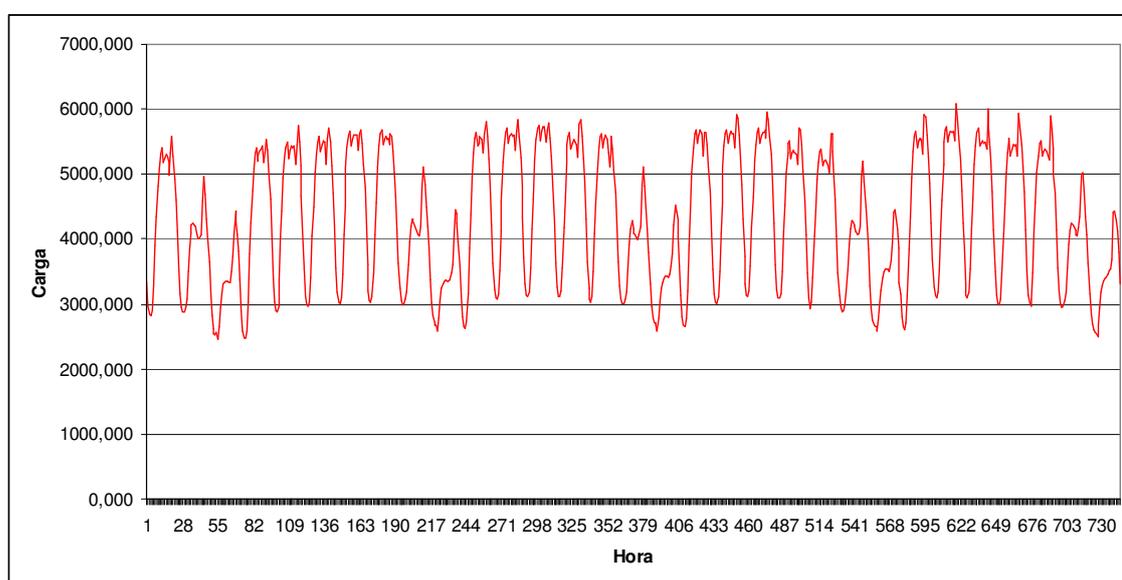
**Figura 14 - Séries de carga do consumo real da semana de previsão.**

Em relação aos dias de medição, pode-se observar que na base de dados utilizada, em sua totalidade, existe um comportamento similar de consumo entre os dias úteis (segunda a sexta-feira) e um comportamento similar entre finais de semana (sábado e domingo). Procurando apresentar esta semelhança, a Figura 15 abrange o gráfico das curvas de consumo, dispostas em série.

Para evitar um grande volume de dados, capaz de comprometer a visualização, é mostrado apenas um curto período, o qual compreende desde sexta-feira (01/03/2002) até Domingo (07/04/2002). Nesta ilustração, é perceptível este comportamento e de fácil identificação ao longo da curva. No caso, os pontos da

curva que apresentam picos mais altos de consumo são representações dos dias úteis e os que apresentam picos mais baixos de consumo são representações dos finais de semana. É notória a presença do domingo neste gráfico, cujos pontos mais baixos de consumo situam-se abaixo da linha de carga equivalente a 3000,00.

Uma forma de visualização dos dados, a qual também se mostra interessante, consiste na exibição das curvas de consumo, de maneira que cada uma delas representa um determinado horário dos dias do histórico de medição. Assim, tem-se 24 curvas representado as 24 horas ao longo de todos os dias em questão. A Figura 15 aborda esta representação.



**Figura 15 - Curvas de consumo dispostas em série.**



# 4

## Metodologia

*Este capítulo apresenta a metodologia empregada para a realização deste trabalho, iniciando com uma descrição sucinta do objetivo deste trabalho, abordando a ideia principal empregada e a forma como foram extraídos os dados do histórico para treinamento dos modelos. Em seguida são discutidas as componentes individuais de previsão e os ensembles utilizados.*

### 4.1 Descrição

Conforme discutido anteriormente, este trabalho tem por finalidade realizar a previsão de carga elétrica à curto prazo, de forma inteligente. Para isso, foi desenvolvida uma metodologia de previsão de carga baseada na combinação de diversos previsores. De acordo com Leone Filho (2006), acredita-se que, este resultado, quando combinado, tende a apresentar soluções melhores ou iguais às soluções apresentadas pelas melhores componentes individuais. Foram utilizadas, como formas de se combinar os resultados neste trabalho, 3 técnicas, das quais pode-se citar a média aritmética, a média ponderada e um modelo não-linear: a rede neural artificial. Os experimentos foram realizados tomando como base de dados o histórico do consumo adquirido de uma empresa elétrica do Brasil, com discretização horária.

### 4.2 Ideia Principal

Visando facilitar a compreensão da finalidade deste trabalho, considere um exemplo prático. Suponha que existam um total de 7 componentes individuais de previsão. Estas componentes serão utilizadas para realizar a previsão hora a hora de um dia X qualquer; uma segunda-feira, por exemplo. É calculado o erro

percentual médio de cada hora (EPMh) para todas as 24 horas deste dia X qualquer, dado pela Equação (2). As variáveis que constituem a Equação (2) são definidas de forma que  $\rho_{real}$  representa o valor real de carga de uma determinada hora e  $\rho_{previsto}$  o valor de carga previsto, por um determinado componente de previsão, para o mesmo horário. Em seguida, é calculada a média de todos os erros das 24 horas, para uma determinada componente. A média dos EPMh's das 24 horas fica definida, neste trabalho, como erro percentual médio diário (EPMd), identificado pela Equação (3). A Figura 16 apresenta esta ideia, facilitando o entendimento.

$$EPMh = \frac{(\rho_{real} - \rho_{previsto})}{\rho_{real}} \times 100 \quad (2)$$

$$EPMd = \frac{\sum_{i=0}^{23} (EPMh)_i}{24} \quad (3)$$

**Dia X (qualquer)**

Horário	Carga Real	Carga Prevista		
00:00	Valor Real 0	Valor Previsto 0	→	EPMh 0
01:00	Valor Real 1	Valor Previsto 1	→	EPMh 1
02:00	Valor Real 2	Valor Previsto 2	→	EPMh 2
03:00	Valor Real 3	Valor Previsto 3	→	EPMh 3
04:00	Valor Real 4	Valor Previsto 4	→	EPMh 4
05:00	Valor Real 5	Valor Previsto 5	→	EPMh 5
06:00	Valor Real 6	Valor Previsto 6	→	EPMh 6
07:00	Valor Real 7	Valor Previsto 7	→	EPMh 7
⋮	⋮	⋮		⋮
23:00	Valor Real 23	Valor Previsto 23	→	EPMh 23

} EPMd

**Figura 16 – Previsão realizada por uma componente individual para um dia X qualquer, encontrando o EPMd.**

Considerando as 7 componentes, suponha que os EPMD's cometidos por cada uma delas serão dados pela Tabela 3. Vale ressaltar que estes valores e o número de componentes são fictícios, sendo utilizados apenas para facilitar a compreensão da ideia principal deste trabalho.

É possível observar que a componente que obteve o menor EPMD, em concordância com a Tabela 3, foi a componente "3". A partir do valor desta, são escolhidas as componentes que obtiveram um EPMD de até 5% acima do erro da melhor componente. Para esta situação, as componentes escolhidas serão aquelas cujo EPMD estão na faixa de 2,00 a 2,10. Estas compreendem "3", "8" e "5", em que os EPMD's são 2,00, 2,04 e 2,08, respectivamente.

**Tabela 3 - Exemplo de componentes e seus respectivos EPMD's**

Componente	EPMD
1	2,35
2	3,20
3	2,00
4	2,93
5	2,08
6	2,73
7	2,04

O valor de 5%, para estipular a faixa de escolha das componentes, foi definido de forma empírica, com base em testes realizados. Nestes testes, considerando a base de dados utilizada neste trabalho, o valores que melhor se adequaram ao modelo ficaram na faixa dos 5%.

Escolhidas as componentes, estas serão utilizadas para realizar a previsão do mesmo dia X da semana posterior. No caso do exemplo, estas seriam utilizadas na previsão da segunda-feira da próxima semana.

Os resultados destas componentes, para a previsão do dia da próxima semana, são combinados para que, desta forma, tente-se alcançar um resultado que seja mais estável e mais próximo do valor real de carga medida. Nos experimentos deste trabalho, ao invés de 7 componentes individuais, foram utilizadas 2500, obtidas através da variação dos parâmetros dos modelos de previsão, a saber,

RNA's, PG's e RLM's. O processo de escolha das componentes é detalhado na próxima seção.

## 4.3 Componentes Individuais

Considerando um dia específico de previsão da semana de validação, a seleção das melhores componentes é feita da seguinte forma: é escolhida a componente que obteve o menor valor do EPMD e as que obtiveram o EPMD até 5% acima do EPMD da primeira. Este valor de 5 % foi escolhido com base em testes realizados de forma empírica, apresentando um comportamento considerável.

Estas mesmas componentes são utilizadas para realizar a previsão do mesmo dia da semana seguinte (semana de previsão). A partir da Figura 17 fica clara a percepção deste processo. Nesta figura são mostradas as componentes sendo geradas a partir da variação dos parâmetros dos modelos (RNA, PG e RLM) e a escolha daquelas que obtiveram o EPMD, tendo em vista uma faixa de 5% acima daquela que obteve o menor EPMD. Na seção 4.4 serão discutidas as formas de se combinar os resultados de previsão das componentes utilizadas neste trabalho.

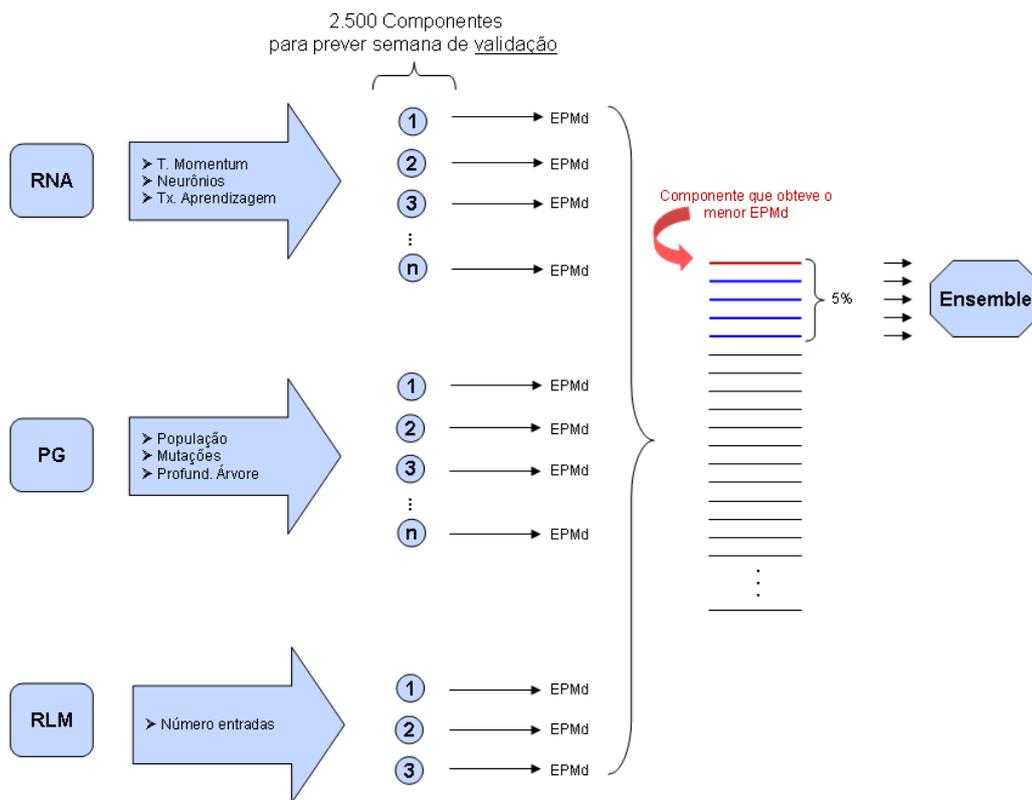


Figura 17 - Geração e escolha das componentes que obtiveram o menor EPMD.

### 4.3.1 Geração das componentes individuais

Os modelos citados, que participam das componentes de previsão, são as redes neurais artificiais multicamadas, a programação genética e a regressão linear múltipla. Por existir uma infinidade de combinações destes parâmetros para cada modelo, foram geradas, no total, 2500 componentes obtidas através da variação aleatória destes parâmetros, ou seja, cada componente é resultante de uma configuração específica dos parâmetros de um determinado modelo. Esta técnica foi utilizada acreditando-se que este número escolhido, de forma empírica, fosse suficientemente capaz de explorar a eficiência destas componentes geradas aleatoriamente através da variação dos parâmetros dos modelos,

Deste total, ficaram divididas em 1251 RNA's, 1246 PG's e 3 RLM's. Estes números foram definidos empiricamente. Foram escolhidas apenas 3 RLM's em razão da variação apenas do número de entradas para o treinamento deste modelo.

Estas entradas consistem em 3 atrasos, 7 atrasos e um número de atrasos escolhidos por uma função de autocorrelação.

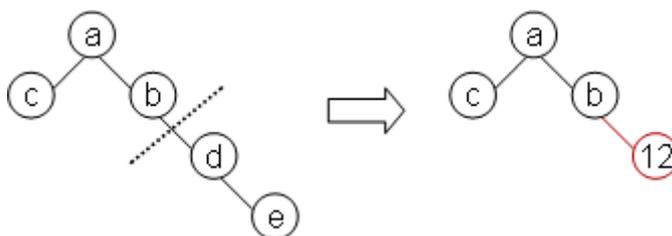
O parâmetros que sofreram alterações na RNA podem ser identificados na Tabela 4. O símbolo  $A^*$  definido como entradas do modelo, corresponde ao número de neurônios da camada de entrada da rede, percebido na primeira linha da Tabela 4, é definido por uma função de autocorrelação, a qual escolhe os índices dos valores de carga do vetor de entradas que serão utilizados.

Considerando a PG, os parâmetros que foram combinados aleatoriamente podem ser visualizados através da Tabela 5. Neste modelo, o objetivo é gerar árvores sintáticas que representem equações matemáticas. Durante o treinamento do modelo, árvores vão sendo geradas até que se encontre uma equação que possa representar o conjunto de dados daquela hora de um determinado dia.

**Tabela 4 – Parâmetros da RNA**

Entradas do modelo	{3, 7, $A^*$ }
Neurônios Intermediários	[1 – 15]
Taxa de Aprendizagem	{0,1; 0,3; 0,5; 0,7; 0,9}
Termo Momentum	{0,1; 0,3; 0,5; 0,7; 0,9}

Considerando ainda a Tabela 5, as mutações utilizadas podem ser entendidas da seguinte forma: No caso da mutação 1, é feita uma “poda” na árvore e naquele ramo é inserido uma nova árvore, uma variável ou uma constante, gerada aleatoriamente. A Figura 18 retrata um exemplo desta mutação, sendo que é colocada uma constante, de valor 12, no ramo em que ocorreu a “poda”. As demais mutações seguem, basicamente, a mesma ideia.



**Figura 18 – Exemplo de mutação.**

**Tabela 5 – Parâmetros da PG**

Entradas do modelo	{3, 7, A*}
População	{30; 40; 50; 60; 70}
Mutações	{Mutação1; Mutação2; Mutação3; Mutação4}
Profundidade da Árvore	[7 - 13]

Na mutação 2 é feita apenas uma troca de operador, selecionando outro dentre os existentes no conjunto de operadores. Na mutação 3, o valor de uma determinada constante ou o domínio de uma determinada variável na equação é modificado. Por último, na mutação 4, semelhantemente a mutação 1, pode ocorrer um corte na árvore e um nó pode ser substituído por uma variável ou uma constante.

Tendo em vista a RLM, as únicas variações que foram feitas consistem apenas no número de entradas do modelo, que abrange os valores {3, 7, A\*}, em que A\* representa um valor escolhido por uma função de autocorrelação, conforme descrito anteriormente.

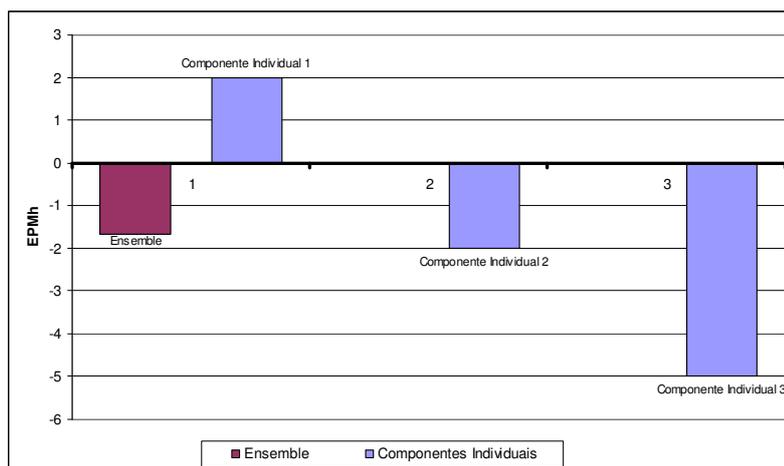
## 4.4 *Ensembles* Utilizados

Conforme já discutido, acredita-se que a utilização de *ensembles* de previsão tende a suavizar os erros dos resultados das componentes individuais, tornando o resultado combinado mais próximo do valor real da demanda. Neste trabalho foram utilizadas 3 formas de se construir o *ensemble*.

A primeira consiste no uso de média aritmética sobre os melhores resultados das componentes selecionadas que obtiveram menor erro. A fórmula da média aritmética é dada pela equação (4), em que  $x_n$  denota o valor previsto de um determinado horário, realizado por uma componente específica e n representa o número total de componentes selecionadas.

$$\overline{MA} = \frac{(x_1 + x_2 + \dots + x_n)}{n} \quad (4)$$

Apenas a título de demonstração para facilitar o entendimento, será apresentado um exemplo que pode ocorrer neste processo. Suponha que o valor real de carga de uma determinada hora do dia seja 100. Três componentes foram escolhidas para realizar a previsão. Os valores obtidos por cada uma delas são 98, 102 e 105. Um forma de combinar estes resultados seria através da média aritmética desses valores. Este processo retorna um valor de consumo de carga observado em 101,66. Logo, através da Figura 19, em que é apresentado o gráfico de erros, é possível analisar que o erro cometido pelo Ensemble, para este exemplo, é menor que os erros das componentes individuais verificados. Este procedimento é feito para as 24 horas do dia considerado, para todos os *ensembles* propostos.



**Figura 19 – Exemplo de erros cometidos pelo *Ensemble* pelas componentes individuais de previsão.**

A segunda maneira de se construir o *ensemble* consiste no uso da média ponderada sobre os resultados das componentes selecionadas. A equação (5) representa esta fórmula, sendo que  $\rho_n$  representa os pesos, distribuídos de forma que as componentes que alcançaram menores índices de erros recebem os maiores pesos no processo e  $x_n$  denota os valores previstos. Considerando que o número de componentes pode variar, a distribuição dos pesos também varia, mas sempre fazendo com que as que obtiveram os menores EPMd's recebam uma porção maior

do total de pesos. Para exemplificar, se 3 componentes foram selecionadas, a distribuição dos pesos fica empiricamente definida como 50 para a que obteve o menor EPMD, 30 para a segunda componente e 20 para a última.

$$\overline{MP} = \frac{(\rho_1 x_1 + \rho_2 x_2 + \dots + \rho_n x_n)}{n} \quad (5)$$

A terceira forma de se criar um *ensemble* foi obtida através da utilização de uma RNA do tipo MLP. Para o treinamento da rede, foram utilizadas como entradas as previsões realizadas nos dias da semana de validação e para entradas de teste, as previsões realizadas nos dias da semana de previsão. Para um melhor entendimento, suponha que se queira realizar a previsão do dia 24/08/2002 (sábado). A Figura 22, encontrada no final da seção 4.5, aborda, em seu conteúdo, um exemplo desta ideia para a previsão de uma determinada hora do dia 24, combinando os resultados das componentes de previsão selecionadas no dia 17/08/2002, através de uma RNA. Esta combinação é feita da seguinte forma: para o treinamento da rede, são utilizados como entradas os valores previstos pelas componentes selecionadas para o dia 17, em um horário específico. Como saída desejada, utiliza-se o valor real de carga da mesma hora deste dia. As entradas de teste, desta abordagem, são os valores previstos pelas mesmas componentes, para a hora considerada, do dia 24. Este processo é destacado em amarelo, em que se obtém uma saída resultante combinada, cujo valor tende a ser melhor ou mais próximo da carga real em relação aos valores alcançados pelas componentes individuais.

## 4.5 Configuração das Entradas e Saídas para os Modelos Individuais e *Ensembles*

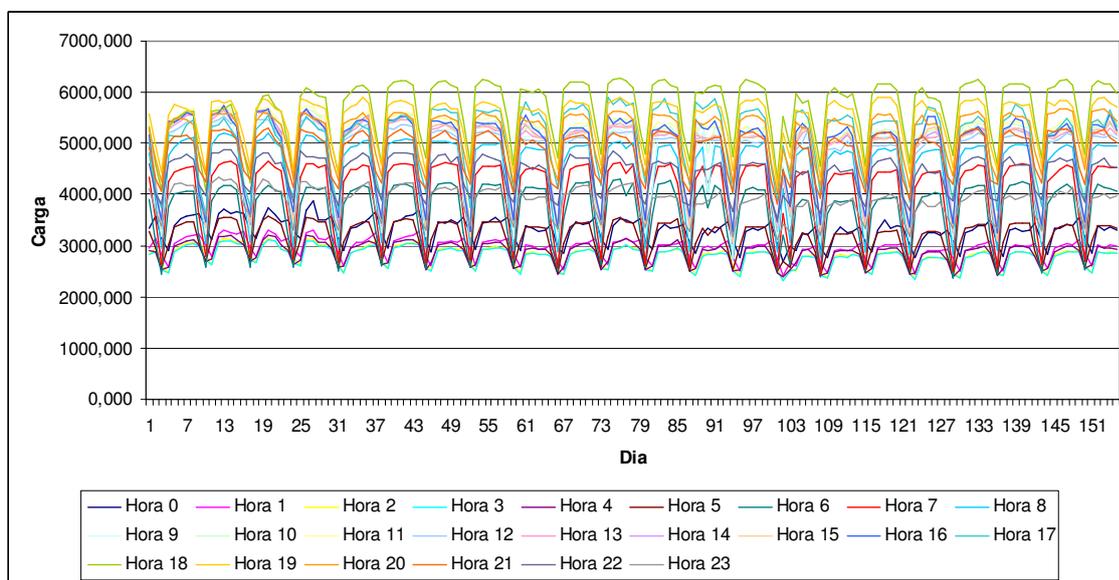
Para treinamento das componentes, foram escolhidos períodos que antecedem o dia de previsão almejado, com a mesma data semanal. Por exemplo, para facilitar o entendimento da forma como os padrões e os atrasos são escolhidos, a Figura 20 apresenta uma previsão para uma determinada hora do dia 23/08/2002 (sexta-feira), destacada em vermelho. Os valores de carga da mesma hora das sextas-feiras

que antecedem o dia 23 são passadas à componente como saídas desejadas e são escolhidas, apenas para exemplificar, 3 entradas para cada uma destas sextas-feiras em questão, neste caso, indicadas pela cor amarela da ilustração.

As entradas de cada saída desejada são escolhidas mediante um atraso, para valores de carga do mesmo horário, de 3 dias, 7 dias ou um número de dias escolhidos por uma função de autocorrelação. Esta função determina os índices dos valores do vetor de entradas que serão utilizados. Portanto, é um número variável. As entradas de teste são representadas pela cor verde.



**Figura 20 - Exemplo de entradas treino, saídas desejadas e entradas teste para a previsão de uma determinada hora do dia 23/08/2002.**



**Figura 21 - Curvas do consumo de carga horário, apresentadas para todos os dias do histórico de medição.**

A Figura 21 apresenta o gráfico de medição horária, para a base de dados considerada neste trabalho. Neste gráfico, cada uma das 24 linhas existentes estão associadas à uma determinada hora do dia, para os 156 dias existentes no histórico de medição.

A escolha das componentes utilizadas para compor o *Ensemble* é feita na semana de validação. Após isso, estas são utilizadas para prever o mesmo dia da semana seguinte, a qual é identificada neste trabalho como semana de previsão. Cada componente prevê todas as horas de um determinado dia X qualquer. Os resultados de previsão destas componentes são combinados através de três técnicas, anteriormente mencionadas, a saber, média aritmética, média ponderada ou RNA, obtendo-se, então, um novo resultado. Através desta técnica, denominada *ensemble*, e em concordância com Leone Filho (2006), acredita-se que o valor combinado deste processo tende a ser melhor ou igual ao resultado da melhor componente, tratada individualmente.

As entradas utilizadas para compor os *ensembles* são os resultados de previsão das próprias componentes individuais, as quais foram selecionadas na semana de validação. A Figura 22 mostra a escolha das componentes que obtiveram os menores índices de erro percentual médio diário na previsão do dia 17 (sábado), e que serão utilizadas também no processo de previsão do próximo sábado, dia 24. Os resultados de previsão destas componentes selecionadas (“16”, “293” e “33”) irão compor as entradas do ensemble para o dia 24, que, no caso do exemplo da Figura 19, é formado por uma RNA.

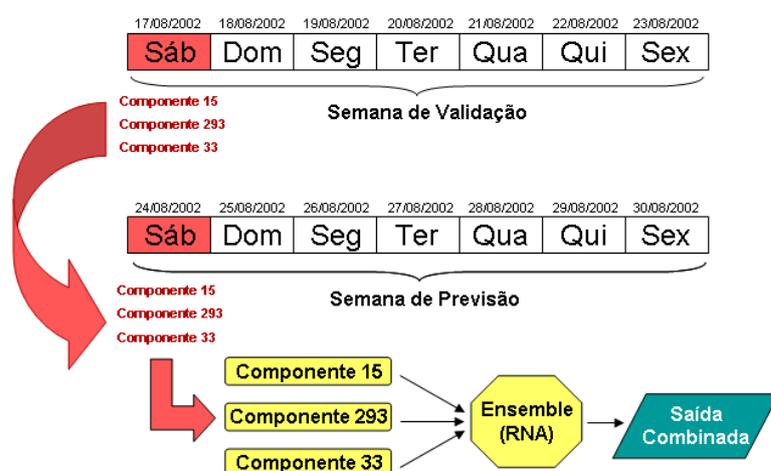


Figura 22 - Componentes selecionadas para compor o *ensemble* do dia 24/08/2002.



# 5

## Resultados

*Neste capítulo é feita uma análise dos resultados obtidos por cada modelo de ensemble proposto e pelas componentes individuais, para cada dia da semana de previsão.*

### 5.1 Descrição

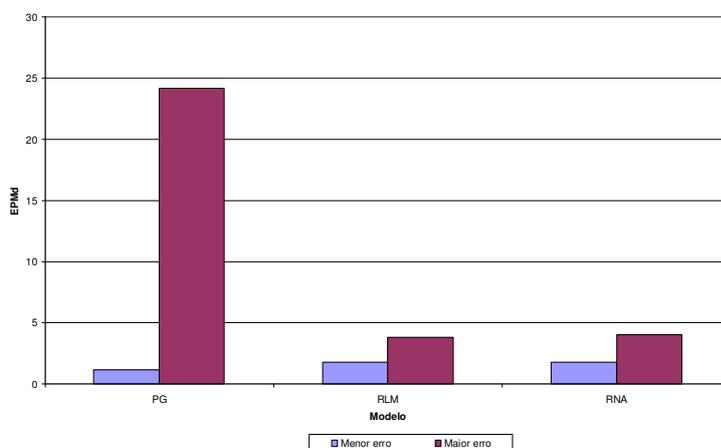
Os resultados apresentados neste capítulo são organizados de forma que são discutidas as componentes individuais na seção 5.2 e na seção 5.3 são discutidos os *ensembles*. Conforme descrito no capítulo anterior, o critério adotado para a comparação das componentes individuais e *ensembles* consiste em analisar os erros percentuais médios diários (EPMd's) cometidos por elas. Esta comparação é feita em termos numéricos e via análise estatística, para que haja uma maior confiabilidade no processo. Vale lembrar que a fase de validação foi usada para selecionar as melhores componentes para compor o *ensemble*. Na fase de teste, ou semana de previsão, os resultados de previsão das componentes selecionadas são combinados pelo *ensemble*.

### 5.2 Componentes Individuais

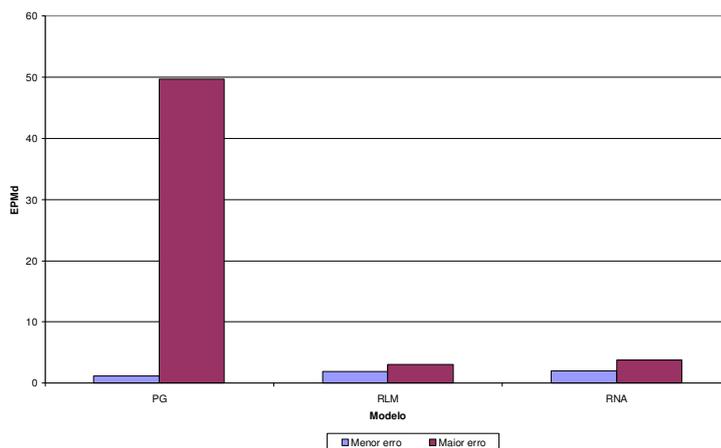
Nesta seção, serão apresentados os resultados de previsão das componentes que foram selecionadas para compor o *ensemble*. Para todos os dias de previsão, definidos no capítulo 3, as componentes que alcançaram numericamente os menores índices de erros foram aquelas obtidas através da variação dos parâmetros da programação genética. Geralmente, são encontradas na literatura recomendações para se utilizar a RNA como um dos principais métodos de

previsão, pelo fato da rede possuir uma capacidade alta de generalização e resolução de problemas envolvendo altos graus de não-linearidade.

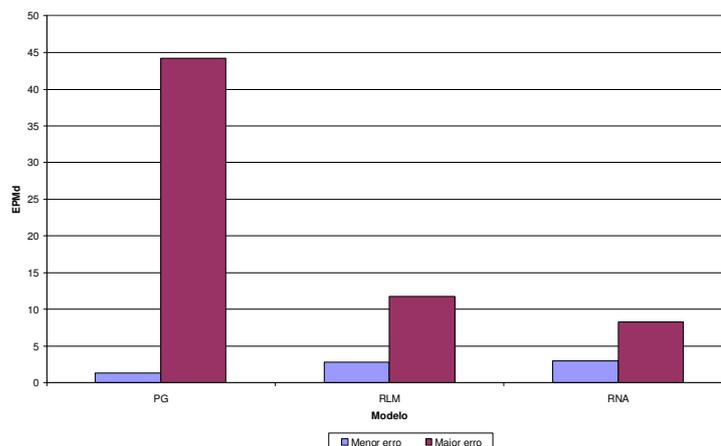
Procurando demonstrar o menor e maior erro percentual diário, cometido pelas componentes em cada modelo, são apresentados, nas Figuras 23, 24 e 25, os gráficos de alguns dias a saber 24, 25 e 26, respectivamente. Ao observá-los, percebe-se que a PG foi a que alcançou os menores e maiores índices de erro em relação às demais componentes dos outros modelos, para os experimentos destes dias mencionados. Vale ressaltar que a escolha dos parâmetros exerce influência sobre o resultado dos previsores, conforme acontece nos gráficos mencionados.



**Figura 23 - Maior e menor erro cometido pelas componentes de cada modelo, para o dia 24.**



**Figura 24 - Maior e menor erro cometido pelas componentes de cada modelo, para o dia 25.**



**Figura 25 – Maior e menor erro cometido pelas componentes de cada modelo, para o dia 26.**

Fazendo uma análise detalhada das componentes selecionadas, na Tabela 6 são apresentados os EPMd's de cada uma delas, observados na semana de validação e organizados de forma crescente, para cada dia. Na Tabela 7 são apresentados os erros destas mesmas componentes quando aplicadas na semana de previsão. É importante ressaltar que o número de componentes varia para cada dia nestas duas tabelas. Esta variação acontece pelo fato de que estas componentes são escolhidas em conformidade com o que fora discutido e definido na seção 4.3 do Capítulo 4.

Analisando estas duas tabelas (6 e 7), é possível observar que as melhores componentes verificadas para cada dia da semana de validação nem sempre se comportaram como melhores para cada dia da semana de previsão.

Este fato, em que a melhor componente de um determinado dia da semana de validação não se comportou como melhor na semana de previsão, pôde ser identificado no dia 17 (sábado), verificando que o EPMd da melhor componente da semana de validação, indicada por "15", apresentou resultado inferior ao das demais componentes para o dia 24 (sábado), na semana de previsão.

Visando verificar a dispersão dos valores individuais em torno da média, são calculados também, para cada componente de cada dia, os desvios padrão observados, e apresentados nas Tabelas 6 e 7.

**Tabela 6 - Erro percentual médio diário e desvio padrão verificados para as componentes selecionadas na semana de validação.**

<b>Dia</b>	<b>Modelo</b>	<b>Componente</b>	<b>EPMd</b>	<b>Desvio Padrão (<math>\sigma</math>)</b>
17 (Sáb)	PG	15	1,20%	1,13%
	PG	293	1,28%	1,14%
	PG	33	1,29%	1,02%
18 (Dom)	PG	80	0,85%	0,95%
	PG	417	0,87%	0,83%
	PG	993	0,88%	0,83%
19 (Seg)	PG	624	1,21%	0,84%
	PG	7	1,26%	1,04%
20 (Ter)	PG	801	0,96%	0,75%
	PG	396	0,98%	0,57%
21 (Qua)	PG	91	0,77%	0,76%
	PG	520	0,80%	0,84%
22 (Qui)	PG	184	0,62%	0,70%
23 (Sex)	PG	551	0,79%	0,39%
	PG	924	0,79%	0,46%
	PG	36	0,79%	0,40%
	PG	820	0,80%	0,48%
	PG	40	0,81%	0,55%
	PG	598	0,82%	0,43%
	PG	174	0,82%	0,51%

**Tabela 7 - Erro percentual médio diário e desvio padrão verificados para as componentes utilizadas na semana de previsão.**

<b>Dia</b>	<b>Modelo</b>	<b>Componente</b>	<b>EPMd</b>	<b>Desvio Padrão (<math>\sigma</math>)</b>
24 (Sáb)	PG	15	2,41%	1,77%
	PG	293	1,85%	1,60%
	PG	33	2,38%	1,76%
25 (Dom)	PG	80	1,72%	1,33%
	PG	417	1,70%	1,41%
	PG	993	2,30%	2,06%
26 (Seg)	PG	624	1,75%	1,18%
	PG	7	2,09%	1,46%
27 (Ter)	PG	801	1,19%	0,89%
	PG	396	1,21%	1,02%
28 (Qua)	PG	91	2,22%	1,40%
	PG	520	2,33%	1,38%
29 (Qui)	PG	184	2,00%	1,44%
30 (Sex)	PG	551	1,91%	1,59%
	PG	924	1,20%	0,95%
	PG	36	2,02%	1,82%
	PG	820	1,23%	1,03%
	PG	40	1,23%	0,94%
	PG	598	1,79%	1,45%
	PG	174	1,49%	1,13%

## 5.2.1 Dia 24 - Sábado

Para este dia, considerando a faixa de seleção de 5% das componentes, definida na seção 4.3 do Capítulo 4, verificou-se que apenas 3 componentes participaram deste processo. O gráfico de erro horário é apresentado na Figura 26, para cada componente em questão, sendo possível observar o período que obteve maior índice de erro pelas componentes. Este período é identificado nas 16:00.

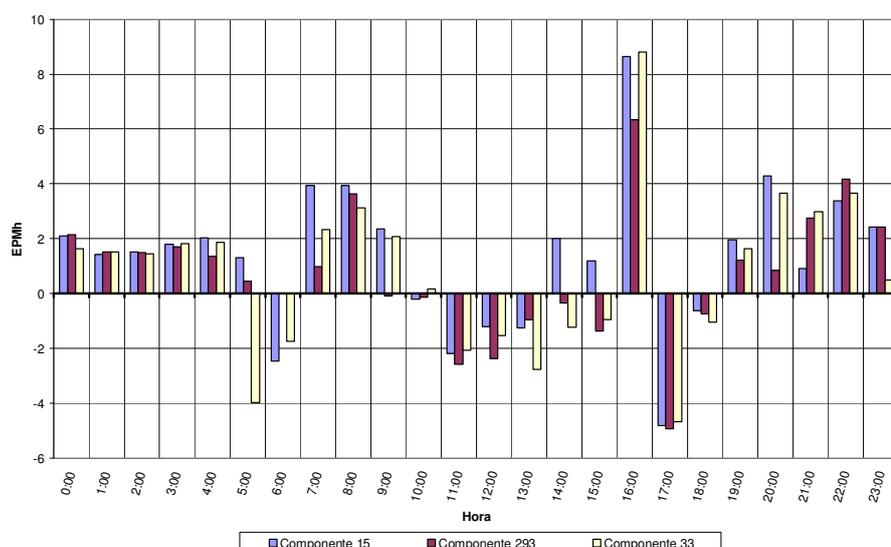


Figura 26 - Gráfico de erros para cada hora do dia 24.

## 5.2.2 Dia 25 - Domingo

Semelhantemente ao dia anterior, o dia 25 caracterizou-se por apenas 3 componentes escolhidas. O gráfico da Figura 27 apresenta os erros horários observados para cada uma destas componentes. Neste gráfico, o EPMh mais alto foi verificado para a 0:00 pela componentes 993.

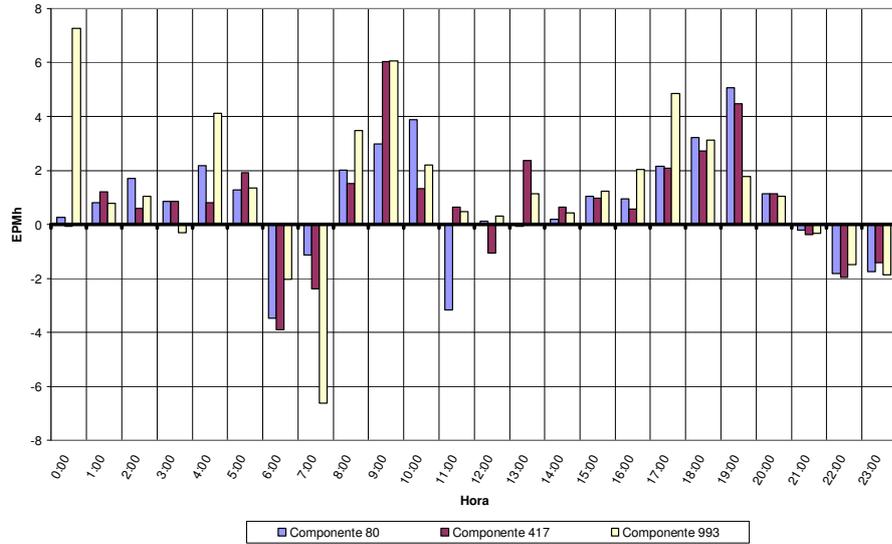


Figura 27 - Gráfico de erros para cada hora do dia 25.

### 5.2.3 Dia 26 - Segunda

Diferentemente dos dois dias anteriores, participaram da previsão do dia 26 apenas duas componentes. Observando a Figura 28, percebe-se que a componente que obteve o maior índice de erro, neste dia, foi a componente 624 às 9:00.

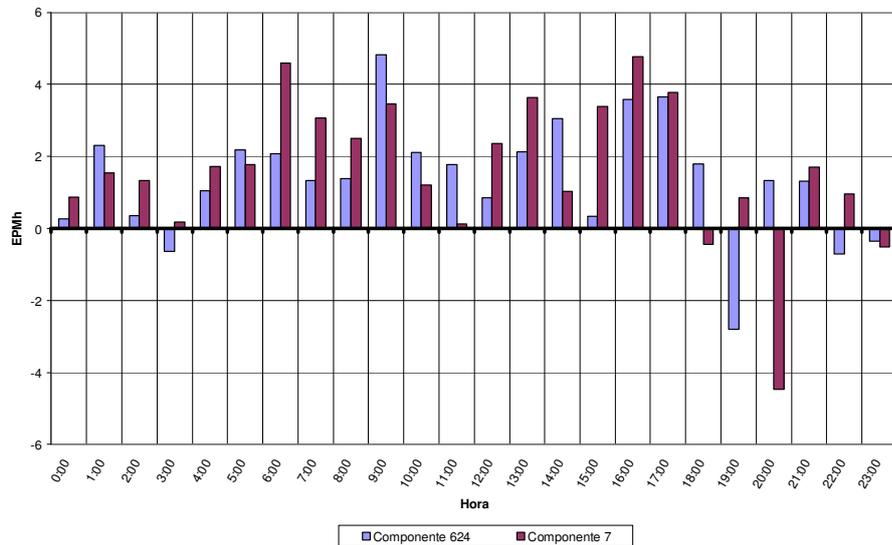


Figura 28 - Gráfico de erros para cada hora do dia 26.

## 5.2.4 Dia 27 – Terça

As componentes que participaram da previsão deste dia se assemelhou, em número, ao dia 26. Portanto, ao verificar a Figura 29, nota-se um índice de erro maior cometido às 7:00 pela componente 801.

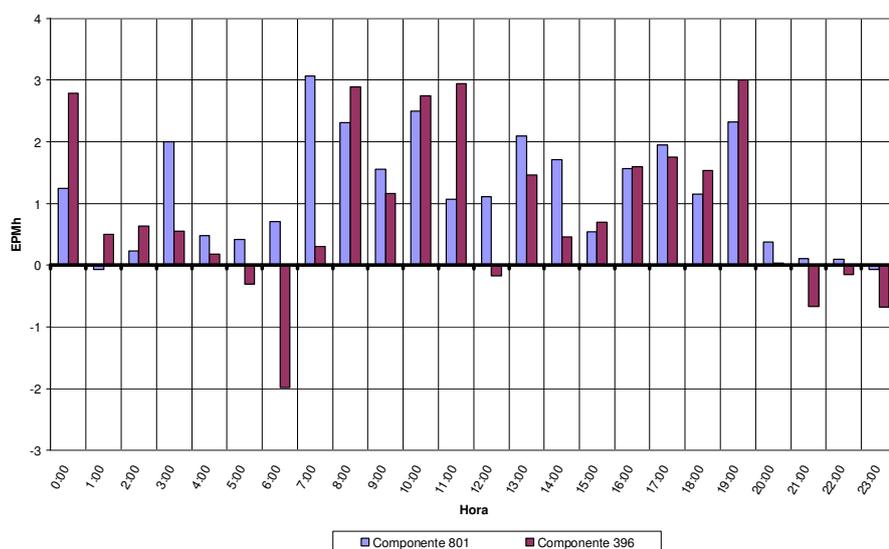


Figura 29 – Gráfico de erros para cada hora do dia 27.

## 5.2.5 Dia 28 – Quarta

É interessante observar, através da Figura 30, que as duas componentes que participaram da previsão deste dia obtiveram a maioria dos seus erros horários abaixo de zero. Isso significa que o valor previsto ficou abaixo do valor real de carga, para aquele determinado horário. O índice de erro mais alto foi verificado às 17:00, cometido pela componente 91, para este dia.

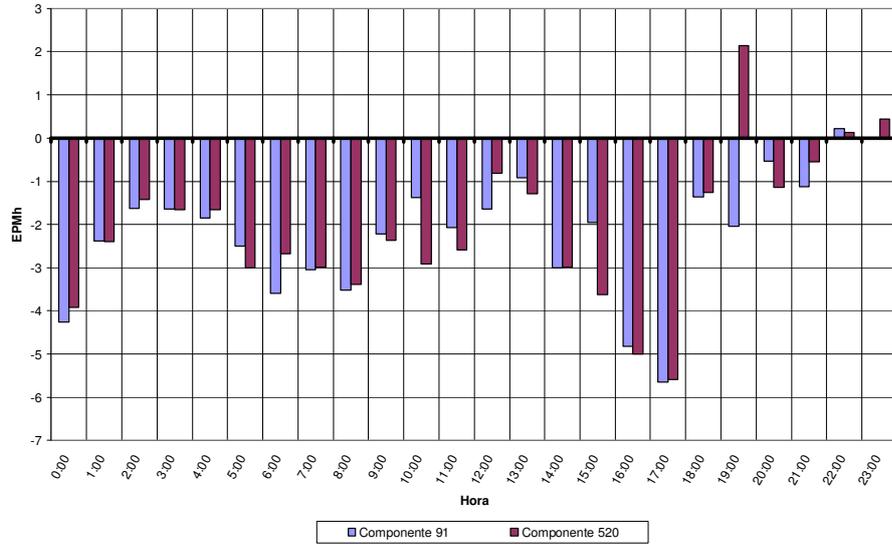


Figura 30 - Gráfico de erros para cada hora do dia 28.

### 5.2.6 Dia 29 - Quinta

Em relação aos demais dias de previsão, este se destacou em relação ao fato de que apenas uma componente participou do processo de previsão. Isso aconteceu devido as demais componentes terem alcançado erros de previsão superior a faixa de 5%, conforme fora definida na seção 4.3 do Capítulo 4. A Figura 31 apresenta os erros horários desta componente.

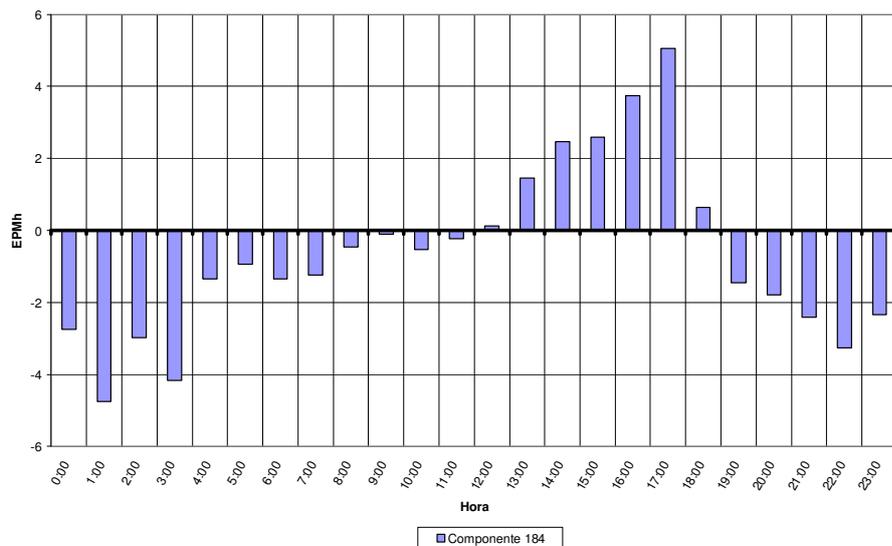


Figura 31 - Gráfico de erros para cada hora do dia 29.

## 5.2.7 Dia 30 – Sexta

Este dia, em relação aos demais dias da semana de previsão, foi o que obteve maior número de componentes selecionadas para o processo de previsão. Isso acontece pelo fato de que o erro diário destas esteve na faixa de erro de 5% acima do erro da melhor componente. Maiores detalhes desta escolha pode ser encontrado na seção 4.3 do Capítulo 4. Ao observar a Figura 32, verificou-se que a componente que obteve o maior erro horário, para este dia, foi a componente 36 às 17:00. É interessante observar que, como a maioria dos erros horários ficam abaixo de zero, a maioria dos valores previstos ficam abaixo do valor real de carga para um determinado horário.

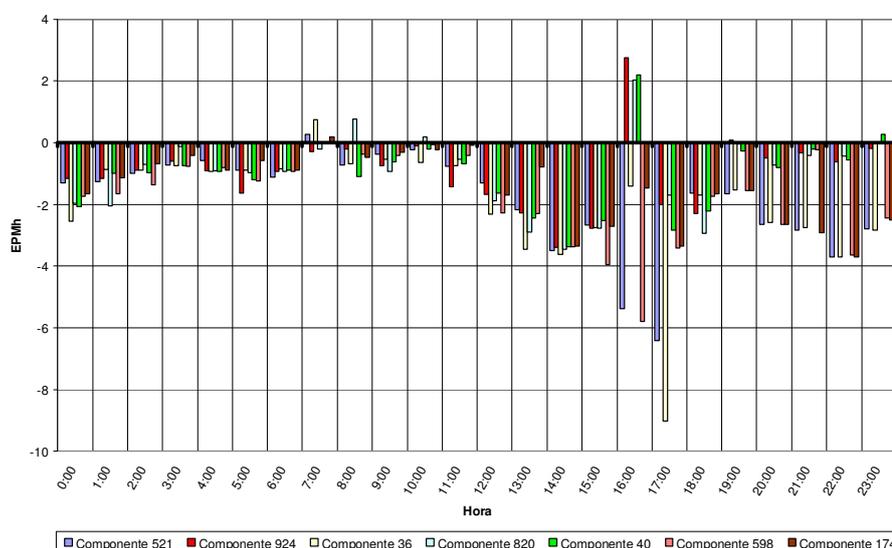
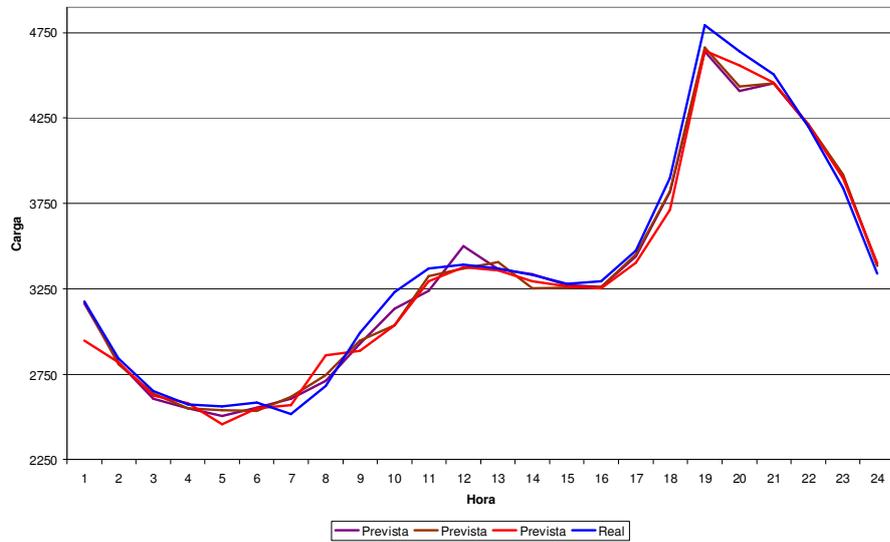


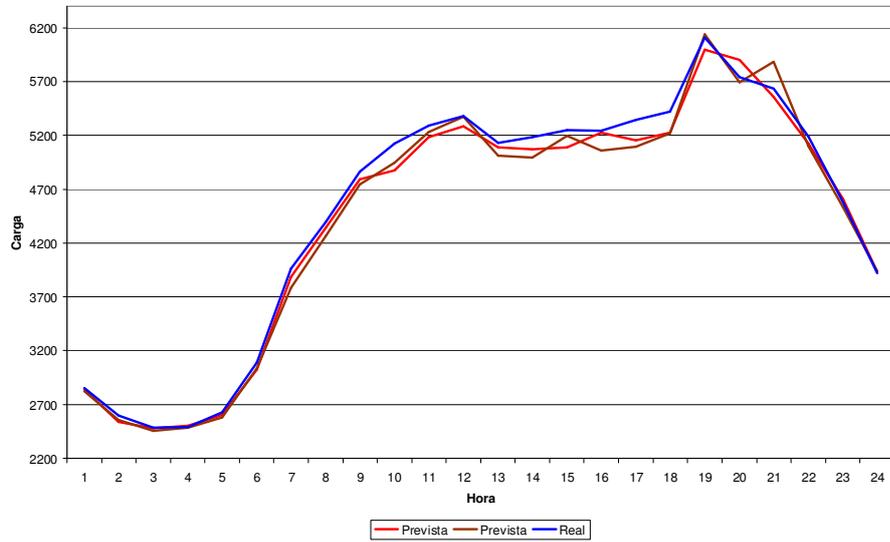
Figura 32 – Gráfico de erros para cada hora do dia 30.

## 5.2.8 Comentários Adicionais

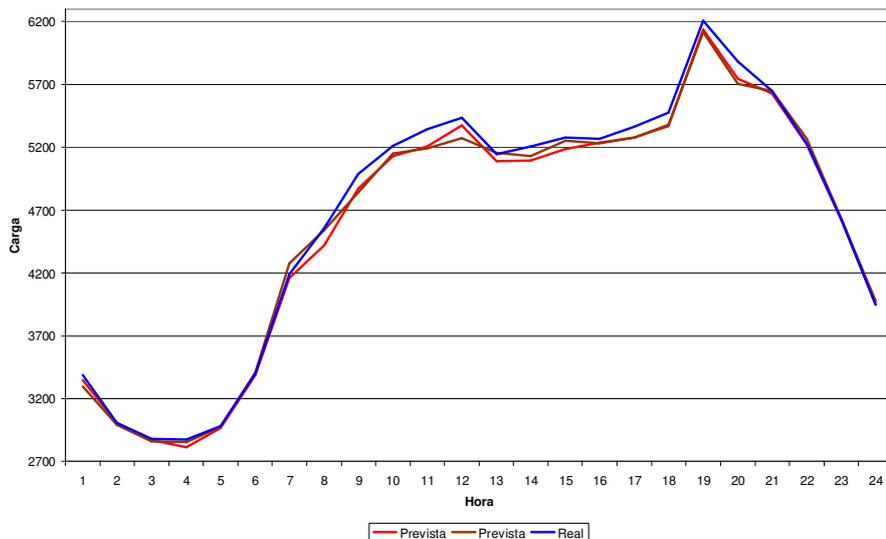
Nesta subseção são apresentados comentários adicionais das componentes individuais. A ideia deste trabalho é combinar os resultados obtidos por estas componentes visando alcançar resultados mais próximos do valor real de carga. A seguir, serão apresentados, nas Figuras 33, 34 e 35, os gráficos que contêm as curvas de previsão de cada componente e a curva real de carga, para os dias 25, 26 e 27, respectivamente.



**Figura 33 – Gráfico das curvas de previsão, obtidas pelas componentes individuais, e da carga real do dia 25.**



**Figura 34 – Gráfico das curvas de previsão, obtidas pelas componentes individuais, e da carga real do dia 26.**



**Figura 35 – Gráfico das curvas de previsão, obtidas pelas componentes individuais, e da carga real do dia 27.**

Observa-se que as curvas de previsão muito se aproximam da curva de carga real. O objetivo deste trabalho consiste em combinar as curvas previstas para que se alcance um resultado que mais se aproxime da curva real. Estes resultados são combinados através de uma técnica denominada *ensemble*. Os resultados dos *ensembles*, propostos na seção 4.4 do Capítulo 4, aplicados nos resultados das componentes selecionadas para cada dia da semana de previsão, são discutidos na próxima seção.

### 5.3 Ensembles

Os resultados dos *ensembles*, contemplados nesta seção, serão apresentados, a princípio, na forma de gráficos diários, para todos os dias da semana de previsão, contendo as curvas de carga real e prevista. As Figuras 36, 37, 38, 39, 40, 41 e 42 abordam, em seu conteúdo, estes gráficos, para os dias 24, 25, 26, 27, 28, 29 e 30, respectivamente.

É possível observar a variação do perfil de consumo de carga de cada dia em questão em cada um dos gráficos apresentados.

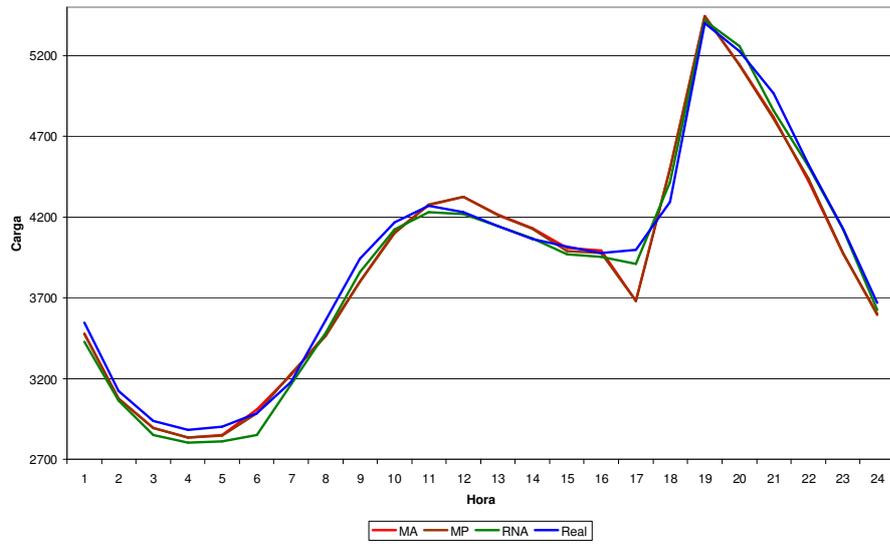


Figura 36 - Gráfico das curvas dos *ensembles* e curva real de carga para o dia 24.

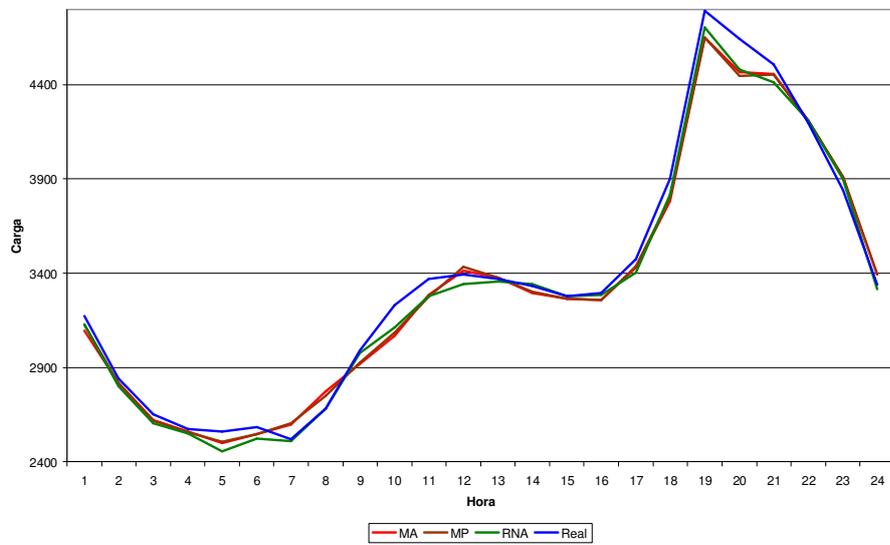


Figura 37 - Gráfico das curvas dos *ensembles* e curva real de carga para o dia 25.

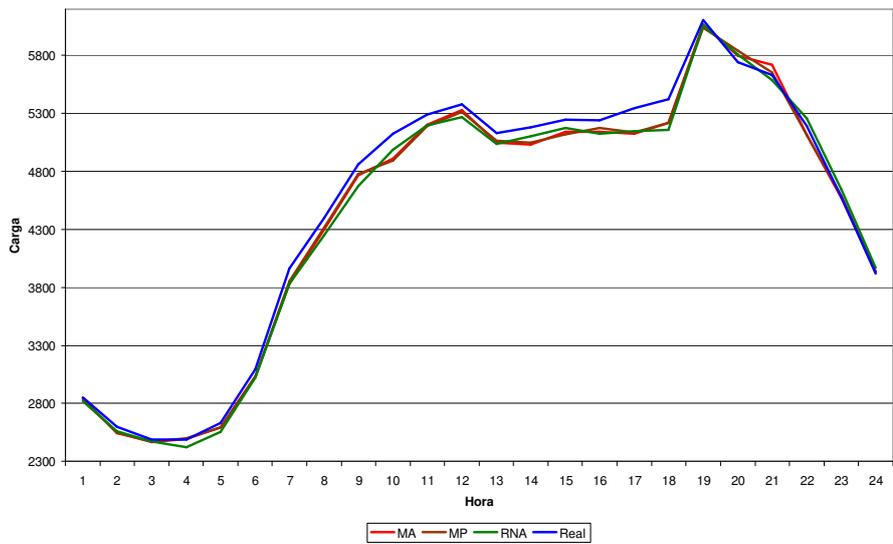


Figura 38 – Gráfico das curvas dos *ensembles* e curva real de carga para o dia 26.

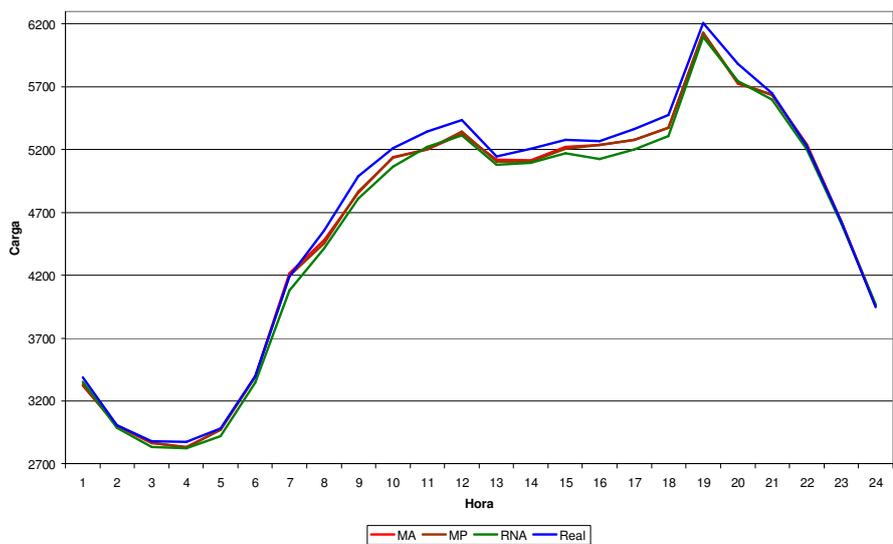


Figura 39 – Gráfico das curvas dos *ensembles* e curva real de carga para o dia 27.

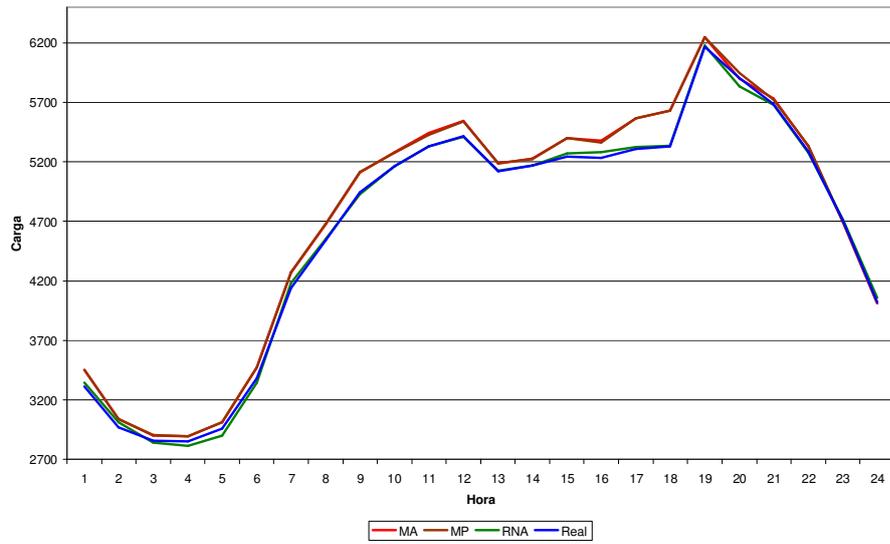


Figura 40 - Gráfico das curvas dos *ensembles* e curva real de carga para o dia 28.

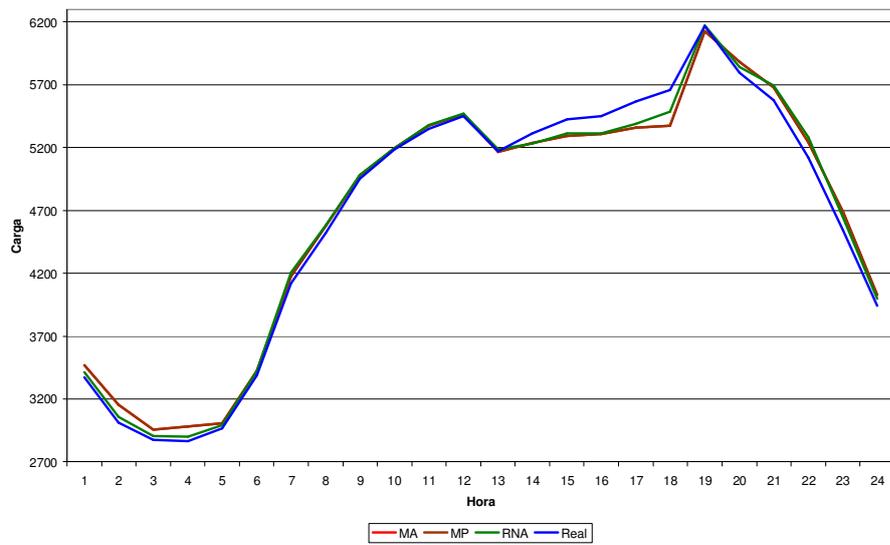
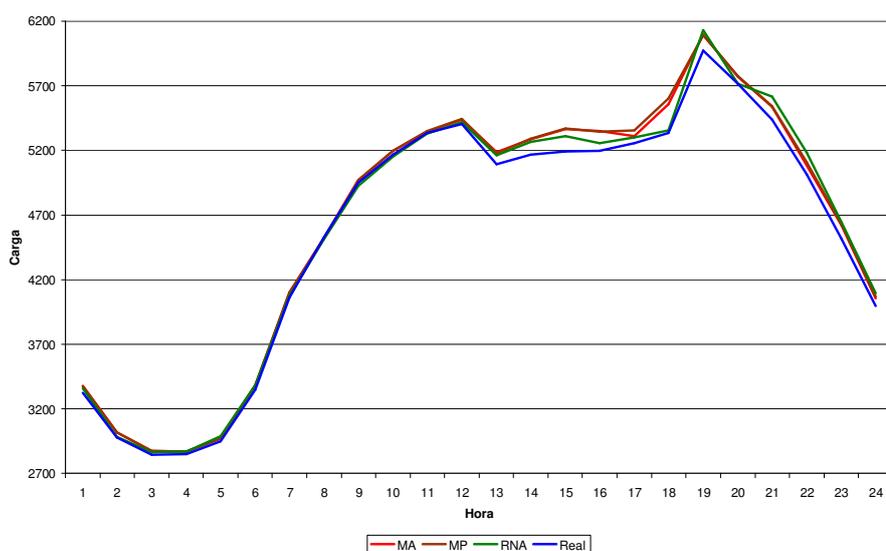


Figura 41 - Gráfico das curvas dos *ensembles* e curva real de carga para o dia 29.



**Figura 42 – Gráfico das curvas dos *ensembles* e curva real de carga para o dia 30.**

A seguir, ao analisar a Tabela 8, verifica-se que os erros foram observados abaixo de 3%, existindo pouca variabilidade entre eles, mas não impedindo com que uma análise e conclusão pudessem ser feitas sobre os mesmos. Nesta tabela são apresentados os *ensembles* utilizados, a melhor e a pior componente de previsão individual, para todos os dias da semana de previsão. Uma das motivações de se utilizar o *ensemble*, considerando os experimentos realizados, reside no fato de que a variação do erro cometido por cada um deles é, geralmente, numericamente menor do que a variação do erro cometido pelas componentes individuais.

**Tabela 8 – Erros percentuais diários verificados para os dias de previsão.**

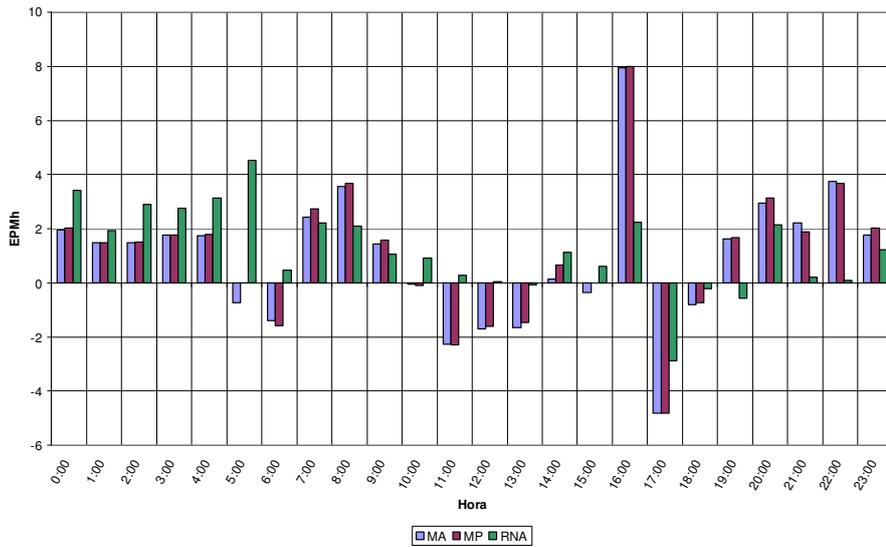
	Dia 24 (Sábado)	Dia 25 (Domingo)	Dia 26 (Segunda)	Dia 27 (Terça)	Dia 28 (Quarta)	Dia 29 (Quinta)	Dia 30 (Sexta)
MA	2,08%	1,85%	1,77%	1,14%	2,1933%	2,00%	1,45%
MP	2,09%	1,79%	1,72%	1,13%	2,20%	2,00%	1,57%
RNA	1,54%	1,49%	2,09%	1,89%	0,59%	1,45%	1,21%
Melhor Componente	1,85%	1,70%	1,75%	1,19%	2,22%	2,00%	1,2%
Pior Componente	2,41%	2,30%	2,09%	1,21%	2,33%	2,00%	2,02%

Considerando ainda a Tabela 8, vale ressaltar que as células identificadas pela cor amarela destacam aquelas componentes ou *ensembles* que obtiveram um erro percentual médio diário numericamente menor que os demais previsores envolvidos. É interessante observar que nem sempre a técnica de *ensemble* garante que os resultados combinados são mais precisos que os obtidos pelas componentes, quando tratadas de forma individual. Isto fica claro ao observar a Tabela 8, especialmente no Dia 30, em que nenhum dos *ensembles* obteve resultado numericamente melhor do que a melhor componente verificada. Na média geral, o *ensemble* que alcançou desempenho numericamente melhor no processo de combinação foi a Rede Neural Artificial

Uma comparação feita apenas de forma numérica não oferece muita confiabilidade. Portanto, a partir disso, visando aumentar a credibilidade desta análise, serão realizados dois testes estatísticos, dos quais podemos elencar o Teste “F” da análise da variância e o Teste de Tukey, utilizando o software R para tal processo. O teste “F” da análise da variância é aplicado para mostrar se existe alguma diferença estatística entre os resultados que, no caso deste trabalho, serão os EPMd’s de cada componente ou modelo envolvidos no processo de previsão. Já o teste de Tukey é aplicado com a finalidade de agrupar as médias ou resultados que se comportam de forma estatisticamente iguais. Maiores detalhes a respeito destes testes são encontrados no Apêndice A, ao final deste trabalho.

### 5.3.1 Dia 24 – Sábado

A Figura 43 aborda o gráfico em barras apresentando os erros percentuais médios horários do dia 24/08/2002 (sábado) para os 3 *ensembles* propostos neste trabalho. Considerando o erro médio diário da melhor componente de previsão, individualmente, para este dia, sendo de 1,85%, percebe-se que o *ensemble* que obteve numericamente o menor índice de erro foi aquele formado pela RNA, cujo valor pôde ser verificado em torno de 1,54%. Quanto aos demais *ensembles*, foi registrado um erro de 2,08% para a média aritmética e 2,09% para a média ponderada. O erro da pior componente individual verificada para este dia foi de 2,41%.



**Figura 43 – Gráfico dos erros horários para os três *ensembles* propostos (MA, MP e RNA) verificados para o dia 24.**

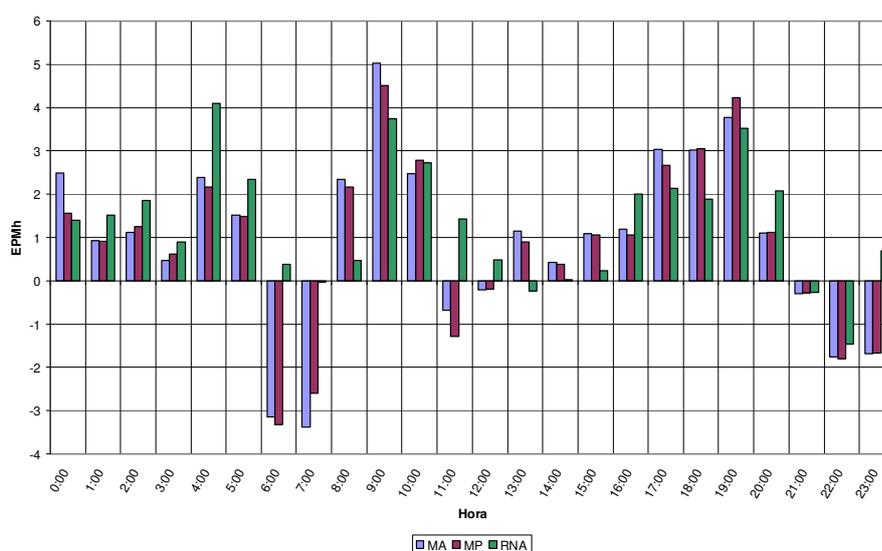
A partir da Tabela 9, em que é feita a análise de variância para este dia, com um nível de 5% de significância, é possível identificar que os resultados, ou médias, obtidos tanto pelos *ensembles* quanto pelas componentes individuais, são estatisticamente semelhantes. Isso se deve pelo fato de que o valor da última coluna da tabela é superior a 0,05. Portanto, pode-se dizer que as componentes e os *ensembles* são estatisticamente equivalentes. Maiores informações em relação à análise de variância poderão ser encontradas no Apêndice A, ao final deste trabalho.

**Tabela 9 – Tabela da análise de variância para o dia 24 (sábado).**

FV	GL	SQ	QM	Fc	Pr > Fc
Grupo	5	12.99	2.5975	0.96371	0.44237
erro	138	371.96	2.6953		
Total	143	384.94			
CV (%) =	79.63				

### 5.3.2 Dia 25 - Domingo

A Figura 44 contém o gráfico em barras mostrando os erros horários para o dia 25/08/2002 (domingo), utilizando os 3 *ensembles* propostos neste trabalho. Considerando o erro médio diário da melhor componente de previsão, individualmente, para este dia, sendo de 1,70%, percebe-se que o *ensemble* que obteve numericamente o menor índice de erro foi aquele formado pela RNA, semelhantemente ao que acontece no dia 24, cujo EPMD pôde ser verificado em torno de 1,49%. Quanto aos demais *ensembles*, registrou-se um erro de 1,85% para a média aritmética, 1,79% para a média ponderada e 2,30% para a pior componente verificada para este dia. É possível observar, através destas informações, que os erros para este dia, exceto o da pior componente observada, foram inferiores a 2%, ao contrário da situação do dia anterior.



**Figura 44 - Gráfico dos erros horários para os três *ensembles* propostos (MA, MP e RNA) verificados para o dia 25.**

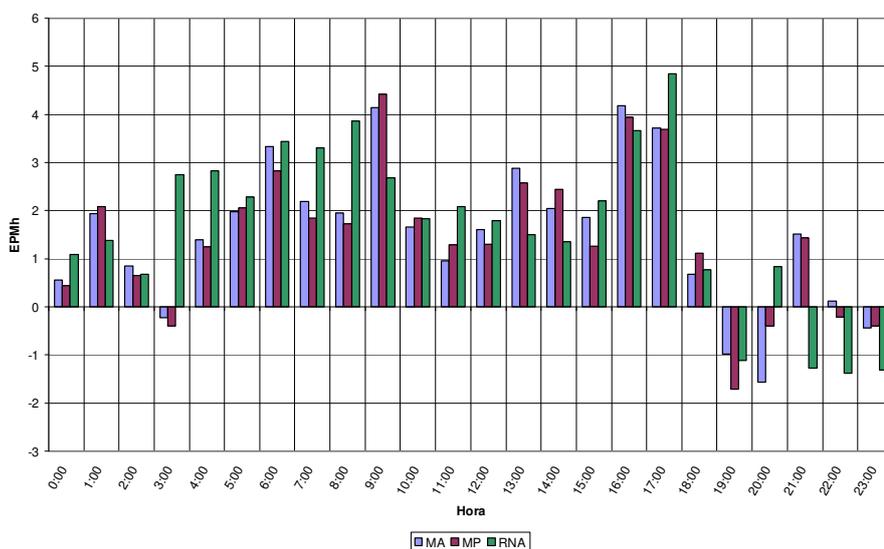
A Tabela 10 traz, em seu conteúdo, a análise de variância para este dia. A partir desta análise, com um nível de 5% de significância, percebe-se que as médias obtidas pelas componentes individuais e pelos *ensembles* são estatisticamente semelhantes. . Isso se deve pelo fato de que o valor da última coluna da tabela é superior a 0,05.

**Tabela 10 – Tabela da análise de variância para o dia 25 (domingo).**

FV	GL	SQ	QM	Fc	Pr > Fc
Grupo	5	8.762	1.7523	0.84861	0.51761
erro	138	284.961	2.0649		
Total	143	293.723			
CV (%) =	79.17				

### 5.3.3 Dia 26 – Segunda

A Figura 45 mostra o gráfico de barras contendo os erros horários para o dia 26.



**Figura 45 – Gráfico dos erros horários para os três *ensembles* propostos (MA, MP e RNA) verificados para o dia 26.**

Em seguida, é apresentada, na Tabela 11, a análise de variância para os erros percentuais médios diários das componentes individuais e para os *ensembles*, com um nível de 5% de significância. É possível identificar que todos os previsores utilizados podem ser considerados estatisticamente semelhantes para este dia. Isso se deve pelo fato de que o valor da última coluna da tabela é superior a 0,05.

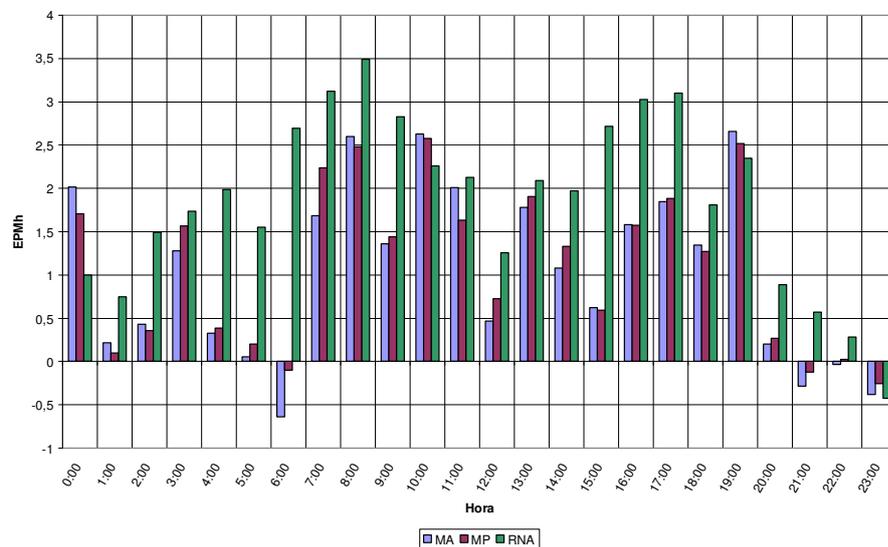
Maiores detalhes sobre como esta análise é realizada podem ser encontrados no Apêndice A, ao final deste trabalho.

**Tabela 11 - Tabela da análise de variância para o dia 26 (segunda).**

FV	GL	SQ	QM	Fc	Pr > Fc
Grupo	4	3.391	0.84773	0.56774	0.68655
erro	115	171.712	1.49315		
Total	119	175.103			
CV (%) =	64.67				

### 5.3.4 Dia 27 - Terça

A Figura 46 apresenta o gráfico de barras com os erros horários para este dia, 27. Em seguida, são discutidos os testes estatísticos efetuados para os resultados obtidos neste dia.



**Figura 46 - Gráfico dos erros horários para os três ensembles propostos (MA, MP e RNA) verificados para o dia 27.**

Apenas a aplicação da análise de variância para verificar a semelhança entre as médias deste não foi suficiente para uma interpretação clara, com um nível de 5% de significância, conforme apresentado na Tabela 12.

**Tabela 12 - Tabela da análise de variância para o dia 27 (terça).**

FV	GL	SQ	QM	Fc	Pr > Fc
Grupo	4	10.143	2.53587	2.999	0.021404
erro	115	97.240	0.84557		
Total	119	107.384			
CV (%) =	69.73				

A aplicação do teste de Tukey, mostrado na Tabela 13, para este mesmo dia, ainda demonstra certa dificuldade na interpretação dos resultados. Para tanto, alternativamente apenas para este dia, aplicou-se o teste de Scott-Knott. Este teste visa a separação de médias de tratamentos em grupos distintos, através da minimização da variação dentro e maximização da variação entre grupos, apresentando-se mais robusto que o teste de Tukey. Existe maior clareza e facilidade na interpretação dos resultados devido à ausência de ambiguidade. Este teste ordena os resultados de forma decrescente, agrupando aqueles que são considerados estatisticamente semelhantes, com letras iguais.

**Tabela 13 - Tabela do teste de Tukey para o dia 27 (terça).**

Grupos	Tratamentos	Médias
a	RNA	1,897073
ab	2	1,217022
ab	1	1,197374
b	MA	1,146455
b	MP	1,135937

A partir da análise da Tabela 14, verificou-se que a RNA perde para as demais componentes em razão de estar com um valor inferior aos demais previsores e em grupo distinto. O interessante desta situação é que as demais

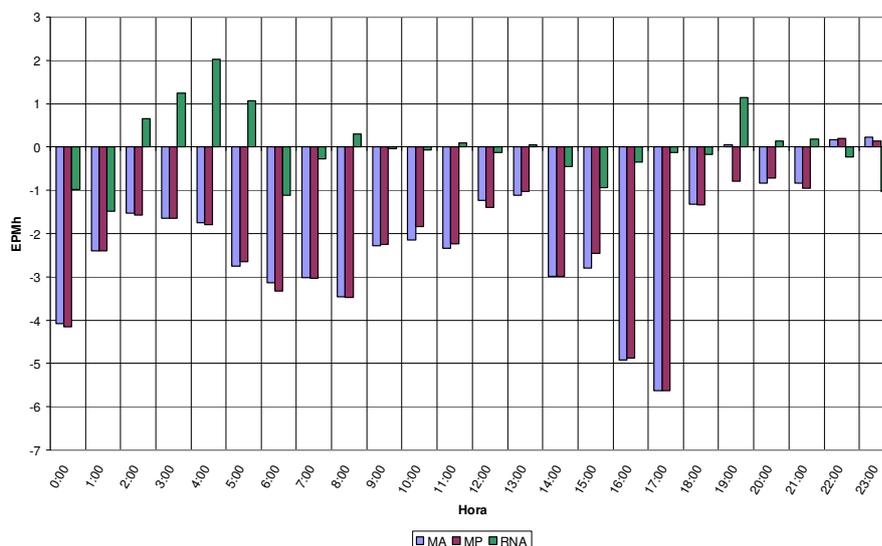
componentes são estatisticamente semelhantes e melhores que a RNA, mas os *ensembles* MA e MP são numericamente melhores que as demais componentes individuais, consideradas estatisticamente equivalentes.

**Tabela 14 – Tabela do teste de Scott-Knott para o dia 27 (terça).**

Grupos	Tratamentos	Médias
a	RNA	1,897073
b	2	1,217022
b	1	1,197374
b	MA	1,146455
b	MP	1,135937

### 5.3.5 Dia 28 – Quarta

A Figura 47 apresenta o gráfico dos erros horários cometidos pelos *ensembles*, para este dia. É interessante observar que a maioria das barras neste gráfico permanecem abaixo do eixo das abcissas (eixo x). Isso significa que o valor previsto ficou abaixo do valor real de carga, para aquele determinado horário.



**Figura 47 – Gráfico dos erros horários para os três *ensembles* propostos (MA, MP e RNA) verificados para o dia 28.**

A seguir, é apresentada na, Tabela 15, a análise de variância dos previsores envolvidos neste dia, com um nível de 5% de significância. Isso acontece pelo fato de que o valor da última coluna da tabela é inferior a 0,05. Portanto, a partir desta análise pode-se concluir que existem médias que diferem estatisticamente entre si, mas não se sabe quais.

**Tabela 15 - Tabela da análise de variância para o dia 28 (quarta).**

FV	GL	SQ	QM	Fc	Pr > Fc
Grupo	4	52.216	13.0540	7.9557	1.0682e-05
erro	115	188.698	1.6408		
Total	119	240.914			
CV (%) =	67.08				

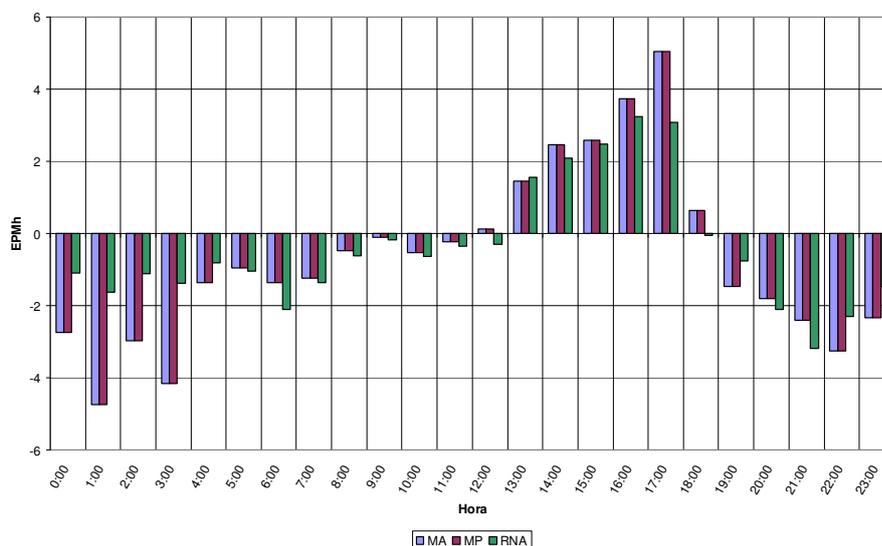
A Tabela 16 apresenta o teste de Tukey para que esta diferença, verificada na análise de variância da Tabela 15, seja identificada de forma clara. É importante lembrar que a análise de variância e o teste de Tukey são independentes entre si. Portanto, pelo fato de o teste de Tukey agrupar os resultados semelhantes e ordenar de forma decrescente, percebe-se que a RNA se mostra mais eficiente para este dia, uma vez que obteve resultado melhor e esteve classificada em um grupo diferente dos demais. Maiores detalhes sobre a análise de variância e o teste de Tukey podem ser encontrados no Apêndice A, ao final deste trabalho.

**Tabela 16 - Tabela do teste de Tukey para o dia 28 (quarta).**

Grupos	Tratamentos	Médias
a	2	2,332273
a	1	2,224727
a	MP	2,203672
a	MA	2,193341
b	RNA	0,594029

### 5.3.6 Dia 29 – Quinta

A Figura 48 apresenta o gráfico de barras contendo os erros horários dos *ensembles* propostos neste trabalho, para este dia.



**Figura 48 – Gráfico dos erros horários para os três *ensembles* propostos (MA, MP e RNA) verificados para o dia 29.**

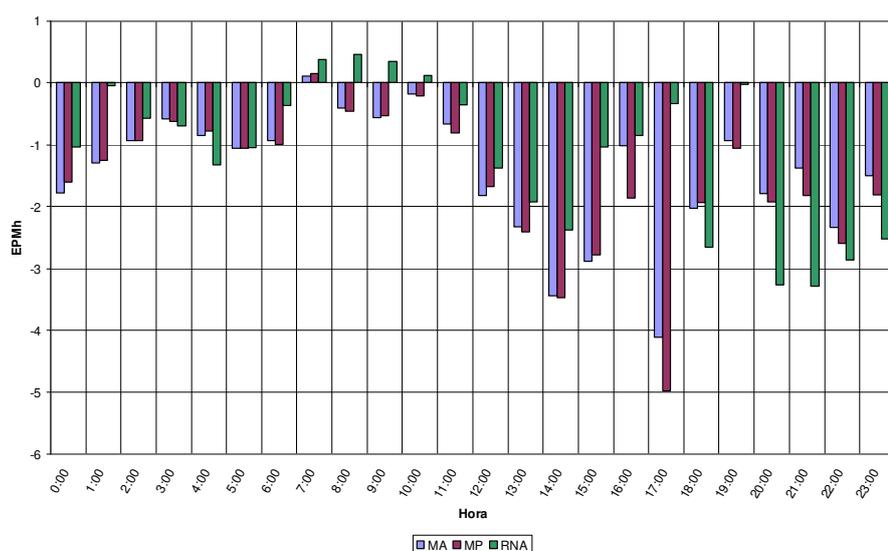
A Tabela 17 apresenta a análise de variância para os previsores deste dia, com um nível de 5% de significância. A partir desta tabela, é possível concluir que os resultados dos *ensembles* utilizados e das componentes individuais são considerados estatisticamente semelhantes. Maiores detalhes sobre esta análise podem ser encontrados no Apêndice A, ao final deste trabalho.

**Tabela 17 – Tabela da análise de variância para o dia 29 (quinta).**

FV	GL	SQ	QM	Fc	Pr > Fc
Grupo	3	5.458	1.8194	1.0129	0.39077
erro	92	165.261	1.7963		
Total	95	170.719			
CV (%) =	71.68				

### 5.3.7 Dia 30 – Sexta

Este dia especificamente, foi o único em que a melhor componente individual alcançou, numericamente, erros menores em relação aos demais *ensembles* utilizados. Para a melhor componente, foi verificado um EPMD de 1,20%, sendo que para a média aritmética foi observado um EPMD de 1,45%, para a média ponderada um EPMD de 1,57% e para a RNA um EPMD de 1,21%. Ao observar o erro da RNA, cujo valor alcançado foi numericamente inferior ao dos demais *ensembles* deste dia, nota-se que, mesmo assim, a proximidade com o erro da melhor componente individual é pequena. Mesmo todos os *ensembles* perdendo, numericamente, para a melhor componente individual do dia 30, é possível perceber que o erro cometido pela RNA não foi tão distante da melhor componente, o que não inviabiliza a utilização da mesma. A Figura 49 apresenta os erros horários dos *ensembles* utilizados neste trabalho para este dia.



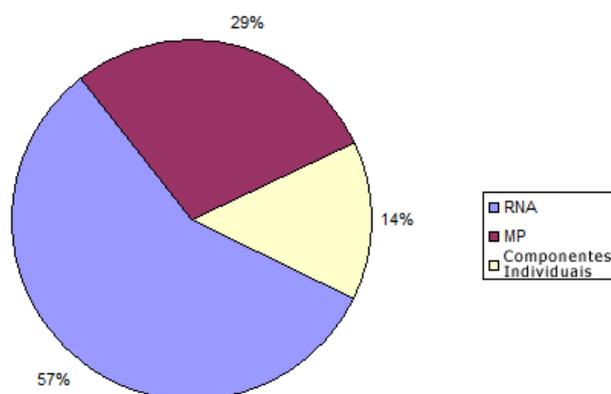
**Figura 49 – Gráfico dos erros horários para os três *ensembles* propostos (MA, MP e RNA) verificados para o dia 30.**

A Tabela 18, apresentada a seguir, mostra a análise de variância para este dia, com um nível de 5% de significância. O valor indicado na última coluna, por ser maior que 0,05, significa que as médias dos tratamentos são estatisticamente semelhantes.

**Tabela 18 – Tabela da análise de variância para o dia 30 (sexta).**

FV	GL	SQ	QM	Fc	Pr > Fc
Grupo	9	20.31	2.2570	1.4514	0.16733
erro	230	357.66	1.5551		
Total	239	377.98			
CV (%) =	79.63				

A Figura 50 apresenta um gráfico em pizza, destacando a porcentagem das componentes que se comportaram numericamente melhores que as demais, para todos os dias de previsão. Neste cenário, recebem destaque os *ensembles* constituídos pela média ponderada e rede neural artificial, ou seja, considerando a semana de previsão, a RNA obteve os melhores resultados numéricos em 57% dos dias, a MP obteve os melhores resultados em 29% dos dias e as componentes individuais sobressaíram em apenas 14% dos dias.



**Figura 50 – Previsores que se comportaram numericamente melhor que os demais.**

Portanto, é possível concluir que os *ensembles*, de uma forma geral, se mostraram eficientes e estatisticamente semelhantes às componentes individuais. Ocorreram apenas duas exceções, em que o *ensemble* constituído pela RNA foi considerado estatisticamente pior e estatisticamente melhor que as demais componentes de previsão, para os dias 27 e 28, respectivamente. Pode-se observar que, pelo menos um *ensemble* proposto é, com exceção apenas para o dia 30, numericamente melhor que as demais componentes de previsão individualmente.



# 6

## Conclusões

*Este capítulo apresenta as conclusões desta monografia. É organizado da seguinte forma: Na Seção 6.1, é apresentada uma descrição sucinta da proposta e metodologia deste trabalho. Na Seção 6.2 são apresentadas as conclusões a respeito da técnica de agrupamento de previsores considerada nesta monografia.*

### 6.1 Sumário da monografia

Este trabalho tratou, em seu conteúdo, uma metodologia para previsão de séries temporais de carga elétrica à curto prazo. Este processo se mostra importante porque o acompanhamento da carga é uma das exigências básicas nos processos de operação e controle em um sistema de potência. A previsão da demanda de carga é uma tarefa fundamental para um bom funcionamento dos sistemas elétricos, pois vários processos de tomada de decisão, tais como planejamento, operação, análise de segurança e decisões de mercado, são fortemente influenciados por ela. Para que haja um equilíbrio entre a energia gerada e energia consumida, é necessário que se estime, com a máxima exatidão, o nível de demanda.

A técnica proposta consiste em uma combinação de previsores, denominada *ensemble*, na qual acredita-se que o resultado deste processo tende a ser melhor ou igual ao resultado obtido pela melhor das componentes individuais. A técnica utilizada neste trabalho envolveu os seguintes modelos: Redes Neurais Artificiais, Programação Genética e Regressão Linear Múltipla. Foram geradas 2500 componentes, resultantes da variação aleatória dos parâmetros dos modelos citados. Foi utilizado um período de medição, como base de dados dos experimentos, cujo histórico foi obtido através de dados de carga adquiridos de uma empresa elétrica do Brasil, com discretização horária.

Os *ensembles* propostos apresentaram resultados interessantes, mesmo sendo considerados, na maioria das vezes, estatisticamente iguais às componentes

individuais e, em alguns casos, não tendo alcançado as melhores previsões nos experimentos verificados.

## 6.2 Conclusões

O cenário de previsão de séries temporais pode ser considerado um campo em que a pesquisa atua de forma constante. Diversas ferramentas são elaboradas visando atender aos mais diversos tipos de séries que existem. A previsão de séries temporais de carga elétrica é uma tarefa complexa, na qual está envolvida uma infinidade de variáveis, as quais definem o comportamento da mesma.

As previsões efetuadas neste trabalho procuraram demonstrar a eficácia de um combinador, denominado *ensemble*, cuja técnica tende a ser robusta e a apresentar desempenho superior ou igual ao desempenho das componentes individuais. Isto pôde ser observado para boa parte dos dias da semana de previsão considerada.

Como é sabido que o comportamento da série é não-linear e costuma sofrer alterações, um previsor especialista tende a registrar altos níveis de erros de previsão ao longo do tempo. Visando suavizar este problema, acredita-se que a técnica *ensemble* apresenta resultados mais otimizados. Na literatura existem diversos trabalhos que alcançaram resultados satisfatórios, os quais motivam a aplicação desta técnica na predição de séries temporais.

O processo de geração das 2500 componentes individuais, tomado de forma aleatória, se mostrou eficiente, pois foi possível alcançar erros consideráveis de previsão a partir destas. Os modelos de *ensemble* demonstraram uma boa capacidade de extração de características das componentes selecionadas, uma vez que os resultados obtidos pela maior parte destes, muitas vezes, superava numericamente ou se aproximava muito do resultado da melhor componente individual verificada.

A partir dos testes estatísticos aplicados nos resultados encontrados para os dias da semana de previsão, verificou-se que para a maior parte dos dias, tanto os

*ensembles* quanto as melhores componentes individuais, se comportaram de forma estatisticamente semelhantes.

Um fato interessante, acontecido na maioria dos dias de previsão, é verificado em casos que pelo menos um dos *ensembles* propostos é considerado numericamente melhor que as demais componentes envolvidas no processo.

Portanto, a utilização de um *ensemble* de previsão em substituição à uma componente, tratada de forma individual, pode ser considerada válida e eficaz, levando em conta a capacidade de generalização do mesmo.



# 7 Referências Bibliográficas

- Altran, A. B., Lopes, M. L. M., Minussi, C. R. & Villarreal, F. *Um Estudo De Funções de Base Radial Aplicadas à Previsão de Cargas Elétricas via Redes Neurais Artificiais*. Congresso Nacional De Matemática Aplicada E Computacional - Xxviii Cnmac, 2005, São Paulo - Sp. Cnmac 2005.
- Banzhaf; W. Nordin, P.; Keller, R. E. & Francone, F. D., *Genetic Programming an introduction*. Morgan Kaufmann, 1998.
- Bashir, Z.A., El-Hawary, M.E. *Short-Term Load Forecasting Using Artificial Neural Network Based On Particle Swarm Optimization Algorithm*. Canadian Conference on Electrical and Computer Engineering, 2007.
- Bashir, Z. A. & El-Hawary, M. E. *Applying Wavelets to Short-Term Load Forecasting Using PSO-Based Neural Networks*. Ieee Transactions On Power Systems, Vol. 24, No. 1, February 2009.
- Caiqing Z., Ming L. & Mingyang T. *BP Neural Network Optimized with PSO Algorithm for Daily Load Forecasting*. International Conference on Information Management, Innovation Management and Industrial Engineering, 2008
- Cicogna, M. A. *Sistema de Suporte à Decisão para o Planejamento e a Programação da Operação de Sistemas de Energia Elétrica*, PhD thesis, FEEC/Unicamp, 2003.
- Chellapilla, K., *Evolutionary programming with tree mutations: Evolving computer programs without sub-tree crossover*. Genetic Programming. In: Proc. Second Annual Conference of San Francisco, 1997.
- Darwin, C. *A Origem das Espécies e a Seleção Natural*. Ed. Hemus, 5ª Ed., 2000.
- Drezga, I. & Rahman, S. *Short-Term Load Forecasting*. IEEE Transactions On Power Systems, August 1999, Vol. 14, No. 3.
- Gross, G. & Galiana, F. *Short-term load forecasting*, Proceedings of the IEEE, 1987, Vol. 75(12), pp. 1558–1573.
- Grimaldi M., E., Grimaccia F., Mussetta, M. & Zich, R. E. *Pso As An Effective Learning Algorithm For Neural Network Applications*. Proceedings 3º International Conference on Computational Electmmagnetics and Its Applications, 2004.

- Hansen L. K. & Salamon P. *Neural network ensembles* IEEE Trans. Pattern Anal. Machine Intell., 1990, PAMI-12, 10, pp. 993-1001.
- Haykin, S. *Neural Networks, A Comprehensive Foundation*, Macmillan Publishing Company, 1994.
- Koza, J. R., *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. MIT Press, 1992
- Leone Filho, M. A. *Previsão de carga de curto prazo usando ensembles de previsores selecionados e evoluídos por Algoritmos Genéticos*. Dissertação de Mestrado, Unicamp 2006.
- Li Y., Wang, D. F. & Han P. *Selective Ensemble Using Discrete Differential Evolution Algorithm For Short-Term Load Forecasting*. Eighth International Conference On Machine Learning And Cybernetics, Baoding, 12-15 July 2009.
- Park, D. C., El-Sharkawi, A., M. & Marks II, R. J. (1991). *Electric load forecasting using an artificial neural network*, IEEE Transactions on Power Systems, 1991, Vol. 6(2), pp. 442–449.
- Salgado, R. M., Pereira, J. J. F., Ohishi, T., Ballini, R., Lima, C. A. M. & Von Zuben, F. J. *A Hybrid Ensemble Model Applied to the Short-Term Load Forecasting Problem*. Wcci-Ieee World Congress On Computational Intelligence, Vancouver – Canadá, 2006.
- Salgado, R. M. *Sistema De Suporte À Decisão Para Previsão De Carga Por Barramento*. Tese de Doutorado, Unicamp, 2009.
- Sapeluk, A. T.; Ozveren, C. S.; Birch, A. P. *Short Term Electric Load Forecast Using Artificial Neural Networks*. IEEE 1994.
- Silveira, T.; Oliveira, H. C. B.; Silva, L. E.; Salgado, R. M. *Controle de Inércia Não-Monotônico na Otimização por Enxame de Partículas*. Scientia (Unisinos), v. 20, p. 69-82, 2010.
- Siwek, K. & Osowski S. *Short Term Load Forecasting Model In The Power System Using Ensemble Of Predictors*. Instrumentation And Measurement Technology Conference - Imtc 2007 Warsaw, Poland, May 1-3, 2007.
- Souza, L. V. *Programação Genética e Combinação de Preditores para Previsão de Séries Temporais*. Curitiba. Tese de Doutorado, Universidade Federal do Paraná, Outubro 2006.

- Sun W., Zhang Y., Li F. *The Neural Network Model Based On Pso For Short-Term Load Forecasting*. Proceedings of the Fifth International Conference on Machine Learning and Cybernetics, Dalian, 13-16 August 2006.
- Sun W. & Zou Y. *Short Term Load Forecasting Based On Bp Neural Network Trained By Pso*. Proceedings of the Sixth International Conference on Machine Learning and Cybernetics, Hong Kong, 19-22 August 2007.
- Vehviläinen, I. & Keppo, J. *Managing Electricity Market Price Risk*, European Journal Of Operational Research, 2003.
- Villanueva, W. J. P. *Comitê de Máquinas em Predição de Séries Temporais*. Dissertação de Mestrado, Unicamp, 2006.



# 8 Apêndices e Anexos

## Apêndice A

Geralmente, uma pesquisa tem por objetivo estabelecer comparações e testes de médias de tratamentos. Inicialmente, estas médias de tratamentos são testadas com o teste F da Análise da Variância, cuja significância a um valor nominal fixado permite que se infira que pelo menos um tratamento difere dos demais. Uma desvantagem deste teste consiste em indisponibilizar ao pesquisador onde estão essas diferenças.

Quando os tratamentos apresentam níveis quantitativos, aconselha-se o ajuste de equações de regressão. Se os níveis dos tratamentos são qualitativos, recomenda-se aplicar algum tipo de procedimento de comparações múltiplas. Dentre estes procedimentos, destaca-se o teste de Tukey como um dos principais.

Portanto, existe uma dificuldade em interpretar os resultados desses procedimentos, apresentando, em alguns casos, características de ambiguidade nos resultados fornecidos por eles. Essa ambiguidade acontece em função da possibilidade de dois níveis de tratamentos serem considerados iguais a um terceiro, mas diferentes entre si.

A aplicação do teste de Scott Knott é uma alternativa interessante. O objetivo deste teste consiste em separar as médias de tratamentos em grupos distintos, através da minimização da variação dentro e maximização da variação entre grupos. Existem maior clareza e facilidade na interpretação dos resultados devido à ausência de ambiguidade.

Nas seções a seguir, são apresentados a análise de variância e o teste de Tukey para comparação das médias dos tratamentos.

## 8.1 Análise de Variância

Em um experimento, cada observação  $Y_{ij}$  pode ser decomposta conforme o modelo a seguir:

$$Y_{ij} = \mu + T_i + \epsilon_{ij} \quad i = 1, \dots, I \text{ e } j = 1, \dots, J$$

em que:

$Y_{ij}$  é a observação do  $i$ -ésimo tratamento na  $j$ -ésima unidade experimental ou parcela;

$\mu$  é o efeito constante (média geral);

$T_i$  é o efeito do  $i$ -ésimo tratamento;

$\epsilon_{ij}$  é o erro associado ao  $i$ -ésimo tratamento na  $j$ -ésima unidade experimental ou parcela assumido como:  $\epsilon_{ij} \stackrel{iid}{\sim} N(0, \sigma^2)$ . Aqui, IID significa que os erros devem ser independentes e identicamente distribuídos.

Em um experimento, existe o interesse em testar se há diferenças entre as médias dos tratamentos, o que equivale a testar as hipóteses:

$$\begin{cases} H_0 : T_1 = T_2 = \dots = T_I = 0 \\ H_1 : T_i \neq 0 \text{ para pelo menos um } i. \end{cases}$$

Note que, se a hipótese nula for verdadeira, todos os tratamentos terão uma média comum  $\mu$ . A análise de variância, baseia-se na decomposição da variação total da variável resposta em partes que podem ser atribuídas aos tratamentos (variância entre) e ao erro experimental (variância dentro). Essa variação pode ser medida por meio das somas de quadrados definidas para cada um dos seguintes componentes:

$$SQ_{Total} = \sum_{i=1}^I \sum_{j=1}^J y_{ij}^2 - C \quad \text{em que } C = \frac{\left( \sum_{i=1}^I \sum_{j=1}^J y_{ij} \right)^2}{IJ}$$
$$SQ_{Trat} = \frac{\sum_{i=1}^I y_i^2}{J} - C$$

e a soma de quadrados dos resíduos pode ser obtida por diferença:

$$SQ_{Res} = SQ_{Total} - SQ_{Trat}$$

A SQTrat também é chamada de variação “Entre”, que é a variação existente entre os diferentes tratamentos e a SQRes é chamada de variação “Dentro” que é função as diferenças existentes entre as repetições de um mesmo tratamento. Essas somas de quadrados podem ser organizadas em uma tabela, denominada tabela da análise de variância, como apresentado na Tabela 19. Para testar a hipótese  $H_0$ , utiliza-se o teste F apresentado na tabela da Análise de Variância (Tabela 19). Vale lembrar que esse teste é válido se os pressupostos assumidos para os erros do modelo estiverem satisfeitos.

**Tabela 19 - Tabela da análise de variância.**

Fonte ou Causas de Variação	Graus de Liberdade	Soma de Quadrados	Quadrados Médios	F calculado
Tratamentos	I-1	SQTrat	QMTrat	QMTrat / QMRes
Resíduo	I(J-1)	SQRes	QMRes	
Total	IJ-1	SQTotal		

em que  $QMTrat = SQTrat / (I - 1)$  e  $QMRes = SQRes / (I(J - 1))$ .

Pode-se mostrar que o quociente  $QMTrat / QMRes$  tem distribuição F com  $(I - 1)$  e  $I(J - 1)$  graus de liberdade, supondo que,  $Y_{ij}$  são variáveis aleatórias independentes, todos os tratamentos têm variâncias iguais a  $\sigma^2$  e  $Y_{ij} \sim N(\mu_i, \sigma^2)$ .

Por esses motivos, os pressupostos da análise de variância devem ser testados ou avaliados em qualquer análise. Se  $(F \text{ calculado}) > (F \text{ tabelado})$ , rejeita-se a hipótese de nulidade  $H_0$ , ou seja, existem evidências de diferença significativa entre pelo menos um par de médias de tratamentos, ao nível  $\alpha$  de significância escolhido. Caso contrário, não se rejeita a hipótese de nulidade  $H_0$ , ou seja, não há evidências de diferença significativa entre tratamentos, ao nível  $\alpha$  de significância escolhido.

Outra maneira de avaliar a significância da estatística F é utilizando o p-valor. Se o p-valor  $< \alpha$ , rejeita-se a hipótese de nulidade  $H_0$ . Caso contrário, não se

rejeita a hipótese de nulidade  $H_0$ , ou seja, não há evidências de diferenças significativas entre os tratamentos, ao nível  $\alpha$  de significância escolhido.

## 8.2 Teste de Tukey para comparação das médias

Após concluirmos que existe diferença significativa entre tratamentos, por meio do teste F, podemos estar interessados em avaliar a magnitude destas diferenças utilizando um teste de comparações múltiplas. O teste de Tukey permite testar qualquer contraste, sempre, entre duas médias de tratamentos, ou seja, não permite comparar grupos entre si.

O teste baseia-se na Diferença Mínima Significativa (DMS)  $\Delta$ . A estatística do teste é dada da seguinte forma:

$$\Delta = q \sqrt{\frac{QMRes}{r}}$$

em que,  $q$  é a amplitude total tabelada,  $QMRes$  é o quadrado médio do resíduo, e  $r$  é o número de repetições. O valor de  $q$  depende do número de tratamentos e do número de graus de liberdade do resíduo. Também, em um teste de comparações de médias, deve-se determinar um nível de significância  $\alpha$  para o teste. Normalmente, utiliza-se o nível de 5% ou 1% de significância.

Como o teste de Tukey é, de certa forma, independente do teste F, é possível que, mesmo sendo significativo o valor de F calculado, não se encontrem diferenças significativas entre contrastes de médias.

Se o contraste for maior do que  $\Delta$ , então as médias diferem ao nível  $\alpha$  de significância. Utilizar-se-á o método de letras para exemplificar o uso do teste, mas existem outras maneiras de representação como, por exemplo, o uso de tabelas ou barras.

Inicialmente, ordenam-se as médias de forma crescente ou decrescente, para facilitar as comparações. Colocamos uma letra do alfabeto na primeira média (normalmente a letra 'a') e, em seguida, comparamos a diferença com as médias seguintes. Se a diferença for superior ao valor de  $\Delta$  (5%), a diferença entre duas

médias será considerada significativa. A diferença entre duas médias é representada pela presença de letras diferentes. Temos que, médias de crescimento, seguidas de letras iguais, não diferem significativamente entre si, pelo teste de Tukey ao nível de 5% de probabilidade.

]